



ISEL



Análise de fiabilidade de componentes críticos em garantia. Caso de estudo na indústria de equipamentos de movimentação de cargas e pessoas

FYODOR SUBOTIN
(Licenciado em Ciências Aeronáuticas)

Dissertação para obtenção do grau de Mestre
em Engenharia Mecânica, na Área de Especialização de Manutenção e Produção

Orientador:
Doutor José Augusto da Silva Sobral

Júri:
Presidente: Doutor André Rui Dantas Carvalho
Vogais:
Doutor Luís António de Andrade Ferreira
Doutor José Augusto da Silva Sobral

dezembro de 2024

Análise de fiabilidade de componentes críticos em garantia. Caso de estudo na indústria de equipamentos de movimentação de cargas e pessoas

FYODOR SUBOTIN
(Licenciado em Ciências Aeronáuticas)

Dissertação para obtenção do grau de Mestre
em Engenharia Mecânica, na Área de Especialização de Manutenção e Produção

Orientador:
Doutor José Augusto da Silva Sobral, ISEL/IPL

Júri:
Presidente: Doutor André Rui Dantas Carvalho, ISEL/IPL
Vogais:
Doutor Luís António de Andrade Ferreira, FEUP/UP
Doutor José Augusto da Silva Sobral, ISEL/IPL

dezembro de 2024

Agradecimentos

Gostaria de agradecer a todos que me acompanharam durante este percurso acadêmico, onde adquiri os conhecimentos necessários para realizar este trabalho.

Agradeço ao meu orientador, Prof. Doutor José Augusto da Silva Sobral, por todo o apoio e o tempo dispensado na orientação.

Um agradecimento especial aos meus pais, Ivan Subotin e Inna Subotina, por serem o suporte que todo filho precisa.

Para Wiliane Fernandes, minha mulher, pelo apoio, incentivo, paciência e compreensão.

A Zoya Nicole Fernandes Subotina, por ser a filha mais querida do mundo e contribuir para eu ser uma pessoa melhor.

E, por último, à Manitou Portugal e a todos os que lá trabalham pela informação disponibilizada e pelo conhecimento adquirido.

Declaração de integridade

Declaro que esta dissertação é o resultado da minha investigação pessoal e independente. O seu conteúdo é original e todas as fontes listadas nas referências bibliográficas foram consultadas e estão devidamente mencionadas no texto. Mais declaro que todas as referências científicas e técnicas relevantes para o desenvolvimento do trabalho estão devidamente citadas e constam das referências bibliográficas.

O autor

Lisboa, 24 de dezembro de 2024

Análise de fiabilidade de componentes críticos em garantia. Caso de estudo na indústria de equipamentos de movimentação de cargas e pessoas

Resumo

Nos dias de hoje, a satisfação do cliente é cada vez mais um fator diferenciador para as empresas. A competitividade na indústria de movimentação de carga é intensa e os clientes procuram bens fiáveis e seguros. Para se conseguirem destacar e construir relacionamentos duradouros com os clientes, as empresas necessitam de adotar estratégias para garantir que os equipamentos sejam de alta qualidade, duráveis e seguros. Isto não só reduzirá o risco de falhas, mas também aumentará a confiança do cliente.

No presente trabalho, foi selecionado um bem crítico de um equipamento de elevação de cargas, através do Processo Analítico Hierárquico (AHP), tendo-se depois desenvolvido um estudo de fiabilidade mais detalhado desse bem recorrendo a ferramentas de análise de fiabilidade. Este estudo não só permitiu identificar as características de fiabilidade do bem em estudo, mas também realizar diversas simulações e análises recorrendo a dados reais. Além disso, elaborou-se uma previsão de retornos em garantia através da análise de vendas vs retornos, o que forneceu uma ferramenta importante para prever as falhas destes bens em período de garantia, em função das vendas mensais dos equipamentos, e assim planear as intervenções e a necessidade de bens a ter em armazém, otimizando toda a gestão das intervenções a realizar no futuro.

Palavras-chave: Fiabilidade, Garantia, Manutenção Preditiva, Processo Analítico Hierárquico.

Reliability analysis of critical components under warranty. A case study in the material handling and people elevation equipment industry

Abstract

In today's business landscape, customer satisfaction is increasingly a differentiating factor for companies. The competitiveness in the cargo handling industry is intense, and customers seek reliable and secure goods. To stand out and build lasting relationships with customers, companies need to adopt strategies to ensure that their equipment is of high quality, durable, and safe. This not only reduces the risk of failures but also enhances customer confidence.

With this dissertation, it was possible to identify the most critical warranty components in a company within this sector and perform a reliability analysis of the identified component.

In the present work, a reliability analysis was developed for one of the most critical components, carefully selected through the Analytical Hierarchy Process. This analysis not only allowed the identification of the reliability characteristics of the component but also facilitated various studies on reliability using different statistical distributions and the inclusion of censored data. Furthermore, a forecast of warranty returns was prepared through the analysis of sales vs returns, which provided an important tool to predict the failures of these goods during the warranty period, depending on the monthly sales of the equipment, and thus plan interventions and the need for goods to be kept in storage, optimizing the entire management of interventions to be carried out in the future.

Keywords: Reliability, Warranty, Predictive Maintenance, Analytic Hierarchy Process.

Lista de Símbolos e de siglas

Alfabeto romano

A – matriz de comparação

a – ordenada na origem

a_{ij} – elemento correspondente na matriz original

b – declive

$E(G)$ – valor estimado uma função G

$f(t)$ – função densidade de probabilidade de falha

$F(t)$ – probabilidade de falha acumulada

$F(t|T)$ – probabilidade condicional de falha

L – função de verossimilhança

n_{ij} – elemento normalizado na linha i e coluna j

n_s – número de componentes sobreviventes no momento t ;

n_f – número de componentes falhados no momento t ;

n_o – número inicial de componentes, que são iguais, independentes e se encontram nas mesmas condições de serviço

v_g – peso global de cada alternativa

v_i – vetor de prioridades dos critérios

$R(t)$ – probabilidade de sucesso

S_x – número de unidades em risco

z_α – valor crítico associado ao nível de confiança

Alfabeto Grego

β – parâmetro de forma

γ – parâmetro de posição

η – parâmetro de escala

θ – parâmetro

∂ – derivada parcial

Λ – função de verossimilhança logarítmica

λ_{max} – algoritmo de autovalor máximo

$\lambda(t)$ – taxa de avarias

μ – média

ρ – vetor de prioridades

$\hat{\rho}$ – coeficiente de correlação

σ – desvio padrão

$\phi(z)$ – função de distribuição acumulada

Siglas

AHP – Analytic Hierarchy Process

CB – Confidence Bounds

CR – Custo de Reparação

DC – Direct Current

ECU – Electronic Control Unit

ERP – Enterprise Resource Planning

IC – Índice Consistência

IE – Instalação Elétrica

IE2 – Instalação Elétrica 2

IR – Índice Consistência Aleatório

MLE – Maximum Likelihood Estimation

NC – Normally Closed

PA – Pressostato Acumulador

PD – Pressostato Direção

PR – Parafusos e Rótulas

QA – Quantidade de Avarias

R – Record

RC – Razão de Consistência

RRX – Rank Regression on X

RRY – Rank Regression on Y

SC – Sensor de Carga

TR – Tempo de Reparação

TTF – Time to Failure

V - Válvulas

W – Peso

Índice

1. Introdução	1
1.1. Enquadramento	1
1.2. Objetivos	2
1.3. Motivação	2
1.4. Estrutura do Documento	2
2. Metodologia AHP	5
2.1. Conceito	5
2.2. Princípios	6
2.3. Aplicações	11
3. Fiabilidade	13
3.1. Introdução	13
3.2. Conceitos Básicos	14
3.3. Distribuições estatísticas	16
3.3.1. Distribuição de Weibull	16
3.3.2. Distribuição Exponencial	20
3.3.3. Distribuição Normal	22
3.3.4. Distribuição Lognormal	25
3.4. Estimativa de Parâmetros	26
3.4.1. Estimativa por Máxima Verossimilhança	27
3.4.2. Regressão dos Mínimos Quadrados	28
3.4.2.1. Regressão em Y	30
3.4.2.2. Regressão em X	31
3.5. Intervalos de Confiança	32
3.5.1. Matriz de Fisher	31
3.6. Gráfico Nevada	33
4. Caso de Estudo	35
4.1. Análise com Dados de Tempos até à Falha	48
4.1.1. Distribuição Lognormal (Regressão em X)	54
4.1.2. Distribuição Lognormal (Regressão em Y)	57
4.1.3. Distribuição Lognormal (MLE)	61
4.2. Análise com Dados Suspensos	67
4.2.1. Lognormal (MLE) – Dados Suspensos	68
4.2.2. Weibull Triparmétrica (MLE) – Dados Suspensos	74
4.3. Previsão de Garantias	80
5. Conclusões e Trabalhos Futuros	87
Referências	89
Anexo 1 – Tabela de Distribuição Normal Padrão	93
Anexo 2 – Esquema hidráulico	94

Anexo 3 – Esquema elétrico	95
----------------------------------	----

Índice Figuras

Figura 2-1 – Estrutura Hierárquica de AHP	5
Figura 2-2 – Número de artigos sobre AHP em função da área do estudo.....	12
Figura 3-1 – Diferentes tipos de Fiabilidade.....	13
Figura 3-2 – Curvas da Fiabilidade, Taxa de Avarias e Probabilidade de Falha.....	16
Figura 3-3 – Distribuição de Weibull $f(t)$ em função de diferentes valores do parâmetro de posição.....	17
Figura 3-4 – Distribuição de Weibull $f(t)$ para diferentes valores do parâmetro de escala.....	18
Figura 3-5 – Distribuição de Weibull $f(t)$ para diferentes valores do parâmetro de forma.....	18
Figura 3-6 – Modos de falha da curva da banheira em função do parâmetro de forma.....	19
Figura 3-7 – Função densidade de probabilidade em função do tempo.....	21
Figura 3-8 – Taxa de avarias em função do tempo.....	22
Figura 3-9 – Influência dos parâmetros na Distribuição Normal.....	23
Figura 3-10 – Influência dos parâmetros na Distribuição Lognormal.....	26
Figura 3-11 – Regressão Linear em Y (à esquerda) e Regressão Linear em X (à direita).....	28
Figura 3-12 – Variação do valor de coeficiente de correlação e a sua influência.....	29
Figura 3-13 – Exemplo de um intervalo de confiança de 90%.....	32
Figura 3-14 – Exemplo do Gráfico de Nevada (vendas mensais vs retornos por mês).....	34
Figura 4-1 – Estrutura hierárquica da empresa.....	35
Figura 4-2 – Estrutura Hierárquica do Caso de Estudo.....	37
Figura 4-3 – Diagrama Esquemático do Orbitrol – volante para esquerda.....	45
Figura 4-4 – Representação do Orbitrol.....	46
Figura 4-5 – Diagrama do Pressostato do Orbitrol.....	46
Figura 4-6 – Esquema hidráulico do equipamento.....	47
Figura 4-7 – Menu Principal do <i>Reliability4All</i>	49
Figura 4-8 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.....	51
Figura 4-9 – Taxa de avarias em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.....	51
Figura 4-10 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.....	52
Figura 4-11 – Calculadora do <i>Reliability4All</i>	53
Figura 4-12 – Fiabilidade $R(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.....	53
Figura 4-13 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRX.....	55
Figura 4-14 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRX.....	55

Figura 4-15 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) com RRX.....	56
Figura 4-16 – Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRX.....	56
Figura 4-17 – Resultado calculado da Fiabilidade com RRX.....	57
Figura 4-18 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRY.....	58
Figura 4-19 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRY.....	59
Figura 4-20 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) com RRY.....	59
Figura 4-21 – Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRY.....	60
Figura 4-22 – Resultado calculado da Fiabilidade com RRY.....	61
Figura 4-23 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com MLE.....	62
Figura 4-24 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com MLE.....	62
Figura 4-25 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) com MLE.....	63
Figura 4-26 – Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com MLE.....	63
Figura 4-27 – Resultado calculado da Fiabilidade com MLE.....	64
Figura 4-28 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY).....	65
Figura 4-29 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY).....	65
Figura 4-30 – Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY).....	66
Figura 4-31 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY).....	66
Figura 4-32 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.....	69
Figura 4-33 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.....	70
Figura 4-34 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.....	70
Figura 4-35 – Resultado calculado da Fiabilidade incluindo dados suspensos (Lognormal) com MLE.....	71

Figura 4-36 – Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.....	71
Figura 4-37 – Comparação dos gráficos da Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos vs dados fixos + suspensos) com o método MLE.....	73
Figura 4-38 – Comparação dos gráficos da Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos vs dados fixos + suspensos) com o método MLE.....	73
Figura 4-39 – Comparação dos gráficos da taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos vs dados fixos + suspensos) com o método MLE.....	74
Figura 4-40 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.....	75
Figura 4-41 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.....	76
Figura 4-42 – Taxa de avarias em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.....	76
Figura 4-43 – Valor da Fiabilidade obtido na calculadora <i>Reliability4All</i>	77
Figura 4-44 – Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.....	77
Figura 4-45 – Comparação dos gráficos da Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos vs dados fixos + suspensos) com o método MLE.....	79
Figura 4-46 – Comparação dos gráficos da Densidade Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos vs dados fixos + suspensos) com o método MLE.....	79
Figura 4-47 – Comparação dos gráficos da taxa de avarias em função do tempo da Distribuição Weibull 3P (dados fixos vs dados fixos + suspensos) com o método MLE.....	80
Figura 4-48 – Gráfico de Nevada (vendas vs retornos por mês).....	81
Figura 4-49 – Probabilidade de Falha $F(t)$ em função do tempo da Distribuição Weibull 3P (previsão garantias) com o método MLE.....	82
Figura 4-50 – Taxa de avarias em função do tempo da Distribuição Weibull 3P (previsão garantias com o método MLE.....	83
Figura 4-51 – Probabilidade de Sucesso $R(t)$ em função do tempo da Distribuição Weibull 3P (previsão garantias) com o método MLE.....	83

Índice de Tabelas

Tabela 2-1 – Tabela de escala de importância relativa de Saaty.....	7
Tabela 2-2 – Exemplo de uma matriz para os critérios.....	8
Tabela 2-3 – Exemplo de uma matriz normalizada	9
Tabela 2-4 – Tabela do Índice de Consistência Aleatório.....	11
Tabela 3-1 – Intervalos da Distribuição Normal.....	24
Tabela 4-1 – Análise das peças causais em garantia.....	36
Tabela 4-2 – Matriz da comparação par a par dos critérios.....	38
Tabela 4-3 – Matriz auxiliar	38
Tabela 4-4 – Matriz normalizada dos critérios.....	38
Tabela 4-5 – Vetor de prioridades dos critérios.....	39
Tabela 4-6 – Cálculo do Produto.....	40
Tabela 4-7 – Matriz de comparações das alternativas em relação a Quantidade de Avarias....	41
Tabela 4-8 – Matriz de comparações das alternativas em relação ao Custo Médio.....	41
Tabela 4-9 – Matriz de comparações das alternativas em relação ao Tempo Médio.....	42
Tabela 4-10 – Matriz normalizada das alternativas em relação a Quantidade de Avarias e o respetivo vetor prioridades.....	42
Tabela 4-11 – Matriz normalizada das alternativas em relação ao Custo Médio e o respetivo vetor prioridades.....	43
Tabela 4-12 – Matriz normalizada das alternativas em relação ao Tempo Médio e o respetivo vetor prioridades.....	43
Tabela 4-13 – Valores da análise de consistência realizada.....	44
Tabela 4-14 – Peso Global de cada alternativa.....	44
Tabela 4-15 – Características do pressostato.....	47
Tabela 4-16 – Tempos de falha (em horas) do componente pressostato da direção.....	48
Tabela 4-17 – Tempos entre falhas (TTF).....	49
Tabela 4-18 – Parâmetros obtidos para Weibull 3P (dados fixos) com MLE.....	50
Tabela 4-19 – Resultado da distribuição com melhor ajuste segundo <i>Reliability4All</i>	54
Tabela 4-20 – Resultado dos parâmetros da Distribuição Lognormal (dados fixos) com RRX.....	54
Tabela 4-21 – Resultado dos parâmetros da Distribuição Lognormal (dados fixos) com RRY.....	58
Tabela 4-22 – Resultado dos parâmetros da Distribuição Lognormal (dados fixos) com MLE.....	61
Tabela 4-23 – Tabela dados suspensos (S) e de falha (F) do componente...67	
Tabela 4-24 – Listagem de distribuições de melhor ajuste para os dados segundo <i>Reliability4All</i>	68

Tabela 4-25 – Resultado dos paramentos da Distribuição Lognormal (dados fixos + suspensos) com MLE.....	68
Tabela 4-26 – Comparação dos parâmetros da Distribuição Lognormal (dados fixos vs dados fixos + suspensos).....	72
Tabela 4-27 – Resultado dos paramentos da Distribuição Weibull 3P (dados fixos + suspensos) com MLE.....	74
Tabela 4-28 – Comparação dos parâmetros da Distribuição Weibull 3P (dados fixos vs dados fixos + suspensos).....	78
Tabela 4-29 – Resultado dos paramentos da Distribuição Weibull 3P (previsão garantias) com MLE.....	81
Tabela 4-30 – Listagem de distribuições de melhor ajuste para os dados segundo <i>Reliability4All</i>	82
Tabela 4-31 – Simulação da previsão de garantias segundo <i>Reliability4All</i>	84
Tabela 4-32 – Quantidade de garantias registadas.....	84

1. Introdução

1.1. Enquadramento

O tema da fiabilidade na indústria de movimentação de cargas e elevação de pessoas assume um papel crucial na eficiência operacional, segurança e satisfação dos clientes. O presente trabalho aborda as questões associadas às falhas de equipamentos, os custos inerentes, a previsão de retornos em garantia, e as implicações de uma eventual escassez de peças, culminando na importância estratégica da fiabilidade para a competitividade e sustentabilidade das operações.

As falhas em equipamentos de movimentação de cargas e elevação de pessoas representam um desafio significativo. As paragens não programadas, resultantes dessas falhas, comprometem a segurança dos operadores e a continuidade das operações. Identificar e mitigar estas falhas precocemente é fundamental para manter a produtividade e segurança no local de trabalho.

Os custos associados às falhas de equipamentos são substanciais e multifacetados. Incluem não só os custos de reparação e substituição de peças, mas também as perdas de produção e possíveis penalizações contratuais por atrasos na entrega. Além disso, os custos indiretos, como a perda de confiança dos clientes e danos à reputação da empresa, não podem ser negligenciados.

As avarias frequentes ou não antecipadas, podem resultar numa escassez de peças de substituição, agravando ainda mais a situação. A falta de peças prolonga o tempo de inatividade dos equipamentos e aumenta a insatisfação dos clientes. Assim, a gestão eficiente do inventário de peças e a previsão precisa das necessidades de manutenção são essenciais.

Equipamentos não fiáveis resultam em atrasos e interrupções que afetam diretamente os clientes. A insatisfação dos clientes pode levar à perda de contratos, reclamações e danos à imagem da empresa.

A capacidade de prever retornos em garantia é crucial para a gestão de riscos e controlo de custos. A análise de dados históricos de manutenção pode identificar padrões e prever potenciais falhas. Este conhecimento permite às empresas planear antecipadamente, reduzir tempos de inatividade e minimizar custos associados a retornos em garantia.

A aplicação de técnicas avançadas de manutenção preditiva, a utilização de sistemas de monitorização em tempo real e a análise de dados são estratégias eficazes para aumentar a fiabilidade. Adicionalmente, a formação contínua dos operadores e a implementação de melhores práticas de manutenção podem contribuir

significativamente para a redução de falhas e melhoria do desempenho dos equipamentos. Garantir a disponibilidade dos equipamentos é, portanto, crucial para manter a confiança e satisfação dos clientes.

1.2. Objetivos

Os principais objetivos deste trabalho consistem na identificação dos componentes críticos em garantia numa empresa de movimentação de cargas e elevação de pessoas, e a respetiva análise de fiabilidade, promovendo desta forma a melhoria contínua da organização.

Assim, esta dissertação teve como objetivos:

O1 – Identificação do componente crítico a ser estudado, através do método AHP (*Analytic Hierarchy Process*);

O2 – Análise de fiabilidade do componente através do *software* dedicado para este efeito;

O3 – Criação de modelo de previsão de garantias em função das vendas.

1.3. Motivação

A motivação para a realização desta dissertação está intrinsecamente ligada ao conceito de melhoria contínua. No contexto competitivo e dinâmico da indústria de movimentação de cargas e elevação de pessoas, a busca incessante pela melhoria contínua é essencial. Ao focar-se na fiabilidade dos equipamentos, este estudo visa não apenas resolver problemas imediatos, mas também promover uma cultura de excelência operacional, melhorando significativamente a satisfação do cliente.

1.4. Estrutura do Documento

A presente dissertação está organizada por cinco capítulos, sendo o primeiro capítulo referente a Introdução, onde serão abordados tópicos como o enquadramento do trabalho, os objetivos, a motivação e, por último a estrutura do documento. O segundo capítulo está dividido em três subcapítulos, onde serão abordados o conceito, os princípios e as aplicações da Metodologia AHP. O terceiro capítulo está dividido em 6 subcapítulos. Neste caso, no primeiro subcapítulo será feita uma introdução e o segundo abordará os conceitos básicos de Fiabilidade. No terceiro subcapítulo serão descritas as distribuições estatísticas. No quarto subcapítulo serão abordados os métodos de estimativa de parâmetros, enquanto que no quinto subcapítulo serão

referidos os intervalos de confiança, e por último, no sexto subcapítulo onde será feita uma abordagem ao método de previsão de garantias segundo o Gráfico de Nevada. O Capítulo 4 da presente dissertação é referente ao Caso de Estudo onde será feita a escolha do componente segundo a Metodologia AHP, a descrição do mesmo e a respetiva análise de fiabilidade com o auxílio do *software Reliability4All*. Por último, o quinto capítulo desta dissertação é referente às conclusões e trabalhos futuros.

2. Metodologia AHP

2.2. Conceito

A metodologia AHP (*Analytic Hierarchy Process*) foi desenvolvida na década de 1970 por Thomas L. Saaty na Wharton Business School. Pode ser descrita como uma abordagem de tomada de decisão multicritério na qual os fatores são organizados em uma estrutura hierárquica (Kostagiolas, 2012).

Segundo Saaty (2008), o AHP é uma metodologia que usa as comparações par a par, tendo por base as opiniões de especialistas para deduzir escalas de prioridade. Para além de simplificar o processo de tomada de decisão ao permitir comparações diretas entre as opções, este método oferece-nos uma maior compreensão sobre as relações entre as diferentes alternativas em termos de compatibilidade (Lee et al., 2007).

De acordo com o Taherdoost (2017), o AHP é uma ferramenta valiosa e um dos sistemas mais abrangentes para a tomada de decisões em situações complexas que requerem a consideração de múltiplos critérios, incorporando tanto critérios quantitativos quanto qualitativos.

O processo de aplicação do AHP começa quando um problema complexo é decomposto em partes mais gerenciáveis, o que ajuda a estruturar a questão de maneira lógica e organizada, facilitando a análise e comparação independentes de cada componente (Figura 2-1) (Vargas, 2010).

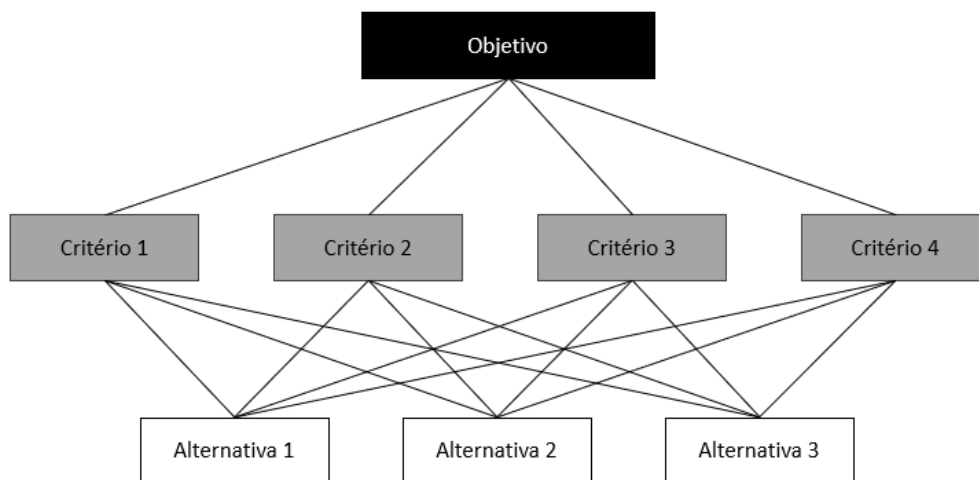


Figura 2-1 - Estrutura Hierárquica de AHP.

Adaptado de (Vargas, 2010).

O objetivo representa o resultado desejado ou propósito orientador do processo de tomada de decisão. Os critérios são fatores específicos que servem de base para avaliar e analisar diferentes alternativas. As alternativas referem-se às várias escolhas disponíveis para avaliação em relação aos critérios (Khaira & Dwivedi, 2018).

Uma vez construída essa hierarquia lógica, os tomadores de decisão podem avaliar as alternativas de forma sistemática. Isso é feito através de comparações em pares para cada critério previamente estabelecido. Durante essas comparações, os tomadores de decisão podem utilizar dados específicos relacionados às alternativas ou fazer julgamentos subjetivos. Esta flexibilidade permite incorporar tanto informações objetivas quanto subjetivas no processo de tomada de decisão (Vargas, 2010).

2.2. Princípios

A adaptação do AHP para diferentes contextos ou a incorporação de melhorias específicas são áreas em que os cientistas podem divergir na descrição detalhada das etapas do método (Carvalho, 2019).

No entanto, de acordo com Saaty (2008), Vargas (2010) e Wollmann et al. (2014) o processo tem 5 fases principais:

1. Definição do Problema

Nesta fase, é necessário clarificar de forma precisa o problema a resolver e especificar o tipo de informação desejada para o processo de tomada de decisão.

2. Estruturação da Hierarquia de Decisão

Organização do problema de decisão numa estrutura hierárquica (*top-down*), começando com o objetivo geral, seguindo os níveis intermédios (critérios) e terminando com um conjunto de alternativas no nível mais baixo.

3. Construção das Matrizes de Comparação Par a Par.

Após a escolha do objetivo e a decomposição hierárquica dos elementos, segue-se a realização das comparações par a par. As mesmas são feitas utilizando a escala de importância relativa de Saaty, cujos valores, definição e explicações se podem observar na Tabela 2-1.

Tabela 2-1 – Tabela de escala de importância relativa de Saaty.

Adaptado de (Saaty, 2008; Vargas, 2010).

Escala de importância	Definição	Explicação	Recíproco
9	Importância Absoluta	As evidências que favorecem uma atividade em relação a outra são da mais alta ordem possível de afirmação	$1/9$
7	Importância Muito Forte	Uma atividade é muito fortemente favorecida em relação a outra, a sua supremacia é demonstrada na prática	$1/7$
5	Importância Forte	A experiência e o julgamento favorecem fortemente uma atividade em relação a outra	$1/5$
3	Importância Moderada	A experiência e o julgamento favorecem ligeiramente uma atividade em relação a outra	$1/3$
1	Igual Importância	As duas alternativas são igualmente importantes para o objetivo	1
2,4,6,8	Valores Intermediários	Utilizados para expressar importâncias que são intermédias entre as descrições principais da escala	$1/2, 1/4, 1/6, 1/8$

Tendo por base a escala de importância apresentada, será possível realizar as comparações par a par e desenvolver as respectivas matrizes. Primeiramente, as comparações são feitas ao nível dos critérios. Um exemplo de matriz de comparação par a par pode ser visto na Tabela 2-2 (Wollmann et al., 2014).

Tabela 2-2 – Exemplo de uma matriz para os critérios.

Adaptado de (Wollmann et al., 2014).

Critérios	Critério 1	Critério 2	Critério N
Critério 1	1	$1/a_{21}$	$1/a_{N1}$
Critério 2	a_{21}	1	$1/a_{N2}$
.....
Critério N	a_{N1}	a_{N2}	1

$$C = \begin{bmatrix} 1 & 1/a_{21} & 1/a_{31} \\ a_{21} & 1 & \frac{1}{a_{32}} \\ a_{31} & a_{32} & 1 \end{bmatrix}$$

Posteriormente, será efetuado o mesmo processo para o nível inferior, isto é, as alternativas serão comparadas entre si em relação a um critério específico.

4. Determinação do peso relativo de cada elemento da estrutura hierárquica

Em seguida, a matriz é normalizada para garantir que os valores expressem relações proporcionais. A normalização da matriz pelo método da soma é obtida através da Equação 2.1, e que envolve dividir cada elemento na matriz pelo somatório dos elementos em sua coluna (Wieckowski & Salabun, 2020). Um exemplo da matriz normalizada pode ser observado na Tabela 2-3, onde n_{ij} representa o elemento normalizado na linha i e coluna j , o a_{ij} representa o elemento correspondente na matriz original.

$$n_{ij} = \frac{a_{ij}}{\sum_{i=1}^m a_{ij}} \quad (2.1)$$

Tabela 2-3 – Exemplo de uma matriz normalizada.

Adaptado de (Wollmann et al., 2014).

Critérios	Critério 1	Critério 2	Critério N
Critério 1	n_{11}	n_{12}	n_{1N}
Critério 2	n_{21}	n_{22}	n_{2N}
.....
Critério N	n_{N1}	n_{N2}	n_{NN}

$$C = \begin{bmatrix} n_{11} & n_{12} & n_{13} \\ n_{21} & n_{22} & n_{23} \\ n_{31} & n_{32} & n_{33} \end{bmatrix}$$

A partir do conjunto de critérios normalizados, é possível obter os pesos relativos. O vetor de prioridades dos critérios v_i é determinado através do cálculo da média aritmética dos elementos das respectivas linhas, conforme ilustrado pela Equação 2.2.

$$v_i = \frac{\sum_{j=1}^m n_{ij}}{N} \quad (2.2)$$

Por outras palavras, os valores normalizados são somados ao longo das linhas, cujo valor final é dividido pelo número de colunas, proporcionando pesos que indicam a importância relativa de cada critério em relação aos outros.

Da mesma forma, o mesmo processo matemático é realizado para cada uma das alternativas. Os valores dos pesos representam a classificação das alternativas sob a perspectiva de cada atributo.

Finalmente, o resultado da análise é determinado através da Equação 2.3, obtendo-se o peso global de cada alternativa sob a perspectiva de todos os critérios.

$$v_g = \sum_1^m (v_i) \cdot (w_i) \quad (2.3)$$

5. Verificação da consistência dos dados

Pretende-se reunir informação suficiente para determinar se os decisores mantiveram consistência nas suas escolhas. Isto implica analisar os dados recolhidos para garantir que as comparações feitas durante o processo de tomada de decisão estejam em linha com padrões lógicos e coerentes. Por exemplo, se $A > B$ e $B > C$, seria inconsistente afirmar que $A < C$. O intuito é detetar discrepâncias ou contradições nas preferências ou classificações dos decisores, assegurando a fiabilidade e precisão das informações recolhidas. A verificação da consistência dos dados começa pelo cálculo do algoritmo de autovalor máximo que corresponde ao produto da matriz de comparação (A) com o vetor de prioridades (p), sendo em seguida realizado o somatório da divisão do produto pelo peso relativo, multiplicado pelo inverso do grau da matriz, cuja fórmula pode ser vista na Equação 2.5.

$$\lambda_{max} = \frac{1}{n} \sum_{i=1}^n v_i \frac{Aw_i}{w_i} \quad (2.4)$$

Depois de encontrar o λ_{max} é possível realizar o cálculo do índice de consistência (IC) através da Equação 2.5, onde n representa a ordem da matriz.

$$IC = \frac{\lambda_{max} - n}{n - 1} \quad (2.5)$$

De maneira a verificar e avaliar a adequabilidade do índice de consistência, Saaty sugere o que chama de razão de consistência (RC), que é determinada pela divisão do índice de consistência pelo índice de consistência aleatório (IR):

$$RC = \frac{IC}{IR} \quad (2.6)$$

A matriz será considerada consistente se o $RC < 0,10$. Caso $RC > 0,10$, o processo necessita de ser revisto. Os valores de IR em função da ordem da matriz podem ser vistos na Tabela 2-4.

Tabela 2-4 – Tabela do Índice de Consistência Aleatório.

Adaptado de (Vargas, 2010).

N	1	2	3	4	5	6	7	8	9	10
IR	0	0	0.58	0.9	1.12	1.24	1.32	1.41	1.45	1.49

2.3. Aplicações

Qualquer situação que exija estruturação, medição e/ou síntese é uma boa candidata para a aplicação do Processo Analítico Hierárquico (AHP). Áreas abrangentes onde o AHP tem sido bem-sucedido incluem: Escolha, Priorização/Avaliação, Alocação de Recursos, Gestão de Qualidade, Políticas Públicas, Cuidados de Saúde ou Planejamento Estratégico. Este método é valioso nestes contextos devido à sua capacidade de lidar com múltiplos critérios, facilitando a tomada de decisões estratégicas e complexas (Forman & Gass, 2001).

Um dos estudos mais abrangentes do AHP foi realizado por Emrouznejad e Marra. Nesse estudo foram analisados 8441 artigos na base de dados *Web of Science* abrangendo um período extenso de 1979 a 2017. O estudo dividiu a evolução do AHP em três períodos distintos. No primeiro período (1979-1990), o foco estava na construção das bases teóricas do AHP, o segundo período (1991-2001) testemunhou um aumento nas aplicações práticas em campos como ciência da computação, matemática, negócios, gestão e por último, o terceiro período (2002-2017) foi caracterizado pela expansão do AHP para áreas como a abordagem *fuzzy* (Emrouznejad & Marra, 2017; Madzík & Falát, 2022).

Um outro estudo mais recente realizado por Madzík e Falát analisou 34530 documentos relacionados com o AHP, publicados entre 1980 e 2021 obtidos na base de dados Scopus. Os autores deste estudo relatam que o notável crescimento de publicações deste método se deve a facilidade de aplicação, lógica e flexibilidade do processo. A tomada de decisão está presente praticamente em todas as áreas de pesquisa, razão pela qual a aplicação do AHP tem sido utilizada em setores como engenharia, ciência da computação, negócios e gestão, matemática e ciências sociais (Madzík & Falát, 2022). Na Figura 2-2 é possível observar o número de artigos sobre o Processo Analítico Hierárquico publicados em função da área de estudo que foram analisados pelo Madzík e Falát.




Figura 2-2 – Número de artigos sobre AHP em função da área do estudo.

Adaptado de (Madzík & Falát, 2022).

3. Fiabilidade

3.1. Introdução

A fiabilidade é uma das características de qualidade exigidas pelos consumidores aos fabricantes de produtos ou fornecedores de serviços. Infelizmente, quando questionados sobre o que significa fiabilidade, as respostas dos consumidores tendem a ser pouco claras. Alguns podem mencionar que o produto deve funcionar sempre corretamente, sem falhas, ou que deve desempenhar a sua função de forma adequada quando necessário. Outros, no entanto, podem ter dificuldade em explicar o significado exato da fiabilidade para eles (Elsayed, 2021).

Do ponto de vista técnico, a fiabilidade é uma característica de um item, expressa pela probabilidade de que o item desempenhará a sua função em condições específicas ao longo de um intervalo de tempo determinado (Biolini, 2007). Geralmente, essa probabilidade é designada por $R(t)$. Qualitativamente, a fiabilidade pode ser definida como a capacidade do item de se manter funcional. De uma perspetiva quantitativa, a fiabilidade especifica a probabilidade de que não ocorram interrupções operacionais durante um intervalo de tempo pré-determinado. Esta definição formal destaca que a fiabilidade não impede que partes redundantes possam falhar (Elsayed, 2021). No entanto, mesmo quando há falhas, a fiabilidade considera a capacidade de reparação sem interrupção operacional ao nível do item ou sistema. O conceito de fiabilidade, portanto, aplica-se tanto a itens não reparáveis quanto a itens reparáveis (Biolini, 2007). A Figura 3-1 ilustra os dois principais tipos de fiabilidade, divididos entre a perspetiva do fabricante e a do utilizador. A fiabilidade intrínseca, também chamada de previsional, está relacionada com o desempenho esperado de um sistema ou produto à saída da fábrica, de acordo com os padrões estabelecidos pelo fabricante. Por outro lado, a fiabilidade extrínseca refere-se ao desempenho real do produto durante a sua utilização, sendo demonstrada e observada em serviço pelo utilizador.

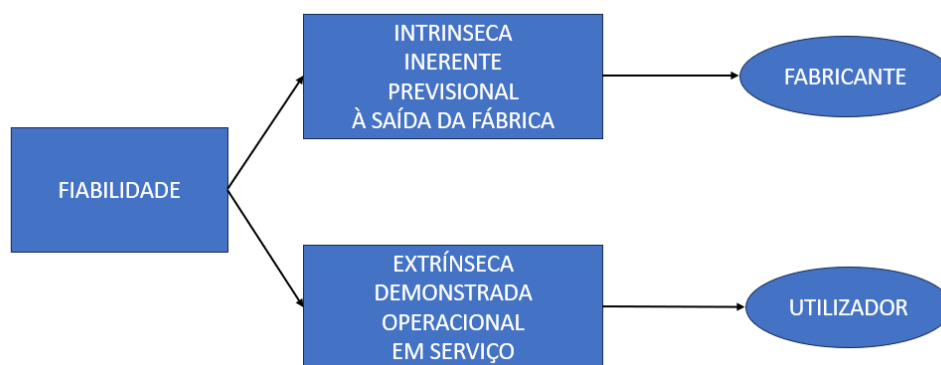


Figura 3-1 – Diferentes tipos de Fiabilidade.

Fonte (Sobral, 2020).

Formalmente, a fiabilidade é encarada como uma noção tanto de engenharia como probabilística. Na verdade, ambas essas perspetivas constituem a base fundamental para os estudos de fiabilidade. A noção de engenharia de fiabilidade lida com atividades de projeto e análise que prolongam a vida de um item ao controlar os seus potenciais modos de falha. Exemplos incluem o projeto de elementos mais robustos e duráveis, a proteção contra condições ambientais adversas, a minimização de cargas e tensões aplicadas a um item durante a sua utilização e a implementação de um programa de manutenção preventiva para reduzir a ocorrência de falhas (Modarres et al., 2016)

Em resumo, a fiabilidade refere-se à capacidade de um produto ou serviço cumprir a sua função ao longo do tempo, sendo uma combinação de características de desempenho, durabilidade e capacidade de manutenção (Elsayed, 2021). A fiabilidade é definida pela norma NP EN 13306 (2017) como sendo a “aptidão de um bem para cumprir uma função requerida sob determinadas condições, durante um dado intervalo de tempo”.

3.2. Conceitos Básicos

A probabilidade de sucesso de um componente durante um determinado intervalo de tempo pode ser definido pela função $R(t)$. Esta função pode ser expressa pela seguinte equação:

$$R(t) = \frac{n_s(t)}{n_s(t)+n_f(t)} = \frac{n_s(t)}{n_o} \quad (3.1)$$

Onde:

n_s - número de componentes sobreviventes no momento t ;

n_f - número de componentes falhados no momento t ;

n_o - número inicial de componentes, que são iguais, independentes e se encontram nas mesmas condições de serviço (Carinhas, 2009).

Neste sentido, a probabilidade de falha será dada pela Equação 3.2

$$F(t) = \frac{n_f(t)}{n_s(t)+n_f(t)} = \frac{n_f(t)}{n_o} \quad (3.2)$$

A relação de complementaridade entre a probabilidade de falha, $F(t)$, e a probabilidade de sobrevivência, $R(t)$, pode ser comprovada pelas equações (3.1) e (3.2), obtendo-se:

$$R(t) + F(t) = 1 \quad (3.3)$$

Neste caso, se $R(t)=0,25$, significa que 75% dos componentes são previstos falhar até ao instante t .

A função densidade de probabilidade de falha (FDP), ou $f(t)$, pode ser definida como a probabilidade da falha instantânea num determinado instante t . Neste caso, pode-se considerar que a probabilidade de falha acumulada será dada pela seguinte equação (Carinhas, 2009):

$$F(t) = \int_0^t f(t) dt \quad (3.4)$$

Ao derivar a Equação 3.4 obtêm-se a fórmula que descreve o cálculo da função probabilidade de falha instantânea:

$$f(t) = \frac{dF(t)}{dt} \quad (3.5)$$

Geralmente, pode-se conhecer mais sobre os mecanismos da falha ao analisar o comportamento da taxa de avarias que também é referida como a taxa de risco ou taxa de mortalidade. A função $\lambda(t)$ representa a taxa a que os componentes estão a falhar por unidade de tempo, no instante t e pode ser definida pelas seguintes expressões (Carinhas, 2009):

$$\lambda(t) = \frac{f(t)}{R(t)} \quad (3.6)$$

$$\lambda(t) = -\frac{1}{R(t)} \frac{d}{dt} R(t) \quad (3.7)$$

Por sua vez, através da Equação 3.8, é possível obter a expressão que permite o cálculo da fiabilidade de um componente em função da sua taxa de avarias:

$$R(t) = e^{-\int_0^t \lambda(t) dt} \quad (3.8)$$

Na Figura 3-2 é possível observar as curvas das funções anteriormente abordadas, nomeadamente a fiabilidade, probabilidade de falha e taxa de avarias. A curva da taxa de avarias ou a “curva da banheira” representa os diferentes estágios de

um componente ou sistema reparável. A mortalidade infantil representa a fase inicial onde a taxa de avarias é elevada (embora que decrescente). Na fase da vida útil, a curva estabiliza e indica uma taxa de avarias constante. Na fase do desgaste, o número de falhas é cada vez maior, muitas vezes provocado pelo desgaste natural do componente ao longo do tempo. É importante referir que nesta Figura, as escalas das ordenadas são distintas, isto é, para a Fiabilidade varia entre 0 e 1, enquanto que para a probabilidade de falha instantânea e a taxa de avarias, o valor representa o número de falhas por unidade de tempo (Sobral, 2020).

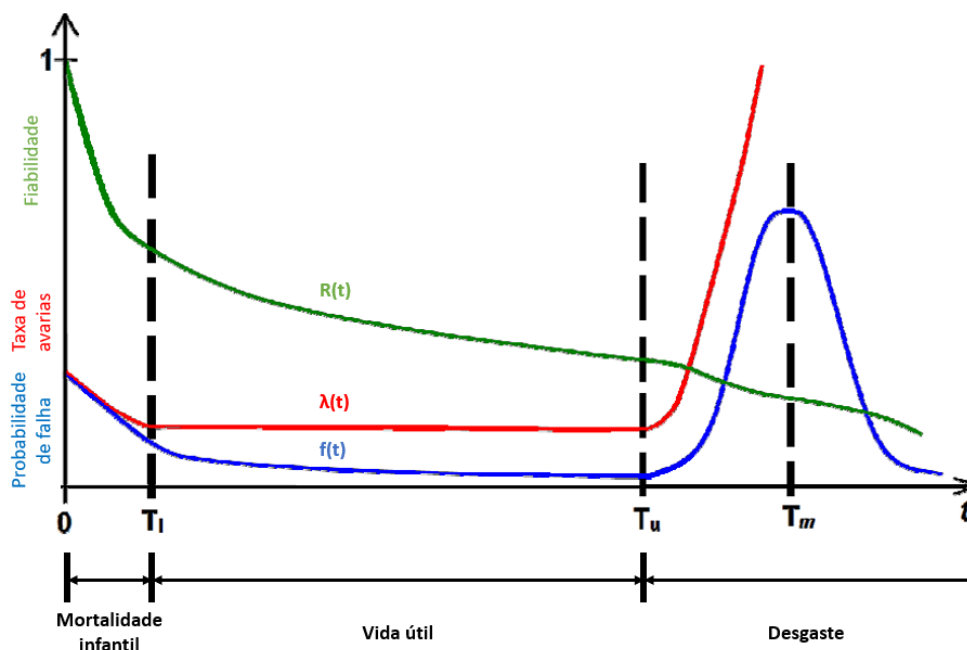


Figura 3-2 – Curvas da Fiabilidade, Taxa de Avarias e Probabilidade de Falha.

Adaptado de (Marques, 2015).

3.3. Distribuições estatísticas

Neste subcapítulo serão descritas as distribuições estatísticas amplamente utilizadas na análise de fiabilidade, abordando as suas características fundamentais e propriedades distintivas.

3.3.1. Distribuição de Weibull

A Distribuição de Weibull é uma distribuição de probabilidade contínua, assim denominada em honra a Waloddi Weibull, que a descreveu detalhadamente em 1951.

Desde então, a distribuição de Weibull tornou-se uma das distribuições de tempo de vida mais referenciadas em engenharia de fiabilidade. A Distribuição de Weibull é capaz de descrever de forma precisa os tempos de falha observados em vários tipos de componentes e fenómenos (Lai, 2014).

A função densidade de probabilidade para a Distribuição de Weibull na sua forma tripamétrica é dada por (Kececioglu, 2002):

$$f(t) = \left(\frac{\beta}{\eta}\right) \cdot \left(\frac{t-\gamma}{\eta}\right)^{\beta-1} \cdot e^{-\left(\frac{t-\gamma}{\eta}\right)^{\beta}} \quad (3.9)$$

Onde:

- $f(t) \geq 0, t \geq \gamma, \beta > 0, \eta > 0, -\infty < \gamma < +\infty$
- β é o parâmetro de forma
- η é o parâmetro de escala
- γ é o parâmetro de posição

O parâmetro γ é denominado de atraso, tempo de garantia, ou mais comumente, vida inicial. Do ponto de vista estatístico, é um parâmetro de posição. Isso significa que, ao alterar γ enquanto os outros parâmetros permanecem constantes, resultará num deslocamento da curva de densidade sobre o eixo horizontal (Rinne, 2008).

Quando γ é menor que zero, indica que o ativo possui falhas crônicas ou algum problema durante a recolha e/ou tratamento dos dados. Quando γ é maior que zero, indica um comportamento mais coerente com o ciclo de vida de um ativo, considerando que o mesmo apresenta uma vida inicial antes da primeira falha (Rocha & Morais, 2020).




Figura 3-3 – Distribuição de Weibull $f(t)$ em função de diferentes valores do parâmetro de posição. Adaptado de (Rinne, 2008).

O parâmetro η é denominado de vida característica. Do ponto de vista estatístico, é um parâmetro de escala. Indica o tempo em que existe uma probabilidade de falha de 63.2%. Como é possível observar na Figura 3-4, quando η é aumentado, enquanto os parâmetros β e γ são mantidos constantes, a distribuição se estende ou alonga para a direita (Rinne, 2008).




Figura 3-4 - Distribuição de Weibull $f(t)$ para diferentes valores do parâmetro de escala. Adaptado de (Rinne, 2008).

O terceiro parâmetro, também conhecido como inclinação da Distribuição de Weibull, é representado pelo símbolo β . Do ponto de vista estatístico, β é um parâmetro de forma. Na Figura 3-5, pode-se observar como a variação desse parâmetro influencia o gráfico da função de distribuição (Rinne, 2008).




Figura 3-5 - Distribuição de Weibull $f(t)$ para diferentes valores do parâmetro de forma. Adaptado de (Rinne, 2008).

Podem-se destacar as principais características o parâmetro de forma (β) (O'Connor et al., 2016) (Galar & Kumar, 2017):

- Se $\beta < 1$ – A taxa de falhas decresce com o tempo (mortalidade infantil);
- Se $\beta = 1$ – Indica falhas aleatórias, constantes e independentes do tempo (distribuição exponencial);
- Se $\beta > 1$ – A taxa de falhas é crescente ao longo do tempo
- Se $3 < \beta < 4$ – A taxa de falhas aproxima-se a uma distribuição normal.
- Se $\beta > 3,4$ – Indica falhas de desgaste acentuado;




Figura 3-6 – Modos de falha da curva da banheira em função do parâmetro de forma. Adaptado de (Galar & Kumar, 2017).

Após se ter escrito os parâmetros fundamentais desta distribuição e a sua influência, é altura de abordar a função de fiabilidade da Distribuição de Weibull que na sua forma triparamétrica é dada por (Kececioglu, 2002):

$$R(t) = e^{-\left(\frac{t-\gamma}{\eta}\right)^\beta} \quad (3.10)$$

Quando a probabilidade de falha se pode verificar logo após a entrada em funcionamento, ou seja, a distribuição começa no ponto de origem ($\gamma=0$). Nessa situação, tanto a função de fiabilidade quanto a função de densidade de probabilidade de falha da Distribuição de Weibull são simplificadas para uma forma biparamétrica. Essas equações podem ser representadas por (Kececioglu, 2002):

$$f(t) = \left(\frac{\beta}{\eta}\right) \cdot \left(\frac{t}{\eta}\right)^{\beta-1} \cdot e^{-\left(\frac{t}{\eta}\right)^\beta} \quad (3.11)$$

$$R(t) = e^{-\left(\frac{t}{\eta}\right)^\beta} \quad (3.12)$$

Conforme previamente discutido, quando o parâmetro de forma (β) é igual a 1, pode-se dizer que se está perante uma distribuição com taxa de falhas constante, uma característica típica de uma distribuição exponencial, assunto a ser detalhado no próximo subcapítulo. Nessa circunstância, as equações são simplificadas e a distribuição de Weibull assume uma forma monoparamétrica.

$$f(t) = \left(\frac{1}{\eta}\right) \cdot e^{-\left(\frac{t}{\eta}\right)} \quad (3.13)$$

$$R(t) = e^{-\left(\frac{t}{\eta}\right)} \quad (3.14)$$

Os principais domínios onde a distribuição de Weibull tem sido comumente aplicada são: (O'Connor et al., 2016)

- Análise de garantia
- Manutenção e renovação
- Modelação da resistência de materiais
- Modelação do desgaste
- Modelação de falhas eletrónicas
- Modelação de corrosão

3.3.2. Distribuição Exponencial

A Distribuição Exponencial desempenha um papel crucial devido à sua aplicabilidade em muitos processos que exibem comportamento à falha do tipo aleatório (Dunn & Shultis, 2012). Na engenharia de fiabilidade esta distribuição é frequentemente utilizada por representar empiricamente a distribuição do tempo até à falha de componentes, equipamentos e sistemas complexos, os quais possuem individualmente diferentes distribuições de vida. Esta distribuição é caracterizada por uma taxa de falha constante ao longo do tempo de operação. As falhas que exibem esta característica são designadas por falhas aleatórias. Portanto, a Distribuição Exponencial é amplamente utilizada para modelar o tempo até à falha em situações em que as falhas ocorrem de forma aleatória e com uma taxa constante ao longo do tempo (Kececioglu, 2002). Em geral, as distribuições de vida dos componentes não possuem uma taxa de falha

constante, devido ao desgaste ou a falhas prematuras. Neste sentido, a Distribuição Exponencial não costuma ser a mais apropriada para modelar a maioria das distribuições de vida, especialmente de componentes mecânicos (O'Connor et al., 2016).

A expressão matemática que descreve a função densidade de probabilidade para a Distribuição Exponencial pode ser vista na Equação 3-15, enquanto a Figura 3-7 representa o gráfico desta distribuição (Kissell & Poserina, 2017).

$$f(t) = \lambda e^{-\lambda t} \quad (3.15)$$




Figura 3-7 – Função densidade de probabilidade em função do tempo.

Fonte: (O'Connor et al., 2016).

Pode-se neste caso referir que a Distribuição Exponencial Negativa, ao contrário da Distribuição de Weibull, necessita de apenas um parâmetro, isto é, λ . A expressão matemática que descreve a função de fiabilidade para a Distribuição Exponencial pode ser vista na Equação 3-16, enquanto a Figura 3-8 representa o gráfico da taxa de avarias constante da distribuição exponencial (Kissell & Poserina, 2017).

$$R(t) = e^{-\lambda t} \quad (3.16)$$




Figura 3-8 – Taxa de avarias em função do tempo.

Fonte: (O'Connor et al., 2016).

Os exemplos de componentes onde a distribuição exponencial tem sido comumente aplicada são (O'Connor et al., 2016):

- Componentes sem desgaste

A Distribuição Exponencial é utilizada para estimar a taxa de falha durante o período útil de vida de um componente, após o período de rodagem e antes do desgaste ocorrer;

- Componentes eletrônicos

Alguns componentes eletrônicos, como condensadores ou circuitos integrados, demonstraram seguir uma distribuição exponencial;

- Choques aleatórios

A Distribuição Exponencial é comum para modelar a ocorrência de choques aleatórios. Um exemplo é a falha de um pneu de veículo devido a uma perfuração causada por um prego.

3.3.3. Distribuição Normal

A Distribuição Normal também conhecida como Distribuição Gaussiana, é uma das bases fundamentais da teoria estatística. Caracteriza-se pela sua forma em sino, simétrica em relação à média, onde a maior parte dos dados está concentrada próximo desta e diminui gradualmente em direção às caudas (Kissell & Poserina, 2017).

A média (μ) e o desvio padrão (σ) são os parâmetros desta distribuição, e definem a sua função densidade de probabilidade que pode ser vista na Equação 3.17 (Dunn & Shultis, 2012).

$$f(t) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2}, -\infty < t < \infty \quad (3.17)$$

A média atua como o parâmetro de localização da função densidade de probabilidade e determina o centro da distribuição ao longo do eixo horizontal. A média representa o valor médio ou esperado da distribuição. O desvio padrão, por sua vez, funciona como o parâmetro de escala. À medida que o desvio padrão diminui, a distribuição torna-se mais estreita e mais alta, indicando que os pontos de dados estão mais concentrados em torno da média. Por outro lado, um desvio padrão maior resulta numa distribuição mais larga e mais baixa, o que significa uma maior dispersão ou variabilidade nos dados.

Resumidamente, a média determina a tendência central da distribuição, enquanto o desvio padrão controla a sua dispersão (Kececioglu, 2002). Na Figura 3-9 pode-se observar a influência de diferentes valores do desvio padrão e da média na Distribuição Normal.




Figura 3-9 – Influência dos parâmetros na Distribuição Normal.

Fonte: (O'Connor et al., 2016).

É habitual descrever os intervalos da Distribuição Normal em relação à distância da média, utilizando unidades de desvio padrão. Os valores aproximados para esses intervalos podem ser vistos na Tabela 3-1.

Tabela 3-1 – Intervalos da Distribuição Normal.

Fonte: (O'Connor et al., 2016).

Intervalo	$\Phi(\mu + n\sigma) - \Phi(\mu - n\sigma)$
$\mu \pm \sigma$	68.27%
$\mu \pm 2\sigma$	95.45%
$\mu \pm 3\sigma$	99.73%
$\mu \pm 4\sigma$	99.99%
$\mu \pm 5\sigma$	99.99%
$\mu \pm 6\sigma$	99.99%

Quando se tem uma variável aleatória t que segue uma Distribuição Normal com uma média (μ) e um desvio padrão (σ), pode-se fazer uma transformação, utilizando a Equação 3.18 para uma variável Z que segue a distribuição normal padrão (O'Connor et al., 2016). O resultado obtido é depois utilizado na Tabela da Distribuição Normal Padrão que pode ser visualizada no Anexo 1.

$$Z = \frac{t - \mu}{\sigma} \quad (3.18)$$

Basicamente, a Distribuição Normal Padrão é uma forma específica da Distribuição Normal em que a média é 0 e o desvio padrão é 1. Esta distribuição é representada matematicamente pela função densidade de probabilidade $\phi(z)$ e pela função de distribuição acumulada $\Phi(z)$. A equação da função densidade de probabilidade padrão é a seguinte:

$$\phi(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} \quad (3.19)$$

Alguns exemplos de aplicações da Distribuição Normal são: (O'Connor et al., 2016)

- Gestão da Qualidade *Six Sigma*;
- Manutenções preventivas, inspeções ou reparações simples;
- Gestão do inventário.

3.3.4. Distribuição Lognormal

A Distribuição Lognormal é uma distribuição contínua de uma variável aleatória cujo logaritmo natural segue uma Distribuição Normal. Por exemplo, se a variável aleatória y tem uma Distribuição Lognormal com $y = e^x$ então $x = \log(y)$ tem uma Distribuição Normal (Kissell & Poserina, 2017). A função da densidade de probabilidade da Distribuição Lognormal é definida pela seguinte equação:

$$f(t) = \frac{1}{\sqrt{2\pi}\sigma_N t} e^{-\frac{1}{2}\left(\frac{\ln(t)-\mu_N}{\sigma_N}\right)^2}, -\infty < \mu_N < \infty, \sigma_N > 0 \quad (3.20)$$

Sendo que, a função de fiabilidade $R(t)$ para a Distribuição Lognormal é expressa como (Hottinger Bruel & Kjaer Inc., 2024):

$$R(t) = \int_t^{\infty} f(x)dx \quad (3.21)$$

Ao contrário da Distribuição Normal, na Distribuição Lognormal, o parâmetro μ_N determina a escala e não a posição. A distribuição é fixada em $f(0)=0$ e um aumento no parâmetro de escala estica a distribuição ao longo do eixo. Isso tem o efeito de aumentar a moda, a média e a mediana da distribuição (O'Connor et al., 2016). Este parâmetro pode ser obtido através da seguinte equação:

$$\mu_N = \ln\left(\frac{\mu^2}{\sqrt{\mu^2 + \sigma^2}}\right) \quad (3.22)$$

O parâmetro σ_N , por sua vez, é o parâmetro de forma. Quanto menor for o σ_N , mais estreita e mais alta é a distribuição. Para valores de $\sigma_N > 1$ a distribuição é mais larga e tem uma cauda mais longa com uma maior dispersão de dados (O'Connor et al., 2016). Este parâmetro pode ser obtido através da seguinte equação:

$$\sigma_N^2 = \ln\left(\frac{\mu^2 + \sigma^2}{\mu^2}\right) \quad (3.23)$$

Na Figura 3-10 pode-se observar a influência dos parâmetros descritos na Distribuição Lognormal.




Figura 3-10 - Influência dos parâmetros na Distribuição Lognormal.

Fonte: (O'Connor et al., 2016).

Alguns exemplos de aplicações da Distribuição Lognormal são (O'Connor et al., 2016),(Kissell & Poserina, 2017):

- Finanças – para modelar uma variedade de fenômenos, como por exemplo os preços das ações os índices de mercado ou os retornos de ativos;
- Tempos de reparações – a Distribuição Lognormal é uma escolha adequada para modelar os tempos de reparação, capturando a assimetria e a tendência de os tempos de reparações complexas aumentarem gradualmente após ultrapassarem a média.
- Modos de falha devido a erros multiplicativos - Aplicações específicas incluem a falha de componentes devido a fissuras por fadiga. Isso ocorre porque a Distribuição Lognormal é capaz de capturar a natureza multiplicativa das falhas, onde pequenas variações ou erros podem se acumular ao longo do tempo e levar a falhas catastróficas em componentes sujeitos a stress repetitivo, como os causados por fadiga mecânica.

3.4. Estimativa de Parâmetros

Neste subcapítulo são explorados os principais métodos para estimar os parâmetros da distribuição escolhida na análise de dados de vida. Os métodos discutidos serão: a Regressão dos Mínimos Quadrados, isto é, a Regressão em X e a Regressão em Y, e o Método da Máxima Verossimilhança.

3.4.1. Estimativa por Máxima Verossimilhança

O Método MLE (Estimativa por Máxima Verossimilhança) será um dos métodos a ser utilizado no Capítulo 4, referente ao caso de estudo. Do ponto de vista estatístico, este método é geralmente considerado o mais robusto de todas as técnicas, contudo com algumas exceções. O método MLE é muito eficiente e consistente para grandes amostras, isto é, à medida que o tamanho da amostra aumenta, as estimativas obtidas convergem para os valores mais precisos (Ikbal et al., 2022). No entanto, para uma melhor eficiência do MLE, o tamanho da amostra não deverá ser inferior a 30. Para além disso, a Estimativa por Máxima Verossimilhança poderá ser usada para análises com tempos suspensos e tempos exatos, o que representa uma vantagem em relação a Regressão Linear (Hottinger Bruel & Kjaer Inc., 2024).

A expressão matemática que descreve a função de verossimilhança pode ser vista na Equação 3.24, enquanto que a expressão para a função de verossimilhança logarítmica está descrita na Equação 3.25 (Sousa, 2018).

$$L = \prod_{i=1}^R f(x_i; \theta_1, \theta_2 \dots, \theta_k) \quad (3.24)$$

$$\Lambda = \ln L = \sum_{i=1}^R \ln f(x_i; \theta_1, \theta_2 \dots, \theta_k) \quad (3.25)$$

Onde:

- $\theta_1, \theta_2 \dots, \theta_k$ são os parâmetros;
- x é a amostra;
- $f(x_i; \theta)$ é a função de densidade de probabilidade.
- R representa o número de unidades com falhas exatas

Desta maneira, os estimadores de Máxima Verossimilhança de $\theta_1, \theta_2 \dots, \theta_k$ são encontrados ao maximizar L ou Λ , que no caso de Λ corresponde a:

$$\frac{\partial \Lambda}{\partial \theta_j} = 0, \quad j = 1, 2 \dots, k \quad (3.26)$$

O objetivo da Estimativa por Máxima Verossimilhança é encontrar o valor do parâmetro θ que maximiza a função de verossimilhança, ou seja, o valor que torna os dados observados mais prováveis de acordo com o modelo assumido (Sugiyama, 2016). A título de exemplo, ao escolher a Distribuição de Weibull para o Caso de Estudo, e tendo uma amostra de tempos até a falha de um componente, é possível utilizar a estimativa por máxima verossimilhança para estimar os valores dos parâmetros de

escala, forma e localização que melhor se ajustam aos dados, ao maximizar a função de verossimilhança correspondente à Distribuição de Weibull.

3.4.2. Regressão dos Mínimos Quadrados

O método dos mínimos quadrados é bastante útil pelo facto de ser fiável, relativamente simples e sem necessidade de recorrer a técnicas numéricas extensas. No entanto, este método não deverá ser utilizado para análises de vida com utilização de tempos suspensos, sendo particularmente eficaz nas análises de tempos de falha exatos. Para além disso, este método não é usado para as distribuições Weibull Triparamétrica, Weibull Mista, Gama ou Gama Generalizada, casos onde uma técnica de regressão não linear é utilizada (Sobral, 2020).

A análise de regressão ajusta matematicamente a melhor linha reta a um conjunto de pontos, com o objetivo de estimar os parâmetros. O método dos mínimos quadrados requer que uma linha reta seja ajustada a um conjunto de pontos referente aos dados de modo a minimizar a soma dos quadrados das distâncias entre esses pontos e a linha (Hottinger Bruel & Kjaer Inc., 2024). Esta minimização pode ser feita na direção vertical ou horizontal. Se a regressão for em X (RRX), a linha é ajustada de modo a minimizar a distância horizontal entre os pontos e a linha. Se a regressão for em Y (RRY), os desvios verticais dos pontos para a linha são minimizados. A título de exemplo, na figura seguinte é ilustrado a RRX (Regressão em X) e a RRY (Regressão em Y).




Figura 3-11 – Regressão Linear em Y (à esquerda) e Regressão Linear em X (à direita).

Fonte: (Hottinger Bruel & Kjaer Inc., 2024).

Ao se abordar este método é importante referir o coeficiente de correlação. Este coeficiente indica o quão bem o método de regressão linear se ajusta aos dados e é geralmente denotado por ρ . O coeficiente de correlação pode ser definido pela Equação 3.26, enquanto que o coeficiente de correlação amostral é dado pela Equação 3.27 (Hottinger Bruel & Kjaer Inc., 2024).

$$\rho = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad (3.27)$$

$$\hat{\rho} = \frac{\sum_{i=1}^N x_i y_i - \frac{\sum_{i=1}^N x_i \sum_{i=1}^N y_i}{N}}{\sqrt{\left(\sum_{i=1}^N x_i^2 - \frac{(\sum_{i=1}^N x_i)^2}{N}\right) \left(\sum_{i=1}^N y_i^2 - \frac{(\sum_{i=1}^N y_i)^2}{N}\right)}} , -1 \geq \hat{\rho} \geq 1 \quad (3.28)$$

Onde:

- σ_{xy} é a covariância entre x e y
- σ_x é o desvio padrão de x
- σ_y é o desvio padrão de y

Quanto mais próximo o valor de $\hat{\rho}$ for de ± 1 , melhor é o ajuste aos dados. Um valor de coeficiente de correlação igual a zero indica uma concentração aleatória dos dados.




Figura 3-12 -Variação do valor de coeficiente de correlação e a sua influência.

Fonte: (Hottinger Bruel & Kjaer Inc., 2024).

3.4.2.1. Regressão em Y

Assumindo um conjunto de pares de dados $(x_1, y_1), (x_2, y_2) \dots (x_N, y_N)$ em que os valores de x são conhecidos, para ajustar uma reta $y = \hat{a} + \hat{b}x$, a estes pontos de dados, o princípio dos mínimos quadrados procura minimizar a soma dos quadrados das diferenças entre os valores y observados e os valores y previstos para cada valor correspondente de x (Hottinger Bruel & Kjaer Inc., 2024):

$$\sum_{i=1}^N (\hat{a} + \hat{b}x_i - y_i)^2 = \min \sum_{i=1}^N (a + bx_i - y_i)^2 \quad (3.29)$$

Onde \hat{a} e \hat{b} são as estimativas dos mínimos quadrados de a e b , respetivamente, e o N é o número de pontos de dados. Ao simplificar as equações em função de \hat{a} e \hat{b} , obtém-se (Hottinger Bruel & Kjaer Inc., 2024):

$$\hat{a} = \frac{\sum_{i=1}^N y_i}{N} - \frac{\hat{b}(\sum_{i=1}^N x_i)}{N} = \bar{y} - \hat{b}\bar{x} \quad (3.30)$$

$$\hat{b} = \frac{\sum_{i=1}^N x_i y_i - \frac{\sum_{i=1}^N x_i \sum_{i=1}^N y_i}{N}}{\sum_{i=1}^N x_i^2 - \frac{(\sum_{i=1}^N x_i)^2}{N}} \quad (3.31)$$

No caso da Distribuição Lognormal utilizada no Caso de Estudo do Capítulo 4, sabendo que $t' = \ln(t)$, y_i e x_i , correspondem a:

$$y_i = \Phi^{-1}[F(t'_i)] \quad (3.32)$$

$$x_i = t'_i \quad (3.33)$$

Os valores de y_i são obtidos através da Tabela da Distribuição Normal Padrão, ao inserir $F(z)$ e obter o correspondente valor z (y_i). Desta forma, os parâmetros da distribuição Lognormal podem ser obtidos através das seguintes equações:

$$\mu_N = -\hat{a} \cdot \sigma_N \quad (3.34)$$

$$\sigma_N = \frac{1}{\hat{b}} \quad (3.35)$$

No caso da Distribuição de Weibull, para a Regressão em Y, tem-se:

$$y_i = \ln[-\ln(1 - F(t_i))] \quad (3.36)$$

$$x_i = \ln(t_i) \quad (3.37)$$

$$\hat{a} = -\beta \ln(\eta) \quad (3.38)$$

$$\hat{b} = \beta \quad (3.39)$$

3.4.2.2. Regressão em X

Assumindo um conjunto de pares de dados $(x_1, y_1), (x_2, y_2) \dots (x_N, y_N)$ em que os valores de y são conhecidos. A mesma aplicação do princípio dos mínimos quadrados é feita, mas desta vez, minimizando a distância horizontal entre os pontos de dados e a linha reta ajustada aos dados. Para ajustar uma reta $x = \hat{a} + \hat{b}y$, a estes pontos de dados, o princípio dos mínimos quadrados procura minimizar a soma dos quadrados das diferenças entre os valores x observados e os valores x previstos para cada valor correspondente de y (Hottinger Bruel & Kjaer Inc., 2024):

$$\sum_{i=1}^N (\hat{a} + \hat{b}y_i - x_i)^2 = \min(a, b) \sum_{i=1}^N (a + by_i - x_i)^2 \quad (3.40)$$

Mais uma vez, \hat{a} e \hat{b} são as estimativas dos mínimos quadrados de a e b , respetivamente, e N é o número de pontos de dados. Ao simplificar as equações em função de \hat{a} e \hat{b} , obtém-se (Hottinger Bruel & Kjaer Inc., 2024):

$$\hat{a} = \frac{\sum_{i=1}^N x_i}{N} - \frac{\hat{b}(\sum_{i=1}^N y_i)}{N} = \bar{x} - \hat{b}\bar{y} \quad (3.41)$$

$$\hat{b} = \frac{\sum_{i=1}^N x_i y_i - \frac{\sum_{i=1}^N x_i \sum_{i=1}^N y_i}{N}}{\sum_{i=1}^N y_i^2 - \frac{(\sum_{i=1}^N y_i)^2}{N}} \quad (3.42)$$

No caso da Distribuição Lognormal são utilizadas as mesmas fórmulas da Regressão em Y para descobrir os parâmetros da distribuição. Da mesma forma, no caso da Distribuição de Weibull, para a Regressão em X, tem-se:

$$\hat{\eta} = e^{\frac{\hat{a}}{\hat{b}} \frac{1}{\hat{\beta}}} \quad (3.43)$$

$$\hat{\beta} = \frac{1}{\hat{b}} \quad (3.44)$$

3.5. Intervalos de Confiança

Neste subcapítulo será abordado o método utilizado no Capítulo 4 para calcular os intervalos de confiança das distribuições. Os intervalos de confiança representam uma faixa de valores na qual acredita-se, com uma determinada confiança, que um parâmetro específico esteja contido. Por exemplo, ao considerar intervalos de confiança de 90% para θ , está-se a afirmar que 90% da população está compreendida entre $\theta_{inferior}$ e $\theta_{superior}$, tal como mostra a Figura 3-13 (Hottinger Bruel & Kjaer Inc., 2024):




Figura 3-13 – Exemplo de um intervalo de confiança de 90%.

Fonte: (Hottinger Bruel & Kjaer Inc., 2024).

3.5.1. Matriz de Fisher

A matriz de Fisher é útil para estimar os erros de um conjunto de parâmetros de uma distribuição sem necessidade de conhecer ou ajustar os valores dos parâmetros (Wang, 2015). No entanto, segundo a opinião de alguns especialistas, a Matriz de Fisher

não é a mais indicada para ser utilizada para pequenas amostras de dados (Hottinger Bruel & Kjaer Inc., 2024).

A fórmula utilizada para calcular a matriz de Fisher em um contexto geral em relação a um parâmetro (θ) é dada por (Geyer, 2007):

$$J_n(\theta) = - \sum_{i=1}^n \frac{\partial^2}{\partial \theta^2} \log f(X_i|\theta) \quad (3.45)$$

Onde:

- n é o número total de observações
- X_i são as observações individuais
- $\log f(X_i|\theta)$ é o logaritmo da função densidade de probabilidade condicional das observações X_i

A matriz de Fisher pode ser representada por (Hottinger Bruel & Kjaer Inc., 2024):

$$F = \begin{bmatrix} Var(\theta_1) & Cov(\theta_1, \theta_2) \\ Cov(\theta_1, \theta_2) & Var(\theta_2) \end{bmatrix} \quad (3.46)$$

Através da matriz de Fisher podem-se obter os *Confidence Bounds* (CB), ou seja, os intervalos de confiança que são dados pela seguinte equação (Hottinger Bruel & Kjaer Inc., 2024):

$$CB = E(G) \pm z_\alpha \sqrt{Var(G)} \quad (3.47)$$

Onde:

- $E(G)$ é o valor estimado da função G , que é função dos parâmetros $\theta_1, \theta_2 \dots \theta_k$;
- CB representa os intervalos de confiança;
- $Var(G)$ é a variância de uma função G ;
- z_α é o valor crítico associado ao nível de confiança desejado, por exemplo, para um nível de confiança de 95%, z_α é aproximadamente 1.96.

3.6. Gráfico Nevada

O método Nevada permite converter dados de vendas de um produto específico e seus retornos em garantia para o formato padrão de dados de fiabilidade, tais como falhas e suspensões. Em cada intervalo de tempo em que uma quantidade de produtos

é colocada em serviço, ocorrerá um determinado número de devoluções ou falhas. Esses dados podem ser organizados em um gráfico diagonal, conhecido como gráfico Nevada, conforme ilustrado na Figura 3-14 (Hottinger Bruel & Kjaer Inc., 2024).




Figura 3-14 – Exemplo de Gráfico de Nevada (vendas mensais vs retornos por mês).

Fonte: (Hottinger Bruel & Kjaer Inc., 2024).

O gráfico diagonal de Nevada permite a análise de dados de vida útil e, dessa forma, a previsão de retornos em garantia em períodos de tempo subsequentes. Esta metodologia utiliza o conceito de fiabilidade condicional para calcular a probabilidade de falha para as unidades restantes em cada período de venda (Hottinger Bruel & Kjaer Inc., 2024). $F(t|T)$ indica a probabilidade condicional de falha entre T+t, com a condição de não-falha até T garantida.

$$F(t|T) = 1 - R(t|T) = 1 - \frac{R(T+t)}{R(T)} \quad (3.48)$$

A probabilidade condicional de falha obtida é então multiplicada pelo número de unidades em risco nesse período específico que ainda estão em campo (ou seja, as suspensões - S_X), a fim de prever o número de falhas ou devoluções de garantia esperadas para este período de tempo (F_X) (Hottinger Bruel & Kjaer Inc., 2024).

$$F_X = S_X \cdot F(t|T) \quad (3.49)$$

4. Caso de Estudo

Em 1958, Marcel Braud teve uma ideia inovadora: *"E se invertêssemos o design de um trator agrícola e adicionássemos um mastro de elevação e direção hidráulica?"*

Essa inovação visionária não só transformou o conceito original, como também foi o ponto de partida para a criação do vasto portfólio de produtos do Grupo Manitou que inclui uma variedade de máquinas, desde empilhadores telescópicos fixos e rotativos até empilhadores de grande tonelagem para terrenos acidentados, empilhadores semi-industriais e industriais, carregadoras de rodas e de esteiras, carregadoras articuladas, retroescavadoras, plataformas de trabalho aéreo industriais e para terrenos acidentados, empilhadores montados em camião e equipamento de armazenamento.

Para além dos equipamentos, o Grupo Manitou oferece um serviço personalizado aos clientes, incluindo uma vasta gama de acessórios e uma oferta completa de serviços, desde a manutenção dos equipamentos até ao financiamento. Do ponto de vista operacional, o grupo possui 10 locais de produção e 7 centros logísticos de peças sobressalentes em todo o mundo, garantindo proximidade aos clientes e um serviço adaptado às suas necessidades.

Esta dedicação resultou em vendas de 2,9 biliões de euros em 2023 e orienta uma talentosa equipa global de 5.500 pessoas, cuja paixão continua a impulsionar o grupo. Mantendo-se fiel às suas raízes, a Manitou mantém a sua sede em França. O Grupo Manitou está sempre atento aos seus clientes, através de uma rede de especialistas com mais de 800 concessionários. Um destes concessionários é o Manitou Center Lisboa, localizado em Vila Franca de Xira. Nos últimos anos, Manitou tem registado números recordes a nível de vendas de equipamentos e isso tudo graças à qualidade e a fiabilidade dos equipamentos colocados em diversos mercados que atua e ao serviço prestado, nomeadamente no que se refere à manutenção dos equipamentos vendidos. Num breve resumo a estrutura hierárquica da Manitou Portugal pode ser dividida da seguinte forma:

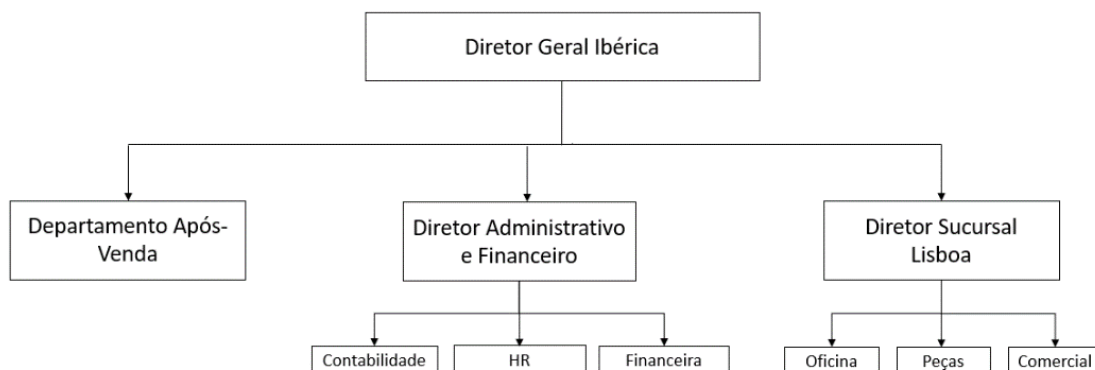


Figura 4-1 – Estrutura hierárquica da empresa.

A presente dissertação tem o propósito de identificar os componentes críticos durante o período de garantia/extensão de garantia ao longo dos últimos anos numa importante organização em Portugal na área de equipamentos de movimentação de carga/pessoas. Para começar a realizar o estudo de fiabilidade e a identificação de componentes críticos foi utilizado o histórico de intervenções dos equipamentos, através da análise de folhas de obra e a consulta do software utilizado na empresa para este efeito.

No decorrer do ano de 2022, começou-se por fazer o arquivo digital das obras em garantia com o intuito de haver um maior controlo por parte da oficina a nível do diferencial entre o custo para a empresa e o valor aceite pela fábrica. Deste modo, foi mais fácil identificar todos os valores necessários para dar início à análise. Neste sentido, e de modo a encontrar os componentes críticos, foram utilizados os dados das garantias dos últimos dois anos. Na Tabela 4-1, é possível observar as peças causais identificadas, a quantidade de avarias por componente, o custo médio por reparação e o tempo médio de reparação, incluindo a deslocação. De notar que as soluções, em todos os casos identificados, levaram à substituição do componente, visto ser, o procedimento preferível descrito no manual do fabricante para garantir a fiabilidade e a qualidade da reparação.

Tabela 4-1 – Análise das peças causais em garantia.

Peça causal	Avarias	Quantidade de avarias	Custo médio por reparação	Tempo médio de reparação - com deslocação
Pressostato Direção	Fuga de óleo	18	125,00 €	3
Válvulas e Kit Vedantes	Fuga de óleo	4	680,00 €	15
Instalação Elétrica	Máquina com erros	3	830,00 €	10
Record	Fuga de óleo	2	210,00 €	4
Instalação Elétrica	Máquina com erros	2	500,00 €	12
Sensor de Carga	Máquina com erros	2	450,00 €	6
Parafusos/Rotulas	Fuga de óleo	4	700,00 €	15
Pressostato Acumulador	Avaria no travão de mão	3	200,00 €	4

Deste modo, e de acordo com a metodologia AHP descrita no Capítulo 2, o objetivo principal consistiu na identificação da peça crítica que mais impacto teve nas

garantias dos últimos anos da organização. Os critérios selecionados foram a quantidade de avarias (QA), o custo médio por reparação (CR) e o tempo médio de reparação (TR). Esta escolha de critérios permitiu uma análise abrangente da eficiência e eficácia das operações de reparação, considerando tanto o aspeto quantitativo das avarias como os fatores económicos e temporais envolvidos nos processos de reparação. Na Figura 4-1, é possível observar a Estrutura Hierárquica deste caso de estudo.

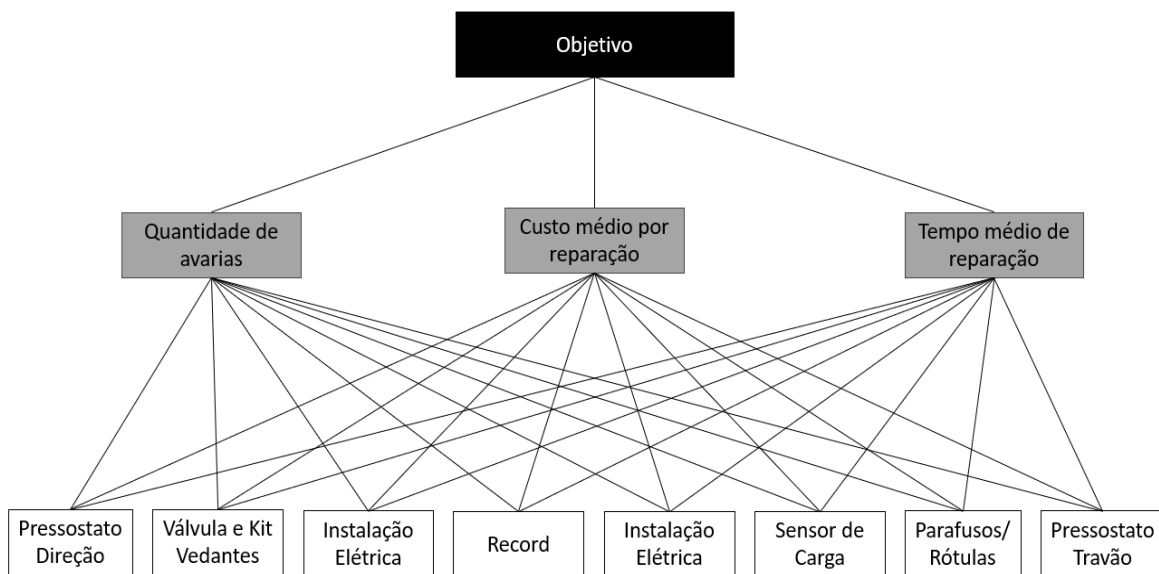


Figura 4-2 – Estrutura Hierárquica do Caso de Estudo.

Após a criação da estrutura hierárquica e a definição dos critérios e alternativas, conforme mencionado anteriormente no Capítulo 2, a próxima fase envolve as comparações par a par. As comparações dos critérios foram efetuadas pelos especialistas da empresa, nomeadamente o Chefe de Oficina e o Diretor da Sucursal, enquanto a comparação entre as alternativas teve por base um registo histórico das avarias dos componentes. A Tabela 4-2 ilustra as comparações efetuadas entre os 3 critérios identificados, contribuindo para a definição dos seus respetivos pesos.

Tabela 4-2 – Matriz da comparação par a par dos critérios.

	QA	CR	TR
QA	1,000	2,000	3,000
CR	0,500	1,000	0,667
TR	0,333	1,500	1,000

Posteriormente, a matriz é submetida a um processo de normalização com o objetivo de assegurar que os valores reflitam relações proporcionais. A normalização da matriz, utilizando o método da soma, é alcançada por meio da aplicação da Equação 2.1. Esta equação consiste em dividir cada elemento presente na matriz pela soma dos elementos na sua respectiva coluna (Tabela 4-3), e o que resulta na matriz normalizada (Tabela 4-4).

Tabela 4-3 – Matriz auxiliar.

	QA	CR	TR
QA	1,000	2,000	3,000
CR	0,500	1,000	0,667
TR	0,333	1,500	1,000
Σ	1,833	4,500	4,667

Tabela 4-4 – Matriz normalizada dos critérios.

	QA	CR	TR
QA	0,545	0,444	0,643
CR	0,273	0,222	0,143
TR	0,182	0,333	0,214

Com base no conjunto de critérios normalizados, torna-se viável derivar os pesos relativos. O vetor de prioridades dos critérios é obtido ao calcular a média aritmética dos elementos nas respectivas linhas, conforme demonstrado pela Equação 2.2. Em termos mais simples, os valores normalizados são somados ao longo das linhas, e o resultado final é dividido pelo número de colunas. Esse procedimento proporciona pesos que indicam a importância relativa de cada critério em relação aos demais. A Tabela 4-5 ilustra o vetor de prioridades dos critérios.

Tabela 4-5 – Vetor de prioridades dos critérios.

Critérios	W
Quantidade de Avarias	0,544
Tempo de Reparação	0,243
Custo de Reparação	0,213

Ao analisar os valores resultantes do vetor de prioridades dos critérios, chegamos à conclusão de que a Quantidade de Avarias (QA) é o critério mais significativo, representando 54,4%. Em seguida, vem o Tempo de Reparação (TR) que inclui a deslocação, com 24,3%, e por último, o Custo da Reparação (CR), com 21,3%. Estes valores refletem a relevância relativa de cada critério no processo decisório, destacando a contribuição específica de cada um na avaliação global.

Em seguida, realizou-se a análise de consistência da metodologia, visando avaliar a coerência e robustez das comparações realizadas. Este procedimento é essencial para verificar a consistência das comparações efetuadas, garantindo a solidez e fiabilidade dos resultados no contexto da análise. Isto implica analisar os dados recolhidos para garantir que as comparações feitas durante o processo de tomada de decisão estejam em linha com padrões lógicos e coerentes. A avaliação da consistência dos dados inicia-se com o cálculo do produto, que pode ser observado na Tabela 4-6, e que corresponde ao produto da matriz de comparação dos critérios pelo vetor de prioridades.

Tabela 4-6 – Cálculo do Produto.

	QA	CR	TR		W	Produto
QA	1,000	2,000	3,000		0,544	1,699
CR	0,500	1,000	0,667		0,213	0,647
TR	0,333	1,500	1,000		0,243	0,743

Posteriormente, realiza-se o somatório da divisão desse produto pelo peso relativo, multiplicado pelo inverso do grau da matriz. A fórmula correspondente pode ser visualizada na Equação 2.4, e ao aplicá-la obtemos o valor do λ_{max} :

$$\lambda_{max} = \frac{1}{3} \cdot \left(\frac{1,699}{0,544} + \frac{0,647}{0,213} + \frac{0,743}{0,243} \right) = 3,074 \quad (4.1)$$

Depois de encontrar o λ_{max} , é possível realizar o cálculo do índice de consistência (*IC*) através da Equação 2.5:

$$IC = \frac{3,074-3}{3-1} = 0,037 \quad (4.2)$$

Por fim, é necessário realizar o cálculo da razão de consistência (*RC*), que é determinada pela divisão do índice de consistência pelo índice aleatório (*IR*), que no nosso caso e de acordo com a Tabela 2-4 corresponde a 0,58.

$$RC = \frac{0,037}{0,58} = 0,064 \quad (4.3)$$

No presente contexto, a matriz é considerada consistente, uma vez que a Razão de Consistência (*RC*) é inferior a 0,10. Essa conclusão indica que as comparações realizadas são coerentes e apresentam uma consistência aceitável, fortalecendo a credibilidade dos resultados obtidos na análise.

Ao considerar concluída a fase de análise de consistência para o nível superior da hierarquia, o mesmo processo é agora aplicado ao nível inferior. Em outras palavras, vão-se comparar as alternativas entre si, mas desta vez em relação a um critério específico. As alternativas ou peças causais consideradas para este estudo são:

Pressostato Direção (PD), Válvulas e Kit Vedantes (V), Instalação Elétrica (IE), Record (R), Instalação Elétrica (IE2), Sensor de Carga (SC), Parafusos/Rotulas (PR), Pressostato Acumulador (PA). Nas Tabelas 4-7, 4-8 e 4-9 podem-se observar as matrizes das comparações das alternativas em relação a cada um dos critérios previamente definidos.

Tabela 4-7 – Matriz de comparações das alternativas em relação a Quantidade de Avarias.

QUANTIDADE DE AVARIAS								
	PD	V	IE	R	IE2	SC	PR	PA
PD	1,00	5,00	6,00	9,00	9,00	9,00	5,00	6,00
V	0,20	1,00	2,00	3,00	3,00	3,00	1,00	2,00
IE	0,17	0,50	1,00	2,00	2,00	2,00	0,50	1,00
R	0,11	0,33	0,50	1,00	1,00	1,00	0,33	0,50
IE2	0,11	0,33	0,50	1,00	1,00	1,00	0,33	0,50
SC	0,11	0,33	0,50	1,00	1,00	1,00	0,33	0,50
PR	0,20	1,00	2,00	3,00	3,00	3,00	1,00	2,00
PA	0,17	0,50	1,00	2,00	2,00	2,00	0,50	1,00
Σ	2,07	9,00	13,50	22,00	22,00	22,00	9,00	13,50

Tabela 4-8 - Matriz de comparações das alternativas em relação ao Custo Médio.

CUSTO MÉDIO								
	PD	V	IE	R	IE2	SC	PR	PA
PD	1,00	0,17	0,14	0,50	0,11	0,25	0,17	0,50
V	6,00	1,00	0,50	3,00	0,33	2,00	1,00	3,00
IE	7,00	2,00	1,00	4,00	0,50	3,00	2,00	4,00
R	2,00	0,33	0,25	1,00	0,14	0,50	0,33	1,00
IE2	9,00	3,00	2,00	7,00	1,00	4,00	2,00	8,00
SC	4,00	0,50	0,33	2,00	0,25	1,00	0,50	2,00
PR	6,00	1,00	0,50	3,00	0,50	2,00	1,00	4,00
PA	2,00	0,33	0,25	1,00	0,13	0,50	0,25	1,00
Σ	37,00	8,33	4,98	21,50	2,96	13,25	7,25	23,50

Tabela 4-9 - Matriz de comparações das alternativas em relação ao Tempo Médio.

TEMPO MÉDIO								
	PD	V	IE	R	IE2	SC	PR	PA
PD	1,00	0,20	0,33	0,50	0,25	0,50	0,20	0,50
V	5,00	1,00	2,00	4,00	2,00	3,00	1,00	4,00
IE	3,00	0,50	1,00	3,00	0,50	2,00	0,33	3,00
R	2,00	0,25	0,33	1,00	0,33	0,50	0,25	1,00
IE2	4,00	0,50	2,00	3,00	1,00	2,00	0,50	3,00
SC	2,00	0,33	0,50	2,00	0,50	1,00	0,33	2,00
PR	5,00	1,00	3,00	4,00	2,00	3,00	1,00	4,00
PA	2,00	0,25	0,33	1,00	0,33	0,50	0,25	1,00
Σ	24,00	4,03	9,50	18,50	6,92	12,50	3,87	18,50

De forma semelhante ao processo aplicado aos critérios, as matrizes foram depois sujeitas a um processo de normalização. Este procedimento, essencial na análise multicritério, permitiu a obtenção dos vetores de prioridades das alternativas para cada um dos critérios.

As Tabelas 4-10, 4-11 e 4-12 mostram a matriz normalizada e o vetor prioridades das alternativas em relação a Quantidade de Avarias, Custo Médio e Tempo de Reparação, respetivamente.

Tabela 4-10 – Matriz normalizada das alternativas em relação a Quantidade de Avarias e o respetivo vetor prioridades.

	PD	V	IE	R	IE2	SC	PR	PA	W
PD	0,484	0,556	0,444	0,409	0,409	0,409	0,556	0,444	0,4639
V	0,097	0,111	0,148	0,136	0,136	0,136	0,111	0,148	0,1280
IE	0,081	0,056	0,074	0,091	0,091	0,091	0,056	0,074	0,0766
R	0,054	0,037	0,037	0,045	0,045	0,045	0,037	0,037	0,0423
IE2	0,054	0,037	0,037	0,045	0,045	0,045	0,037	0,037	0,0423
SC	0,054	0,037	0,037	0,045	0,045	0,045	0,037	0,037	0,0423
PR	0,097	0,111	0,148	0,136	0,136	0,136	0,111	0,148	0,1280
PA	0,081	0,056	0,074	0,091	0,091	0,091	0,056	0,074	0,0766
Σ									1,0000

Tabela 4-11 – Matriz normalizada das alternativas em relação ao Custo Médio e o respectivo vetor prioridades.

	PD	V	IE	R	IE2	SC	PR	PA	W
PD	0,027	0,020	0,029	0,023	0,038	0,019	0,023	0,021	0,0250
V	0,162	0,120	0,100	0,140	0,113	0,151	0,138	0,128	0,1314
IE	0,189	0,240	0,201	0,186	0,169	0,226	0,276	0,170	0,2072
R	0,054	0,040	0,050	0,047	0,048	0,038	0,046	0,043	0,0457
IE2	0,243	0,360	0,402	0,326	0,338	0,302	0,276	0,340	0,3233
SC	0,108	0,060	0,067	0,093	0,084	0,075	0,069	0,085	0,0803
PR	0,162	0,120	0,100	0,140	0,169	0,151	0,138	0,170	0,1438
PA	0,054	0,040	0,050	0,047	0,042	0,038	0,034	0,043	0,0435
									Σ 1,0000

Tabela 4-12 - Matriz normalizada das alternativas em relação ao Tempo Médio e o respectivo vetor prioridades.

	PD	V	IE	R	IE2	SC	PR	PA	W
PD	0,042	0,050	0,035	0,027	0,036	0,040	0,052	0,027	0,0385
V	0,208	0,248	0,211	0,216	0,289	0,240	0,259	0,216	0,2359
IE	0,125	0,124	0,105	0,162	0,072	0,160	0,086	0,162	0,1246
R	0,083	0,062	0,035	0,054	0,048	0,040	0,065	0,054	0,0552
IE2	0,167	0,124	0,211	0,162	0,145	0,160	0,129	0,162	0,1574
SC	0,083	0,083	0,053	0,108	0,072	0,080	0,086	0,108	0,0842
PR	0,208	0,248	0,316	0,216	0,289	0,240	0,259	0,216	0,2490
PA	0,083	0,062	0,035	0,054	0,048	0,040	0,065	0,054	0,0552
									Σ 1,000

Foi também realizada a análise de consistência, cujos valores podem ser observados na Tabela 4-13, e que demonstram que as comparações são coerentes e que cada matriz é consistente, uma vez que a Razão de Consistência (RC) é inferior a 0,10 em todas as situações.

Tabela 4-13 – Valores da análise de consistência realizada.

	QA	CR	TR
λ_{max}	8,064	8,092	8,166
IC	0,009	0,013	0,024
RC	0,007	0,009	0,017

Por fim, depois de se ter o vetor prioridades de cada alternativa em relação a cada um dos critérios, e se obter os pesos dos critérios, é possível calcular o peso global de cada alternativa em relação ao objetivo. Neste sentido, e de acordo com a Equação 2.3, os pesos dos critérios são multiplicados pelos vetores de prioridade das alternativas, e em seguida, sendo o valor total obtido pela soma dos produtos resultantes. Ao aplicar a seguinte metodologia, foram obtidos os pesos de cada alternativa em relação ao objetivo que podem ser observados na Tabela 4.14.

Tabela 4-14 – Peso Global de cada alternativa.

Componente	Peso Global	Classificação
Pressostato Direção	26,71%	1º
Parafusos/Rótulas	16,08%	2º
Válvula Kit Vedante	15,50%	3º
Instalação Elétrica	13,00%	4º
Instalação Elétrica	11,60%	5º
Pressostato Acumulador	6,43%	6º
Sensor Carga	6,05%	7º
Record	4,61%	8º

Analisando, a Tabela 4-14, pode-se constatar que o Pressostato Direção é o componente mais influente, tendo obtido 26,71%, seguido dos Parafusos/Rótulas, com 16,08%. O terceiro componente mais importante segundo os critérios definidos é a Válvula/Kit Vedante, com 15,50%, seguido das duas Instalações Elétricas do Motor, com 13,00% e 11,60% respectivamente. Por último ficaram o Pressostato Acumulador (6,43%), o Sensor de Carga (6,05%) e o Record (4,61%).

Após a seleção do componente mais crítico através da Metodologia AHP, apresenta-se uma descrição detalhada do mesmo. Isso envolveu fornecer uma explicação abrangente das características físicas, funcionalidades e importância do componente dentro do sistema em que está inserido. Essa descrição permitiu uma compreensão completa do papel e impacto do componente no contexto da pesquisa.

De uma forma resumida, os sensores de pressão podem ser descritos como dispositivos eletrônicos que monitorizam a pressão num determinado sistema. Neste caso em concreto o pressostato de direção, monitoriza a pressão do orbitol, cuja função consiste em gerir e regular o fluxo para alimentar o circuito da direção. Na Figura 4-3, pode-se observar o princípio de funcionamento do orbitol quando o operador vira o volante para a esquerda. As linhas a vermelho representam a pressão do orbitol, as linhas a azul o retorno ao tanque e as linhas à verde a linha de pilotagem. Neste sentido, o P é a Pressão, T é o Tanque, R é a Direita e L é a Esquerda.

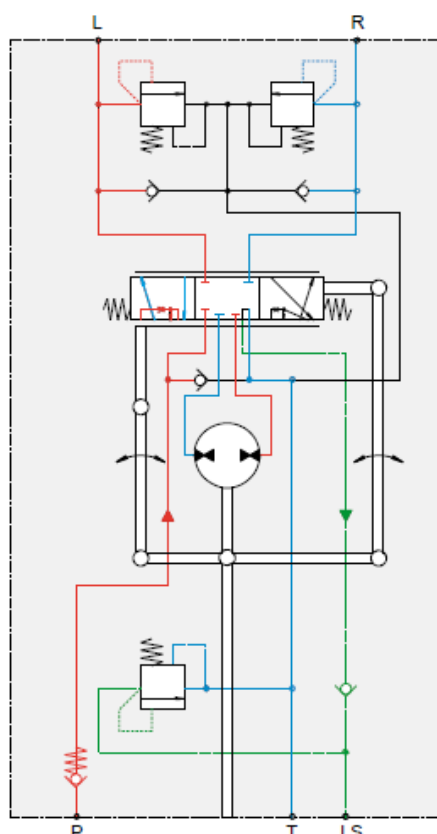


Figura 4-3– Diagrama Esquemático do Orbitrol – volante para esquerda.

Fonte: Manitou Repair Manual (2021).




Figura 4-4 – Representação do Orbitrol.

Fonte: Manitou Repair Manual (2021).

Os pressostatos consistem numa parte que deteta a pressão e um componente eletrónico que converte essa pressão num sinal elétrico. Quando a pressão atinge um valor predefinido, o sensor de pressão envia um sinal elétrico para a ECU (*Engine Control Unit*) do equipamento. A ECU, ou centralina, é uma unidade de controlo que gere o funcionamento do equipamento com base nas informações recebidas dos sensores. Dependendo do tipo de sinal enviado pelo sensor de pressão, a centralina pode tomar várias ações, como ativar ou desativar funções do equipamento, ajustar a pressão, ou mesmo enviar alertas para o operador através de erros no ecrã. Na Figura 4-5, pode-se observar o Diagrama do Pressostato do Orbitrol.




Figura 4-5 – Diagrama do Pressostato do Orbitrol.

Fonte: Manitou Repair Manual (2021).

O interruptor abre quando a pressão atinge no máximo 9 bar e fecha quando a pressão diminui para 7.5 ± 0.69 bar. O pressostato do orbitrol com esta referência é encontrado nos telescópicos para a agricultura cuja capacidade máxima varia dos 2500kg aos 4100kg, e a altura de elevação máxima varia dos 6 aos 11 metros. Na Figura 4-6, pode-se observar o componente (PRES 1) em estudo no sistema hidráulico de um desses equipamentos. O esquema completo do sistema hidráulico pode ser visto no Anexo 2.

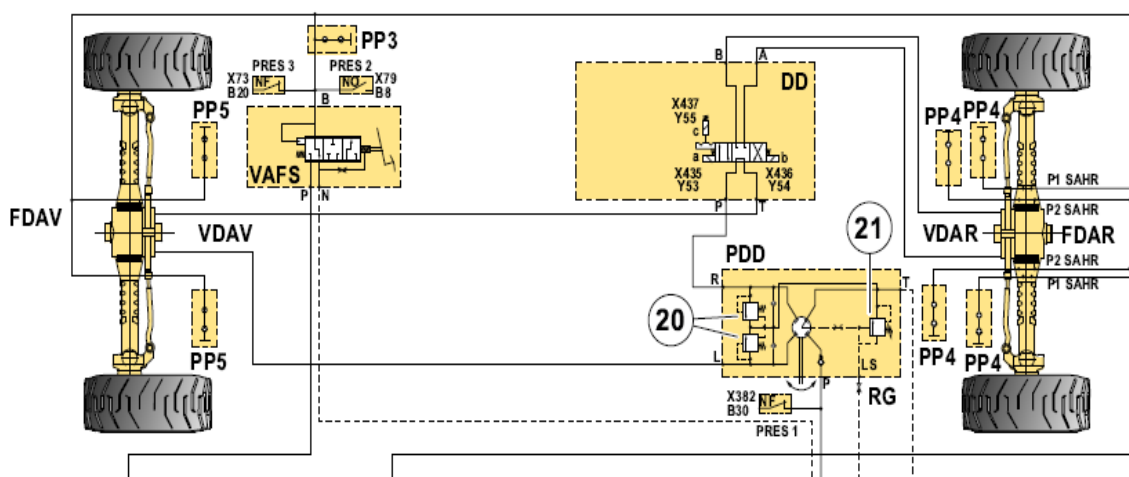


Figura 4-6 – Esquema hidráulico do equipamento. Fonte: Manitou Repair Manual (2021).

As características técnicas do pressostato podem ser vistas na Tabela 4-15. No Anexo 3 pode ser visto o esquema elétrico do equipamento, em que o pressostato do orbitrol é identificado como B30/X382, e está conectado à massa no Pin2 (a azul) e ao Navegador no Pin1.

Tabela 4-15 – Características do pressostato. Fonte: Manitou Repair Manual (2021).

Descrição	Típico	Máx
Tipo de Contacto	NC	—
Tensão	12 V DC	42 V DC
Corrente nominal	6 mA	—
Potência nominal	100 VA	—

4.1. Análise com Dados de Tempos até à Falha

Para começar o caso de estudo, analisaram-se as avarias da peça causal ao abrigo de garantia que ocorreram nos últimos 2 anos através do ERP (Planeamento de Recursos Empresariais) e da consulta de folhas de obra existentes. Com a identificação das avarias, conseguiu-se conhecer os números de série dos equipamentos que tiveram avarias relacionadas com o pressostato do orbitrol. Ao todo, neste estudo foram analisadas 50 avarias em 20 equipamentos diferentes. Por razões de proteção, os números de série dos equipamentos foram omitidos. Alguns dos equipamentos em análise, apesar de terem apenas 2 anos desde a colocação de serviço, tiveram 6 falhas do referido componente. Na Tabela 4-16, pode-se observar os tempos (em horas) de várias falhas do componente selecionado para este caso de estudo.

Tabela 4-16 – Tempos de falha (em horas) do componente pressostato da direção

Equipamento	1ª Falha	2ª Falha	3ª Falha	4ª Falha	5ª Falha	6ª Falha
740	701	1466				
153	739					
288	1636	3483	3821	4746		
330	1156	2479	3357	5671		
891	1410	2047	2835	3453	4123	4780
833	1151	2083	3078			
313	1204	2135	4187	5104	6722	
767	1351	1820				
990	2043	2849	3926	4600		
678	1887	2938	3477			
067	560					
985	1582					
824	4417	6624	7512			
591	3927	4575				
106	284	996				
162	517					
718	2109					
886	1987	2591	3466			
996	638					
559	669					

Neste caso de estudo utilizou-se a ferramenta denominada *Reliability4All* que foi especialmente desenvolvida por uma equipa especializada de Engenheiros de Fiabilidade, e cedida gratuitamente para a realização das análises neste trabalho. Na página inicial da ferramenta, foi selecionado o módulo *Life Data Analysis* (Análise de Tempos de Vida).

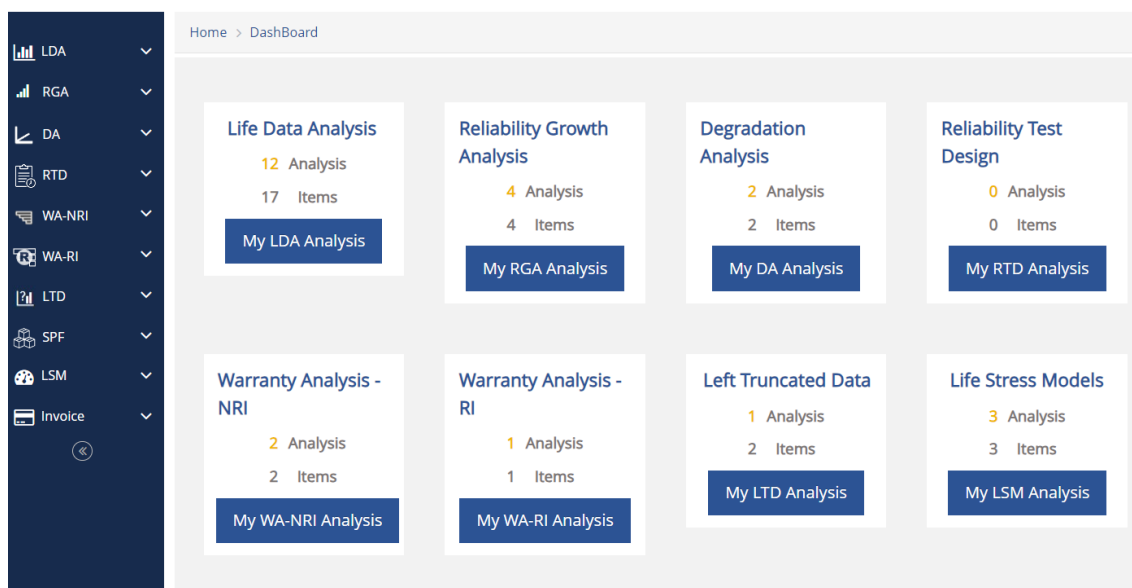


Figura 4-7 – Menu Principal do *Reliability4All*.

Para continuar, foi necessário criar uma nova análise, que neste caso é denominada: “Pressostato Orbitrol Dados Fixos”. Utilizando os dados da Tabela 4-17, calculou-se o tempo entre cada falha (em horas), e os dados obtidos foram organizados por ordem crescente e inseridos na ferramenta.

Tabela 4-17 – Tempos entre falhas (TTF).

Tempos entre falhas (TTF)			
284	670	931	1635
338	701	932	1847
469	712	995	1887
517	734	1051	1987
539	739	1077	2043
560	765	1151	2052
604	788	1156	2109
618	806	1204	2207
637	875	1323	2314
638	878	1351	3927
648	888	1410	4417
657	917	1582	
669	925	1618	

Nesta análise, foram escolhidos tempos exatos até a falha. Os tempos suspensos não foram inicialmente utilizados por gerarem uma maior ambiguidade no estudo. No caso de alguns clientes, cuja garantia dos equipamentos terá expirado, eles podem ter optado por outra alternativa sem recorrer aos nossos serviços, o que não significa que o componente tenha deixado de causar falhas. A primeira distribuição a ser escolhida para esta análise foi a Weibull Triparamétrica, pelo facto de ser, segundo a literatura, a que mais se enquadra ao estudo de garantias. Foi seleccionado o método MLE (Estimativa por Máxima Verossimilhança) sendo considerado um dos melhores métodos para estimar os parâmetros para tamanhos de amostra acima de 30 (Ikbal et al., 2022).

Ao calcular os parâmetros segundo as condições enunciadas e com um intervalo de confiança de 90%, obtiveram-se os seguintes valores:

Tabela 4-18 – Parâmetros obtidos para Weibull 3P (dados fixos) com MLE.

Parâmetro de Forma (β)	Parâmetro de Escala (η)	Parâmetro de Posição (γ)
1.230	986.88	277.30

O valor do parâmetro de posição (γ) obtido corresponde a vida inicial do pressostato antes de apresentar falha, tal como observa-se na Figura 4-8 que representa a probabilidade de falha $F(t)$ em função do tempo da distribuição. O parâmetro de forma (β) obtido, indica que a taxa de avarias do componente é crescente ao longo do tempo, tal como demonstra o gráfico da Figura 4-9.

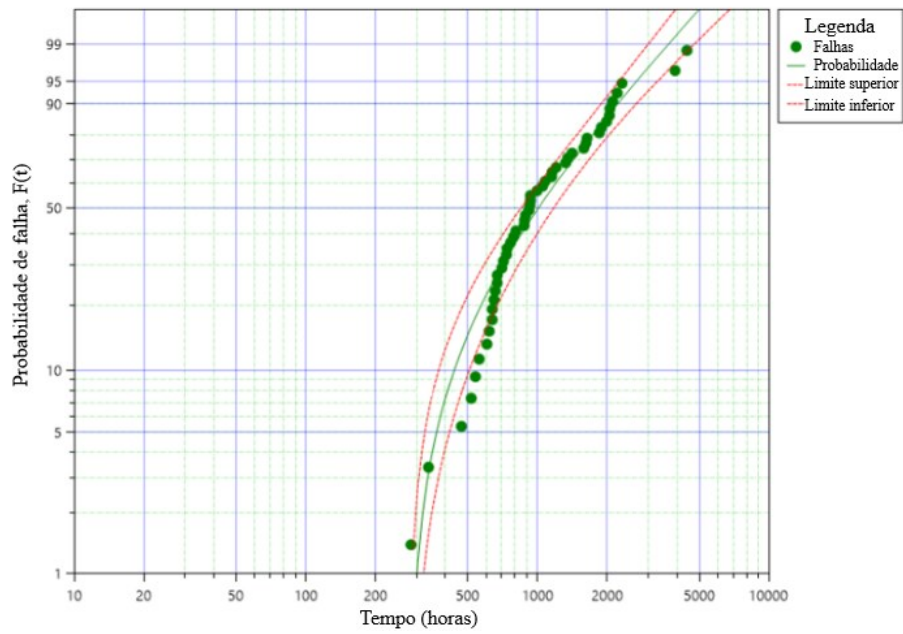


Figura 4-8 – Probabilidade de falha $F(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.




Figura 4-9 – Taxa de avarias em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.

O parâmetro de escala (η) é a vida característica do componente, e neste caso o valor obtido significa que até às 986.88 horas, 63.2% dos pressostatos terão falhado. Na Figura 4-10, é possível observar o gráfico correspondente à função Densidade de Probabilidade de Falha da distribuição.




Figura 4-10 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.

De modo a realizar uma comparação dos valores teóricos e analíticos, aplicaram-se os valores dos parâmetros de posição, forma e escala na Equação 3.10, tendo obtido o seguinte resultado para um tempo de funcionamento de 1000 horas (como exemplo):

$$R(1000) = e^{-\left(\frac{1000-277.3007}{986.8807}\right)^{1.2340}} = 0.5062 \quad (4.4)$$

O valor de Fiabilidade para um tempo de funcionamento de 1000 horas de 0.5062 indica que o componente em questão apresenta uma fiabilidade substancialmente inferior ao desejado. Este valor sugere uma probabilidade significativa de ocorrência de falhas durante o período em análise.

Em seguida, verificou-se na calculadora do software a Fiabilidade, $R(t)$ do pressostato ao fim de 1000 horas de trabalho. O valor obtido de Probabilidade de Sucesso ao fim de 1000 horas de serviço foi igual a 0.5062, conforme pode ser observado na figura seguinte:

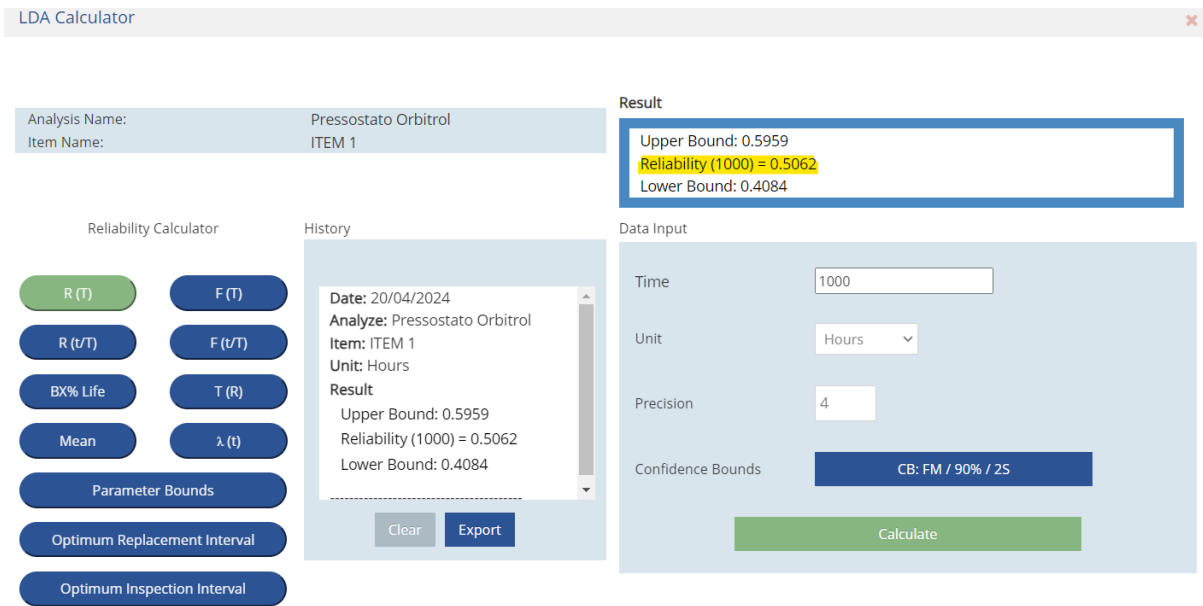


Figura 4-11 – Calculadora do *Reliability4All*.

Com isto, pode-se comprovar que a calculadora do software é uma funcionalidade adequada para calcular diversos tipos de funções de fiabilidade, garantindo os valores corretos comparativamente com o cálculo teórico. Na figura seguinte, pode se observar o gráfico de Fiabilidade, $R(t)$ em função do tempo:




Figura 4-12 - Fiabilidade $R(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos) com MLE.

No entanto, para realizar as simulações usando o Método da Regressão em X (RRX) e a Regressão em Y (RRY), foi necessário realizar uma nova análise, visto que esses métodos não são adequados para serem usados com a Distribuição de Weibull Triparmétrica conforme foi referido no Capítulo 3. Neste sentido, com a ajuda do *Reliability4All*, determinou-se que a Distribuição Lognormal é a que melhor se ajusta ao nosso conjunto de dados:

Tabela 4-19 – Resultado da distribuição com melhor ajuste segundo *Reliability4All*.

Distribuição	ρ (RRY)	ρ (RRX)	LKV (MLE)
Lognormal	0.9887	0.9887	-388.2331
Weibull-3P	0.9817	0.9778	-389.3525
Weibull-2P	0.9643	0.9595	-394.8774
Normal	0.9270	0.9386	-404.3218
Exponencial	0.8502	0.8285	-405.5223

4.1.1 Distribuição Lognormal (Regressão em X)

Utilizando os mesmos tempos de falha da Tabela 4-17, começou-se por realizar uma nova análise, desta vez com a Distribuição Lognormal e selecionando o Método RRX. Os dados dos parâmetros obtidos foram os seguintes:

Tabela 4-20 – Resultado dos parâmetros da Distribuição Lognormal (dados fixos) com RRX.

Parâmetro de Forma (σ)	Parâmetro de Escala (μ)	Coeficiente de correlação (ρ)
0.5794	6.9143	0.9887

Em seguida, podem ser observados os gráficos relativos a Distribuição Lognormal utilizando o método da Regressão em X, da Probabilidade de Falha $F(t)$, da Taxa de Avarias, da Densidade de Probabilidade de Falha e da Probabilidade de Sucesso $R(t)$, todas elas em função do tempo.




Figura 4-13 – Probabilidade de Falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRX.




Figura 4-14 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRX.




Figura 4-15 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) com RRX.




Figura 4-16 - Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRX.

De modo a realizar uma comparação dos valores teóricos e analíticos, aplicaram-se os valores dos parâmetros obtidos com a Regressão em X na Equação 3.20 e 3.21 para o mesmo tempo do exemplo anterior:

$$R(1000) = \int_{1000}^{\infty} \frac{1}{\sqrt{2\pi} \cdot 1000 \cdot 0.5794} e^{-\frac{1}{2} \left(\frac{\ln(1000) - 6.9143}{0.5794} \right)^2} = 0.5044 \quad (4.5)$$

O resultado obtido para uma Fiabilidade de 1000 horas na calculadora da ferramenta *Reliability4All* foi de 0.5045, conforme mostra a seguinte figura:

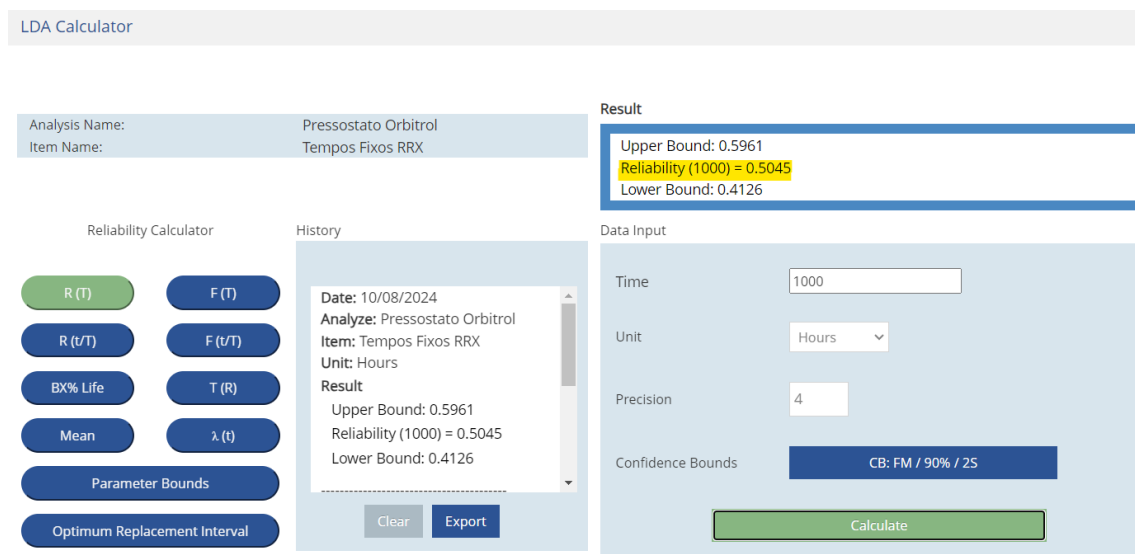


Figura 4-17 – Resultado calculado da Fiabilidade com RRX

4.1.2. Distribuição Lognormal (Regressão em Y)

Da mesma forma, utilizando os mesmos tempos de falha da Tabela 4-17, começou-se por realizar uma nova análise, desta vez com a Distribuição Lognormal e selecionando o Método RRY. Os dados dos parâmetros obtidos foram os seguintes:

Tabela 4-21 - Resultado dos parâmetros da Distribuição Lognormal (dados fixos) com RRY.

Parâmetro de Forma (σ)	Parâmetro de Escala (μ)	Coefficiente de correlação (ρ)
0.5969	6.9143	0.9887

Em seguida, podem ser observados os gráficos relativos a Distribuição Lognormal utilizando o método da Regressão em Y, da Probabilidade de Falha $F(t)$, da Taxa de Avarias, da Densidade de Probabilidade de Falha e da Probabilidade de Sucesso $R(t)$, todas elas em função do tempo.




Figura 4-18 - Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRY.




Figura 4-19 - Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRY.




Figura 4-20 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) com RRY.




Figura 4-21 - Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com RRY.

De modo a realizar uma comparação dos valores teóricos e analíticos, aplicaram-se os valores dos parâmetros obtidos com a Regressão em Y na Equação 3.20 e 3.21:

$$R(1000) = \int_{1000}^{\infty} \frac{1}{\sqrt{2\pi} \cdot 1000 \cdot 0.5969} e^{-\frac{1}{2} \left(\frac{\ln(1000) - 6.9143}{0.5969} \right)^2} = 0.5043 \quad (4.6)$$

O resultado obtido para a fiabilidade, referente a um período de 1000 horas, na calculadora da ferramenta Reliability4All foi de 0,5044, conforme apresentado na Figura 4-22:

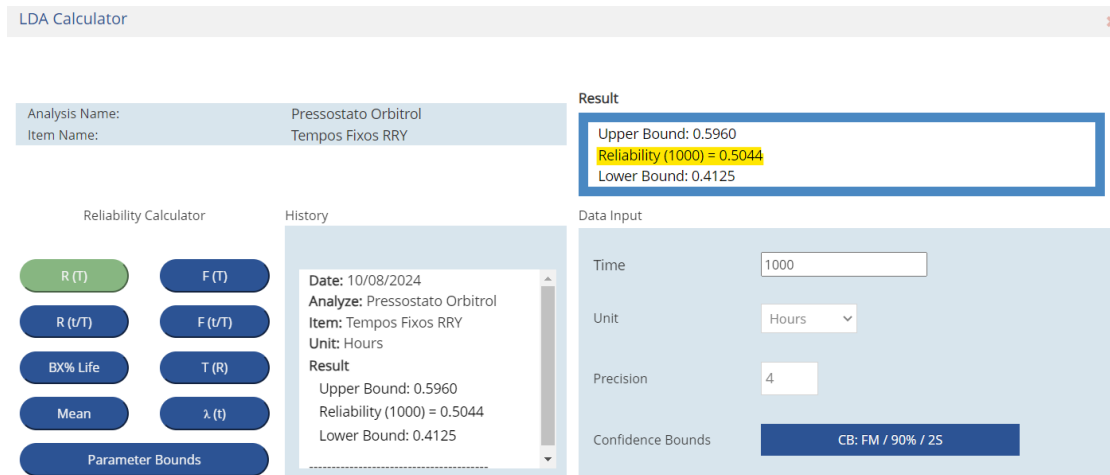


Figura 4-22 – Resultado calculado da Fiabilidade com RRY

4.1.3. Distribuição Lognormal (MLE)

Utilizando os mesmos tempos de falha da Tabela 4-17, começou-se por realizar uma nova análise, desta vez com a Distribuição Lognormal e selecionando o Método MLE. Os dados dos parâmetros obtidos foram os seguintes:

Tabela 4-22 - Resultado dos parâmetros da Distribuição Lognormal (dados fixos) com MLE.

Parâmetro de Forma (σ)	Parâmetro de Escala (μ)	Coefficiente de correlação (ρ)
0.5663	6.9143	0.9884

Em seguida, podem ser observados os gráficos relativos a Distribuição Lognormal utilizando o método MLE, da Probabilidade de Falha $F(t)$, da Taxa de Avarias, da Densidade de Probabilidade de Falha e da Probabilidade de Sucesso $R(t)$, todas elas em função do tempo.




Figura 4-23 - Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com MLE.




Figura 4-24 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com MLE.




Figura 4-25 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) com MLE.




Figura 4-26 - Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) com MLE.

De modo a realizar uma comparação dos valores teóricos e analíticos, aplicaram-se os valores dos parâmetros obtidos com o Método MLE na Equação 3.20 e 3.21:

$$R(1000) = \int_{1000}^{\infty} \frac{1}{\sqrt{2\pi} \cdot 1000 \cdot 0.5663} e^{-\frac{1}{2} \left(\frac{\ln(1000) - 6.9143}{0.5663} \right)^2} = 0.5046 \quad (4.7)$$

Exatamente o mesmo valor foi obtido utilizando a calculadora da ferramenta *Reliability4All*:

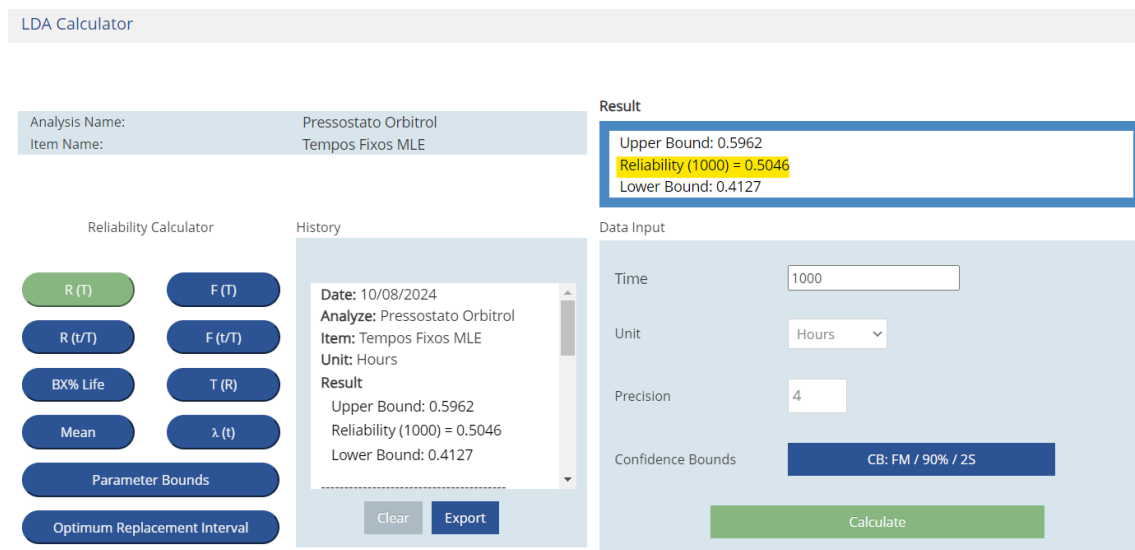


Figura 4-27 - Resultado calculado da Fiabilidade com MLE.

De maneira a obter os gráficos que integrem os três métodos anteriormente abordados, isto é, a Regressão em X, Regressão em Y e o MLE utilizados na Distribuição Lognormal, inseriu-se um filtro para os três métodos anteriores no “*OverlayPlot*” da ferramenta *Reliability4All*. Com esta análise, conseguiu-se compreender melhor o comportamento e a influência de cada um dos métodos anteriormente abordados na Distribuição Lognormal seleccionada para análise. Na Figura 4-28 é possível observar o gráfico comparativo da Probabilidade de Falha.




Figura 4-28 - Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY).

Embora os resultados obtidos sejam muito semelhantes, é possível admitir que o método MLE é o que apresenta a maior taxa de avarias, o que conseqüentemente resulta em uma maior probabilidade de falha para um mesmo tempo de funcionamento. Isso pode ser comprovado pelos gráficos, bem como pelos cálculos teóricos e analíticos.




Figura 4-29 - Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY).

No entanto, a fiabilidade calculada para 1000 horas de trabalho é ligeiramente menor para a Regressão em Y, em comparação com o Método MLE e a Regressão em X.




Figura 4-30 - Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY)

O aumento da taxa de avarias, que influencia a diferença dos resultados para o Método MLE, é notório a partir das 1000 horas, conforme pode ser observado pelo Gráfico 4-31.




Figura 4-31 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos) dos três métodos (MLE, RRX e RRY)

A Regressão em X tende a ser o método que apresenta resultados intermédios em comparação com os restantes métodos e para esta análise. No entanto, é necessário referir que, para esta análise de fiabilidade, utilizando os tempos de falha fixos na Distribuição Lognormal, o método mais adequado tende a ser o de Regressão em Y. Isto deve-se ao facto de ser o método que apresenta o coeficiente de correlação mais próximo de 1, e por esta razão, deverá ser o mais apropriado para esta análise

4.2. Análise com Dados Suspensos

Em seguida, identificou-se uma necessidade de comparar a análise de vida do componente com a utilização dos tempos exatos de falha abordado na primeira análise, mas agora com a introdução dos tempos suspensos.

Deste modo, procedeu-se com uma nova análise de fiabilidade, agora com a utilização dos tempos suspensos, isto é, o tempo decorrido desde a instalação do componente até a data da análise, sem que tenha ocorrido qualquer falha, e neste sentido, em vez de ser considerado uma falha, passa a ser considerado uma suspensão. Com a ajuda do software utilizado na empresa, que permite controlar as horas dos equipamentos, conseguiu-se identificar as horas atuais do equipamento após a última falha registada, ou a desde a sua instalação inicial. Para os equipamentos que não possuem este serviço e que não são comercializados com essa opção, foram considerados apenas os dados de falha exatos.

Neste sentido, fez-se uma análise dos tempos de falha da Tabela 4-16, de maneira a obter os dados suspensos (S) e de falha (F) a utilizar nesta análise e que podem ser observados na Tabela 4-23:

Tabela 4-23 – Tabela dados suspensos (S) e de falha (F) do componente.

Tempo (h)	Estado (F/S)	Tempo (h)	Estado (F/S)	Tempo (h)	Estado (F/S)	Tempo (h)	Estado (F/S)
10	S	648	F	917	F	1847	F
261	S	657	F	925	F	1887	F
284	F	669	F	931	F	1987	F
289	S	670	F	932	F	2043	F
294	S	701	F	995	F	2052	F
338	F	712	F	1051	F	2109	F
469	F	718	S	1077	F	2207	F
517	F	734	F	1126	S	2314	S
539	F	739	F	1151	F	2432	F
560	F	765	F	1156	F	3927	F
561	S	765	S	1204	F	4417	F
578	S	788	F	1323	F		
604	F	804	S	1351	F		
618	F	806	F	1410	F		
634	S	875	F	1582	F		
637	F	878	F	1618	F		
638	F	888	F	1635	F		

Para esta análise e de acordo com o que foi exposto no Capítulo 3, o método de análise que mais se ajusta para a utilização de dados suspensos é o Método da Máxima Verossimilhança, e portanto, é o que será utilizado nesta análise de fiabilidade.

Neste caso, antes de proceder com a análise, fez-se o teste, utilizando o software *Reliability4All*, para encontrar a distribuição que melhor se ajusta aos nossos dados de falha. Tal como pode ser visto na Tabela 4-24, a Distribuição Lognormal é novamente a que apresenta a melhor correspondência:

Tabela 4-24 - Listagem de distribuições de melhor ajuste para os dados segundo *Reliability4All*.

Distribuição	LKV Value
Lognormal	-393.3640
Weibull-3P	-399.9250
Weibull-2P	-400.0953
Normal	-410.8806
Exponencial	-410.9484

4.2.1. Lognormal (MLE) – Dados Suspensos

Neste sentido, começou-se por realizar a análise selecionando a Distribuição Lognormal com o Método MLE. No total foram considerados 50 tempos de falha exatos e 12 suspensões. Os dados do parâmetro de forma (σ), de escala (μ) podem ser vistos na Tabela 4-25.

Tabela 4-25 - Resultado dos parâmetros da Distribuição Lognormal (dados fixos + suspensos) com MLE

Parâmetro de Forma (σ)	Parâmetro de Escala (μ)
0.5747	6.9724

Em comparação com a análise efetuada utilizando a Distribuição Lognormal com o Método MLE mas apenas com os tempos de falha fixos, houve ligeiras alterações que podem ser observadas pelos gráficos da Probabilidade de Falha, da Taxa de Avarias, da função Densidade de Probabilidade de Falha e da Probabilidade de Sucesso, todas elas em função do tempo.




Figura 4-32 - Probabilidade de falha $F(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.

Neste caso, com a introdução dos tempos suspensos na nossa análise, o pico da função da Densidade de Probabilidade de Falha, é ligeiramente inferior comparativamente à distribuição utilizando apenas os tempos fixos. A Figura 4-33 ilustra o gráfico da Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE. Relativamente a taxa de avarias desta análise, que pode ser observada na Figura 4-34, os valores são também ligeiramente inferiores em comparação com a que foi obtida, utilizando apenas os tempos fixos.




Figura 4-33 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.




Figura 4-34 – Taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.

De modo a realizar uma comparação dos valores teóricos e analíticos, aplicaram-se os valores dos parâmetros obtidos com Método MLE na Equação 3.20 e 3.21:

$$R(1000) = \int_{1000}^{\infty} \frac{1}{\sqrt{2\pi} \cdot 1000 \cdot 0.5747} e^{-\frac{1}{2} \left(\frac{\ln(1000) - 6.9724}{0.5747} \right)^2} = 0.5448 \quad (4.8)$$

Exatamente o mesmo valor foi obtido utilizando a calculadora da ferramenta *Reliability4All*:

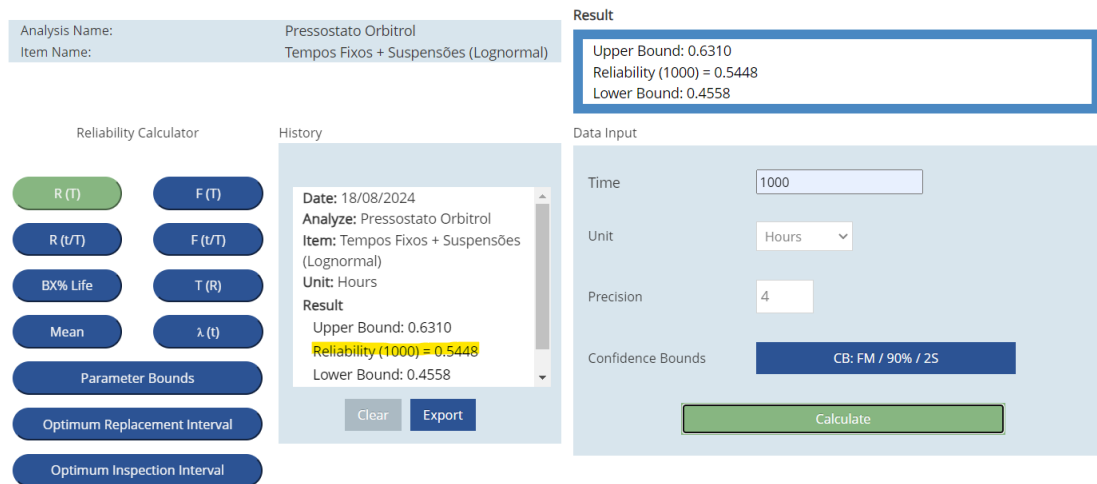


Figura 4-35 - Resultado calculado da Fiabilidade incluindo dados suspensos (Lognormal) com MLE.

Como era de esperar, a introdução dos tempos suspensos na análise, fez otimizar os valores de fiabilidade tal como pode ser observado na Figura 4-36.




Figura 4-36 - Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos + suspensos) com o método MLE.

Em seguida é possível observar uma tabela comparativa de parâmetros obtidos utilizando a Distribuição Lognormal com o Método MLE para a análise de dados fixos e dados fixos mais dados suspensos:

Tabela 4-26 – Comparação dos parâmetros da Distribuição Lognormal (dados fixos vs dados fixos + suspensos).

	Parâmetro de Forma (σ)	Parâmetro de Escala (μ)
Análise com dados de falha fixos	0.5663	6.9143
Análise com dados de falha fixos + suspensos	0.5747	6.9724

De maneira a obter os gráficos comparativos, foram selecionadas a análise dos tempos fixos e a análise dos tempos fixos incluindo os suspensos. Em ambas as análises utilizou-se a Distribuição Lognormal segundo o Método da Máxima Verossimilhança. Para esse efeito, utilizou-se a janela denominada *Overlay Plot* dentro da análise do software *Reliability4All*. Nesta janela, ao criar diferentes análises, é possível visualizar gráficos comparativos entre as mesmas.

Com a introdução dos dados suspensos, houve uma melhoria notória da probabilidade de sucesso. A Figura 4-37 ilustra o gráfico da Fiabilidade em função do tempo para as duas análises realizadas.




Figura 4-37 - Comparação dos gráficos da Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Lognormal (dados fixos vs dados fixos + suspensos) com o método MLE.

Com a introdução dos dados suspensos, o parâmetro de forma (σ) aumentou ligeiramente passando de 0.5663 para 0.5747, e portanto, fez com que a distribuição fosse mais baixa. Por outro lado, o parâmetro de escala (μ) também aumentou, passando de 6.9143 para 6.9724, o que fez estender o gráfico ligeiramente para a direita, tal como demonstra gráfico da Densidade de Probabilidade de Falha da Figura 4-38.




Figura 4-38 - Comparação dos gráficos da Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Lognormal (dados fixos vs dados fixos + suspensos) com o método MLE.

Na Figura 4-39, é possível visualizar o gráfico que representa a taxa de avarias para ambas as análises que sofreu uma diminuição notória com a introdução dos dados suspensos na análise.




Figura 4-39 - Comparação dos gráficos da taxa de avarias em função do tempo da Distribuição Lognormal (dados fixos vs dados fixos + suspensos) com o método MLE.

4.2.2. Weibull Triparamétrica (MLE) – Dados Suspensos

Para a Distribuição Weibull Triparamétrica, e à semelhança da análise anterior, o método utilizado para análise foi a Estimativa por Máxima Verossimilhança. Ao calcular os parâmetros segundo as condições enunciadas, com um intervalo de confiança de 90%, com 50 falhas e 12 suspensões, obtiveram-se os seguintes valores dos parâmetros.

Tabela 4-27 - Resultado dos parâmetros da Distribuição Weibull 3P (dados fixos + suspensos) com MLE

Parâmetro de Forma (β)	Parâmetro de Escala (η)	Parâmetro de Posição (γ)
1.6862	1435.85	9.90

O parâmetro de escala (η) ou a vida característica do componente, e neste caso o valor obtido significa que até às 1435.85 horas, cerca de 63.2% dos pressostatos terão falhado. Com a introdução dos dados suspensos, obteve-se uma clara melhoria na vida característica do componente em comparação com o valor do parâmetro de escala (986.88h) obtido na primeira análise. O valor do parâmetro de posição (γ) ou a vida inicial do pressostato sofreu alteração passando das 277.30 horas obtidas na análise anterior para 9.90 horas com a introdução dos dados suspensos, o que significa que praticamente desde a entrada em funcionamento do componente existe a possibilidade de falhar. Na Figura 4-40 e 4-41, é possível observar o gráfico correspondente a Probabilidade de falha $F(t)$ e o gráfico da Densidade de Probabilidade de Falha da distribuição em função do tempo, respetivamente.




Figura 4-40 - Probabilidade de falha $F(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.




Figura 4-41 – Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.

O parâmetro de forma (β) obtido, indica que a taxa de avarias do componente é crescente ao longo do tempo. Ao analisar o gráfico obtido (Figura 4-42), é possível constatar que o crescimento da taxa de avarias desta análise seja maior a partir de aproximadamente 1800 horas comparativamente com o gráfico que representa a taxa de avarias dos tempos de falha exatos utilizando a Distribuição Weibull Triparamétrica.




Figura 4-42 - Taxa de avarias em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.

De modo a comparar o valor de fiabilidade ao fim de 1000 horas de serviço desta análise com o valor anteriormente calculado apenas com os dados de falha exatos, procedeu-se com o mesmo cálculo na ferramenta:

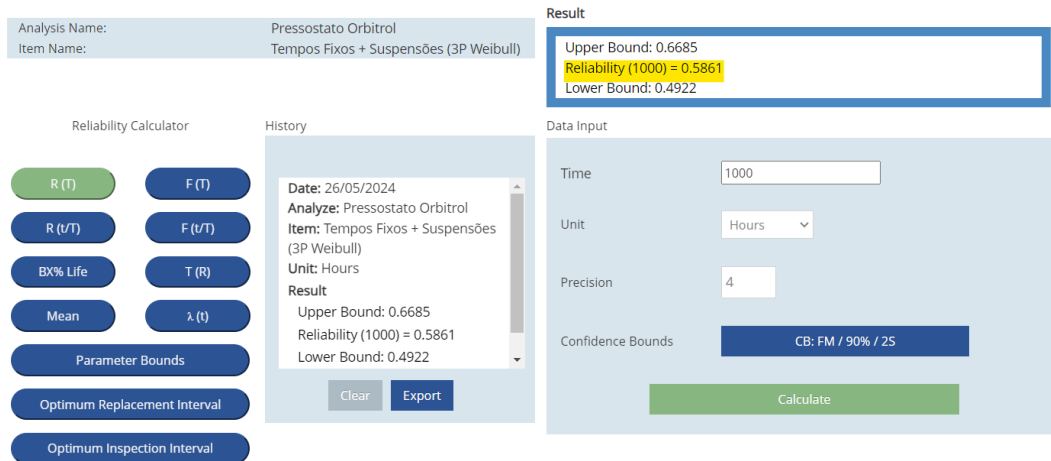


Figura 4-43 – Valor da Fiabilidade obtido na calculadora *Reliability4All*.

O valor obtido de Fiabilidade ao fim de 1000 horas com a introdução dos dados suspensos na análise foi igual a 0.5861. É um valor relativamente superior em comparação com o valor obtido anteriormente $R(1000) = 0.5062$. Confirma-se o valor pela análise do gráfico de Fiabilidade em função do tempo da Figura seguinte:




Figura 4-44 - Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos + suspensos) com o método MLE.

Em seguida é possível observar uma tabela comparativa de parâmetros obtidos utilizando a Distribuição de Weibull com o Método MLE para a análise de dados fixos e dados suspensos:

Tabela 4-28 – Comparação dos parâmetros da distribuição Weibull 3P (dados fixos vs dados fixos + suspensos).

	Parâmetro de Forma (β)	Parâmetro de Escala (η)	Parâmetro de Posição (γ)
Análise com Dados de Falha Fixos	1.2340	986.88	277.30
Análise com Dados de Falha Fixos + Suspensos	1.6862	1435.85	9.90

De maneira a obter os gráficos comparativos, foram selecionadas a análise dos tempos fixos e a análise dos tempos fixos incluindo os suspensos. Em ambas as análises utilizou-se a Distribuição Weibull Triparamétrica segundo o método da máxima verossimilhança. Para esse efeito, utilizou-se a janela denominada *Overlay Plot* dentro da análise do software *Reliability4All*.

A Figura 4-45 ilustra os gráficos da Fiabilidade em função do tempo para as duas análises realizadas.




Figura 4-45 - Comparação dos gráficos da Probabilidade de sucesso $R(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos vs dados fixos + suspensos) com o método MLE.

A Figura 4-46 apresenta o gráfico da função Densidade de Probabilidade de Falha. É possível verificar que a introdução dos dados suspensos faz reduzir o máximo da função. É possível constatar também a influência do parâmetro de posição no gráfico que faz com que o mesmo início num valor bem mais perto do 0. O maior valor do parâmetro de escala com a introdução dos dados suspensos é também notório, fazendo com que a distribuição se estenda para a sua direita., pelo que o tempo em que expetavelmente falharão cerca de 63,2% dos bens é agora mais elevado.




Figura 4-46 - Comparação dos gráficos da Densidade de Probabilidade de Falha $f(t)$ em função do tempo da Distribuição Weibull 3P (dados fixos vs dados fixos+suspensos) MLE.

Na Figura 4-47, é possível visualizar o gráfico que representa a taxa de avarias para ambas as análises. A taxa de avarias é superior na parte inicial para a análise de tempos fixos. Contudo, a partir de 1800 horas, a taxa de avarias incluindo os tempos suspensos tende a ser mais alta.




Figura 4-47 - Comparação dos gráficos da taxa de avarias em função do tempo da Distribuição Weibull 3P (dados fixos vs dados fixos + suspensos) com o método MLE.

4.3. Previsão de Garantias

Com o uso do *software Reliability4All* foi também possível realizar uma previsão de retornos em tempo de garantia. Para isso, foi selecionado o módulo *Warranty Analysis - NRI* (Itens não-reparáveis), pois as garantias abordadas nesta análise envolvem situações em que o componente danificado é substituído, em vez de ser reparado.

O primeiro passo foi identificar a quantidade de equipamentos vendidos e os retornos de cada mês do ano de 2023. Estes dados foram então inseridos no Gráfico Nevada, que pode ser observado na Figura 4-48.

Figura 4-48 – Gráfico de Nevada (vendas vs retornos por mês).

Período	Vendas	Retornos por mês											
		fev/23	mar/23	abr/23	mai/23	jun/23	jul/23	ago/23	set/23	out/23	nov/23	dez/23	jan/24
jan/23	21	3	3	2	1	3	2	1	1	1	1	1	1
fev/23	18		2	2	0	1	1	1	1	1	1	0	0
mar/23	17			6	1	1	2	1	3	1	1	0	1
abr/23	7				0	0	2	0	1	0	1	0	1
mai/23	19					1	0	0	1	2	1	0	1
jun/23	8						0	1	0	0	0	0	0
jul/23	16							2	1	1	0	1	2
ago/23	9								2	0	1	0	0
set/23	5									1	2	0	0
out/23	7										1	1	1
nov/23	16											4	1
dez/23	11												1
jan/24	14												
fev/24	7												
mar/24	10												

A distribuição selecionada para este estudo foi a Weibull 3P, por ser a que melhor se ajusta aos dados apresentados, conforme mostra a Tabela 4-30. De acordo com os dados introduzidos, os valores dos parâmetros de escala e de posição são expressos em meses. Os parâmetros obtidos com esta simulação foram os seguintes:

Tabela 4-29 - Resultado dos parâmetros da Distribuição Weibull 3P (previsão garantias) com MLE.

Parâmetro de Forma (β)	Parâmetro de Escala (η)	Parâmetro de Posição (γ)
0.5102	9.59	0.99

Tabela 4-30 - Listagem de distribuições de melhor ajuste para os dados segundo *Reliability4All*.

Distribuição	LKV Value
Weibull-3P	-210.7253
Lognormal	-253.6137
Weibull-2P	-255.9957
Exponencial	-258.7527
Normal	-276.1287

Em seguida, podem ser observados os gráficos da Probabilidade de Falha $F(t)$, da Taxa de Avarias, e da Probabilidade de Sucesso $R(t)$, todas elas em função do tempo.




Figura 4-49 - Probabilidade de Falha $F(t)$ em função do tempo da Distribuição Weibull 3P (previsão garantias) com o método MLE.

Tal como mostra o gráfico da probabilidade de falha, o parâmetro de localização (γ) define o início do período de falhas, ajustando a distribuição no eixo do tempo, sugerindo que as falhas começam a ocorrer perto de 1 unidade de tempo (mês) após a venda.




Figura 4-50 – Taxa de avarias em função do tempo da Distribuição Weibull 3P (previsão garantias) com o método MLE.

Neste caso, tal como o parâmetro de forma ($\beta=0.5102$) indica uma taxa de falhas decrescente, sugerindo que a probabilidade de falha diminui com o tempo, o que pode também ser confirmado no gráfico obtido da taxa de avarias da distribuição.




Figura 4-51 - Probabilidade de Sucesso $R(t)$ em função do tempo da Distribuição Weibull 3P (previsão garantias) com o método MLE.

No gráfico da fiabilidade é possível confirmar o valor do Parâmetro de Escala (η) obtido, isto é, 9.60 meses, que representa a vida característica do produto, o ponto em que aproximadamente 63,2% dos produtos terão falhado.

Continuando a simulação, obteve-se o número previsto de garantias para os meses de fevereiro, março, abril e maio de 2024 pela simulação do *Software Reliability 4All*, conforme apresentado na Tabela 4-32.

Tabela 4-31 – Simulação da previsão de garantias segundo *Reliability4All*.

Período	Vendas	Fev/24	Mar/24	Abr/24	Mai/24
Jan/23	21	0,05	0,04	0,04	0,04
Fev/23	18	0,40	0,36	0,33	0,30
Mar/23	17	0,00	0,00	0,00	0,00
Abr/23	7	0,11	0,10	0,09	0,08
Mai/23	19	0,76	0,67	0,60	0,54
Jun/23	8	0,44	0,38	0,34	0,30
Jul/23	16	0,61	0,52	0,46	0,41
Ago/23	9	0,45	0,37	0,32	0,28
Set/23	5	0,17	0,14	0,11	0,10
Out/23	7	0,39	0,30	0,25	0,21
Nov/23	16	1,37	0,94	0,73	0,59
Dez/23	11	2,49	0,94	0,64	0,50
Jan/24	14	0,42	3,39	1,27	0,87
Fev/24	7		0,21	1,69	0,64
Mar/24	10			0,30	2,42
Total		7,64	8,37	7,17	7,28

Da mesma forma, através da recolha de dados das obras em garantia da Oficina, foi possível identificar o número de devoluções em tempo de garantias reais para os meses anteriormente referidos, os mesmos são apresentados na Tabela 4-33.

Tabela 4-32 – Quantidade de garantias registadas.

Mês	Fev/24	Mar/24	Abr/24	Mai/24
Nº Garantias	8	9	7	8

Ao comparar os números previstos com os números reais, observa-se as seguintes variações:

- Fevereiro: A previsão na simulação era de 7,64 retornos em tempo de garantia, enquanto o número real de retornos foi de 8 garantias, registrando um desvio percentual de 4,48%.
- Março: A previsão na simulação era de 8,37 retornos em tempo de garantia, enquanto o número real de retornos foi de 9 garantias, registrando um desvio percentual de 7,02%.
- Abril: A previsão na simulação era de 7,17 retornos em tempo de garantia, enquanto o número real de retornos foi de 7 garantias, registrando um desvio percentual de -2,49%.
- Maio: A previsão na simulação era de 7,28 retornos em tempo de garantia, enquanto o número real de retornos foi de 8 garantias, registrando um desvio percentual de 9%.

Esses resultados indicam que as previsões por simulação se encontram bastante próximas dos valores reais, com pequenas diferenças que podem ser justificadas por algum equipamento não identificado ou pelas variabilidades inerentes ao processo de previsão. No entanto, é possível afirmar que este modelo de previsão de garantias pode continuar a ser utilizado para obter uma gestão mais eficiente dos retornos em fase de garantia.

5. Conclusões e Trabalhos Futuros

Esta dissertação teve como objetivo realizar uma análise detalhada de fiabilidade e previsão de retorno de garantias, utilizando métodos estatísticos e analíticos robustos. O método de Análise Hierárquica de Processos (AHP) foi essencial para identificar a peça crítica entre todas as garantias avaliadas. A aplicação do AHP permitiu hierarquizar as peças de acordo com a importância e, deste modo, garantir que o estudo fosse focado nos componentes mais relevantes para as necessidades específicas da empresa. Esta abordagem facilitou a priorização e proporcionou uma base sólida para as etapas subsequentes da análise de fiabilidade.

A análise de fiabilidade foi realizada com vários modelos estatísticos para determinar a distribuição mais adequada para os dados de falha. Após uma comparação detalhada, a Distribuição Lognormal foi identificada como a mais apropriada segundo o Método de Regressão Linear em Y, isto devido ao facto de ser o método que apresentou o coeficiente de correlação mais próximo de 1. Esta escolha foi baseada no *Software Reliability4All*, que demonstrou que a Distribuição Lognormal oferece uma representação mais precisa dos dados de falha analisados.

Uma nova análise foi conduzida para incluir dados suspensos, isto é, os tempos dos equipamentos que estavam em serviço sem apresentar falhas desde a última falha registada. Com a introdução dos dados suspensos na Distribuição Weibull, obteve-se uma clara melhoria na vida característica do componente (1435.35h) em comparação com o valor do parâmetro de escala (986.88h) obtido na primeira análise, fazendo com que a distribuição se estendesse para a sua direita. O valor do parâmetro de posição (γ) ou a vida inicial do pressostato sofreu alteração passando das 277.30 horas obtidas na análise anterior para 9.90 horas com a introdução dos dados suspensos. Por outro lado, com a introdução dos dados suspensos na Distribuição Lognormal, o parâmetro de forma aumentou e, portanto, fez com que a distribuição fosse mais baixa.

Em suma, a introdução de dados suspensos, com a análise realizada através do método de Máxima Verosimilhança (MLE), melhorou significativamente a fiabilidade dos modelos. Foi observado que a inclusão destes dados resultou em melhorias nos parâmetros de escala e forma para a peça crítica selecionada. Esta abordagem confirmou que o MLE é particularmente eficaz para este tipo de análise, proporcionando uma avaliação mais precisa e abrangente da fiabilidade dos equipamentos.

Para completar o estudo, foi realizada uma previsão de retorno de garantias com base nas vendas mensais de 2023 e nos retornos de garantia subsequentes registados. A precisão do modelo foi validada comparando as previsões com os resultados reais, onde o desvio percentual máximo foi de 9%. Este resultado indica que o modelo

desenvolvido é fiável e pode ser utilizado para previsões futuras de retorno de garantias. Contudo, é importante reconhecer a possibilidade de erros na identificação dos equipamentos, que podem afetar a precisão das previsões. Portanto, recomenda-se uma revisão contínua dos dados e dos modelos para garantir a manutenção da sua precisão.

O presente trabalho demonstrou a eficácia de combinar diferentes métodos analíticos e estatísticos para a análise de fiabilidade e previsão de retorno de garantias. A identificação da peça crítica através do método AHP, a escolha da Distribuição Lognormal como modelo mais adequado, a incorporação de dados suspensos via MLE, e o modelo de previsão de garantias são contribuições significativas desta pesquisa.

Além disso, a aplicação prática das conclusões deste trabalho pode resultar em melhorias significativas na gestão de garantias e na fiabilidade dos sistemas analisados dentro da estrutura da empresa.

Relativamente aos trabalhos futuros, recomenda-se que se explore a integração de novas técnicas de *machine learning e big data analytics* para potencializar ainda mais a precisão das previsões e a eficácia das análises de fiabilidade. A evolução tecnológica e a disponibilidade crescente de dados oferecem oportunidades promissoras para o avanço contínuo neste campo. Através de futuros estudos realizados, a organização poderá vir a usar estes dados para organizar melhor o serviço de assistência de acordo com as necessidades previstas.

Para além disso, sugere-se que todos os componentes que demonstrem falhas sucessivas sejam alvos de uma análise de fiabilidade, com o objetivo de identificar a vida útil dos mesmos e garantir que exista sempre stock suficiente em função da quantidade de equipamentos existentes. A implementação de tais medidas é essencial para assegurar a continuidade operacional e otimizar a gestão de recursos.

No âmbito da previsão de retornos em garantia, sugere-se identificar nos retornos esperados em garantia quais os componentes que expetavelmente poderão ser as razões dos retornos e assim otimizar toda a gestão de stocks.

Por fim, ao contribuir para a manutenção preditiva, estas medidas promovem uma cultura de melhoria contínua dentro da organização. Dessa forma, a empresa não só aumenta a fiabilidade e a vida útil dos seus equipamentos, como também otimiza seus recursos e melhora a satisfação dos clientes.

Referências

- Birolini, A. (2007). *Reliability engineering: Theory and practice* (5th ed.). Springer. <https://doi.org/10.1007/978-3-540-49390-7>
- Carinhas, H. P. (2009). *Disciplina de Fiabilidade*. Instituto Superior de Engenharia de Lisboa - Departamento de Engenharia Mecânica.
- Carvalho, A. J. O. (2019). *Análise da influência das atividades de operação e manutenção na disponibilidade operacional de um ativo físico* (Master's thesis). Instituto Superior de Engenharia de Lisboa - Departamento de Engenharia Mecânica.
- Dunn, W. L., & Shultis, J. K. (2012). *Exploring Monte Carlo Methods* (1st ed.). Elsevier. ISBN: 978-0-444-51575-9
- Elsayed, E. A. (2021). *Reliability engineering* (3rd ed.). Wiley-Blackwell. Rutgers University. ISBN: 978-1-119-66592-2
- Emrouznejad, A., & Marra, M. (2017). The state of the art development of AHP (1979–2017): A literature review with a social network analysis. *International Journal of Production Research*, 55(22), 6653–6675. <https://doi.org/10.1080/00207543.2017.1334976>
- Forman, E. H., & Gass, S. I. (2001). The analytic hierarchy process—An exposition. *Operations Research*, 49(4), 469–486. <https://doi.org/10.1287/opre.49.4.469.11231>
- Galar, D., & Kumar, U. (2017). Chapter 6 - Prognosis. In *eMaintenance - Essential Electronic Tools for Efficiency* (pp. 311–370). Elsevier. <https://doi.org/10.1016/B978-0-12-811153-6.00006-3>
- Geyer, C. J. (2007). *Fisher information and confidence intervals using maximum likelihood*. University of Minnesota.
- Hottinger Bruel & Kjaer Inc. (2024). *Life data analysis—ReliaSoft*. Technology Centre, Advanced Manufacturing Park.
- Ikbal, N. A. M., Halim, S. A., & Ali, N. (2022). Estimating Weibull parameters using maximum likelihood estimation and ordinary least squares: Simulation study and application on meteorological data. *Mathematics and Statistics*, 10(2), 269–292. <https://doi.org/10.13189/ms.2022.100201>
- Kececioglu, D. (2002). *Reliability engineering handbook* (Vol. 1). Destech Publications.
- Khaira, A., & Dwivedi, R. K. (2018). A state of the art review of the analytic hierarchy process. *Materials Today: Proceedings*, 5(2), 4029–4035. <https://doi.org/10.1016/j.matpr.2017.11.663>
- Kissell, R., & Poserina, J. (2017). Advanced math and statistics. In *Optimal sports math, statistics, and fantasy* (pp. 103–135). Elsevier. <https://doi.org/10.1016/B978-0-12-805163-4.00004-9>
- Kostagiolas, P. (2012). Measuring libraries' intellectual capital. In *Managing intellectual capital in libraries* (pp. 87–127). Chandos Publishing. <https://doi.org/10.1016/B978-1-84334-678-4.50004-9>
- Lai, C.-D. (2014). *Generalized Weibull distributions* (1st ed.). Springer. <https://doi.org/10.1007/978-3-642-39106-4>

Lee, M. C., Wang, W., & Wang, H. Y. (2007). A method of performance evaluation by using the analytic network process and balanced score card. In *Proceedings of the 2007 International Conference on Convergence Information Technology (ICCIT 2007)* (pp. 235–240). IEEE. <https://doi.org/10.1109/ICCIT.2007.4420266>

Madzík, P., & Falát, L. (2022). State-of-the-art on analytic hierarchy process in the last 40 years: Literature review based on Latent Dirichlet Allocation topic modelling. *PLoS ONE*, 17(5), e0268777. <https://doi.org/10.1371/journal.pone.0268777>

Manitou Repair Manual (2021). Manitou BF.

Marques, J. D. A. (2015). *Implementação de um programa de fiabilidade de aeronaves* (Master's thesis). Instituto Superior de Engenharia de Lisboa - Departamento de Engenharia Mecânica.

Modarres, M., Kaminskiy, M. P., & Krivtsov, V. (2016). *Reliability engineering and risk analysis: A practical guide* (3rd ed.). CRC Press. <https://doi.org/10.1201/9781315382425>

NP EN 13306. (2017). Terminologia da Manutenção. BSI Standards Publication.

O'Connor, A., Modarres, M., & Mosleh, A. (2016). *Probability distributions used in reliability engineering*. Center for Risk and Reliability, University of Maryland. ISBN: 978-0-9966468-1-9

Rinne, H. (2008). *The Weibull distribution: A handbook* (1st ed.). CRC Press. <https://doi.org/10.1201/9781420087444>

Rocha, D. A. P., & Morais, W. A. (2020). Análise dos dados de vida para ativos industriais utilizando distribuição Weibull 3P. *Tecnologia Em Metalurgia Materiais e Mineração*, 17(1), 53–60. <https://doi.org/10.4322/2176-1523.20202032>

Saaty, T. L. (2008). Decision making with the analytic hierarchy process. *International Journal of Services Sciences*, 1(1), 83–98. <https://doi.org/10.1504/IJSSCI.2008.017590>

Sobral, J. (2020). *U.C. Fiabilidade do Mestrado em Engenharia Mecânica*. Instituto Superior de Engenharia de Lisboa - Departamento de Engenharia Mecânica.

Sousa, W. B. (2018). *Estimadores de máxima verossimilhança: Casos que não satisfazem as condições de regularidade* (Master's thesis). Universidade de Brasília - Instituto de Ciências Exatas.

Sugiyama, M. (2016). *Introduction to statistical machine learning*. Morgan Kaufmann. <https://doi.org/10.1016/C2014-0-01992-2>

Taherdoost, H. (2017). Decision making using the analytic hierarchy process (AHP): A step by step approach. *International Journal of Economics and Management Systems*, Vol. 2.

Vargas, R. V. (2010). Using the analytic hierarchy process (AHP) to select and prioritize projects in a portfolio. *PMI Global Congress 2010 - North America*.

Wang, L. (2015). *Fisher matrix*.

Wieckowski, J., & Salabun, W. (2020). How the normalization of the decision matrix influences the results in the VIKOR method. *Procedia Computer Science*, 176, 2222–2231. <https://doi.org/10.1016/j.procs.2020.09.259>

Wollmann, D., Steiner, M. T. A., Vieira, G. E., & Steiner, P. A. (2014). Details of the analytic hierarchy process technique for the evaluation of health insurance companies. *Gestão & Produção*, 21(3), 583–593. <http://dx.doi.org/10.1590/S0103-65132013005000070>

Anexo 1 – Tabela de Distribuição Normal Padrão

x	0.00	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5753
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6736	0.6772	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7019	0.7054	0.7088	0.7123	0.7157	0.7190	0.7224
0.6	0.7257	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7517	0.7549
0.7	0.7580	0.7611	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7881	0.7910	0.7939	0.7967	0.7995	0.8023	0.8051	0.8078	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8289	0.8315	0.8340	0.8365	0.8389
1	0.8413	0.8438	0.8461	0.8485	0.8508	0.8531	0.8554	0.8577	0.8599	0.8621
1.1	0.8643	0.8665	0.8686	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9082	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9192	0.9207	0.9222	0.9236	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9357	0.9370	0.9382	0.9394	0.9406	0.9418	0.9429	0.9441
1.6	0.9452	0.9463	0.9474	0.9484	0.9495	0.9505	0.9515	0.9525	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9599	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9678	0.9686	0.9693	0.9699	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9761	0.9767
2	0.9772	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
2.1	0.9821	0.9826	0.9830	0.9834	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9864	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9913	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9932	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9974	0.9975	0.9976	0.9977	0.9977	0.9978	0.9979	0.9979	0.9980	0.9981
2.9	0.9981	0.9982	0.9982	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995
3.3	0.9995	0.9995	0.9995	0.9996	0.9996	0.9996	0.9996	0.9996	0.9996	0.9997
3.4	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9997	0.9998
3.5	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998	0.9998
3.6	0.9998	0.9998	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.7	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.8	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999
3.9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

Anexo 3 – Esquema elétrico

