

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
CAMPUS JOÃO PESSOA
BACHARELADO EM ENGENHARIA ELÉTRICA

**“WEIBULL PREDICTOR STM” UMA PROPOSTA DE SOFTWARE PARA
ACOMPANHAMENTO E OTIMIZAÇÃO DE CUSTOS DE MANUTENÇÃO EM
ATIVOS NÃO SUJEITOS À MANUTENÇÃO CORRETIVA**

IURY PEREIRA DE ARAÚJO

JOÃO PESSOA – PB
2025

IURY FERREIRA DE ARAÚJO

“WEIBULL PREDICTOR STM” UMA PROPOSTA DE SOFTWARE PARA
ACOMPANHAMENTO E OTIMIZAÇÃO DE CUSTOS DE MANUTENÇÃO EM ATIVOS
NÃO SUJEITOS À MANUTENÇÃO CORRETIVA

Trabalho de conclusão de curso submetido à
coordenação de Engenharia Elétrica do Instituto
Federal da Paraíba como parte dos requisitos
necessários para a obtenção do título de
engenheiro eletricitista.

Orientador: Prof. Dr. José Artur Alves Dias

JOÃO PESSOA – PB

2025

Dados Internacionais de Catalogação na Publicação – CIP
Biblioteca Nilo Peçanha – IFPB, *Campus* João Pessoa

A663w	Araújo, Iury Ferreira de. “<i>Weibull predictor STM</i>” uma proposta de <i>software</i> para acompanhamento e otimização de custos de manutenção em ativos não sujeitos à manutenção corretiva / Iury Ferreira de Araújo. – 2025. 85 f. : il. TCC (Curso Superior de Bacharelado em Engenharia Elétrica) – Instituto Federal de Educação da Paraíba / Unidade Acadêmica de Controle e Processos Industriais / Coordenação do Curso Superior de Bacharelado em Engenharia Elétrica, 2025. Orientador: Prof. Dr. José Arthur Alves Dias. 1. <i>Software</i>. 2. Confiabilidade. 3. Reposição preventiva. 4. Previsão de falhas. 5. Distribuição de <i>weibull</i>. I. Título. CDU 004.4:519.873(043)
-------	---



MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA

FOLHA DE APROVAÇÃO

IURY FERREIRA DE ARAÚJO

20201610037

“WEIBULL PREDICTOR STM” UMA PROPOSTA DE SOFTWARE PARA ACOMPANHAMENTO E OTIMIZAÇÃO DE CUSTOS DE MANUTENÇÃO EM ATIVOS NÃO SUJEITOS À MANUTENÇÃO CORRETIVA”

Trabalho de Conclusão de Curso submetido à Coordenação do Curso Superior de Bacharelado em Engenharia Elétrica do Instituto Federal da Paraíba, como parte dos requisitos para a obtenção do grau de Engenheiro Eletricista.

Trabalho aprovado pela banca examinadora em 21 de agosto de 2025.

BANCA EXAMINADORA:

(assinaturas eletrônicas via SUAP)

Dr. José Artur Alves Dias

IFPB (Orientador)

Dr. Álvaro de Medeiros Maciel

IFPB (Examinador Interno)

Dr. Franklin Martins Pereira Pamplona

IFPB (Examinador Interno)

Documento assinado eletronicamente por:

- **Jose Artur Alves Dias**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 29/08/2025 16:00:37.
- **Alvaro de Medeiros Maciel**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 29/08/2025 16:36:53.
- **Franklin Martins Pereira Pamplona**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 29/08/2025 23:34:28.

Este documento foi emitido pelo SUAP em 26/08/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 755274
Verificador: 76a67fe845
Código de Autenticação:



Av. Primeiro de Maio, 720, Jaguaribe, JOÃO PESSOA / PB, CEP 58015-435
<http://ifpb.edu.br> - (83) 3612-1200

AGRADECIMENTOS

Gostaria de agradecer profundamente meus familiares pelo apoio durante essa jornada que perdurou por mais de cinco anos. Cada conselho, incentivo e presença foram essenciais para que eu persistisse e continuasse a crescer.

Aos amigos e colegas, sou igualmente grato. Foram, e continuam sendo, importantes pelos aprendizados compartilhados. Cada experiência e momentos juntos enriqueceram minha jornada acadêmica e pessoal.

Aos professores, agradeço pelo compromisso em transmitir seus conhecimentos técnicos e experiências profissionais, além dos valores que moldam o profissional. Suas contribuições construíram uma visão ampla e zelosa da profissão que escolhi, sendo indispensáveis para minha formação.

Em especial, agradeço ao meu orientador pela confiança, esforço e atenção dedicados durante a produção deste trabalho. Sua orientação contribuiu para novas perspectivas e melhorias, que somaram às minhas experiências, me possibilitaram desafios enriquecedores e me ajudaram alcançar, com êxito, os objetivos desejados.

Por Iury Ferreira de Araújo

“Se em certa altura

Tivesse voltado para a esquerda em vez de para a
direita;

[...]

Seria outro hoje, e talvez o universo inteiro

Seria insensivelmente levado a ser outro também.”

(Fernando Pessoa)

RESUMO

A aplicação “Weibull Predictor STM” foi desenvolvida neste trabalho como solução de baixo custo alinhada à manutenção preditiva, uma estratégia com ênfase na previsão de falhas em que se baseia em modelos estatísticos. Essa proposta foi direcionada para o acompanhamento e otimização dos custos de manutenção em ativos não sujeitos à manutenção corretiva, tais como as lâmpadas e os capacitores. A fundamentação se concentrou na norma NBR 5462 para empregar as terminologias recorrentes na engenharia da confiabilidade e na estatística, quando aplicada à manutenção, contribuindo para destacar as funções da distribuição de Weibull. Os métodos estatísticos propostos por Waloddi Weibull, e empregados dentro do software, viabilizaram – a partir de análises de histórico de falhas, definição do intervalo ideal de reposição e cálculo do tempo médio esperado até a falha (*MTTF*) – a redução do custo de reposição e de falhas inesperadas. A estrutura do STM tem como alicerce o uso da linguagem Python, escolhida para executar a interface gráfica, disponibilizada pelo Tkinter, e carregar e editar planilhas Excel, tornando a utilização acessível para pequenas e médias empresas. Em sua interface apresenta métricas, obtidas por meio do módulo direcionado aos cálculos, como a confiabilidade instantânea, coeficiente de determinação, tempo ótimo e custo mínimo. O intuito é proporcionar ao usuário a possibilidade de interpretar dados imediatamente para que a previsão de falhas auxilie na tomada de decisões. Contudo, o software atualmente aplica apenas a reposição preventiva como única estratégia de prevenção de falhas, não integrando inspeções regulares que mitigam as degradações dos equipamentos. A proposta de melhoria é dedicada a implementar a aba para manutenção preventiva, que irá conter registros de inspeções, detalhes sobre os ajustes e as horas trabalhadas de cada evento em novos históricos. Incorporar a reposição e a manutenção preventiva amplia o objetivo do STM, refina os dados e resultados obtidos a partir deles e contribui, também, para o aumento da disponibilidade, da confiabilidade e vida útil dos ativos, fornecendo novas métricas como indicadores de desempenho. Com base nisso, o Weibull Predictor STM exprime sua capacidade de previsão de falhas e análises de confiabilidade aplicada à realidade de processos produtivos, sua eficiência demonstra potencial para aprimorar a logística organizacional de empresas e a gestão de manutenção delas.

Palavras chaves: Software; Confiabilidade; Reposição preventiva; Previsão de falhas; Distribuição de Weibull.

ABSTRACT

The "Weibull Predictor STM" application was developed in this work as a low-cost solution aligned with predictive maintenance, a strategy that emphasizes failure prediction and is based on statistical models. This proposal was aimed at monitoring and optimizing maintenance costs for assets not subject to corrective maintenance, such as lamps and capacitors. The foundation focused on the NBR 5462 standard to employ common terminology in reliability engineering and statistics when applied to maintenance, helping to highlight the functions of the Weibull distribution. The statistical methods proposed by Waloddi Weibull, and employed within the software, enabled—through failure history analysis, definition of the ideal configuration interval, and calculation of the expected mean time to failure (MTTF)—reducing intervention costs and unexpected failures. The STM framework is based on the Python language, chosen to run a graphical interface provided by Tkinter and to load and edit Excel spreadsheets, making it accessible for small and medium-sized businesses. The interface presents statistics and results through the calculation module, such as instantaneous reliability, coefficient of determination, optimal time, and minimum cost. The goal is to provide the user with the ability to interpret data immediately so that failure prediction can aid decision-making. However, the software currently only uses preventive maintenance as its sole failure prevention strategy, not integrating regular inspections that mitigate equipment degradation. The proposed improvement is to implement a preventive maintenance tab, which contains inspection records, adjustment details, and the hours worked for each event in new histories. Incorporating replacement and preventive maintenance expands the STM's objective, refining the data and results obtained from them and also contributing to increased asset availability, reliability, and useful life, providing new information such as performance indicators. Based on this, the Weibull Predictor STM demonstrates its ability to predict failures and analyze reliability applied to the reality of production processes. Its efficiency demonstrates its potential to improve companies' organizational logistics and maintenance management.

Keywords: Software; Reliability; Preventive Replacement; Failure Prediction; Weibull Distribution.

LISTA DE FIGURAS

Figura 1: Curva da banheira; três tipos de falhas que ocorre em muitos sistemas e equipamentos.	18
Figura 2: Efeito da variação de β na função f.d.p.	36
Figura 3: Efeito da variação de β na função f.d.c.	37
Figura 4: Efeito da variação de β na função de risco $h(t)$	38
Figura 5: Ajuste da linha da regressão linear	44
Figura 6: Interface gráfica do Weibull Predictor STM.	54
Figura 7: Estrutura de planilha para histórico de reposição.	54
Figura 8: Campos de entrada de informações do STM.	55
Figura 9: Aba "Reposição"; exibição das estimativas.	56
Figura 10: Balões (tooltips) na interface.	58
Figura 11: Histórico de reposição preventiva do capacitor de barramento CC.	61
Figura 12: Carregamento do arquivo (.xlsx) do histórico de reposição.	62
Figura 13: Exibição dos dados de reposição preventiva do capacitor de barramento CC no Weibull Predictor STM.	62
Figura 14: Inserindo a data em que é realizada a análise do histórico do capacitor de barramento CC.	63
Figura 15: Controle de alterações da planilha Excel através da interface do software STM. ..	64
Figura 16: Inserindo valores no campo de entrada de horas trabalhadas no histórico do capacitor de barramento CC.	64
Figura 17: Adicionando um novo evento no histórico de reposição do capacitor de barramento CC.	65
Figura 18: Evento de reposição no histórico de reposição preventiva do capacitor de barramento CC.	66
Figura 19: Aba "Reposição" após adicionar um evento no histórico do capacitor de barramento CC.	67
Figura 20: Aba "Reposição" sem adicionar eventos no histórico do capacitor de barramento CC.	69
Figura 21: Histórico de reposição preventiva da lâmpada LED industrial.	71
Figura 22: Trocando de planilha dentro do Weibull Predictor STM.	72
Figura 23: Aba "Reposição" sem adicionar eventos no histórico da lâmpada LED industrial.	73
Figura 24: Aba "Manutenção Preventiva" no software Weibull Predictor STM.	78

LISTA DE ABREVIATURAS E SIGLAS

r^2	Coeficiente de determinação
t_0	Parâmetro de localização (tempo mínimo considerado) do modelo de distribuição de Weibull
ARM	Modelo de reposição por idade
$f(t)$	Função de densidade de probabilidade em t
$F(t)$	Função de distribuição de falhas acumulada em t
f.d.c	Função de distribuição acumulada de falhas
f.d.p	Função de densidade de probabilidade
FMEA	<i>Failure Modes and Effects Analysis</i> – Análise dos Modos de Falhas e seus Efeitos
GUI	Interface Gráfica
$h(t)$	Função de risco
IEC	<i>International Electrotechnical Commission</i>
MC	Manutenção corretiva
MP	Manutenção preventiva
MTBF	Tempo médio entre falhas
MTTF	Tempo médio até falha
MTTFF	Tempo médio até a primeira falha
MTTR	Tempo médio de reparo
NBR	Norma Brasileira Regulamentadora
$R(t)$	Função da confiabilidade
RP	Reposição preventiva
STM	<i>Statistical Tracking Module</i> – Módulo Estatístico de Rastreamento
T	Variável aleatória, representa a vida útil do produto ou sistema até a falha
t	Variável de tempo contínuo até a falha
β (beta)	Parâmetro de forma do modelo de distribuição de Weibull
η (eta)	Parâmetro de escala/Vida Característica do modelo de distribuição de Weibull

SUMÁRIO

1.	INTRODUÇÃO	11
1.1	Objetivo geral	13
1.2	Objetivos específicos.....	13
2.	FUNDAMENTAÇÃO	14
2.1.	Conceitos fundamentais (norma NBR 5462)	14
2.1.1.	Confiabilidade	15
2.1.2.	Função de falha	16
2.1.3.	Taxa de falha e Função de risco	17
2.1.3.1.	Falha de fabricação.....	18
2.1.3.2.	Falha aleatória	19
2.1.3.3.	Falha por deterioração.....	19
2.1.4.	Esperança até a falha	20
2.1.5.	MTTF - Tempo médio até falha.....	20
2.1.6.	MTBF – Tempo médio entre falhas.....	21
2.1.7.	Disponibilidade	22
2.1.8.	Tempo de indisponibilidade	23
2.1.9.	Falha x defeito.....	24
2.1.10.	Manutenção	24
2.1.11.	Manutenção programada	25
2.1.11.1.	Manutenção preditiva	26
2.1.12.	Manutenção não programada	27
2.1.13.	Vida útil.....	27
2.1.14.	Modelo de confiabilidade	28
2.1.15.	FMEA	29
2.2.	Confiabilidade de sistemas de componentes	30
3.	Modelo de distribuição de Weibull	31
3.1.	Função de distribuição e Função de densidade de Weibull	31
3.2.	Função de risco e Tempo médio esperado até a falha de Weibull	32
3.3.	Função de confiabilidade de Weibull.....	33
3.4.	Parâmetros da função e tipos de falha (Falha de fabricação, aleatória e de desgaste).....	34
3.5.	Estimativa de parâmetros da distribuição de Weibull	39
3.5.1	Estimativa por regressão linear	39

3.5.2	Fórmula de Bernard para classificação de <i>rank</i> mediano	45
4.	INFORMAÇÕES IMPORTANTES E DECISÕES A SEREM TOMADAS	47
4.1.	Coeficiente de determinação da estimação dos parâmetros de Weibull	47
4.2.	Confiabilidade instantânea do componente.....	48
4.3.	Estimativa de <i>MTTF</i> do componente	50
4.4.	Período de reposição do componente correspondendo ao custo mínimo.....	50
5.	ESTRUTURA DO SOFTWARE	52
5.1.	Apresentação geral	52
5.2.	Ferramentas utilizadas.....	52
5.3.	Visão geral da arquitetura do sistema	53
5.4.	Detalhamento da estrutura dos módulos	57
6.	APLICAÇÃO EM ESTUDOS DE CASOS.....	59
6.1.	Caso: Capacitores de barramento CC.....	60
6.2.	Caso: Lâmpadas LED industriais.....	70
7.	CONCLUSÃO	74
8.	PROPOSTA PARA CONTINUAÇÃO DO TRABALHO	77
	Referências	79
	Apêndice A – Interface gráfica stm ampliada.....	82

1. INTRODUÇÃO

Um sistema de produção confiável é fundamental para desempenhar de maneira eficiente suas funções. Uma das dimensões da qualidade dos produtos e serviços é a confiança em relação ao atendimento dos prazos. O mau funcionamento de um processo produtivo não só implica na paralisação das atividades, como também na geração de custos e, ocasionalmente, em danos físicos aos operadores da produção. A falha é descrita por modelos probabilísticos, uma vez que é inviável modelar, com modelos determinísticos, o desgaste ao longo do tempo, tampouco as condições intrínsecas ao acaso, como as descargas atmosféricas e outros fenômenos semelhantes. Dessa forma, a probabilidade é empregada para tomar decisões relativas a falhas em sistemas de produção, proporcionando instrumentos que otimizem o gerenciamento dos gestores (KAPUR; LAMBERSON, 1997).

O processo de gerenciamento das falhas é tão importante que, ao longo do século XX, ganhou corpo uma disciplina científica denominada “Confiabilidade”, dando origem, posteriormente, a uma engenharia com ferramentas especializadas para lidar com falhas: a “engenharia de confiabilidade”. A disciplina científica de Confiabilidade possui seu nome derivado de uma função probabilística relacionada à ausência de falhas ou ao sucesso de componentes, estabelecendo a estatística como cerne desse estudo (SALEH; MARAIS, 2006).

Há softwares comerciais excelentes, como é o caso do pacote *ReliaSoft*, que são capazes de acompanhar processos e gerenciar ensaios de componentes com elevada robustez e flexibilidade. Contudo, esses softwares são de alto custo para empresas de pequeno e médio porte (MONTGOMERY, 2020).

Os componentes que justificam a adoção de manutenção corretiva geralmente são os de alto investimento inicial, como os motores elétricos de médio e grande porte. Tais componentes possuem valores residuais significativos ao final de sua vida útil, valores esses que são incorporados no sistema de depreciação. Noutra perspectiva, há outros componentes que são próximos à descartabilidade, sendo em sua maioria de baixo custo e com valores residuais de final de vida útil insignificantes. Para esses últimos, a reposição preventiva se destaca em relação à manutenção corretiva, e, para essa categoria, o software se torna apropriado para averiguar a obsolescência deles, aplicando técnicas de análises de manutenção preditiva. O aplicativo propõe como solução: monitoramento em tempo real da confiabilidade do equipamento analisado; estimação do tempo médio até a falha (*MTTF*) e determinação do

momento ideal de reposição para um custo total, de reposição e de quebra, mínimo. Assim, essa ferramenta potencializa a disponibilidade do processo produtivo com um custo mínimo, mantendo o objetivo de todo sistema de manutenção com eficiência técnica e operacionalidade.

O processo de manutenção preventiva (MP) consiste em uma sequência de estratégias com o intuito de diminuir a frequência de falhas de um componente. Para a reposição preventiva (RP), a ideia segue-se no alinhamento entre tempo de inatividade e custo esperado após a expiração da garantia do produto, momento que surgirá um custo esperado para o cálculo, que será a base do estudo para obter o custo mínimo e, conseqüentemente, o tempo ótimo. Em Ahmad *et al.* (2011) é discutido a formulação matemática do modelo RP e descrito por Jin e Yamamoto (2017, p. 120, tradução nossa) como o ciclo de reposição, que seria “o tempo entre duas substituições sucessivas do sistema”. Ambos apresentam a política do modelo de reposição por idade (ARM), que enriquece a fundamentação sobre manutenção programada e que será debatida nos próximos tópicos.

A técnica central do software é a previsão de falhas, baseada em históricos de reposição e em modelos estatísticos, alinhando a ferramenta à manutenção preditiva – estratégia que antecipa falhas analisando as condições reais de operação dos ativos. Com o uso do modelo estatístico da distribuição de Weibull, a técnica de previsão de falhas define o intervalo com maior probabilidade de falhas, fornecendo suporte para monitoramento e otimização dos custos de manutenção. Essa análise estatística auxilia na compreensão do comportamento dos componentes durante sua vida útil, permitindo, também, a definição do momento ideal para reposição. O emprego desse procedimento se destaca por gerar indicadores de risco de falha, contribuindo para a prevenção de falhas inesperadas e reduzindo custos associados a falhas operacionais. Enquanto isso, a manutenção preventiva segue intervalos programados ou fixos, cujo resultado pode apresentar intervenções desnecessárias ou em falhas em decorrência do atraso na reposição.

Reforçando que as previsões de falha de determinado componente são estimadas através de modelos probabilísticos, tal confiabilidade se apresenta como modelo, podendo ser encontrada pela função estatística da distribuição de Weibull. Desenvolvida por Waloddi Weibull (1939), responsável por difundir e criar os conceitos a respeito do tema, aborda que é possível estimar a vida útil, ou a distribuição dessa vida, para diferentes produtos da engenharia. Mas esse não é o único conceito por trás da distribuição de Weibull, além de análises de confiabilidade, verifica a resistência e a fadiga da vida mecânica dos materiais e investiga a garantia deles (MENČÍK, 2016).

Nesse aspecto, os componentes dedicados a reposição e que obtiverem sua confiabilidade através da distribuição de Weibull podem estimar o *MTTF*, apresentando uma importante característica a respeito da taxa de falha ou erro. Para determinados produtos ou sistemas o início da distribuição de falhas acaba sendo de maior importância comparado a média, ou seja, o conhecimento da média até a falha (*MTTF*) pode ser mais eficaz do que a média entre falhas (*MTBF*), pois apresentará grande impacto na segurança e na garantia, consequentemente afetando na rentabilidade (KAPUR; LAMBERSON, 1997, p. 36).

A ferramenta é voltada para o desenvolvimento da interface gráfica (GUI), cujo processo de criação do aplicativo é baseado na linguagem de programação Tkinter, do Python. Seu foco é desempenhar interatividade quanto ao possível grande volume de dados de equipamentos que ela estiver sujeita. Permitindo que o usuário possua informações úteis com praticidade sobre determinado componente, aferindo a respeito de sua confiabilidade e tempo ótimo para reposição.

1.1 Objetivo geral

Sob essa perspectiva, o objetivo geral deste trabalho é desenvolver o aplicativo Weibull Predictor STM orientado a auxiliar na organização e na tomada de decisões pertinentes à manutenção e reposição de equipamentos em sistemas de produção. Ao utilizar históricos de reposição preventiva em arquivos Excel, possibilita que as empresas que não possuem o STM possam importar seus dados, ou, mesmo que não haja tais dados armazenados a respeito, iniciem algum registro previamente. Ele carrega em seu modelo simples e intuitivo – atendendo às expectativas dos pequenos e médios empreendimentos – a predisposição para monitorar a confiabilidade, a fim de obterem melhor economia e conforto no gerenciamento de suas máquinas. O software realizará monitoramentos, previsões e, através de funções de análise estatística de falhas de acordo com a distribuição de Weibull, proporcionará recomendações de manutenção.

1.2 Objetivos específicos

Os objetivos específicos que merecem destaque são:

- Aplicar o modelo probabilístico de distribuição de Weibull à análise de falhas, explorando a base teórica e aplicação na confiabilidade;

- Implementação de Weibull Predictor STM, envolvendo as atribuições:
 - Veiculação de dados de múltiplas planilhas Excel;
 - Estimativa da confiabilidade instantânea utilizando a distribuição de Weibull;
 - Cálculo do coeficiente de determinação (r^2), tempo médio até a falha (*MTTF*), do tempo ótimo e do custo mínimo da reposição.
- Criação de interface gráfica, com guia e avisos explicativos para intuitivamente sanar dúvidas sobre confiabilidade e facilitar o uso do Weibull Predictor STM para o usuário.
- Testes em processos de falhas gerados por IA; estimar e aferir a aplicabilidade prática da previsão de falhas.

2. FUNDAMENTAÇÃO

Antes da construção da interface gráfica da ferramenta, é necessário que os pilares conceituais sejam discutidos, visto que constituem o alicerce do funcionamento do sistema. Para esse propósito, analisa-se a base teórica sobre a confiabilidade, integrando preceitos importantes para o estudo pertinente à reposição dos equipamentos, como o desenvolvimento de parâmetros e interpretação da norma NBR 5462.

2.1. Conceitos fundamentais (norma NBR 5462)

A Associação Brasileira de Normas Técnicas (ABNT), através da NBR 5462 (1994), define uma terminologia técnica para múltiplos parâmetros essenciais relacionados à confiabilidade e à manutenibilidade de componentes e sistemas. Expõe conceitos que viabilizam análise de falhas e desempenho de ativos, como defeito, pane, *MTBF* e disponibilidade, no cenário nacional. O emprego desta norma permite o alinhamento de metodologias e de práticas para o desenvolvimento de modelos preditivos e políticas de manutenção, contribuindo para a prevenção de falhas e otimização operacional dos sistemas. Assim, a apresentação dos conceitos por esta norma auxilia na estruturação e formulação do software Weibull Predictor STM, cuja atribuição principal será o acompanhamento e otimização de custos de manutenção em ativos não sujeitos à manutenção corretiva.

Além da norma de regulamentação brasileira apresentada, a norma INTERNATIONAL ELECTROTECHNICAL COMMISSION (2024), ou IEC 60300-1:2024, complementa as diretrizes com caráter internacional e amplia o escopo. Sua implementação proporciona uma

harmonização entre variadas diretrizes e também abrange conceitos existentes na NBR 5462. Nesse sentido, o modelo internacional promove a abordagem de propriedades como disponibilidade, segurança, manutenibilidade e resiliência, com o intuito de incorporar tais características ao ciclo de vida do sistema ou equipamento. Seu reconhecimento propiciou a consolidação de sua aplicação em múltiplos ambientes, com a visão de garantia de alto desempenho e custo otimizado. Porém, a adoção da IEC 60300-1:2024 não foi possível devido à escassa disponibilidade, não sendo utilizada neste estudo para fundamentação e, portanto, sendo mencionada com intuito de contribuir para o tema de confiabilidade. A NBR 5462 (1994) se responsabilizará pela estruturação deste trabalho, permitindo que o Weibull Predictor STM ainda assim formule soluções especificamente voltadas para ativos não sujeitos à manutenção corretiva.

2.1.1. Confiabilidade

Determinada como parâmetro probabilístico, a confiabilidade verifica o desempenho de determinado item ou sistema durante um intervalo de tempo, qualificando a capacidade de operação sem falhas. Para NELSON (2004), é incerto acreditar que um produto estará em funcionamento no futuro, assemelhando-se a algo estocástico; nessa perspectiva, a confiabilidade passa a ser uma variável com comportamento aleatório.

Tal incerteza evidenciada é um problema, pois não seria possível definir o desempenho de um produto. Porém, quando se sugere que a verificação seja feita sob uma condição específica, é possível encontrar a confiabilidade enquanto tal situação vigorar. Essa definição é concebida por Kapur e Lamberson (1997, p. 3, tradução nossa), “confiabilidade é a habilidade de um produto ou sistema de funcionar como previsto (ou seja, sem falhas e dentro dos limites de desempenho especificados) durante um determinado período de tempo, nas condições do seu ciclo de vida”, em outras palavras, é uma probabilidade de não falha.

Consideremos que a variável aleatória seja a vida útil do produto ou sistema representados por T e não negativa, para um tempo de vida contínuo em um intervalo entre $[0, \infty]$. A função de densidade da probabilidade (f.d.p) de T será determinada por $f(t)$, que corresponde a $\int_0^{\infty} f(t) dt = 1$, indicando que a proporção de falha de um produto é grande (1), devido o intervalo de tempo ser extenso. Nesse período será possível encontrar a relação entre confiabilidade e não confiabilidade, a primeira será definida pela função $R(t)$, função de confiabilidade, e a segunda pela função $F(t)$, conhecida por função de distribuição acumulada

de falhas (f.d.c).

Para encontrar a $F(t)$, a função de distribuição acumulada de falhas, assim como anteriormente foi mencionado para a f.d.p, necessita determinar o limite ou período em que ocorrerá a falha em um componente. Ou seja, para estipular uma falha, o componente precisaria estar em atividade do início, que será o instante 0, até um tempo específico, que será chamado de t , concluindo que a equação no intervalo $[0, t]$ é:

$$F(t) = \int_0^t f(t) dt \quad (2.1.1)$$

A não confiabilidade, determinada pela f.d.c, delimitou a região à esquerda da área sob a curva da função de $f(t)$

$$F(t) = P[T \leq t] \quad (2.1.2)$$

levando a dedução de que a confiabilidade é a função da probabilidade de não falha, estipulada de maneira similar a equação (2.1.2). A região à direita da área sob a curva de $f(t)$ e a função da confiabilidade compõe o intervalo de $f(t)$

$$R(t) = P[T > t] = 1 - P[T \leq t] = \int_t^{\infty} f(t) dt \quad (2.1.3)$$

afirmando que, T e P seria a vida do produto que é analisada, configurada como variável aleatória, e a própria probabilidade definida por “P”, respectivamente.

2.1.2. Função de falha

A função de distribuição acumulada de falhas, conhecida resumidamente por função de falha, é definida por $F(t)$, descrita como a probabilidade em um instante de tempo t de que um componente apresente alguma falha. Com base na equação (2.1.3) e sua definição dada no item 2.1.1, a f.d.c dispõe de uma expressão similar à equação determinada para a confiabilidade, sendo sua forma matemática estabelecida como:

$$F(t) = 1 - R(t) \quad (2.1.4)$$

Sendo $R(t)$ definida como a probabilidade de sobrevivência do componente durante o tempo t . O emprego da função da confiabilidade auxilia na quantificação da probabilidade acumulada de falha, sobretudo em modelos de distribuição de Weibull, em que as falhas variam à medida que o tempo passa (MCCOOL, 2012).

A aplicação da função de falha contribui para que modelos estatísticos determinem a degradação ou desgaste de sistemas ou equipamentos, justificando planejamentos voltados para manutenção e reposição (NELSON, 2004). Referente a resoluções técnicas, a f.d.c propicia, em aplicações industriais, na previsão de falhas e no planejamento preventivo, suas estimativas de porcentagens de falha promove organização quanto a reposição de equipamentos nos setores de processamento (MONTGOMERY, 2020).

Anteriormente foi demonstrado a f.d.c operando em conjunto com a função de densidade de probabilidade e obtendo-se a região à esquerda da área sob a curva de $f(t)$, encontrada no intervalo de 0 a t , chegando na equação (2.1.1). Essa equação expressa que, com a variação do tempo, a função de falha aumenta e aproxima-se de 1, sendo o equivalente a 100% de porcentagem, ou probabilidade, de falha.

2.1.3. Taxa de falha e Função de risco

A taxa de falha é associada à função de risco, ambas possuem características relacionadas aos estudos apresentados até o momento a respeito da duração de vida dos componentes. O item deste tópico se diferencia por analisar um intervalo de tempo $[t_1, t_2]$, apresentando-se como uma função dependente de um período. A taxa de falha define a probabilidade que uma falha por unidade de tempo ocorra dentro dessa faixa temporal, sob a condição de que não haja falha antes do tempo t_1 . Portanto, sua expressão apresenta-se como

$$\text{Taxa de falha} = \frac{R(t_1) - R(t_2)}{(t_2 - t_1) \cdot R(t_1)} \quad (2.1.5)$$


A função de risco é propriamente definida como o limite da taxa de falha à medida que $(t_2 - t_1)$ ou Δt tende a zero, sua expressão é dada por $h(t)$, representando-a como a taxa de falha instantânea no tempo t . Considerando que o sistema ou componente sobreviva até o tempo t , é

possível redefinir o intervalo para $[t, t + \Delta t]$, fundamentando a equação para

$$h(t) = \lim_{\Delta t \rightarrow 0} \left(\frac{R(t) - R(t + \Delta t)}{\Delta t \cdot R(t)} \right) = \frac{f(t)}{R(t)} \quad (2.1.6)$$

A função de risco para muitos componentes tem como representação gráfica a “curva da banheira”, no estudo de Heiser e Hofmeister (2018) é descrito como a “representação estatística da taxa de falha sobre a vida de uma população de produtos e está relacionada a uma curva de distribuição de falhas” (tradução nossa). Com três fases de falhas distintas distribuídas no tempo t , a função de risco se destaca pela predisposição de identificar a taxa de falha decrescente, constante e crescente. Porém, em situações que o sistema ou componente apresente apenas taxa de falha decrescente ou crescente durante sua vida observada, a curva da taxa de risco pode não conseguir apresentar os três períodos. Ainda assim, a curva presente na Figura 1 demonstra ser útil para produtos que dispõem de taxa de falha decrescente no início da vida útil e uma taxa de falha crescente ao longo do tempo. Aplicada sobre a vida de uma população de produtos que apresentam falhas, seja pelo desempenho debilitado, complicações provenientes da fabricação ou uso inadequado.

Figura 1: Curva da banheira; três tipos de falhas que ocorre em muitos sistemas e equipamentos.



Fonte: Adaptado de Maisonnier (2018).

2.1.3.1. Falha de fabricação

Durante o período $[t_0, t_1]$ presente na Figura 1, chamada de falha precoce na “mortalidade infantil”, a função de risco demonstra elevada taxa de risco, porém seu comportamento denota que há diminuição ao longo do tempo. Após o primeiro período, é encontrada estabilização em certo tempo t_1 , este instante é o ponto ideal para que os produtos sejam colocados em serviço, visto que haverá eliminação de falhas precoces. Para que os produtos superem este estágio, onde defeitos surgem na fabricação, a aplicação do método conhecido como “Burn-in” se apresenta como solução. Esta estratégia proporciona aumento da confiabilidade submetendo equipamentos a “queima”, que seria a provocação de estresse, quando a operação está acima da regularidade. A partir desse procedimento, produtos serão removidos antes do surgimento de desgaste e a porção que estará em funcionamento apresentará baixa taxa de falha (NELSON, 2004).

O procedimento de recall é muito utilizado nesse período pela indústria. Falhas devido ao processo de fabricação ou à matéria prima utilizada são detectadas depois que o produto entrou no mercado consumidor, no início da vida útil física. Depois dessa identificação, a indústria estimula o recolhimento do produto ou manutenção corretiva, sem custo para o consumidor (BRASIL. MINISTÉRIO DA JUSTIÇA. SECRETARIA NACIONAL DO CONSUMIDOR., 2013).

2.1.3.2. Falha aleatória

Para o período $[t_1, t_2]$ da Figura 1, conhecido como período da vida útil, como comentado por Kapur e Lamberson (1997), é o melhor estágio de operação possível do produto, onde a taxa de risco é consideravelmente baixa. A chance de acontecer algum defeito é mínimo e, por isso, a falha passa a ser determinada por eventos aleatórios. Sua definição é dada por: “qualquer falha cuja causa ou mecanismo faça com que seu instante de ocorrência se torne imprevisível, a não ser no sentido probabilístico ou estatístico” (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1994, p. 4). Um exemplo claro desse padrão de falha acontece em fontes de alimentação de computadores. Tais fontes apresentam falhas em função de eventos súbitos no sistema de distribuição, como sobretensão, fenômenos atmosféricos e umidade.

2.1.3.3. Falha por deterioração

Também conhecida por falha por envelhecimento ou desgaste, sua presença é destacada

ao final da curva da banheira, como a Figura 1 representa. À medida que o tempo t excede o instante de tempo t_2 , a taxa de risco aumenta significativamente, isso se deve aos fenômenos por deterioração, desgaste mecânico, degradação química e envelhecimento de componentes elétricos (MENČÍK, 2016). Para NBR 5462 (1994). Esse período indica o eventual fim da vida útil de determinado componente, sendo sua taxa de falha superior à de períodos anteriores. Além disso, equipamentos com este tipo de falha costumam provocar custos elevados, riscos à segurança de operadores e paradas indesejáveis em processos de produção, sendo crucial a programação de reposições e manutenções preventivas (AHMAD, KAMARUDDIN, *et al.*, 2011). Ou seja, o adiamento da reposição nesta perspectiva aumenta a taxa de risco e maximiza o custo da manutenção corretiva.

2.1.4. Esperança até a falha

De acordo com a NBR 5462 (1994), a “esperança até a falha” é a esperança matemática de que componentes incapazes de serem reparados eventualmente alcance o tempo médio até a primeira falha (*MTTFF*). Ou seja, tal métrica se baseia na sobrevivência de um produto novo e, portanto, dada a conceituação da confiabilidade, a esperança é de que a falha não aconteça em um intervalo extremamente grande. Afim de aumentar o valor esperado da função da *MTTFF* para que a chance de falha seja mínima, é necessário que a confiabilidade do produto ou sistema seja relativamente alta, sendo possível tal verificação através da equação

$$MTTFF = \int_0^{\infty} t f(t) dt = \int_0^{\infty} [1 - F(t)] dt = \int_0^{\infty} R(t) dt \quad (2.1.7)$$

A estimativa da esperança até a falha permite compreender o comportamento do produto investigado. Na prática, Ahmad *et al.* (2011) utilizaram o *MTTFF* em modelos estatísticos direcionados à minimização dos custos voltados a manutenções não programadas, contribuindo também para o planejamento de reposições preventivas.

2.1.5. MTTF - Tempo médio até falha

Aplicável em uma população de itens não reparáveis, o tempo médio até a falha (*MTTF*) independe das condições impostas, seja sobre o componente ou sistema, e do tempo de vida útil. Isso se deve pela inexatidão individual da falha, que é ocasionada pela variação no processo

de degradação do item investigado.

A utilização da *MTTF* promove uma base sólida na aquisição e implementação de modelos de reposição preventiva, alinhando-se ao objetivo deste trabalho, destinado a ativos não sujeitos a manutenção corretiva. Os estudos de Ahmad *et al.* (2011) e de Jin e Yamamoto (2017) não apenas mencionam como reforçam a integração da função *MTTF* a respeito da reposição preventiva e do modelo *age replacement*.

Apesar de similar ao *MTTFF*, e de ser regular a permuta com a *MTTF*, o tempo médio até a primeira falha também se destaca por utilizar dados de itens não reparáveis, porém se refere majoritariamente a produtos que estão na fase inicial da vida útil.

Por uma perspectiva normativa, a distinção da nomenclatura entre *MTTF* e *MTTFF* permite uma análise correta do componente, sendo confiável a formalidade dos itens empregando a NBR 5462 (1994).

Além disso, como discutido na seção 2.1.4, ambas as métricas agregam para planejamentos de manutenções e reposições preventivas com base no valor esperado do tempo até a falha, tendo em vista que se assemelham mesmo com diferentes distribuições de falhas. Por compartilharem fundamentos semelhantes, as duas funções proporcionam predições de disponibilidade operando de forma conjunta ou não.

2.1.6. *MTBF* – Tempo médio entre falhas

Diferente das últimas duas seções, sobre *MTTF* e *MTTFF*, o tempo médio entre falhas (*MTBF*) costuma ser designado para sistemas reparáveis (MCCOOL, 2012). Sua presença se deve pela exibição da taxa de risco ou falha constante de determinado componente, estimando o tempo médio entre duas falhas sucessivas de um equipamento em operação.

De forma análoga ao comportamento da falha constante presente no intervalo $[t_1, t_2]$ da curva da banheira, o *MTBF* apresenta-se comumente em equações que estimam o valor esperado através da relação entre o tempo de operação e o total de falhas observadas, dentro do ciclo de operação (HEISER; HOFMEISTER, 2018):

$$MTBF = \frac{\text{Tempo de operação total}}{N^\circ \text{ de falhas}} \quad (2.1.8)$$

Um dos tópicos importantes que envolvem a *MTBF*, que será mencionado

posteriormente, é a disponibilidade. O aumento da disponibilidade depende diretamente da melhoria da confiabilidade e, conseqüentemente, do aumento do *MTBF*.

Observação importante quanto a esse TCC é que o mesmo não aborda componentes sujeitos a recuperação, sua abordagem se concentra em componentes não recuperáveis. Um módulo para componentes sujeitos a recuperação, cujo os objetivos seriam o aumento da disponibilidade desses componentes e a redução do custo da manutenção, é alvo de proposta de continuação do trabalho.

2.1.7. Disponibilidade

A disponibilidade é a métrica responsável por definir o desempenho de um item, avaliando as condições, dentro de um intervalo ou instante de tempo, acerca da aptidão para uma função específica, admitindo que os recursos externos se encontrem assegurados (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1994). Ou seja, de maneira sucinta, sua designação detém-se na probabilidade de que um equipamento esteja disponível para atuação em um determinado instante.

A equação matemática da disponibilidade se manifesta regularmente como:

$$Disponibilidade = \frac{MTBF}{MTBF + MTTR} \quad (2.1.9)$$

A função *MTTR*, apresentada na equação (2.1.9), corresponde ao tempo de restabelecimento médio ou Tempo Médio de Reparo, conforme especificado pela NBR 5462 (1994). De modo semelhante ao que foi explicitado na equação (2.1.8), que se refere a *MTBF*, a *MTTR* baseia-se na relação entre o tempo total aplicado aos reparos e o número total de falhas registradas. Ou seja, essa métrica revela o intervalo de tempo entre a identificação da falha e o retorno do equipamento à sua operação normal.

No âmbito de produção industrial, a disponibilidade torna-se um dos fatores essenciais, principalmente se associada à redução de custos empregando políticas de reposição preventiva, previamente discutido. A ocorrência de atrasos na fabricação e a resultante perda de lucratividade, ocasionada por interrupções não programadas dos equipamentos, por exemplo, se apresentam justamente como o oposto da disponibilidade, sendo denotada como indisponibilidade (SILVA e ANDRADE, 2016; SPADER e ANDRADE, 2015).

Sendo assim, analisando a equação (2.1.9), constata-se que a confiabilidade é

apresentada como importante contribuidora para a disponibilidade (MAISONNIER, 2018), pois, uma vez que a confiabilidade seja incrementada, resulta consequentemente no crescimento do valor esperado do *MTBF*, beneficiando na elevação da disponibilidade.

2.1.8. Tempo de indisponibilidade

Definido previamente o conceito de disponibilidade, é imprescindível o entendimento do tempo de indisponibilidade, consequentemente por sua representação complementar à disponibilidade no ciclo de vida de um ativo. Para reforçar este aspecto, o tempo de indisponibilidade, conhecido pelo termo em inglês *downtime*, caracteriza-se por determinar o período em que um ativo se apresenta inapto a exercer sua função, seja em razão de manutenções corretivas ou preventivas ou na presença de falhas.

De acordo com a NBR 5462 (1994), o tempo de indisponibilidade se expressa mediante um métrico denominado tempo médio de indisponibilidade, ou *Mean Down Time* (MDT). Seu destaque é ocasionado pela inclusão de todo o período no qual o item permanece inapto a exercer sua função, diferentemente da MTTR, cujo tempo de reparo do item pode ou não ser igual ao tempo de inatividade. Maisonnier (2018) debate que essa distinção é a principal diferença entre as duas métricas.

Logo, o MDT é calculado mediante a relação entre o tempo total de inatividade e do número de falhas no período em que se realizou a análise, sendo seu resultado implementado na equação:

$$\text{Tempo de indisponibilidade} = \frac{MDT}{MTBF + MDT} \quad (2.1.10)$$

Porém, a depender da métrica utilizada para monitoramento e/ou planejamento do equipamento ou sistema, o tempo de indisponibilidade também pode ser representada por:

$$\text{Tempo de indisponibilidade} = \frac{MTTR}{MTBF + MTTR} \quad (2.1.11)$$

Além disso, a equação (2.1.9) poderá utilizar a métrica MDT no lugar da MTTR, pois, como discutido anteriormente, o enfoque mantém-se na escolha da investigação. A prioridade entre uma ou outra será definido por meio do estudo pesquisado a respeito, se abordará apenas

o tempo de reparo ou se considerará o tempo de logística/administrativo.

2.1.9. Falha x defeito

A falha e o defeito de determinado componente são comumente equiparados, porém apresentam distinções relevantes tanto quanto são pertinentes aos estudos de confiabilidade e às análises de desempenho. A inaptidão de um item desempenhar sua função é conhecida como falha, ou melhor, isto seria o momento exato em que ocorreu a interrupção da execução de um item, impedindo-o de atender as suas demandas ou de continuar a sua operação (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1994).

Enquanto isso, o defeito é representado pela NBR 5462 (1994) como o desvio ou mudança de característica de um item, sendo possível que não haja paralisação da operação e que não ocorra uma falha imediata. Um produto que não segue uma ou mais especificações – conhecido como não conforme – não é obrigatoriamente impróprio para atuação, porém ele pode ser classificado como defeituoso caso apresente um ou mais defeitos, ou não conformidades.

Essa perspectiva é dada por Montgomery (2020, p. 9, tradução nossa), que explica que estes defeitos são “não conformidades suficientemente graves para afetar significativamente a utilização segura ou eficaz do produto”. Sendo assim, entende-se que a existência do defeito torna o item predisposto a falhar, mas que não implica, de maneira imediata, na suspensão das atividades predefinidas, sendo capaz de comprometer aspectos associados à segurança e à eficiência.

2.1.10. Manutenção

A manutenção tem como objetivo preservar que um ativo mantenha sua funcionalidade ou, em situações em que houve a perda dela, que a recupere. A elaboração da definição feita pela NBR 5462 (1994, p. 2) é dada como a

Combinação de todas as ações técnicas e administrativas, incluindo as de supervisão, destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida.

Menčík (2016) comenta que, historicamente, a manutenção surgiria somente após a falha, sendo uma das estratégias mais comuns e primordiais, que ainda se mantém em uso atualmente. Isto se deve ao fato de que a manutenção está vinculada ao avanço e desenvolvimento da tecnologia, permitindo o surgimento de novas técnicas e estratégias ao

longo dos anos (KAPUR; LAMBERSON, 1997).

Sobre isto, estratégias como a manutenção preventiva ou a manutenção corretiva são utilizadas para estabelecer condições satisfatórias de operação, Maisonnier (2018, p. 2, tradução nossa) indica que estes métodos providenciam “inspeção sistemática, detecção e correção de falhas incipientes, seja antes delas ocorrerem ou de se transformarem em defeitos graves”.

O conceito de política de manutenção surgiu com o aprimoramento das metodologias da engenharia da confiabilidade, o qual possibilitou a classificação da manutenção em dois âmbitos: manutenção programada e manutenção não programada. Nos próximos tópicos, essa distinção será debatida com base no momento e no planejamento da intervenção, com destaque nas características e suas implicações no desempenho dos ativos.

2.1.11. Manutenção programada

Conhecida pelo planejamento prévio, a manutenção programada executa mediações em ativos conforme os padrões sejam estabelecidos, quer seja por tempo, condições ou estatísticas, sendo considerado um dos propósitos da confiabilidade: garantir e assegurar a prevenção de problemas (KAPUR; LAMBERSON, 1997). A norma NBR 5462 (1994) define que ela abrange todas as formas de atuação de manutenções agendadas previamente, seu objetivo é que o item desempenhe sua função com baixa probabilidade de falha, permitindo uma atuação contínua.

A manutenção preventiva (MP) introduziu-se na política de manutenção como um conceito simples: o reparo ou reposição periódica de peças que apresentem falhas graduais. Progressivamente se evidencia a ocorrência de deterioração por desgastes, fadiga e corrosões, sendo ideal para a inibição desses fatores a aplicação da MP enquanto o material possuir uma baixa variação da taxa de deterioração e de tempo até a falha de itens individuais (MENČÍK, 2016). Ou seja, estratégias que antecedem falhas inesperadas é o objetivo principal deste tópico. Com o intuito de preservar e/ou restaurar a serventia do produto, expõe-se o desenvolvimento da manutenção preventiva, previamente debatida, e a reposição preventiva (RP), respectivamente.

A reposição preventiva se exprime em modelos como o *Age Replacement Model* (ARM), ou Modelo de Reposição por Idade. Tais modelos estatísticos almejam a reposição de um item antes que aconteça uma falha, baseando-se no tempo de vida útil ou em seu histórico de falhas (AHMAD; KAMARUDDIN, *et al.*, 2011; JIN; YAMAMOTO, 2017). Esta derivação do método de manutenção programada otimiza o custo de manutenção compensando os custos

de reposição com os custos relacionados a falhas.

2.1.11.1. Manutenção preditiva

Outro ponto crucial da manutenção programada é a inserção da manutenção preditiva, que utiliza como estratégia a aplicação de técnicas de análise com intuito de manter a qualidade de serviço, além de reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1994). Há diferentes interpretações dessas técnicas e se modificam a depender do ambiente, enquanto uns as descrevem como o ato de monitorar vibrações de máquinas rotativas, outros as definem como o monitoramento da imagem infravermelha de determinados equipamentos elétricos (MOBLEY, 2002).

Mobley (2002) argumenta que a manutenção preditiva melhora produtividade e qualidade do produto ao investigar as condições reais de operação, otimizando a disponibilidade dos ativos. Com a implementação dessa estratégia, a capacidade dos gestores em administrar as manutenções é aprimorado, uma vez que é disponibilizado dados que indicam a condição mecânica e a eficiência operacional de cada ativo ou sistema. O monitoramento desses dados possibilita a determinação do tempo médio até a falha do equipamento, enquanto que a manutenção preventiva orienta-se baseada na experiência do gestor. Logo, a manutenção preditiva amplia a manutenção preventiva, que se baseia em cronogramas fixos, utilizando informações de condições reais e permitindo, com modelos estatísticos, a previsão de falhas e a determinação da confiabilidade instantânea dos ativos.

O emprego da estratégia da manutenção preditiva contribui para que a intervenção antecipada possua justificativas ideais e reais que partem da condição do ativo. Isso permite que a técnica central proposta, a previsão de falhas, atue com modelos estatísticos, como a distribuição de Weibull, para a determinação do momento ideal das interrupções, propiciando a redução de paradas não programadas e nos custos associados às falhas corretivas.

Com o Weibull Predictor STM, tais conceitos teóricos de manutenção preditiva são empregados em conjunto com os históricos de falhas dos componentes. Ao ser processado os dados dos históricos e fornecer indicadores que potencializam a disponibilidade e eficiência dos ativos, é fornecido aos usuários métricas de desempenho que orientam tomadas de decisões. Logo, o software se torna uma aplicação prática de manutenção preditiva ideal para os gestores de manutenção executarem previsões de falha, pois estará antecipando suas predições com base

no comportamento dos ativos.

2.1.12. Manutenção não programada

A manutenção não programada se destaca por ser o oposto da manutenção programada, ela é caracterizada por intervir em situações de emergência. Ou seja, quando acontece uma falha inesperada e o item não pode ficar inapto a exercer sua função, é realizado o reparo no instante da interrupção do ativo (SELLITTO e FACHINI, 2014). Por frequentemente ser relacionada à paralisação da produção, quando ocasionalmente o equipamento tem suas funções comprometidas, há uma preocupação maior relativo ao impacto financeiro. Essa aflição é constituída pela incerteza do tempo inativo e pelo custo referente a correção do item, sendo também conhecida pelo termo manutenção corretiva (MC).

Em determinadas circunstâncias a manutenção corretiva pode ser programada, são ocasiões em que o ativo não necessita de uma intervenção emergencial, mantendo-se em estado de falha até a efetuação do reparo (SILVA e ANDRADE, 2016). Apesar da manutenção não programada ser demonstrada pouco benéfica em sistemas de produção, ela pode se sobressair em situações estratégicas em que o item possua pequenas falhas, que não comprometem significativamente a segurança e o desempenho (MENDES, 2011). Outra situação importante de ser considerada é a estratégia aplicada sobre os custos operacionais, quando a opção de que um ativo opere até a falha se apresente menos dispendiosa em relação a manutenção programada.

O tempo ótimo para a realização da manutenção dispõe de uma imprevisibilidade que impacta na eficiência da estratégia de maneira negativa. Pode resultar em perdas de recursos, caso a aplicação da manutenção programada seja executada muito cedo, ou aumento de risco operacional, caso ela seja efetuada muito tarde. Por outro lado, na manutenção não programada é necessário verificar a viabilidade econômica perante a paralisação e o impacto financeiro que ela gera. Como Maisonnier (2018) aborda, para manutenções não programadas é possível que a perturbação muitas das vezes cause consequências dramáticas, devido às diferentes probabilidades e severidades das falhas em determinados sistemas.

2.1.13. Vida útil

A vida útil foi exemplificada previamente nas formulações de confiabilidade e não

confiabilidade apresentadas neste estudo. Ao condicionar a perspectiva sobre um ativo, a vida útil corresponde ao intervalo de tempo entre: o momento em que um ativo é iniciado pela primeira vez, em estado de disponibilidade, e o momento da falha, que compromete o seu funcionamento ou o torna inapto para exercer sua função (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 1994).

Neste caso, a vida útil, que está presente em diversas métricas e modelos estatísticos, é representada como uma variável aleatória contínua e é associada à taxa de falha, em que se espera que a falha se mantenha ausente até certo instante t (MCCOOL, 2012; SHEU, KUO, NAKAGAWA, 1993). Além disso, ocorre que uma única vida útil pode ser considerada para diferentes sistemas, sendo a mesma variável para análises em diferentes condições de operação, que se diferenciam-se por fatores ambientais e operacionais (JIN; YAMAMOTO, 2017).

Utilizando no monitoramento e na política de manutenção, a vida útil representa uma estrutura estratégica que administra os ativos. Por estar presente nas funções de confiabilidade $R(t)$, de distribuição acumulada de falhas $f(t)$ e na função de risco $h(t)$ (MCCOOL, 2012), ela auxilia na determinação do tempo ótimo de reposição e na definição do custo mínimo de manutenção de ativos não sujeitos à manutenção corretiva.

2.1.14. Modelo de confiabilidade

Após a fundamentação teórica da confiabilidade, compreendendo-a e a utilizando como base, revisaremos os conceitos sobre modelo de confiabilidade (em inglês, *reliability engineering*). Sua representação matemática e estatística é comumente associada com manutenibilidade, disponibilidade e engenharia logística, isso se deve ao fato de que seu uso possibilita realizar previsões do comportamento de sistemas e equipamentos com o passar do tempo (MAISONNIER, 2018, tradução nossa). Nessa perspectiva, é notória a importância do modelo de confiabilidade no contexto da engenharia de confiabilidade, pois ela fomenta o embasamento teórico que auxilia em resoluções de manutenção e reposição.

De acordo com a NBR 5462 (1994), o modelo de confiabilidade e sua representação matemática são utilizados para previsões a respeito da capacidade de um item desempenhar sua tarefa durante determinado intervalo de tempo. Além disso, segundo a norma, esse modelo estima medidas de confiabilidades, formulações estas que foram apresentadas de modo prévio no presente estudo, como, por exemplo, a função de confiabilidade $R(t)$, a função de falha $F(t)$ e a função de risco $h(t)$.

Reiterando o tópico 2.1.1 sobre confiabilidade, o desenvolvimento do modelo de confiabilidade segue o mesmo preceito: sua representação é dada por uma variável aleatória T que considera o tempo de vida útil ou o tempo até a falha do componente ou sistema. A distribuição de Weibull atua como um tipo de modelo probabilístico, amplamente utilizado em análises de confiabilidade. Kapur e Lamberson (1997) debatem que este modelo específico é capaz de modelar uma grande diversidade de curvas de taxa de risco, se destacando por sua flexibilidade e capacidade de retratar diferentes padrões de falhas, como os que aparecem na curva da banheira: falhas precoces, falhas aleatórias e falhas por desgaste.

A distribuição exponencial, cuja a taxa de falha é constante, é muito utilizada em manuais de fabricantes, estimulada pela sua simplicidade. No entanto, a distribuição de Weibull, como já foi mencionado, é capaz de modelar os diversos padrões de falha, inclusive o padrão descrito pela distribuição exponencial.

2.1.15. FMEA

A *Failure Mode and Effect Analysis* (FMEA), ou Análise dos Modos de Falhas e seus Efeitos, é caracterizada por Menčík (2016) como um procedimento simples. Ela revela possíveis falhas de uma estrutura ou processo durante a fase do projeto, aplicada com o objetivo de evitá-las e mitigá-las. Ainda segundo o autor, a FMEA se destaca por aplicar um procedimento sistemático que segue uma ideia básica e fundamental: prevenir falhas é mais vantajoso e econômico do que as detectá-las e repara-las posteriormente.

Desenvolvida pela *Grumman Aircraft Corporation* em 1950, a FMEA foi criada como uma metodologia voltada à análise e ao gerenciamento da segurança de sistemas de controle de voo de aeronaves navais (KAPUR; LAMBERSON, 1997). Atualmente, conforme a NBR 5462 (1994), a FMEA é descrita como uma metodologia qualitativa, utilizada para o estudo dos modos de falhas em subitens de um sistema, avaliando individualmente os efeitos sobre os outros componentes e sobre a função requerida do item.

Com isso, a FMEA contribui para a construção de projetos sólidos, antecipando a identificação dos mecanismos de falha ocasionados por estresses (mecânicos, térmicos, elétricos, químicos e de radiação) (KAPUR; LAMBERSON, 1997). Ou seja, de acordo com os autores, o conhecimento da influência do estresse nos mecanismos de falha e das condições de operação permitem o monitoramento do desempenho de um produto durante sua vida útil.

2.2. Confiabilidade de sistemas de componentes

O processo de decisão deve levar em consideração a confiabilidade do sistema como um todo e não apenas a confiabilidade de componentes separados. De acordo com a NBR 5462 (1994), a confiabilidade determina a competência para um item ou sistema desempenhar sua função, sob condições específicas, durante um intervalo de tempo e sem apresentar falhas.

Em uma aplicação prática, um sistema pode envolver centenas ou milhares de componentes, tornando inviável o acompanhamento individual de todo sistema devido sua complexidade. Assim, a análise de confiabilidade dedica-se aos componentes críticos com maior taxa de falha, numa tentativa de tornar o estudo menos complexo e de reduzir o impacto na operação do sistema. Por exemplo, em um conversor estático, os capacitores possuem alta taxa de falha; as chaves estáticas geram muito calor nas junções e os drivers também necessitam de mais atenção e, portanto, tudo isso deve ser levado em conta na determinação da confiabilidade do conversor.

É fundamental o conhecimento da arquitetura dos componentes, pois, se os componentes estão conectados em série, do ponto de vista de confiabilidade basta um deles falhar para que todo o sistema falhe. A arquitetura em série é a mais encontrada em produtos industriais (NELSON, 2004), é também conhecida por Modelo do elo mais fraco (em inglês, *the model of the weakest link*). Rinne (2008) complementa que a confiabilidade desse sistema é dada através de n itens conectados em série operando ao mesmo tempo, visto que a vida útil desse sistema termina com a menor vida útil do elo, sua representação equacional é demonstrada na equação (2.2.1). Caso a arquitetura seja paralela, ou melhor, com componentes redundantes, significará que uma ou mais partes do sistema podem falhar e o sistema ainda será capaz de funcionar com as partes que permanecem em operação (KAPUR e LAMBERSON, 1997, p. 381, tradução nossa). O sistema paralelo falha apenas quando todos os n componentes falharem (MCCOOL, 2012), a confiabilidade dos n componentes para esse sistema é mostrado na equação (2.2.2).

$$R_T = R_1 R_2 R_3 \dots R_N \quad (2.2.1)$$

$$R_T = 1 - (1 - R_1)(1 - R_2)(1 - R_3) \dots (1 - R_N) \quad (2.2.2)$$

É importante não confundir componentes redundantes com tolerância a falha. Um sistema tolerante a falha possui a capacidade de se reconfigurar de tal forma que continue

operando mesmo após o componente apresentar falha. Por exemplo, um conversor estático para acionamento de motores trifásicos pode ter um braço a mais de IGBT *dual* para, em caso de falha, ocorra automaticamente a substituição do braço defeituoso. Isso garante a continuidade da operação enquanto ocorre o planejamento da manutenção. A obtenção da confiabilidade em sistemas com tolerância a falha é bem mais complexa que as expressões da equação (2.2.1) e da equação (2.2.2), e foge ao escopo desse TCC.

3. MODELO DE DISTRIBUIÇÃO DE WEIBULL

A distribuição de Weibull é extensivamente utilizada na engenharia da confiabilidade, caracterizada e distinguida por duas formas: com a presença de dois ou três parâmetros (MCCOOL, 2012; LAWLESS, 2003). Este modelo tem sido continuamente aplicado no tempo de vida útil dos produtos, por sua facilidade em modelar as taxas de falha crescentes ou decrescentes (NELSON, 2004). Desenvolvida por Walloddi Weibull, sua formulação matemática destaca-se pela capacidade e eficiência em adaptar-se a múltiplas formas de distribuição da vida útil, possibilitando aplicar o modelo de distribuição de Weibull em componentes cujas falhas são associadas ao desgaste (taxa crescente), falhas aleatórias (taxa constante) e falhas de fabricação (taxa decrescente). (KAPUR; LAMBERSON, 1997).

Conforme previamente discutido a respeito da curva da banheira – que representa estes três tipos de comportamentos – reforça-se a versatilidade do modelo de Weibull diante dos diferentes intervalos do ciclo de vida dos ativos. Através dessa perspectiva, a aplicação do modelo demonstra-se adequado para análises de ativos não reparáveis e aos componentes que estão mais sujeitos à reposição preventiva do que à manutenção corretiva, devido às suas características econômicas e operacionais.

No contexto da ferramenta Weibull Predictor STM, o modelo de distribuição de Weibull concede uma estrutura estatística que contribui para a estimativa da confiabilidade no decorrer do tempo, proporcionando ao software a capacidade de prever falhas utilizando históricos de reposição. Com isso, viabiliza-se a indicação de parâmetros como o tempo médio até a falha (*MTTF*), a taxa de confiabilidade, tempo ótimo de reposição e o custo benefício associado ao dilema dos sistemas de produção, “substituir o componente ou arriscar uma parada súbita?”.

3.1. Função de distribuição e Função de densidade de Weibull

A função de densidade de probabilidade (f.d.p), representada por $f(t)$, é estimada através da razão entre o número de falhas de um produto em um intervalo e o número total de produtos que corresponde ao intervalo (KAPUR; LAMBERSON, 1997, p. 23). No entanto, nesta seção será verificado a aplicação da f.d.p para uma função de distribuição de Weibull de três parâmetros, cuja estimativa passa a ser obtida da seguinte forma:

$$f(t) = \frac{\beta}{\eta} \left(\frac{t - t_0}{\eta} \right)^{\beta-1} e^{-\left(\frac{t-t_0}{\eta}\right)^\beta}, \text{ para } \eta > 0, \beta > 0, t_0 \geq 0, t \geq t_0 \quad (3.1.1)$$

as definições dos três parâmetros são: β (parâmetro de forma); η (parâmetro de escala/vida característica) e t_0 (parâmetro de localização) (MCCOOL, 2012). Segundo o mesmo autor, McCool, a distribuição de Weibull de dois parâmetros é utilizada comumente quando o parâmetro de localização t_0 é igual zero. Em variadas referências, este parâmetro é retirado da equação (3.1.1), fazendo com que a função de Weibull possua apenas duas variáveis, de forma e de escala.

A função de distribuição acumulada de falhas (f.d.c) aplicada para uma função de distribuição de Weibull de três parâmetros é estimada, como Nelson (2004) diria, pela fração da população que falha no tempo t , dada por:

$$F(t) = 1 - e^{-\left(\frac{t-t_0}{\eta}\right)^\beta}, \text{ para } \eta > 0, \beta > 0, t_0 \geq 0, t \geq t_0 \quad (3.1.2)$$

segundo o autor, η é conhecida não apenas por parâmetro escalar, como também por vida característica, assim como adota o uso das mesmas unidades de t (horas, ciclos ou dias), confirmando as explicações de McCool (2012) sobre a equação (3.1.2) da f.d.c.

3.2. Função de risco e Tempo médio esperado até a falha de Weibull

A função de risco reduzida para a distribuição de Weibull é

$$h(t) = \frac{f(t)}{R(t)} = \frac{\beta}{\eta} \left(\frac{t - t_0}{\eta} \right)^{\beta-1}, \text{ para } \eta > 0, \beta > 0, t_0 \geq 0, t \geq t_0 \quad (3.2.1)$$

segundo Lawless (2003) e Nelson (2004), β coordena a natureza da taxa de falha, e, através da

função de risco de Weibull, auxilia no levantamento de informações pertinentes ao uso de reposição preventiva de ativos. Semelhante à explicação da curva da banheira para $h(t)$, neste tópico, o parâmetro de forma β é “crucial para o comportamento de uma função de risco de Weibull e para o processo de envelhecimento” (RINNE, 2008, p. 46-47, tradução nossa).

A função de risco costuma ser também representada por λ , porém, quando tratamos do tempo médio esperado até a falha (*MTTF*), observa-se que, quando a função de risco se torna constante, pode-se utilizar a média da distribuição para representá-la por $MTTF = 1/\lambda$ (MENČÍK, 2016). Nelson (2004) ressalta que essa relação é válida no caso da distribuição exponencial, considerada um caso particular da distribuição de Weibull em que as falhas ocorrem de maneira aleatória. A expressão de *MTTF*, que abrange não apenas o período de falhas constantes da curva da banheira, é representada por $E(T)$ ou μ , cuja equação é dada por:

$$E(T) = MTTF = \int_0^{\infty} t f(t) dt = \int_0^{\infty} R(t) dt \quad (3.2.2)$$

quando considerado t_0 igual a 0, a função *MTTF* de Weibull é

$$E(T) = \int_0^{\infty} t \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^{\beta}} dt \quad (3.2.3)$$

Montgomery (2020) e Lawless (2003) apontam que a expressão da função *MTTF*, para a distribuição de Weibull com três parâmetros, é dada através da função de Gamma.

Considerando $u = \left(\frac{t}{\eta}\right)^{\beta}$, equação se apresenta como

$$E(T) = t_0 + \eta \cdot \Gamma\left(1 + \frac{1}{\beta}\right), \text{ em que } \Gamma(k) = \int_0^{\infty} u^{k-1} e^{-u} du, k > 0 \quad (3.2.4)$$

onde Γ é a representação da função de gama.

3.3. Função de confiabilidade de Weibull

Também conhecida como a função de sobrevivência, a depender da situação, a função de confiabilidade pode ser a conexão para a função de risco, a função de distribuição acumulada de falha e a função de densidade de probabilidade. Progredindo na explicação de McCool

(2012), o autor comenta que o conhecimento de uma das três funções permite a determinação das outras. Lawless (2003) complementa tal confirmação fomentando que as funções $f(t)$, $F(t)$, $R(t)$ e $h(t)$ contribuem para especificações matemáticas da distribuição da variável aleatória de T , devido a presença de características similares. Kapur e Lamberson (1997) exemplificam essa evidência demonstrando, com o modelo de Weibull de três parâmetros, a relação entre a f.d.p e a $R(t)$, estimando a função de confiabilidade de Weibull a partir de

$$R(t) = \int_t^{\infty} f(t) dt = e^{-\left(\frac{t-t_0}{\eta}\right)^{\beta}}, \text{ para } \eta > 0, \beta > 0, t_0 \geq 0, t \geq t_0 \quad (3.3.1)$$

logo, com a estimativa obtida através da equação (3.2.2) partindo da função de densidade de probabilidade, agora, partindo da função de confiabilidade, é possível utilizarmos as últimas duas funções para obtermos a função de risco, como mostra a equação (3.2.1).

3.4. Parâmetros da função e tipos de falha (Falha de fabricação, aleatória e de desgaste)

Os parâmetros de cada função dada na distribuição de Weibull foram, inicialmente, apresentados e estudados de outra maneira. Hallinan (1993) aborda que Wallodi Weibull formulava a equação de distribuição com diferentes notações, considerada a fórmula original cujos símbolos seriam:

- σ que equivalente a variável t ,
- σ_u para o parâmetro de localização/deslocamento t_0 ,
- σ_0 para o parâmetro de escala η , e
- m para o parâmetro de forma β .

porém, atualmente estas notações da fórmula original da função de distribuição de Weibull abriram espaço para os parâmetros reconhecidos por t_0 , β e η .

O parâmetro de localização é uma unidade de medida de tempo, assim como t e T (indicando segundos, minutos, horas, etc), sendo comumente denominada por origem ou limite e associada ao tempo de garantia, em que a falha não pode ocorrer até que t exceda t_0 (MCCOOL, 2012). Esse parâmetro é definido por números reais $\mathbb{R}$, podendo assumir valores no intervalo $[-\infty, \infty]$. Entretanto, por ser implementada como suporte para aplicações da distribuição de Weibull, onde t normalmente não assume valores de duração negativos, seu

intervalo passa a ser caracterizado por $[0, \infty]$ (RINNE, 2008).

Para f.d.c de Weibull, o parâmetro de forma β determina o formato de distribuição: conforme seu valor aumenta, menos dispersão será encontrada (o inverso também acontece) (NELSON, 2004). Além disso, de acordo com o autor, quando $\beta = 1$ a distribuição de Weibull se torna a distribuição exponencial, confirmado também por McCool (2012). Nesse estágio a função denota falhas do tipo aleatórias, visto que sua estimativa obtém valores constantes independente da variação do tempo, operando apenas com os parâmetros de localização e de vida característica, ou apenas com o parâmetro η no caso do modelo ser de dois parâmetros.

Para a função de risco $h(t)$, similar aos fundamentos associados a curva da banheira, a distribuição da vida útil do ativo é representada inicialmente pelo intervalo $0 < \beta < 1$, onde a função indica falhas por “mortalidade infantil”, diminuindo continuamente ao longo do tempo (taxa de falha decrescente). Para $\beta = 1$, a função demonstra constância ao longo da variação do tempo, esse estágio é associado ao período de vida útil, onde as falhas são de natureza aleatória. Para $\beta > 1$, a função de risco aumenta continuamente, representando as falhas por desgaste (KAPUR; LAMBERSON, 1997).

Os três estágios da variação do parâmetro de forma na função de risco podem ser analisados na Figura 4, enquanto isso, para a função de densidade de probabilidade e para a função de distribuição acumulada, a Figura 2 e a Figura 3 ilustram ambas respectivamente. As três figuras utilizaram como base os valores fixos $\eta = 1$ e $t_0 = 0$, variando apenas os valores de β para (0.5), (1) e (10), correspondendo aos limites definidos para demonstrar as falhas precoces ($0 < 0.5 < 1$), aleatórias ($1 = 1$) e por desgaste ($10 > 1$). Analisando a Figura 2, quando os valores do parâmetro de forma são inferiores a 1, as falhas se concentram no começo da vida útil do componente. Se o parâmetro β for igual a 1, a função corresponderá a distribuição exponencial, onde as falhas se comportam de modo flat (taxa fixa) ao longo da vida útil do componente. A partir disso, a distribuição de falhas nesse estágio não demonstra concentração de falhas em um instante de tempo, mas uma tendência às falhas se comportarem de modo aleatório. E, quando há aumento do parâmetro β , sendo superior a 1, as falhas tendem a se concentrarem em um determinado instante, exprimindo um padrão de falhas ocasionados por desgaste ao longo do tempo.


Analisando o comportamento da função de distribuição acumulada f.d.c em relação ao parâmetro β na Figura 3, observa-se que quanto maior o parâmetro, mais a curva de distribuição de falhas mantém valores baixos. Isso permanece até a função encontrar um instante de tempo específico que concentra a maior parte das falhas e eleva a curva de $F(t)$. Com este

comportamento é possível identificar o padrão de falhas de forma mais eficiente para tomada de decisão, como, por exemplo, definir o intervalo de reposição ou tempo de garantia de produtos.

O parâmetro de escala η é também conhecido como vida característica, considerado um dos principais parâmetros presentes na distribuição de Weibull. Ele utiliza minutos, horas, dias, entre outras unidades de tempo, assim como a variável aleatória T . Ao ser mantido fixos os valores dos parâmetros β e t_0 , o parâmetro de escala proporciona às funções a distribuição para a direita no eixo do tempo e a diminuição na amplitude, desde que a área total sob a curva da função de densidade da probabilidade seja igual a unidade (KAPUR; LAMBERSON, 1997). Nelson (2004) acrescenta que, como a $\int_0^\infty f(t) dt = 1$ (100%), a vida característica determina o ponto no tempo em que cerca de aproximadamente 63.2% dos produtos já falharam, cujo o valor é atribuído à função de distribuição acumulada de falhas $F(t)$. Os 36.8% restantes representam a probabilidade de terem sobrevividos ou não apresentarem falha até esse ponto, ou melhor, essa fração representa a confiabilidade $R(t)$. Na Figura 3 o ponto no tempo que divide a f.d.p entre $F(t)$ e $R(t)$ é exposta graficamente.

A compreensão de referências a respeito do comportamento dos parâmetros β e η é essencial para auxiliar em análises de confiabilidade, especialmente no desenvolvimento de projetos voltados aos produtos de sistemas de produção, tornando-os eficientes e seguros. O parâmetro de forma propicia o entendimento do tipo de falha predominante durante a vida útil do ativo, ou melhor, é possível melhorar a previsão de falhas a partir de β . Enquanto isso, o parâmetro de escala contribui para o planejamento de reposição, pois permite identificar o tempo médio esperado até a falha a partir de sua estimativa. No estágio em que ocorre a maior parte das falhas, os valores elevados de η são importantes, pois apontam que há maior resistência do item ao longo da sua vida útil, sendo úteis para determinar o momento ideal para a realização de manutenções preventivas. Por fim, avaliar e aperfeiçoar tais parâmetros implica diretamente na melhoria da confiabilidade e da qualidade das estimativas, assim como no desempenho do processo de fabricação e no desenvolvimento dos projetos dos produtos.

Figura 2: Efeito da variação de β na função f.d.p.



Fonte: Elaborado pelo autor.

Figura 3: Efeito da variação de β na função f.d.c.





Figura 4: Efeito da variação de β na função de risco $h(t)$.



Fonte: Elaborado pelo autor.

3.5. Estimativa de parâmetros da distribuição de Weibull

A estimativa dos parâmetros presentes na distribuição de Weibull é um estágio fundamental para a aplicação eficiente do modelo na análise de confiabilidade. Como previamente discutido, os parâmetros – de forma β , de escala η e de localização t_0 – estabelecem o comportamento das funções reduzidas ao modelo de Weibull, como a função de confiabilidade $R(t)$, de densidade de probabilidade $f(t)$, de distribuição acumulada $F(t)$ e de risco $h(t)$. Essa influência afeta nas decisões vinculadas à manutenção e reposição de ativos. Para essa estimativa, dois métodos são comumente utilizados, sendo eles: regressão linear embasada no gráfico de probabilidade de Weibull e a aplicação da fórmula de Bernard (MCCOOL, 2012).

3.5.1 Estimativa por regressão linear

Uma das abordagens mais recorrentes para estimar os parâmetros da distribuição de Weibull é a aplicação da regressão linear. Esse método gráfico permite transformar a função de

confiabilidade $R(t)$ de Weibull em uma expressão linear, possibilitando ajustar os dados de falha ordenados a uma reta. Obtidos os dados transformados, o método de mínimos quadrados, aplicado para realizar os ajustes, determinará os coeficientes da equação linear.

A função de confiabilidade de Weibull de três parâmetros é representada por:

$$R(t) = e^{-\left(\frac{t-t_0}{\eta}\right)^\beta} = 1 - F(t) \quad (3.5.1)$$

Kapur e Lamberson (1997) abordam que, devido cada distribuição de probabilidade da f.d.c possuir eixos diferentes, a linearização ocorre ao calcular o logaritmo repetidamente de ambos os lados da equação. Os autores afirmam que manipular a distribuição de Weibull, presente na equação (3.5.1), resultará na representação do eixo das ordenadas através de $R(t)$, ou $1 - F(t)$, e o eixo das abscissas através do logarítmico do tempo até a falha, obtendo-se

$$\ln(R(t)) = \beta \ln\left(\frac{t-t_0}{\eta}\right) \quad (3.5.2)$$

$$\ln(-\ln(R(t))) = \beta \ln(t-t_0) - \beta \ln(\eta) \quad (3.5.3)$$

para

$$y = \ln(-\ln(R(t))), \quad (3.5.4)$$

$$x = \ln(t-t_0), \text{ e} \quad (3.5.5)$$

$$c = -\beta \ln(\eta) \quad (3.5.6)$$

Resultando na equação

$$y = \beta x + c \quad (3.5.7)$$

Em um determinado ensaio de amostra, o número de pontos de dados na amostra é definido por n , em que t_i ($i = 1, 2, \dots, n$) representa o tempo até a falha, cujo os valores de x e y são calculados como:

$$x_i = \ln(t_i - t_0) \text{ e } y_i = \ln(-\ln(R(t_i))).$$

O parâmetro β assume o papel de coeficiente angular, sendo responsável por determinar a inclinação da reta ajustada nos pontos (x_i, y_i) ($i = 1, 2, \dots, n$), presente na equação (3.5.7). Enquanto isso, η , apesar de não possuir a mesma caracterização do parâmetro de forma, é definido através da interceptação da reta com o eixo y e o valor de β , representado e conhecido respectivamente por “c” e intercepto (GUJARATI e PORTER, 2011).

Para realizar o ajuste da reta na regressão linear, é aplicado o método dos mínimos quadrados com objetivo de minimizar a distância vertical (analisando o eixo y) da soma dos quadrados entre os pontos (x_i, y_i) e os valores da reta ajustada $(x_i, \hat{y}_i)$. Montgomery (2020) representa essa relação através da equação da soma dos quadrados do erro de predição, *prediction error sum of squares* (PRESS). Segundo o autor, o valor previsto do erro de predição no ponto i é dado por $e_i = (y_i - \hat{y}_i)$, em que $\hat{y}_i$ é o valor esperado de y_i para um determinado valor de x_i . Nessa perspectiva, o erro de predição é também visto como desvio, é preciso considerar cada soma dos n desvios ao quadrado para estimar β e c (KUTNER, NACHTSHEIM, *et al.*, 2005), sendo, neste momento, a equação representada por D:

$$\sum_{i=1}^n D_i^2 = \sum_{i=1}^n (\beta x_i + c - \hat{y}_i)^2 \quad (3.5.8)$$

A equação (3.5.8) é descrita por Gujarati e Porter (2011, p. 79) como a função de regressão amostral (FRA), adotando o critério dos mínimos quadrados com o objetivo de fazer as diferenças entre os valores observados e estimados de y serem as menores possíveis. De acordo com os autores, é inviável escolher combinações de valores para β e c afim de encontrar o menor valor possível para o resíduo $(\sum_{i=1}^n D_i^2)$. Porém, através das equações normais a estimativa destes valores, para uma amostra de tamanho n , se apresenta como solução, formulada do seguinte modo:

$$\sum_{i=1}^n y_i = \beta \sum_{i=1}^n x_i + cn \quad (3.5.9)$$

$$\sum_{i=1}^n y_i x_i = \beta \sum_{i=1}^n x_i^2 + c \sum_{i=1}^n x_i \quad (3.5.10)$$

As equações (3.5.9) e (3.5.10), conhecidas por equações normais, tem como resultantes os parâmetros $\hat{\beta}$ e $\hat{c}$, conhecidos por estimadores pontuais (KUTNER, NACHTSHEIM, *et al.*, 2005) de β e c , respectivamente. A representação individual de cada estimador é

$$\hat{\beta} = \frac{\sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})]}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad e \quad \hat{c} = \bar{y} - \hat{\beta} \bar{x} = \frac{\sum_{i=1}^n y_i - \hat{\beta} \sum_{i=1}^n x_i}{n} \quad (3.5.11)$$

em que $\bar{x}$ e $\bar{y}$ denotam as médias amostrais de x e y e também definem os pontos $x_i = (x_i - \bar{x})$ e $y_i = (y_i - \bar{y})$, que representam o desvio em relação à média (GUJARATI e PORTER, 2011, p. 81). As médias amostrais servem como ponto de referência para a amostra e são obtidos a partir de

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (3.5.12)$$

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n}$$

Por meio da equação (3.5.11), obtendo-se $\hat{\beta}$ e $\hat{c}$, torna-se viável a aplicação dos estimadores na equação (3.5.6) afim de definir o parâmetro de escala η , agora, como um novo estimador pontual caracterizado por $\hat{\eta}$.

O coeficiente de determinação (r^2), é aplicado para medição da qualidade do ajuste da reta de regressão linear para os pontos $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$. Ou melhor, ela indica quão ajustada a linha de regressão amostral está em relação aos dados (GUJARATI e PORTER, 2011, p. 97).

A partir disso, r^2 expressa a redução da variação total de y relacionada ao uso da variável preditora x , logo, para o valor do coeficiente de determinação aumentar, a variação total de y é reduzida conforme a variável preditora x é inserida, enquanto que, para redução do coeficiente essa relação é inversamente proporcional (KUTNER, NACHTSHEIM, *et al.*, 2005). Sua formulação é descrita por Gujarati e Porter (2011, p. 97) como sendo a razão entre a variação dos valores estimados de y em torno da sua própria média ($\bar{\hat{y}} = \bar{y}$) e a variação total dos valores

observados de y em torno da média amostral:

$$r^2 = \frac{\sum_{i=1}^n \hat{y}_i^2}{\sum_{i=1}^n y_i^2} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.5.13)$$

segundo os autores, a equação (3.5.13) do coeficiente de determinação não possui valores negativos devido aos seus limites $0 \leq r^2 \leq 1$. Como mencionado anteriormente, essa medida indica o grau de eficácia do ajuste da reta da regressão linear, logo, quanto mais próximo de 1 o coeficiente estiver, menor será a o percentual de variação total de y . Para que essa métrica atinja o valor máximo, é preciso que, para cada ponto i , os valores observados sejam iguais aos valores estimados pelo ajuste da linha de regressão ($y_i = \hat{y}_i$). Enquanto que, no momento em que os valores estimados e os valores da média geral são iguais ($\hat{y}_i = \bar{y}$), será um sinal que o estimador pontual não apresenta inclinação ($\hat{\beta} = 0$). Ou seja, esta situação indica que o coeficiente de determinação atingiu o valor 0. Esse caso é demonstrado por meio das seguintes equações:

$$\hat{c} = \bar{y} - \hat{\beta} \bar{x} = \frac{\sum_{i=1}^n y_i - \hat{\beta} \sum_{i=1}^n x_i}{n} \quad (3.5.11)$$

$$\text{Linha ajustada } \hat{y}_i = x_i \hat{\beta} + \hat{c}$$

$$\hat{y}_i = x_i \hat{\beta} + (\bar{y} - \hat{\beta} \bar{x}) \quad (3.5.14)$$

$$\hat{y}_i = (x_i - \bar{x}) \hat{\beta} + \bar{y}$$

se considerarmos que não houve inclinação, conclusivamente, teremos como resultado


$$\hat{y}_i = \hat{c} = \bar{y} \quad (3.5.15)$$

considerando a equação das médias amostrais, presentes na equação (3.5.12), e aplicando na equação (3.5.15), será obtido o valor amostral dos valores estimados da linha de regressão linear, assim como Gujarati e Porter (2011, p. 82) demonstram:

$$\hat{y}_i = \bar{y} \quad (3.5.16)$$

Nesse contexto, quanto mais próximo os valores estimados $\hat{y}_i$ estiverem da média amostral $\bar{y}$, mais próximo o coeficiente de determinação estará de 0, indicando que o ajuste da reta não foi satisfatório. Com isso, na Figura 5 é possível analisar a demonstração de cada parâmetro utilizado na estimativa de r^2 , auxiliando na fundamentação do presente estudo.

Figura 5: Ajuste da linha da regressão linear



Fonte: Adaptado de Draper e Smith (1998).

A estimativa dos parâmetros da distribuição de Weibull, mediante a regressão linear e o método dos mínimos quadrados, não só garantem a realização da análise de confiabilidade de ativos não sujeitos à manutenção corretiva, mas também a estimativa do comportamento das falhas dos componentes em ensaios de amostras (sem censura – considera o tempo de falha de todos os itens – e sob estresse normal). Os parâmetros juntamente com os valores de *MTTF* possibilitam a tomada de decisões importantes como a estipulação de tempo de garantia. A possibilidade de linearizar a função de confiabilidade de Weibull permitiu a obtenção de parâmetros como β e η , considerados elementos cruciais para o entendimento do comportamento do padrão de falhas dos componentes.

Nesse aspecto, o papel fundamental que o coeficiente de determinação r^2 se destaca é o de qualificar a aptidão do ajuste da regressão linear. Ela válida a precisão do modelo aplicado, atuando como uma métrica que investiga a proporção da variabilidade dos dados observados

representada pela reta ajustada. Sendo assim, quanto mais próximo de 1 estiver o coeficiente, maior será a eficiência das estimativas dos parâmetros de Weibull, permitindo que o modelo represente precisamente o padrão de falhas com base nos dados reais.

3.5.2 Fórmula de Bernard para classificação de *rank* mediano

Para análise de confiabilidade, a obtenção dos parâmetros da distribuição de Weibull e o desenvolvimento do gráfico de probabilidade partem da determinação dos dados do tempo até a falha (presentes no eixo das abscissas x) associados a não confiabilidade – função de distribuição acumulada de falhas (f.d.c). Esse procedimento, essencial para determinar a probabilidade acumulada, é realizado por meio da classificação dos *ranks* ou, como Nelson (2004, tradução nossa) menciona, posição de plotagem, os quais apresentam uma representação aproximada da mediana da f.d.c associada a cada elemento da amostra. A posição de plotagem consiste na classificação dos tempos de falha em ordem crescente, ou seja, para n tempos de falha, a distribuição de *ranks* é feito por: a primeira falha (*rank* 1), a segunda primeira falha (*rank* 2), e assim por diante (MCCOOL, 2012). Devido cada classificação ser uma posição estatística do dado dentro da amostra, sua função é estabelecida como base para o cálculo de $F(t)$ relacionada à falha.

A representação do tempo até a falha foi caracterizada anteriormente por tempo contínuo, cuja representação dada foi t . Nesse caso, para cada valor individual medido será demonstrado t_i e $F(t_i)$, em que t_i é obtido através da classificação dos *ranks* para um total de n dados, partindo do valor mínimo ($i = 1$) ao valor máximo ($i = n$) (MENČÍK, 2016).

McCool (2012) aborda que a classificação dos *ranks* varia de amostra para amostra, logo, são caracterizados como variáveis aleatórias. A partir disso, o autor menciona que, se for considerado um *rank* i e associá-lo aos valores do tempo até falha (t_i) para uma amostra de tamanho n , o cálculo da distribuição da f.d.c passa a variar de amostra para amostra $F(t_i)$ também. Por meio dessa variação encontra-se a distribuição de beta. Zhang (2008) complementa que essa distribuição é encontrada ao ser analisado a f.d.c como uniformemente distribuída entre 0 e 1. Estimada por meio dos parâmetros i e $n - i + 1$, a distribuição de beta é utilizada em diferentes referências para obter a média e a mediana das posições de plotagem no eixo das ordenadas y .

A equação da média da posição de plotagem é descrita por Nelson (2004, p. 116) como posição de plotagem esperada, utilizada para obter o valor para a i -ésima falha, sendo

expressa por m_i como

$$m_i = \frac{i}{n+1} \quad (3.5.17)$$

Zhang (2008, p. 32) argumenta que a equação (3.5.17), na teoria, indica a posição exata da plotagem do *rank* médio de cada ponto dos dados.

Para a classificação de *rank* mediano para i -ésima falha, será representada por M_i . Kapur e Lamberson (1997, p. 78) apresentam a equação da seguinte maneira

$$\sum_{h=i}^n \frac{n!}{h! (n-h)!} (1 - M_i)^{n-h} M_i^h = 0.5 \quad (3.5.18)$$

de acordo com McCool (2012), a mediana dos valores de $F(t_i)$ é a classificação de *rank* mediano, conseqüentemente, a média dos valores de $F(t_i)$ classifica o *rank* médio. Para a mediana dos *ranks*, a função de distribuição acumulada de falhas até certo tempo t_i pode ser encontrada utilizando a mediana da distribuição de beta.

Os pontos percentuais da distribuição de beta são utilizados em gráficos de probabilidade e são conhecidos por *ranks* de 5% e 95% (MCCOOL, 2012). Para os valores da mediana dos *ranks*, as estimativas serão representadas por $X(0.50, i, n - i + 1)$, em que 0.50 representa a mediana, enquanto que i e $n - i + 1$ continuam sendo os parâmetros da distribuição de beta, como anteriormente mencionado, utilizados para definir os intervalos ou limites de confiança aproximados.

Como resultado, em diferentes referências encontra-se a posição de plotagem do *rank* mediano definida como fórmula de Bernard. Zhang (2008) e McCool (2012) consideram a *rank* mediano ideal para posições de plotagem para estimativa gráfica de parâmetros de Weibull, cujas aproximações propostas para a classificação do *rank* mediano por Bernard e Bosi-Levenbach (1953) levaram a caracterização do estimador de Bernard:

$$M_i = X(0.50, i, n - i + 1) = \frac{i - 0.3}{n + 0.4} \quad (3.5.19)$$

Utilizar a classificação de *rank* mediano em conjunto com a fórmula de Bernard, apesar de sua aparência simples, se apresenta como uma ferramenta eficaz. A equação (3.5.19) não

apenas permite a obtenção aproximada da estimativa da probabilidade de falha acumulada $F(t_i)$ associada ao momento da falha da i -ésima falha da equação (3.5.18), como também se apresenta como substituta (KAPUR; LAMBERSON, 1997).

Para a aplicação do software Weibull Predictor STM, a fórmula de Bernard possibilita a ordenação dos tempos de falha para uma f.d.c distribuída uniformemente entre 0 e 1. Esse método é essencial para a estimativa da probabilidade acumulada. Uma vez linearizados os valores de t_i por meio da classificação de *ranks*, são fornecidos recursos suficientes para estimar os parâmetros da distribuição de Weibull. Com isso, o estimador de Bernard auxilia o funcionamento do software na previsão de falhas de ativos não sujeitos à manutenção corretiva, realizando os objetivos de otimização de custos presentes no estudo em questão.

4. INFORMAÇÕES IMPORTANTES E DECISÕES A SEREM TOMADAS

Com base na apresentação e compreensão dos conceitos fundamentais de confiabilidade e da aplicação da distribuição de Weibull na investigação estatística de falhas, o software Weibull Predictor STM integra à lógica computacional o referencial teórico durante o seu desenvolvimento. Projetado com a funcionalidade de automatizar o processamento de dados oriundos de históricos de falhas em planilhas Excel, o STM efetua cálculos que contribuem para a gestão de manutenção preventiva de ativos. Permitindo o processamento de estimativas e análises de variáveis essenciais como a confiabilidade, o tempo médio até a falha e o tempo ótimo, que se correlaciona ao custo mínimo de reposição.

4.1. Coeficiente de determinação da estimação dos parâmetros de Weibull

A aplicação da regressão linear realiza o ajuste da distribuição de Weibull aos dados coletados do histórico de falhas, enquanto que o coeficiente de determinação identifica a qualidade desse método gráfico. O coeficiente r^2 é calculado por dois métodos:

Manualmente, aplicando a equação, que também é demonstrada por Zhang (2008, p. 130), como

$$r^2 = 1 - \frac{\sum_{i=1}^n D_i^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.1.1)$$

em que $y_i = \ln[-\ln(1 - F(t_i))]$ e $\hat{y}_i = \hat{\beta}x_i + \hat{c}$. O autor ainda complementa – assim como de maneira automática é manifestado após utilizar o comando (`'stats.linregress'`) no código do aplicativo – que é possível encontrar o coeficiente de correlação r , na qual é relacionado ao coeficiente de determinação. Ou melhor, r^2 é estimado após o comando computacional encontrar o coeficiente de correlação r entre os valores observados y_i e estimados $\hat{y}_i$ elevando-o ao quadrado

$$r = \pm\sqrt{r^2} \quad (4.1.2)$$

logo, o coeficiente r da equação (4.1.2) leva à conclusão que o coeficiente de determinação é $r^2 = r^2$ (GUJARATI e PORTER, 2011, p. 98).

Essa métrica representa a proporção da variabilidade dos dados observados. Se o coeficiente se aproximar de 1, a linha de regressão linear ajustada estará fiel ao comportamento das falhas observadas. Mas, caso os valores do coeficiente sejam baixos, será uma representação da dispersão bem como da inadequação do modelo de Weibull para os dados observados.

4.2. Confiabilidade instantânea do componente

A confiabilidade instantânea $R(t)$ corresponde a probabilidade de sobrevivência do componente operar sem falhas até o instante de tempo t . Fundamentada na seção 3.3, seu referencial teórico é aplicado no cálculo computacional do software STM por meio da função de confiabilidade de Weibull de três parâmetros:

$$R(t) = \begin{cases} 1, & t \leq t_0 \\ e^{-\left(\frac{t-t_0}{\eta}\right)^\beta}, & t > t_0 \end{cases} \quad (4.2.1)$$

O parâmetro de localização t_0 , que corresponde ao período de garantia, representa o tempo mínimo de vida do componente. Logo, a probabilidade de falha de um componente dentro desse período é considerada nula (0%). Em conformidade com o que foi abordado na seção 3.4, seu intervalo é definido por $[0, \infty]$. No entanto, é importante indicar que, quando t_0 assume 0, o cálculo do tempo até a falha dos dados pode apresentar problemas.

Analizando o cálculo do eixo das abscissas x , quando $t_0 = 0$,

$$x_i = \ln(t_i - t_0) \quad (4.2.2)$$

quando os valores do tempo até a falha t_i se aproximarem de 0 ($t_i \approx 0$), a função do logaritmo encontrará valores numéricos instáveis, prejudicando a aplicação do Weibull Predictor STM. Além disso, se o tempo até a falha t_i for 0 ($t_i = 0$), a função logarítmica $\ln(0)$ representará uma indefinição. Ou seja, dados próximos de zero ocasionam instabilidade e distorções significativas nos resultados, tanto para a linearização da função quanto para a estimativa dos parâmetros de escala e de forma da distribuição de Weibull.

Se analisarmos este conceito para a equação (4.2.1) em uma situação em que o componente não está no período de vida ativa, o tempo até a falha se apresentará menor que o parâmetro de localização ($t \leq t_0$). Como solução para a realização dos cálculos no software, considerou-se no STM o ajuste do menor tempo de falha para um valor mínimo de 1%. A partir disso, evita-se que funções como a de confiabilidade apresentem imprecisão. Essa abordagem garante que os parâmetros β e η , estimados pela regressão linear, não resultem em indefinições numéricas nos cálculos dos pontos dos eixos das abscissas e das ordenadas, representadas respectivamente por $x_i = \ln(t_i - t_0)$ e $y_i = \ln(-\ln(R(t_i)))$.

Contudo, nas situações em que o ativo se encontra no período de vida ativa, a confiabilidade instantânea é um parâmetro importante. Além do parâmetro de localização, a função de confiabilidade precisa dos parâmetros de forma β e de escala η , estimados através do histórico de reposição do componente. Enquanto isso, o tempo contínuo até a falha t irá se comportar como variável dependente, correspondendo ao tempo total em operação que o equipamento apresenta.

O usuário registrará manualmente as “horas trabalhadas”, atualizando-as diariamente – o valor de horas corresponde ao tempo t na função $R(t)$. A partir do momento em que o período de vida ativa é iniciado, tem como objetivo evidenciar a confiabilidade no instante de tempo que corresponde ao total de horas acumuladas, ou melhor, ao tempo em que o equipamento continua em operação. Dessa maneira, a determinação da confiabilidade instantânea permite estimar, em qualquer instante de tempo, a probabilidade de sobrevivência do ativo com base no tempo acumulado em atividade e em seu histórico de reposição. Essa concepção é fundamental para que o Weibull Predictor STM forneça análises de confiabilidade com maior precisão e oriente a gestão de ativos não sujeitos à manutenção corretiva.

4.3. Estimativa de *MTTF* do componente

O tempo médio esperado até a falha (*MTTF – Mean Time To Failure*), definido como a esperança matemática de que um componente não reparável sobreviva até sua primeira falha, é um elemento essencial dentre as métricas da confiabilidade. Na aplicação do Weibull Predictor STM, estimativa de *MTTF* é obtida através dos parâmetros da distribuição de Weibull. A relação entre os parâmetros de Weibull e a formulação matemática do tempo médio até a falha será implementado, de acordo com a seção 3.2, do seguinte modo:

$$MTTF = t_0 + \eta \cdot \Gamma\left(1 + \frac{1}{\beta}\right) \quad (4.3.1)$$

A estimativa da função *MTTF* utilizando a equação (4.3.1) contribui para a gestão da reposição preventiva, reduzindo o risco de interrupções não planejadas no sistema de produção e minimizando os impactos na segurança dos operadores. No software STM, a métrica *MTTF* informa ao usuário quão próxima a falha está do equipamento, permitindo o acompanhamento do ciclo de vida ativo do componente e a avaliação da sua probabilidade de sobrevivência por meio da confiabilidade instantânea.

Quando aplicada para ativos de baixo custo unitário, cujo contexto apresenta a reposição preventiva como preferência no lugar da manutenção corretiva, esse indicador torna-se mais relevante. Assim sendo, o aplicativo Weibull Predictor STM contribui para que o usuário alinhe suas estratégias de manutenção de acordo com o ciclo de vida de seus equipamentos, favorecendo a realização da reposição no momento ideal.

Consequentemente, a métrica *MTTF* contribui para que gestores adequem o momento certo para reposição, evitando tanto substituições prematuras, que elevam os custos desnecessários, quanto falhas inesperadas, que resultam em interrupções indesejadas nos processos de produção.

4.4. Período de reposição do componente correspondendo ao custo mínimo

O equilíbrio entre o custo de reposição preventiva e o custo proveniente da falha corretiva (não programada) é uma das estratégias mais importantes da manutenção preventiva. Conforme a discussão teórica e a apresentação do modelo de reposição por idade (ARM) realizados na seção (2.1.11), o ponto de equilíbrio indica o intervalo de reposição ideal (*optimal*

replacement interval) (JIN; YAMAMOTO, 2017), que será definido como tempo ótimo de reposição. Esse elemento é adquirido por meio do estudo sobre o custo médio de manutenção por unidade de tempo. Trata-se de um intervalo de reposição que minimiza o custo total de manutenção, melhorando as estratégias de manutenção preventiva para ativos sob diferentes condições de operação.

De maneira prática, o custo médio de manutenção será dividido entre o custo de reposição (CR), em que ocorre a reposição antes da falha, e o custo da parada não programada (CPNP), que envolve a reposição, atuando como solução para a interrupção do equipamento, e o impacto da falha inesperada.

Algumas referências, como a dos autores Sheu, Kuo e Nakagawa (1993), denotam que a expressão clássica da política de reposição por idade, proposta por Barlow e Hunter (1960), apresenta-se na equação (4.4.3):

$$\overline{CPNP} = \frac{\sum_{i=1}^n CPNP_i}{n} \quad (4.4.1)$$

$$\overline{CR} = \frac{\sum_{i=1}^n CR_i}{n} \quad (4.4.2)$$

$$C(T) = \frac{\overline{CR} \cdot R(T) + (\overline{CPNP} + \overline{CR}) \cdot F(T)}{\int_0^T R(t)dt} \quad (4.4.3)$$

os valores de $\overline{CPNP}$ e $\overline{CR}$ se comportam como médias amostrais dos custos de parada não programada e de reposição para cada ponto dos dados da amostra, representadas respectivamente por $CPNP_i$ e CR_i . Enquanto que, $\int_0^T R(t)dt$ é descrita por Jin e Yamamoto (2017, p. 120) como a média do tempo para um ciclo de reposição.

De acordo com Ahmad *et al.* (2011), a principal função do modelo na equação (4.4.3) é a determinação do tempo ótimo de reposição T , encontrado por meio da minimização da taxa de custo total da função $C(T)$. Logo, quando a taxa de custo total atingir o custo por unidade de tempo mínimo, será também definido o tempo ótimo de reposição T , assegurando que a manutenção preventiva ocorra no instante de tempo ideal.

No Weibull Predictor STM, a metodologia argumentada é implementada com o objetivo de fornecer ao usuário o instante de tempo de reposição mais econômico, considerando o

histórico de falhas do ativo e os custos médios relacionados tanto à reposição preventiva quanto à falha não programada. Com isso, o aplicativo auxilia na gestão da manutenção orientando-se por históricos de reposição, cuja finalidade é reduzir os custos e prevenir falhas indesejadas e imprevisíveis, evitando o comprometimento da disponibilidade operacional dos ativos.

5. ESTRUTURA DO SOFTWARE

5.1. Apresentação geral

Após compreender as decisões importantes pertinentes para o aplicativo STM e para a aplicação das funções (do coeficiente de determinação, de confiabilidade, de MTTF, da taxa do custo total do equipamento) debatidas na seção 4, será iniciado a explicação da estrutura do software. Nesta seção, apresenta-se os componentes considerados essenciais para o desenvolvimento do Weibull Predictor STM, produzido como parte prática deste estudo. A estrutura deste trabalho, que se apresenta como um conjunto de fundamentos teóricos e de métricas estatísticas, permite descrever a organização interna do sistema, técnicas manuseadas e módulos que compõe as funções do STM.

5.2. Ferramentas utilizadas

O Weibull Predictor STM, além de aderir a técnicas de prototipagem rápida, tem como princípio exercer suas funções por meio de um modelo simples, prático e intuitivo. A escolha das ferramentas e das bibliotecas utilizadas para sua construção foi realizada com base em critérios específicos:

- Python: esta linguagem de programação se encaixa nos adjetivos que o software STM possui e proporciona para seus usuários, sendo também considerada simples e clara (MENEZES, 2010). Além de ser amplamente utilizada pela comunidade científica, Python comporta um grande número de bibliotecas voltadas para manipulação de dados, permitindo que o STM execute sua interface gráfica (GUI) e seja hábil na realização dos cálculos estatísticos.
- Tkinter: é uma das bibliotecas existentes no Python para a criação da interface gráfica. Escolhida para ser introduzida no software STM e, além de demonstrar fácil desenvolvimento, é considerada ideal para aplicação de pequenos aplicativos de *desktop*

(CHAUDHARY, 2013), que é o caso deste trabalho.

- `ttkbootstrap`: para detalhes técnicos e visuais, essa biblioteca do Tkinter atribui temas que facilitam o desenvolvimento de práticas intuitivas para a interface. As divisões do conteúdo por cores permitem uma padronização, auxiliando os usuários a seguirem comandos e a identificarem respostas com mais clareza.
- `Openpyxl`: para que haja compatibilidade entre multiplataforma, essa biblioteca contribui para que o software Weibull Predictor STM leia e sobrescreva arquivos Excel (.xlsx), facilitando a importação de históricos de reposição previamente registrados em planilhas.
- `Módulo calculos.py`: com intuito de melhorar a organização, este módulo dedica-se a realizar os cálculos estatísticos, atribuindo todas as funções presentes na seção 4. A sua criação ajuda na diferenciação do conteúdo computacional, permitindo a leitura e ajustes de modo rápido e prático.

Utilizar essas ferramentas permite que o aplicativo STM se aproxime dos objetivos deste trabalho, contribuindo para que esta aplicação prática se apresente como solução de fácil acesso e compreensão, sendo destinada a empresas de pequeno porte ou profissionais autônomos. Esses fatores também ajudam os usuários a se adaptarem e a se familiarizarem com o STM, mesmo que não haja conhecimento prévio de programação.


5.3. Visão geral da arquitetura do sistema

Esta seção será dedicada a contribuir para a compreensão da estrutura do software, fundamentando as principais camadas que a compõe. Além do intuito de esclarecer as diferenças entre interface gráfica, lógica computacional dos custos, armazenamento das estimativas e controle do fluxo dos dados, esta organização auxilia na manutenção e na implementação clara do código.

Interface gráfica (GUI): Com intuito de proporcionar ao usuário interações diretas com os dados que lhe são relevantes, este item possibilita incluir campos de entrada para informações (como a seleção de planilhas, horas trabalhadas e datas), bem como botões de execução (para gerar estimativas, adicionar informações de falha e reposição, modificar o Excel e reverter ações). Materializando a visualização da GUI, a Figura 6 demonstra a estrutura do Weibull Predictor STM: a primeira aba (*Dados*) será onde o histórico de reposição será analisado; a segunda aba (*Reposição*), indicará os parâmetros estatísticos do ativo e a terceira aba

(Manutenção Preventiva), servirá como proposta de solução futura para o presente estudo. A imagem estará ampliada no Apêndice A para melhor identificação dos itens.


Figura 6: Interface gráfica do Weibull Predictor STM.



Fonte: Elaborado pelo autor.

Camada de acesso a dados: com o openpyxl, o software STM permite que os usuários importem e exportem informações de planilhas Excel. Essa biblioteca será responsável por possibilitar que o software acesse uma estrutura de planilha preestabelecida, com objetivo de servir como guia para organização dos dados de reposição preventiva. A Figura 7 é uma exemplificação de como é feito o tratamento dos dados, onde cada coluna presente será analisada pelo software de modo estratégico, incluindo o nome do ativo do histórico de reposição a que se dedica.


Figura 7: Estrutura de planilha para histórico de reposição.



Fonte: Elaborado pelo autor.

Camada de aplicação para estimativas: após a introdução dos dados na interface, o aplicativo Weibull Predictor STM poderá realizar as estimativas com base no histórico de reposição preventiva do ativo. Com a importação do histórico executada pelo aplicativo STM, o usuário poderá definir o dia em que ocorre a análise da confiabilidade do ativo (apesar que o software realiza esta função automaticamente). E, após isto, uma das condições impostas ao usuário, para que seja gerado as estimativas, é que ele informe a quantidade de horas trabalhadas que o equipamento acumula no dia em que é feita a análise. Estes três pontos específicos encontram-se contornados na Figura 8 e podem ser analisados com maior legibilidade no Apêndice A. Essa informação irá garantir a obtenção da confiabilidade instantânea $R(t)$, enquanto que o tempo médio esperado até a falha ($MTTF$), o tempo ótimo de reposição e o custo mínimo serão definidos por meio dos dados registrados na planilha.


Figura 8: Campos de entrada de informações do STM.



Fonte: Elaborado pelo autor.

Controle de fluxo: é o que permite a comunicação entre os módulos, principal e de cálculo, definindo uma lógica, uma sequência de operações, como a condição exemplificada na camada de aplicação. A partir disso, torna-se realizável o gerenciamento de eventos (salvar ou apagar alterações, confirmar se o usuário pressionou o botão), validação de dados (verificação e correção de pontuação e confirmação de valores numéricos para horas trabalhadas, confirmação da escolha de planilha, realização de condições obrigatórias) e processamento de dados para estimativas dos cálculos. Para este último, existe o botão dedicado para esta função, chamado *Gerar estimativas*, em que, após preencher e escolher corretamente os dados para os campos de entrada destacados na Figura 8, os cálculos irão ser apresentados na aba de *Reposição*, como mostra a Figura 9. O usuário poderá acessar diferentes abas mesmo sem realizar os pré-requisitos, ou seja, é possível realizar análises de diferentes planilhas antes de qualquer cálculo. Sendo assim, se não houve escolha do histórico, assim como não ocorreu a inserção de horas trabalhadas, a Figura 9 demonstra que a aba aparecerá sem estimativas.

Figura 9: Aba "Reposição"; exibição das estimativas.



Fonte: Elaborado pelo autor.

5.4. Detalhamento da estrutura dos módulos

Durante o desenvolvimento do código algumas classes e módulos apresentaram demandas essenciais para a aplicação do software, a partir disso, detalha-se nesta seção como ocorre a estruturação interna do código.

Classe App: esta classe é a principal do software, organizando a localização de cada botão e de cada campo de entrada, ela também ordena as abas da interface gráfica, separando-a em três: Dados, Reposição e Manutenção Preventiva. Dentro da classe App encontra-se outros pontos cruciais do programa, como o armazenamento temporário dos dados enquanto o aplicativo estiver em aberto, respostas com elementos gráficos e gerenciamento das estimativas. Algumas das funções que compõe essa classe, são:


- `carregar_arquivo_excel`: esta função se responsabiliza por importar o arquivo Excel e apresentar os dados principais na interface (com exceção das “Horas Trabalhadas”), porém, para isso, ela realiza uma normalização de datas e dados e gerencia múltiplas planilhas, caso o arquivo possua.
- `atualizar_horas_trabalhadas` e `horas_trabalhadas_no_excel`: ambas organizam os valores atribuídos a horas trabalhadas. O primeiro atualiza o display de horas na interface com base no histórico de reposição do Excel carregado (localiza a coluna “Horas Trabalhadas” no Excel e atualiza o display conforme o usuário escolhe a

planilha para o respectivo ativo que deseja analisar). O segundo entra para o tópico de camada de aplicação, em que recebe um novo valor, inserido pelo usuário no campo de entrada de horas trabalhadas, soma com o valor existente no Excel e atualiza o display após pressionar o botão de confirmação (o estado do botão tornasse bloqueado automaticamente após a confirmação para evitar sobreposição de dados; para escolher um novo valor, o usuário precisará apagar a alteração pressionando o botão Apagar alterações).

- `gerar_estimativas`: responsável por chamar o módulo `calculos` e exibir as estimativas baseando-se no histórico de reposição e no valor de horas trabalhadas, que a planilha verificada do ativo acumula, somado com o valor inserido pelo usuário. Esta função também implementa gráficos de medidor para auxiliar o usuário a verificar a seriedade do estado do equipamento com base na confiabilidade e no tempo esperado até a falha.

Classe `BalaoTutorial`: uma das características mais importantes do software está nesta classe, apresentando mensagens introdutórias para os usuários sobre cada botão, campo de entrada, abas, explicando cada métrica e resultados. A Classe `BalaoTutorial` é destinada a criar balões flutuantes (*tooltips*) com objetivo de instruir sobre o uso do aplicativo, permitindo que o próprio software STM sirva como manual. A Figura 10 demonstra um exemplo de balão que auxilia na compreensão das abas e na navegação entre elas.

Figura 10: Balões (tooltips) na interface.



Fonte: Elaborado pelo autor.

Módulo `calculos`: com intuito de melhorar a identificação dos itens na parte interna do software, este módulo tornou-se o centro da aplicação das funções estatísticas fundamentadas na seção 2 e 3. Após o usuário realizar os pré-requisitos para gerar estimativas e pressionar o botão `Gerar estimativas`, o módulo irá receber os dados de entrada (`histórico de reposição` e `horas trabalhadas atualizadas pelo usuário`), realizará análises sobre as `Data falha` do componente, assim como sobre as `Horas até o evento` de cada falha, e obterá os custos médios (`Custo da Parada Não Programada` e `Custo da Reposição`). Com isto, é feito o processamento dos dados para aplicação da Classificação dos *ranks* (apresentando as posições de plotagem dos tempos até a falha em ordem crescente), definição do estimador de Bernard para as funções logarítmicas e execução da regressão linear. Como resultado, obtém-se os parâmetros da distribuição de Weibull, por meio da reta ajustada da regressão linear, e as métricas classificadas como indicadores de performance (tempo ótimo, custo mínimo, *MTTF* e r^2).

O software Weibull Predictor STM está programado para realizar a leitura das colunas, como demonstra a Figura 7, e, para que ocorra a integração com as planilhas Excel, para validar os dados para formatos específicos de pontuação numérica, `(.)` no lugar de `(,)`, e para normalizar o estilo de data, em `(dia/mês/ano)`. Além disso, o software está preparado para lidar com dados ausentes e erros de formatação, informando o usuário com avisos (*pop-ups*), seja para alertar ou para informar problemas.

6. APLICAÇÃO EM ESTUDOS DE CASOS

Com intuito de verificar a aplicação do software Weibull Predictor STM, esta seção dedica-se a apresentar os estudos de caso elaborados por meio de dois históricos de reposição preventiva gerados por Inteligência Artificial (IA), sendo eles: capacitores de barramento CC e lâmpadas LED industriais. O objetivo é estimar a previsão de falhas com elementos o mais próximo possível da realidade, apesar da restrição de dados de empresas pertinentes aos registros de manutenção de seus ativos e da ausência de informações em artigos e repositórios para compor, suficientemente, as colunas da planilha Excel, como o exemplo da Figura 7.

Logo, para fundamentar a aplicação de cada estudo de caso, considerou-se análises técnicas com intuito de reproduzir ambientes industriais, cujo objetivo seria o de classificar dados como horas de operação, custo de reposição e condições de uso. Com exceção do último, esses elementos foram preestabelecidos como essenciais ao software STM para a realização das

equações demonstradas na seção 2, 3 e 4, que estimam parâmetros estatísticos e de desempenho e auxiliam na economia da reposição.

Um dos motivos da utilização da IA para a criação de históricos de reposição foi o difícil acesso a informações de manutenção de equipamentos de pequenas e médias empresas. Habitualmente mantém-se sigilo devido a presença da competitividade entre elas, ocasionando na impossibilidade de utilizar dados de aplicações reais neste estudo. Outra vertente que se mostra viável é a utilização de artigos científicos e repositórios, contudo, a literatura técnica presente nestas fontes mostrou-se insuficientes para preencher as colunas do modelo de planilha que é requerido pelo STM.

A partir disso, a aplicação em estudos de caso será realizada com informações suficientemente próximas da realidade, cuja intenção será demonstrar o funcionamento do software e seu potencial em contribuir na previsão de falhas, na otimização de custos de reposição e na organização de registros de histórico de manutenção.

6.1. Caso: Capacitores de barramento CC

O primeiro exemplo de ativo não sujeito à manutenção corretiva é o capacitor de barramento CC, comumente empregado em carregadores de bateria, acionamentos de motores e inversores de frequência de energia renovável (VISHAY, 2023). Dos mais variados ambientes que esses componentes são inseridos, quando se trata do ambiente industrial, é preciso se atentar para as diferentes circunstâncias que os conduzem à falha. Como por exemplo, no setor industrial os capacitores estarão sujeitos a variações térmicas, vibração mecânica e picos de tensão provocados por chaveamento e distúrbio na rede, que aceleram o processo de desgaste e elevam a probabilidade de falhas prematuras.

De acordo com o catálogo do fabricante Vishay (2023), a vida útil estimada dos capacitores de barramento CC é de 110.000 horas, em condições otimistas e ideais de operação. A partir disso, essa informação serve como base teórica para realizar a simulação no software STM, sendo possível considerar, para fins de aprendizado, que o ativo opere continuamente durante 24 horas por dia com um tempo de vida útil entre 20.000 e 40.000 horas (cerca de 2 a 5 anos de operação). Essa decisão foi tomada com propósito de apresentar uma interpretação mais próxima da realidade, considerando que o componente opere sob diferentes condições de operação no ambiente industrial, tendendo a diminuir a vida útil do ativo.

Para os custos de parada não programada (CPNP), a inteligência artificial considerou

que, se houve interrupção em um processo de produção que opera continuamente, o custo de parada será de 4.700 a 5.000 reais por evento, refletindo o impacto operacional ocasionado pela falha do ativo. Enquanto isso, o valor atribuído ao custo de reposição (CR) programada será de 500 reais por evento. O catálogo tem como base capacitores DC-Link, na qual os dados retirados são relativos a VSI com potência de aproximadamente de 2000 W(Watts), permitindo aplicações para sistemas de baixa potência e acessibilidade para empresas de pequeno porte.

A determinação das características é importante para operação e definição dos custos no histórico, sendo encontrado, dentro do catálogo da Vishay, o capacitor de barramento CC MKP1848C71050JY5. Sua tensão nominal e capacitância são, respectivamente, 100 μ F (microFarad) e 500 V (Volts), apresentando um custo unitário de aproximadamente de 43 dólares (ROEDERSTEIN), que, considerando os impostos e o frete, este ativo pode chegar a ter um custo de reposição superior a 500 reais.

A adaptação dos dados utilizados tem como objetivo expressar a tentativa de encontrar o equilíbrio entre a referência técnica e a ocorrência de possíveis falhas durante a prática de uso, para que a aplicação deste estudo de caso seja uma referência aos usuários do Weibull Predictor STM.

Sendo assim, realizemos a aplicação do seguinte modo:

- 1º estágio: organização dos dados, fornecidos pela inteligência artificial, dentro da planilha Excel para representar o histórico de reposição preventiva do capacitor de barramento CC, como mostra a Figura 11.

Figura 11: Histórico de reposição preventiva do capacitor de barramento CC.

Capacitor de barramento CC					
Data falha	Data Reposição Programada	Horas até o evento	Custo da Parada Não Programada	Custo da Reposição	Horas Trabalhadas
	01/01/2020	0	0	0	0
	15/11/2021	16416	0	500	
20/10/2022		8136	4700	500	
	10/03/2023	3384	0	500	
05/09/2023		4296	4800	500	
	25/01/2024	3048	0	500	
15/06/2024		3048	4900	500	
	10/11/2024	3552	0	500	
05/04/2025		3504	5000	500	

Fonte: Elaborado pelo autor.


As datas de cada evento foram organizadas para que a coluna “Horas até o evento” represente a diferença de tempo entre elas. No Excel, a diferença entre a data final e a data inicial tem como resultado o total de dias, multiplicando por 24 horas (tempo em operação do capacitor) é possível estimar a quantidade de horas que o evento possui. Organizando esses

valores, cada evento obtém uma representação em horas, seja por falha ou reposição, indicando que o ativo até aquele momento acumulou um certo total de horas até o evento.

Com a reposição preventiva realizada, a contagem do ativo reinicia, assim também quando ocorre a falha do componente. Por fim, o histórico de reposição preventiva do capacitor de barramento CC, presente na Figura 11, é montado, dando início ao próximo estágio onde a planilha Excel será utilizada pelo software STM.

- 2º estágio: Apresentar os dados do histórico de reposição na interface do aplicativo Weibull Predictor STM. O usuário deverá acessar o histórico após pressionar o botão “Carregar arquivo Excel”, como mostra a Figura 12, procurando pelo nome do arquivo que corresponde a planilha com os dados de reposição preventiva do ativo não sujeito à manutenção corretiva.

Figura 12: Carregamento do arquivo (.xlsx) do histórico de reposição.



Fonte: Elaborado pelo autor.

Na Figura 13 é encontrado a planilha Excel introduzida na interface do software STM, sendo a única coluna não visível a “Horas trabalhadas”. Como há um *display* dedicado para exibir e atualizá-las no Excel diretamente pelo aplicativo, fez-se necessário a retirada da coluna horas trabalhadas para evitar excesso e/ou redundância de informações. A imagem da Figura 13 pode ser encontrada no Apêndice A ampliada para melhorar a análise das informações. Além disso, o campo de entrada para a data encontra-se atualizado no momento em que o aplicativo é acessado, podendo ser alterado digitando no teclado ou acessando o ícone em amarelo que simboliza um calendário, como mostra a Figura 14.


Figura 13: Exibição dos dados de reposição preventiva do capacitor de barramento CC no Weibull Predictor STM.



- 3º estágio: Feito o acesso do histórico de reposição preventiva na interface do aplicativo STM com sucesso, o usuário necessitará inserir a quantidade de horas que o equipamento acumula. Essa informação é importante tanto para gerar as estimativas quanto para informar novos eventos, seja uma data de uma nova falha ou para registrar uma nova data de reposição programada. Os valores para o campo de horas trabalhadas

não podem ser negativos, na verdade, os valores que estarão permitidos no software devem respeitar o intervalo $[0, \infty]$. Números negativos serão bloqueados, assim como símbolos diferentes de (.) e (,). O uso de ponto e vírgula permite que o usuário tenha mais liberdade para escolher o símbolo que separa as casas decimais, sendo permitido até duas casas decimais (ou centésimos) no campo de entrada de horas trabalhadas. Para fins de simulação, será utilizado a data atual do teste prático (20/07/2025), cuja diferença com a última data do histórico (05/04/2025) multiplicado pelo tempo de operação do ativo (24 horas/dias) fornece um total de 2544 horas (total aproximado de 106 dias em operação). Após digitar no campo de entrada o total de horas que o equipamento acumula, é preciso pressionar o botão “Adicionar horas trabalhadas” para que o valor seja salvo temporariamente pela interface. O valor alterará o *display* que antes era 0 para o valor atual (a soma do valor antigo mais o valor inserido). O usuário poderá decidir se deseja manter essa alteração no Excel ou apagar as alterações de maneira independente após inserir um valor no campo de entrada de horas trabalhadas, basta escolher entre os botões “Salvar alterações” e “Apagar alterações”. Estas duas opções encontram-se no canto inferior esquerdo da interface, como mostra a Figura 15. Enquanto isso, o botão para adicionar horas trabalhadas, após inserir um valor válido, será desabilitado para que seja possível realizar uma análise por vez das estimativas, evitando sobreposição de dados e erros nos cálculos, como mostra a Figura 16.

Figura 15: Controle de alterações da planilha Excel através da interface do software STM.



Fonte: Elaborado pelo autor.

Figura 16: Inserindo valores no campo de entrada de horas trabalhadas no histórico do capacitor de barramento CC.

data 20/07/2025

Horas trabalhadas

2544

Adicionar horas trabalhadas

Horas atuais: 2544.0

Clique para confirmar a quantidade de horas, isso irá permitir que você adicione alguma ocorrência de falha e de reposição e gere estimativas.

Componente: Capacitor de barramento CC

Data Reposição Programada	Horas até o evento	Custo da Parada Não Programada	Custo da Reposição Programada
---------------------------	--------------------	--------------------------------	-------------------------------

Fonte: Elaborado pelo autor.

- 4º estágio: Após seguir os três estágios anteriores adequadamente, o usuário poderá escolher entre gerar estimativas com o valor informado de horas trabalhadas ou adicionar um novo evento. Iremos supor para o 4º estágio que é desejado adicionar um novo evento, que seguirá o padrão dos dados apresentado na Figura 11. Logo, o próximo evento será uma reposição programada que, após obtido o valor de horas trabalhadas, será necessário obter os custos de parada e de reposição para adicionar na planilha, inicialmente, apresentada na interface. Ou seja, a modificação da planilha Excel irá ocorrer somente quando o usuário pressionar o botão “Salvar alterações”. A Figura 17 demonstra como é inserido os dados do evento de reposição programada (para adicionar a data de falha, o procedimento é idêntico), os valores aparecem na última linha da tabela, como mostra a Figura 18. Quando a adição do evento é concluída, os botões para adicionar novos eventos serão bloqueados, isso se deve a lógica de que não acontece duas falhas ou duas reposições consecutivas durante a análise do componente. Assim, previne-se que o software apresente instabilidade na leitura dos dados e consiga operar normalmente, continuando a exercer suas funções.

Figura 17: Adicionando um novo evento no histórico de reposição do capacitor de barramento CC.

3048

3048

0

4900

Adicionar Data de Reposição Programada

×

Custo da Parada Não Programada:

Custo da Reposição:

Confirmar

Cancelar

-

-

-

-

-

-

-

-

-

Adicionar Data de Falha

Adicionar Data de Reposição

Gerar estimativas

Fonte: Elaborado pelo autor.

Figura 18: Evento de reposição no histórico de reposição preventiva do capacitor de barramento CC.

[illegible]

Fonte: Elaborado pelo autor.

Com o novo evento registrado, o valor de horas trabalhadas irá retornar zero, não mais exibindo o valor de antes, pois é considerado que, após a falha ou reposição, o ativo obterá uma nova vida útil ou que o tempo ativo de operação foi reiniciado. Logo, espera-se que a confiabilidade instantânea deste ativo seja 100%.

Para comprovar este fato, o usuário poderá pressionar o botão “Gerar estimativas”, não apenas obtendo a confiabilidade instantânea, mas os parâmetros de distribuição de Weibull e os

indicadores de desempenho, como demonstrado pela Figura 19. A interface do Weibull Predictor STM estimou os seguintes parâmetros:

- Coeficiente de determinação r^2 : 0.809
- Confiabilidade instantânea $R(t)$: 100.0%
- Tempo esperado até a falha ($MTTF$): 4893.84 horas
- β (Beta): 2.089
- η (Eta): 5525.213
- Tempo ótimo: 1808.0 horas
- Custo mínimo: 0.54 reais/horas

Figura 19: Aba "Reposição" após adicionar um evento no histórico do capacitor de barramento CC.



Fonte: Elaborado pelo autor.

- 5º estágio: Após realizado o 4º estágio, o mesmo procedimento será feito para gerar estimativas, porém não mais será optado a adição de um novo evento para o histórico de reposição preventiva. Para isso, o botão “Apagar alterações” será utilizado, visto que a sua função é a de restaurar o padrão do histórico e da interface para o estado original do arquivo Excel, cujo estado nada mais é do que o momento em que o arquivo foi aberto pela interface, como a Figura 13 representa. Como mencionado anteriormente, o botão “Salvar alterações” alteraria imediatamente o arquivo Excel. Não apenas adicionando o novo valor para horas trabalhadas (0), como também a data de reposição, as horas até o evento e os custos de reposição e de parada, sendo possível ser analisado na Figura 18, em que é demonstrado esses dados. Como não foi salvo as alterações, a função de apagar alterações será utilizada apenas para apagar os dados temporários que foram armazenados no software STM, permitindo a realização de novas estimativas em

casos de erros ou de experimentação no aplicativo. Para este último caso, a nova experimentação irá considerar novamente as 2544 horas, gerando as estimativas na aba “Reposição”, como mostra a Figura 20, com os seguintes resultados:

- Coeficiente de determinação r^2 : 0.809
- Confiabilidade instantânea $R(t)$: 82.05%
- Tempo esperado até a falha ($MTTF$): 4893.84 horas
- β (Beta): 2.089
- η (Eta): 5525.213
- Tempo ótimo: 1808.0 horas
- Custo mínimo: 0.54 reais/horas

O histórico de reposição preventiva deste ativo possui uma variação muito abrupta, como mostra a Figura 11, em que há uma dispersão dos tempos até a falha, afetando na qualidade do coeficiente de determinação. O total de horas até o evento, referente a cada data de falha, recebe uma posição de plotagem após serem organizados em ordem crescente e utilizados para definir o eixo das abscissas. Como o valor de r^2 expressa a redução da variação total de y relacionada ao uso da variável preditora x e indica o grau de eficiência do ajuste da reta da regressão linear, é preciso que o tempo até a falha seja mais uniforme. Ou melhor, como o valor de 8136 horas denota um valor superior aos outros valores das datas de falha (4296, 3048 e 3504), o coeficiente obteve uma redução brusca, atingindo o resultado de 0.809. Para que essa variação de y diminua e a estimativa de r^2 aumente e seja próximo ou igual a 1, é preciso que a dispersão dos tempos até a falha seja reduzida. Como resultado, será obtido um modelo que representa precisamente o padrão de falhas e estima com maior qualidade os parâmetros da distribuição de Weibull. Além de que, consequentemente, representará os indicadores de desempenho adequadamente aos usuários, auxiliando na gestão da manutenção de capacitores de barramento CC.


A métrica do tempo ótimo indica, com 1808 horas (cerca de 2 a 3 meses), seja o período ideal para que aconteça uma reposição preventiva, evitando possíveis falhas no capacitor de barramento CC. Este instante de tempo beneficiará com uma economia de 976.32 reais (ou 0.54 reais/horas), encontrado através da relação entre o custo de reposição e o custo esperado da parada não programada, fundamentado na seção 4.4. O equilíbrio entre os resultados do tempo e do custo retorna para as empresas o melhor custo-benefício, diminuindo os gastos por reposições prematuras e por falhas em operação.

Outro ponto que não pode ser ignorado são os parâmetros de distribuição de Weibull e

quais informações são repassadas por elas. Fundamentado na seção 3.4 sobre os intervalos de parâmetro de forma (β) e suas definições, com auxílio da interpretação da curva da banheira, o valor estimado de β (2.089) informa que o intervalo central deste histórico de reposição são as falhas por desgaste ($\beta > 1$). Significa dizer que o componente está se aproximando do tempo esperado até a falha devido seu envelhecimento e, logo, sua confiabilidade está diminuindo.

O parâmetro de escala/vida característica (η) está diretamente relacionado com o tempo médio esperado até a falha do componente, além de que, como mencionado na seção 3.4, essa métrica define a durabilidade. Quanto maior o valor de η for, menos suscetível a falhas o ativo estará e mais prolongado o tempo de vida útil será representado. Neste estudo de caso do capacitor de barramento CC, o ativo obteve um total de 5525.213 de vida característica e, deste modo, um *MTTF* de 4893.84 horas. Isso explica o porquê da confiabilidade ainda se manter acima de 80% mesmo após a simulação ser realizada com 2544 horas trabalhadas, um valor de 736 horas superior ao tempo ótimo de reposição.

Figura 20: Aba "Reposição" sem adicionar eventos no histórico do capacitor de barramento CC.



Fonte: Elaborado pelo autor.

Os parâmetros da distribuição de Weibull (β e η) e os indicadores de desempenho (*MTTF*, tempo ótimo, custo mínimo e r^2) dependem do histórico de reposição e se adaptam à medida que o ativo apresenta falhas. Significa dizer que, exceto a confiabilidade instantânea, essas estimativas preveem as falhas com base nas falhas registradas, logo, a adição do evento de reposição preventiva não provocou variações nos valores. Enquanto isso, a confiabilidade

instantânea apresentou mudança com base nas horas trabalhadas que a métrica considerou, sendo, agora, visto que ela foi mensurada utilizando as 2544 horas que o usuário informou. Para $R(t)$, os efeitos visuais consideram três recomendações:

- De 100% a 80% (verde-ciano): o componente estará operando idealmente, sem risco de obter falhas durante sua operação.
- De 80% a 50% (amarelo queimado): é possível que o equipamento seja um risco aos operadores, logo, continuar com sua operação pode ocasionar falha e atrapalhar os sistemas de produção, por exemplo.
- De 50% a 0 (laranja): risco alto, a operação do ativo pode ser perigosa e danosa tanto para o equipamento quanto para a fábrica e seus operários.

Estes efeitos visuais auxiliam no cuidado com o equipamento e com os operadores, visto que as cores ajudam a denotar os riscos de operação, assim como os semáforos ajudam a manter a segurança no trânsito. Além disso, contribui para aumentar a atenção para o tempo esperado até a falha, visto que, com metade do tempo esperado até a falha, a confiabilidade instantânea do equipamento obtém uma estimativa superior a 80% (apesar que essa consideração pode não ser válida para todo e qualquer ativo). Com o total de horas trabalhadas igual ou superior ao *MTTF*, a confiabilidade obteria um agravamento, chegando a operar com médio e alto risco, elevando rápido ou não a probabilidade de falha com base no histórico de reposição. Logo, é importante considerar o tempo ótimo de reposição e o custo benefício que ele apresenta, não apenas com objetivo econômico, mas para segurança e para a continuidade da operação do ativo.

6.2. Caso: Lâmpadas LED industriais

Outro tipo de ativo não sujeito à manutenção corretiva e que costuma ser empregado em ambientes industriais é a lâmpadas LED. A inteligência artificial considerou como exemplo a lâmpada LED industrial de 150 W, com proteção IP65 (proteção contra poeira e jatos de água de baixa pressão), retirado do catálogo do fabricante OSRAM GmbH (2021). De acordo com o fabricante, este ativo atua com frequência em armazéns, oficinas e linhas de montagem. Por esse motivo, estes ambientes levam o equipamento à falha devido as altas temperaturas internas, poeira, vibrações ocasionadas por maquinários e variações no nível de tensão, que afetam a qualidade de energia.

Consequentemente, estes fatores levam a redução da vida útil, pois provocam o desgaste

dos componentes internos da luminária. Com essa perspectiva, de acordo com o catálogo do fabricante OSRAM GmbH (2021), a expectativa é de que a lâmpada de LED industrial, em condições ideais, alcance o total de 50.000 horas. Essa informação irá servir como base teórica para as simulações, assim como foi considerado para o capacitor de barramento CC. Dessa forma, os dados contribuem para que seja possível encontrar o equilíbrio entre o relatório técnico e as supostas condições no ambiente industrial, que diminuem a vida útil do ativo. Espera-se que o ativo, de acordo com a IA, possua em torno de 1.500 a 3.800 horas de vida útil, cujo intervalo representa o tempo até a reposição.

Como o histórico de reposição preventiva da lâmpada de LED industrial foi gerado pela inteligência artificial, respeitar a datação obtida torna inviável considerar o dia em que é realizado o teste para analisar as estimativas (consideração feita para o estudo de caso do capacitor de barramento CC). Refrisando, considerar a data atual 20/07/2025, em que é realizado o estudo de caso, tem como resultado o total de 25.800 horas (cerca de 3 anos) para o tempo de operação de 24 horas/dias das lâmpadas. Esta estimativa é obtida por meio da diferença com a última data do histórico de reposição (10/08/2022), presente na Figura 21. Ou seja, significa dizer que o ativo tem altas chances de ter falhado e não houve registros ou reposição preventiva. Logo, para manter a coerência, consideremos uma aproximação de 2 meses de diferenciação da última última falha observada, ou melhor, utilizaremos a data 20/10/2022 para fins de simulação, que fornece um total de 1704 horas.

Para a definição dos custos, de parada e de reposição, foi considerado que o CR é um valor fixo que corresponde a 50 reais por unidade de equipamento, enquanto que o CPNP atribui um variação entre 100 a 200 reais por evento, cujas atribuições foram feitas apenas para fins de simulação e encontram-se, também, na Figura 21.

Figura 21: Histórico de reposição preventiva da lâmpada LED industrial.

Lâmpadas elétricas industriais					
Data falha	Data Reposição Programada	Horas até o evento	Custo da Parada Não Programada	Custo da Reposição	Horas Trabalhadas
	01/03/2021	0	0	0	0
	15/05/2021	1800	0	50	
20/07/2021		1584	100	50	
	10/09/2021	1248	0	50	
05/11/2021		1344	120	50	
	15/01/2022	1704	0	50	
20/03/2022		1536	150	50	
	25/05/2022	1584	0	50	
10/08/2022		1848	180	50	


Fonte: Elaborado pelo autor.

Com o histórico de reposição preventiva obtido e com a definição do total de horas trabalhadas, é possível adiantarmos os estágios 1, 2 e 3 mencionados na seção 6.1. Com a adição

de mais de uma planilha dentro do arquivo Excel, a interface do Weibull Predictor STM consegue diferenciar os históricos dos ativos não sujeitos à manutenção corretiva e realizar ininterruptamente diferentes previsões de falhas para diferentes componentes.

A planilha que correspondeu ao histórico de reposição preventiva do capacitor de barramento CC foi nomeada de “Plan 1”, enquanto que a planilha que corresponde ao histórico das lâmpadas LED industriais se chama “Plan 2”, ilustrado na Figura 22. Assim é possível trocar de histórico ou analisar diferentes ativos ao mesmo tempo, onde cada aba de reposição mostrará o último registro de estimativas do ativo em questão, gerado pela interface.

Figura 22: Trocando de planilha dentro do Weibull Predictor STM.



Fonte: Elaborado pelo autor.

Inserir os dados na interface, neste caso, em que o arquivo Excel contém múltiplos históricos de reposição em diferentes planilhas, poderá ser feito através do método que a Figura 22 apresenta, como também é possível pressionando novamente o botão “Carregar arquivo Excel”. Para isso, pressionar o botão mais uma vez permitirá que o usuário abra novos arquivos Excel, caso possua diferentes históricos de reposição preventiva em diferentes arquivos, sendo notificado de que os dados atuais serão substituídos pelos novos.

Para a simulação, as estimativas serão geradas diretamente, isso porque adicionar um novo evento de reposição programada implicaria apenas na modificação da confiabilidade, como demonstrado na seção 6.1 no 4º estágio. Logo, parâmetros de distribuição de Weibull e os indicadores de desempenho mantêm-se baseados no histórico de reposição, como a Figura 23 demonstra, obtendo-se os seguintes resultados:


- Coeficiente de determinação r^2 : 0.946
- Confiabilidade instantânea $R(t)$: 31.43%
- Tempo esperado até a falha ($MTTF$): 1568.65 horas

- β (Beta): 7.494
- η (Eta): 1671.072
- Tempo ótimo: 1139.51 horas
- Custo mínimo: 0.05 reais/horas

Diferentemente do histórico de reposição preventiva do capacitor de barramento CC, o segundo estudo de caso obteve um maior r^2 , sendo igual a 0.946. Este resultado indica que, além das outras métricas que contribuem para a previsão de falhas, as estimativas do tempo ótimo e do custo mínimo serão definidas com maior qualidade. Logo, para o tempo dedicado ao teste e introduzido nas horas trabalhadas (1704 horas), definiu-se que este ativo necessita de reposição muito antes que 2 meses, sendo, possivelmente, 1 mês ou antes disso. Demonstrando que, apesar da baixa durabilidade do componente, a empresa que utiliza o software Weibull Predictor STM estará ciente das diferentes ocasionalidades e do quanto o ambiente industrial afeta a operação destas lâmpadas. O monitoramento e a otimização que o STM proporciona, para esta situação, se tornam eficazes e essenciais, pois organizam e auxiliam na gestão da manutenção entre multiplataformas, além de garantirem a economia e a segurança na indústria em que este ativo for empregado.

Outra maneira de confirmar que o equipamento deste estudo de caso deverá acumular menos horas trabalhadas é observando o valor de β (7.494), que se encontra muito superior a 1 e indica que a falha do ativo será por desgaste. Enquanto que a durabilidade do componente, ou melhor, a vida característica, obteve um valor relativamente baixo, proporcionando redução da vida útil e, por conseguinte, do tempo médio esperado até a falha. Logo, a observação destas métricas comprovam que a lâmpada LED industrial permanece por pouco tempo em operação e que o melhor momento de realizar uma reposição preventiva é respeitando o tempo ótimo de 1139.51 horas (cerca de 1 mês e meio). A confiabilidade instantânea é extremamente eficiente para esta situação, em que o componente precisa de estimativas para previsão de falhas em decorrência do curto prazo de vida e baixa resistência/sobrecarga de operação, evitando reposições prematuras não econômicas e perturbações em sistemas de produção.

Figura 23: Aba "Reposição" sem adicionar eventos no histórico da lâmpada LED industrial.



Fonte: Elaborado pelo autor.

O resultado, evidentemente, não foi satisfatório porque a quantidade de horas trabalhadas que o ativo acumula ultrapassou o tempo esperado até a falha, indicando o sinal de “perigo” pela cor vermelha. Considera-se também que o tempo de aproximadamente de 2 meses não é o ideal para adicionar uma nova reposição programada, pelo contrário, devemos considerar um tempo inferior a este.

Outro detalhe é o coeficiente de determinação que se encontra satisfatório, ele indica que os valores observados do histórico de reposição preventiva da lâmpada LED industrial estão próximos dos valores estimados. Logo, é preciso se atentar ainda mais para o *MTTF*, visto que o tempo médio apresenta uma boa precisão.

As estimativas encontradas processaram os dados pelo Weibull Predictor STM, encontrando o menor custo possível para reposição preventiva e orientando o usuário sobre o tempo esperado até que a falha do componente ocorra. O objetivo deste estudo de caso, assim como para o capacitor de barramento CC, é aplicar o STM em ativos não sujeitos à manutenção corretiva para demonstrar a aplicabilidade do software, apesar das adversidades que o ambiente proporciona para os equipamentos.

7. CONCLUSÃO

A estrutura do atual estudo apresentou o objetivo geral de maneira prática e teórica, cuja finalidade consistiu no desenvolvimento do software Weibull Predictor STM, que monitora e

otimiza os custos de reposição em ativos não sujeitos à manutenção corretiva. Sua construção obteve progresso ao utilizar como base os conceitos fundamentais da confiabilidade, presente em diferentes livros e referências, e, principalmente, da norma NBR 5462 (1994). Tais definições contribuíram para implementar modelos probabilísticos que modelam o desgaste dos ativos ao longo do tempo, assim como a previsão de falhas deles.

Os objetivos específicos definidos previamente, no início do trabalho, foram atendidos satisfatoriamente. O modelo probabilístico da distribuição de Weibull à análise de falhas foi aplicado de forma adequada, assim como a implementação do software Weibull Predictor STM com todas as atribuições necessárias, sendo elas: a criação da interface gráfica compatível com diferentes distribuições de dados entre planilhas, a estimativa do tempo esperado até a falha (*MTTF*), da confiabilidade instantânea e do coeficiente de determinação (r^2), além do cálculo do tempo ótimo e do custo mínimo de reposição de ativos. Nessa perspectiva, o STM também priorizou o uso dos balões (*tooltips*) como manual de ajuda, orientando o uso de cada botão, campo de entrada, aba e interpretação dos resultados obtidos por meio do histórico de reposição preventiva.

A partir da definição dos objetivos, que atribuíram orientação para este trabalho, tornou-se possível definir os resultados que comprovaram a eficiência do software STM para representar casos reais, como as simulações dos históricos de reposição preventiva do capacitor de barramento CC e da lâmpada LED industrial. O software desempenhou capacidade suficiente para organizar os dados de múltiplas planilhas e adicionar novos eventos, assim como para demonstrar as métricas e informações intuitivas sobre a gravidade dos ativos. Esses fatores contribuíram para apresentar intervalos de reposição com base no comportamento das falhas, cujas previsões apresentaram custos-benefícios que agregam para a gestão de manutenção de pequenas e médias empresas.

Como proposta de baixo custo, optou-se pela estratégia de reposição preventiva, destinada a ativos não sujeitos à manutenção corretiva e que costumam ser um item interno ou externo de um componente. Este tipo de manutenção oferece recuperação da vida útil do ativo e o controle de sua função operacional. Associada ao STM – apresentado neste estudo como alternativa aos softwares comerciais de alto investimento –, essa estratégia contribui para que o gerenciamento da confiabilidade se integre a logística de empresas de pequeno porte, prolongando a operação e a segurança de seus equipamentos.

As principais adversidades encontradas foram a limitação do estudo a ativos não sujeitos à manutenção corretiva e a restrição dos dados às informações disponibilizadas pelas empresas,

que dificultaram análises mais robustas e sofisticadas para as previsões das falhas dos componentes. A escolha da estratégia de reposição preventiva, a ser implementada nos ativos pelo software, discrimina aqueles que requerem manutenção corretiva. Isso também implica na perda da acessibilidade de dados relevantes, prejudicando na ampliação dos testes em diferentes tipos de componentes.

Logo, propõe-se para continuidade deste estudo, a adaptação do software com o objetivo de integrar novos módulos para melhorar e aprimorar as análises de previsões de falha, permitindo que as métricas de reposição preventiva sejam também aplicadas à manutenção preventiva. A intenção é melhorar o Weibull Predictor STM para que se torne mais eficaz no apoio à gestão de manutenção, aperfeiçoando a tomada de decisão em condições reais de operação, com múltiplos ativos e variados ciclos de vida. A extensão de novas abas irá incorporar novas estratégias de reparo, ampliando a quantidade de históricos e/ou dados e acrescentando novas métricas, proporcionando prevenções ajustadas ao modo de operação dos ativos.

A evolução deste trabalho possibilitou aprendizado técnico, com o desenvolvimento de aplicativos utilizando a linguagem de programação Python, e científico, através da experimentação e da exploração de condições de operação de ativos por meio dos estudos de caso. Ademais, fortaleceu a relevância dos métodos probabilísticos e dos conceitos das normas técnicas, contribuindo para que o Weibull Predictor STM integre não apenas o campo conceitual da engenharia da confiabilidade, mas também da logística de empresas que não adotam processos de gerenciamento de falhas. Com uma solução prática e eficaz de baixo custo à gestão de manutenção, torna viável a redução dos custos operacionais com o acompanhamento e otimização de processos, adequando-se conforme as necessidades de eficiência do setor de produção.

A estratégia de manutenção preditiva adotada pelo software STM proporcionou aos gestores métricas importantes – como MTTF, confiabilidade instantânea e custo mínimo – que permitiram a programação da reposição preventiva em intervalos ideais, definidos pelo tempo ótimo. Quando associada ao modelo probabilístico proposto por Weibull, o monitoramento contínuo, baseado no comportamento dos ativos, e os indicadores que alertam sobre o momento ideal para reposição, comprovaram a redução dos custos desnecessários e o aumento da disponibilidade dos itens. Por fim, a solução preditiva de baixo custo, o Weibull Predictor STM, promove eficiência e segurança nos processos de manutenção.

8. PROPOSTA PARA CONTINUAÇÃO DO TRABALHO

Um dos problemas no software STM está na garantia de apenas um serviço orientado à análise de falhas: a reposição preventiva. Essa estratégia de manutenção atua em um intervalo programado, porém não integra ao seu planejamento inspeções regulares para mitigar a degradação dos ativos. Noutro ângulo, apesar de o aplicativo otimizar os custos, a definição do período ideal para a reposição pode ser prejudicada a depender da qualidade do histórico utilizado. Ou melhor, a programação prematura ou tardia das reposições afeta diretamente os custos e os riscos de falha, respectivamente.

Como proposta de melhoria e solução para esses problemas, a manutenção preventiva será implementada com o objetivo de contribuir na análise de confiabilidade do Weibull Predictor STM. Na seção 2.1.11 foi argumentado que essa estratégia antecipa a prevenção da deterioração dos equipamentos por desgastes, fadiga e corrosões, reduzindo a probabilidade de falhas dos equipamentos. Considerar intervalos predefinidos de inspeções e de ajustes permitirá que o escopo do software seja ampliado, garantindo, além do tempo ótimo de reposição, o aumento da disponibilidade e da vida útil dos ativos.


Similar ao método utilizado no Weibull Predictor STM para realizar análises de confiabilidade e prever falhas para a reposição preventiva, será necessário um novo arquivo Excel, dedicado apenas aos intervalos de manutenção preventiva. O novo histórico para inspeções obterá as datas e indicará os ajustes e as horas acumuladas de cada evento, permitindo que a estrutura da planilha se mantenha semelhante à que aparece na Figura 7, criando-se um padrão organizado do arquivo Excel para inserir os dados. Além disso, o módulo existente no aplicativo, e que foi debatido na seção 5.4, será utilizado para calcular um novo tempo ótimo, destinado a indicar o intervalo ideal para inspeções nos ativos. Nesse aspecto, são necessários estudos que fundamentem a possibilidade de indicar a redução da taxa de falha com essa estratégia, além do impacto no custo total, agora integrando as inspeções regulares da manutenção preventiva.

No Weibull Predictor STM, a aba “Manutenção preventiva”, presente na Figura 24, precisará de uma nova forma de carregamento de planilhas, permitindo que as informações sejam revisadas individualmente para melhorar a interpretação das estimativas pelo usuário. Para inserir as datas de inspeções, é importante a implementação de novos botões, para realizar essa ação e para aprimorar a interatividade entre o arquivo Excel e o aplicativo, automatizando a organização dos dados na nova planilha.

Com o carregamento do histórico da MP e com os botões para os novos eventos, a aba “Manutenção Preventiva” estará pronta para apresentar as métricas que contribuirão para ajustar os resultados obtidos e demonstrados na aba “Reposição”. Considerar as estratégias que a MP põe em prática permitirá a redução da probabilidade de falhas, afetando diretamente o resultado da *MTTF* e modificando o intervalo de reposição.

A partir disso, o foco dessa proposta é propiciar o aumento da confiabilidade, da disponibilidade e da vida útil do ativo. Unir a estratégia da manutenção preventiva com a reposição preventiva melhora a tomada de decisões e prolonga o período em operação dos ativos.

Figura 24: Aba "Manutenção Preventiva" no software Weibull Predictor STM.



Fonte: Elaborado pelo autor.

REFERÊNCIAS

AHMAD, Rosmaini et al. Preventive replacement schedule: a case study at a processing industry. **International Journal of Industrial and Systems Engineering**, 8, n. 3, 2011. Disponível em: <<http://dx.doi.org/10.1504/IJISE.2011.041544>>.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5462 CONFIABILIDADE E MANTENABILIDADE**. Rio de Janeiro. 1994.

BRASIL. MINISTÉRIO DA JUSTIÇA. SECRETARIA NACIONAL DO CONSUMIDOR. **Recall: guia prático do fornecedor**. Ministério da Justiça – Secretaria Nacional do Consumidor. Brasília. 2013.

CHAUDHARY, Bhaskar. **Tkinter GUI application development hotshot**.

DRAPER, Norman R.; SMITH, Harry. **Applied Regression Analysis**. 3. ed.

GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria Básica**. 5. ed.

HALLINAN, Arthur J. A review of the Weibull distribution. **Journal of Quality Technology**, 25, 1993. 85-93.

HEISER, Thomas; HOFMEISTER, James P. **Bathtub, failure distribution, MTBF, MTTF, and more: they are related**. Ridgetop Group. Tucson. 2018.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. **IEC 60300-1:2024 – Dependability Management – Part 1: Managing Dependability**. Geneva. 2024.

JIN, Lu; YAMAMOTO, Watalu. Adaptive Age Replacement Using On-Line Monitoring. **Procedia Engineering**, 174, 2017. Disponível em: <<https://doi.org/10.1016/j.proeng.2017.01.177>>.

KAPUR, Kailash C.; LAMBERSON, Leonard R. **Reliability in engineering design**.

KUTNER, Michael H. et al. **Applied Linear Statistical Models**. 5. ed.

LAWLESS, J. F. **Statistical Models and Methods for Lifetime Data**. 2. ed.

MAISONNIER, David. RAMI: The main challenge of fusion nuclear technologies. **Fusion Engineering and Design**, 136, 2018. Disponível em: <<https://doi.org/10.1016/j.fusengdes.2018.04.102>>.

MCCOOL, John I. **Using the Weibull Distribution: Reliability, Modeling, and Inference.**

MENČÍK, Jaroslav. **Concise Reliability for Engineers.**

MENDES, Angélica A. **Manutenção centrada em confiabilidade: uma abordagem quantitativa.**

MENEZES, Nilo N. C. **Introdução a Programação com Python.**

MOBLEY, R. K. **AN INTRODUCTION TO PREDICTIVE MAINTENACE.** 2. ed.

MONTGOMERY, Douglas C. **Introduction to statistical quality control.** 7. ed.

NELSON, Wayne. **Accelerated Testing: Statistical Models, Test Plans, and Data Analyses.**

OSRAM GMBH. **LED COMFO® Highbay V3 – Technical Datasheet.** [S.l.]. 2021.

RINNE, Horst. **The Weibull Distribution: A Handbook.**

ROEDERSTEIN, Vishay. MKP1848C71050JY5 – Capacitor de Filme 100 μ F / 500 VDC. **Mouser Brasil.** Disponível em: <<https://br.mouser.com/ProductDetail/Vishay-Roederstein/MKP1848C71050JY5?qs=zDkSFN9STR%252BPs7VNm%252Bxrgg%3D%3D>>. Acesso em: 06 agosto 2025.

SALEH, J.H.; MARAIS, K. Highlights from the Early (and pre-) History of Reliability Engineering. **Reliability Engineering & System Safety**, 91, 2006. 249-256. Disponível em: <<https://doi.org/10.1016/j.ress.2005.01.003>>.

SELLITTO, Miguel A.; FACHINI, Silmar J. Análise estratégica da gestão da manutenção industrial de uma empresa de metal-mecânica. **E-Tech: Tecnologias para a Competitividade Industrial**, 7, 2014. 49-66.

SHEU, Shey-Huei; KUO, Chung-Ming; NAKAGAWA, Toshio. Extended optimal age replacement policy with minimal repair. **RAIRO. Recherche opérationnelle**, 27, 1993. 337-351. Disponível em: <http://www.numdam.org/item?id=RO_1993__27_3_337_0>.

SILVA, Fernanda G.; ANDRADE, Jairo J. D. O. Análise de falhas de equipamentos da indústria metal-mecânica como subsídio para estabelecimento de atividades de manutenção. **Revista Espacios**, 37, 2016. Disponível em: <<https://www.revistaespacios.com/a16v37n12/16371217.html>>.


SPADER, Ana Letícia R.; ANDRADE, Jairo J. D. O. Emprego da análise de falhas para direcionamento das atividades de manutenção em equipamentos na indústria do ramo de higiene e cuidados pessoais. **Revista Espacios**, 36, 2015. Disponível em: <<https://www.revistaespacios.com/a15v36n12/15361205.html>>.

VISHAY. **MKP1848 DC-Link capacitors**. Vishay Intertechnology, Inc. Malvern, PA. 2023.

ZHANG, Lifang. **Linear regression parameter estimation methods for the Weibull distribution**.

APÊNDICE A – INTERFACE GRÁFICA STM AMPLIADA

Devido a limitação gráfica para reproduzir a imagem da interface do software, é apresentado neste apêndice a Figura 3 ampliada.



Fonte: Elaborado pelo autor.

Exibição ampliada dos dados de reposição preventiva do capacitor de barramento CC na interface do Weibull Predictor STM para fins de análise da Figura 13.

[illegible]

	INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
	Campus João Pessoa - Código INEP: 25096850
	Av. Primeiro de Maio, 720, Jaguaribe, CEP 58015-435, João Pessoa (PB)
	CNPJ: 10.783.898/0002-56 - Telefone: (83) 3612.1200

Documento Digitalizado Ostensivo (Público)

Trabalho de conclusão de curso

Assunto:	Trabalho de conclusão de curso
Assinado por:	Iury Araujo
Tipo do Documento:	Anexo
Situação:	Finalizado
Nível de Acesso:	Ostensivo (Público)
Tipo do Conferência:	Cópia Simples

Documento assinado eletronicamente por:

- Iury Ferreira de Araujo, ALUNO (20201610037) DE BACHARELADO EM ENGENHARIA ELÉTRICA - JOÃO PESSOA, em 03/09/2025 08:22:29.

Este documento foi armazenado no SUAP em 03/09/2025. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1595319
Código de Autenticação: c59454e872

