




UNIVERSIDADE FEDERAL DE OURO PRETO
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE ESTATÍSTICA
BACHARELADO EM ESTATÍSTICA



Modelo Geral de Degradação: Aplicação do Método Aproximado a Dados de Laser

Pedro Henrique Romanhol Pessoa

Ouro Preto-MG
Fevereiro de 2024

Pedro Henrique Romanhol Pessoa

Modelo Geral de Degradação: Aplicação do Método Aproximado a Dados de Laser

Monografia de Graduação apresentada ao Departamento de Estatística do Instituto de Ciências Exatas e Biológicas da Universidade Federal de Ouro Preto como requisito parcial para a obtenção do grau de bacharel em Estatística.

Orientador(a)

Prof. Dr. Rivert Paulo Braga Oliveira

UNIVERSIDADE FEDERAL DE OURO PRETO – UFOP
DEPARTAMENTO DE ESTATÍSTICA – DEEST

Ouro Preto-MG

Fevereiro de 2024

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

P475m Pessoa, Pedro Henrique Romanhol.

Modelo geral de degradação [manuscrito]: aplicação do método
aproximado a dados de laser. / Pedro Henrique Romanhol Pessoa. - 2024.
47 f.: il.: , gráf., tab..

Orientador: Prof. Dr. Rívert Paulo Braga Oliveira.

Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Exatas e Biológicas. Graduação em Estatística .

1. Estatística. 2. Métodos de aproximação. 3. Monte Carlo, Método de.
4. Lasers. I. Oliveira, Rívert Paulo Braga. II. Universidade Federal de Ouro
Preto. III. Título.

CDU 311

Bibliotecário(a) Responsável: Paulo Vitor Oliveira - CRB6/2551



FOLHA DE APROVAÇÃO

Pedro Henrique Romanhol Pessoa

Modelo Geral de Degradação: Aplicação do Método Aproximado a Dados de Laser

Monografia apresentada ao Curso de Estatística da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Estatística.

Aprovada em 20 de fevereiro de 2024

Membros da banca

Dr. Rivert Paulo Braga Oliveira - Orientador (Universidade Federal de Ouro Preto)
Dra. Carolina Silva Pena - Membro (Universidade Federal de Ouro Preto)
Dr. Eduardo Bearzoti - Membro (Universidade Federal de Ouro Preto)

Prof. Dr. Rivert Paulo Braga Oliveira, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 20/02/2024



Documento assinado eletronicamente por **Rivert Paulo Braga Oliveira**, **PROFESSOR DE MAGISTERIO SUPERIOR**, em 21/02/2024, às 18:19, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Eduardo Bearzoti**, **PROFESSOR DE MAGISTERIO SUPERIOR**, em 21/02/2024, às 20:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Carolina Silva Pena**, **PROFESSOR DE MAGISTERIO SUPERIOR**, em 22/02/2024, às 09:46, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0670897** e o código CRC **0E26E250**.

Este trabalho é todo dedicado aos meus pais, pois é graças ao seus esforços que hoje posso concluir o meu curso, à minha irmã, Maria Eduarda e à minha namorada Marina.

Agradecimentos

Agradeço aos meus pais, Alan e Silvana; a minha irmã Maria Eduarda; a minha namorada Marina; aos meus amigos e familiares.

Agradeço a todos os meus professores do IFMG pelo conhecimento transmitido, em especial ao professor Bruno, que me incentivou a conhecer o curso de estatística.

Ao meu orientador Prof. Dr. Rivert Paulo Braga Oliveira, pela orientação e dedicação na elaboração desta monografia.

Agradeço aos meus professores de graduação em Estatística pelo conhecimento transmitido.

"Sem dados você é apenas mais uma pessoa com uma opinião."

William Edwards Deming

Modelo Geral de Degradação: Aplicação do Método Aproximado a Dados de Laser

Autor: Pedro Henrique Romanhol Pessoa

Orientador(a): Prof. Dr. Rivert Paulo Braga Oliveira

RESUMO

Neste trabalho uma base de dados de degradação laser serviu de ponto de partida para ensinar a apresentação do Modelo Geral de Degradação e dois de seus métodos de estimação. Também importantes para a inferência sobre a distribuição dos Tempos de Falha, os modelos probabilísticos Weibull e Lognormal foram apresentados com as respectivas quantidades de interesse na área de confiabilidade que caracterizam tais modelos. Ademais, apresentaram-se os passos da simulação Monte Carlo para construção de intervalos de confiança. A metodologia foi então aplicada a dados de laser para ilustração do passo a passo de análise de dados de degradação com a utilização do método aproximado. As quantidades de interesse estimadas permitiram extrair informações importantes para o contexto da situação prática motivadora deste texto.

Palavras-chave: Modelo Geral de Degradação, Método Aproximado

General Path Models for Degradation Data: an Application of Approximated and Numerical Methods for Laser Data

Author: Pedro Henrique Romanhol Pessoa

Advisor: Prof. Dr. Rivert Paulo Braga Oliveira

ABSTRACT

In this work, the laser degradation database served as a starting point to present the General Degradation Model and two of its estimation methods. Also important for inferring the distribution of Failure Times, the Weibull and Lognormal probabilistic models were presented with the respective quantities of interest in the area of reliability that characterize such models. Furthermore, the Monte Carlo simulation steps for constructing Confidence Intervals were presented. The methodology was then applied to laser data to illustrate step-by-step degradation data analysis using the approximated method. The estimated quantities of interest made it possible to extract important information for the context of the practical situation that motivated this text.

Keywords: General Path Models, Approximated Method,

Lista de figuras

1	Perfis de Degradação	p. 28
2	$R(T)$: Kaplan-Meier versus Modelos Paramétricos (Exponencial, Weibull e Lognormal, respectivamente.)	p. 30

Lista de tabelas

1	Dados de degradação de laser	p. 16
2	Parâmetros - Método Aproximado	p. 32

Lista de abreviaturas e siglas

UFOP – Universidade Federal de Ouro Preto

DEEST – Departamento de Estatística

N – distribuição Normal

fda – função distribuição acumulada

fdp – função densidade de probabilidade

Lista de símbolos

Y_{ij} (variável aleatória da degradação da i -ésima unidade sob teste, no j -ésimo tempo)

t_{ij} (j -ésimo tempo de medição do i -ésimo item sob teste com $i = 1, 2, \dots, n$ unidades sob teste, $j = 1, 2, \dots, m_i$ tempos de medição da i -ésima unidade)

n (número de itens sob teste)

m_i (número de medições do i -ésimo item sob teste)

β_i (vetor de parâmetros da equação $D(t_{ij}, \beta_i)$)

$D(t_{ij}, \beta_i)$ (forma funcional determinística que modela os perfis de degradação de cada unidade amostral i)

ε_{ij} (erro do Modelo Geral de Degradação, da i -ésima unidade sob teste, no j -ésimo tempo)

σ_ε^2 (variância dos erros ε_{ij})

D_f (limiar de degradação definidor de falha)

T (variável aleatória do tempo até a falha)

F (função distribuição acumulada)

β (matriz de parâmetros da equação $D(t, \beta)$)

$D(t, \beta)$ (equação da forma funcional determinística que modela conjuntamente os n perfis de degradação)

θ (vetor de parâmetros de uma distribuição de probabilidade genérica. Neste texto pode se referir tanto a β , quanto β_i , ou quanto a T . No contexto ficará claro)

\hat{T}_i (“pseudo tempo de falha” da i -ésima unidade sob teste)

$\hat{\bullet}$ (estimador genérico)

$\Phi_{nor}(\bullet)$ (fda da distribuição normal padrão)

μ_\bullet parâmetro de locação genérico da distribuição Lognormal

σ_\bullet parâmetro de escala genérico da distribuição Lognormal

λ_{\bullet} parâmetro de escala genérico da distribuição Weibull

δ_{\bullet} parâmetro de forma genérico da distribuição Weibull

X (variável aleatória genérica)

f (função densidade de probabilidade)

R (função de Confiabilidade/Sobrevivência)

Q (percentil)

E (tempo médio até a falha)

MTTF (*mean time to failure* ou tempo médio até a falha)

Var (variância do tempo até a falha)

$(1 - \alpha)\%$ (nível de confiança)

Sumário

1	Introdução	p. 15
1.1	Situação Prática Motivadora	p. 15
1.2	Organização do trabalho	p. 17
2	Objetivos	p. 18
3	Metodologia	p. 19
3.1	Modelo Geral de Degradação	p. 19
3.1.1	Método Aproximado	p. 20
3.1.2	Método Analítico	p. 21
3.2	Funções Distribuições Úteis para este Estudo	p. 22
3.2.1	Distribuição Weibull	p. 23
3.2.2	Distribuição Lognormal	p. 24
3.3	Monte Carlo para a construção de intervalos de confiança	p. 25
4	Resultados e Discussão	p. 27
4.1	Método Apróximado	p. 27
4.2	Ajuste dos Modelos Paramétricos	p. 29
4.3	Quantidades de Interesse: Estimativas Pontuais e Intervalares	p. 31
5	Considerações finais	p. 33
	Referências	p. 34
	Anexo A – Primeiro anexo	p. 35

1 Introdução

Atualmente as empresas têm uma grande preocupação com a confiabilidade de seus produtos e equipamentos. A obtenção da falha dos equipamentos pode ser um problema, uma vez que modelos convencionais para estudo da confiabilidade, baseados na teoria da normalidade dos estimadores de máxima verossimilhança, requerem a ocorrência de falhas. Para preencher essa lacuna, é necessário utilizar os modelos gerais de degradação, os quais permitem a estimação dos tempos de falha através da análise de degradação dos equipamentos ao longo do tempo.

Um livro importante e seminal para dados de degradação é o de Meeker e Escobar (1998), o qual compila vários modelos de degradação, dentre eles o método de aproximação e o método numérico. No livro são também apresentados dados de degradação de laser, os quais este texto de monografia se debruça em sua re-análise pelo método analítico.

Após a impressão do livro de Meeker e Escobar (1998) uma série de artigos foi publicada no tema e, posteriormente, os de maior impacto para a área aparecem no livro de Nikulin et al. (2010). Outra revisão sistemática mais recente pode ser encontrada em Shahraki, Yadav e Liao (2017).

A Seção 1.1 ilustra bem a que contexto se aplicam os modelos de degradação.

1.1 Situação Prática Motivadora

Os dados apresentados na Tabela 1 fazem parte de um exemplo no livro de Meeker e Escobar (1998). Tratam-se de dados de degradação de quinze ($n = 15$) emissores de laser cujas medições aconteceram num período de $t_f = 4000$ horas, isto é, o tempo final do estudo. A cada 250 horas, para cada unidade emissora de laser, registrava-se o percentual de aumento na corrente de operação calculado em relação à corrente nominal de operação, ou seja, aquela do início do ensaio. Note que a informação é importante pois a potência da luz dos lasers se degrada ao longo do tempo se a corrente de operação é mantida

constante. Então a corrente de operação precisa ser corrigida ao longo do tempo de uso para garantir a mesma potência de emissão da luz. A medida de degradação y , neste caso, é o percentual de aumento na corrente de operação. A “falha” do laser é definida quando o percentual de aumento na corrente excede 10%. Assim, a partir do limiar $D_f = 10\%$ o laser “falha”, embora ainda esteja em operação.

Unidade	Tempo	Desgaste	Unidade	Tempo	Desgaste	Unidade	Tempo	Desgaste	Unidade	Tempo	Desgaste	Unidade	Tempo	Desgaste	Unidade	Tempo	Desgaste
1	0	0.00	4	0	0.00	7	0	0.00	10	0	0.00	13	0	0.00			
1	250	0.47	4	250	0.36	7	250	0.36	10	250	0.41	13	250	0.30			
1	500	0.93	4	500	0.62	7	500	0.92	10	500	1.49	13	500	0.74			
1	750	2.11	4	750	1.36	7	750	1.21	10	750	2.38	13	750	1.52			
1	1000	2.72	4	1000	1.95	7	1000	1.46	10	1000	3.00	13	1000	1.85			
1	1250	3.51	4	1250	2.30	7	1250	1.93	10	1250	3.84	13	1250	2.39			
1	1500	4.34	4	1500	2.95	7	1500	2.39	10	1500	4.50	13	1500	2.95			
1	1750	4.91	4	1750	3.39	7	1750	2.68	10	1750	5.25	13	1750	3.51			
1	2000	5.48	4	2000	3.79	7	2000	2.94	10	2000	6.26	13	2000	3.92			
1	2250	5.99	4	2250	4.11	7	2250	3.42	10	2250	7.05	13	2250	5.03			
1	2500	6.72	4	2500	4.50	7	2500	4.09	10	2500	7.80	13	2500	5.47			
1	2750	7.13	4	2750	4.72	7	2750	4.58	10	2750	8.32	13	2750	5.84			
1	3000	8.00	4	3000	4.98	7	3000	4.84	10	3000	8.93	13	3000	6.50			
1	3250	8.92	4	3250	5.28	7	3250	5.11	10	3250	9.55	13	3250	6.94			
1	3500	9.49	4	3500	5.61	7	3500	5.57	10	3500	10.45	13	3500	7.39			
1	3750	9.87	4	3750	5.95	7	3750	6.11	10	3750	11.28	13	3750	7.85			
1	4000	10.94	4	4000	6.14	7	4000	7.17	10	4000	12.21	13	4000	8.09			
2	0	0.00	5	0	0.00	8	0	0.00	11	0	0.00	14	0	0.00			
2	250	0.71	5	250	0.27	8	250	0.46	11	250	0.44	14	250	0.44			
2	500	1.22	5	500	0.61	8	500	1.07	11	500	1.00	14	500	0.70			
2	750	1.90	5	750	1.11	8	750	1.42	11	750	1.57	14	750	1.05			
2	1000	2.30	5	1000	1.77	8	1000	1.77	11	1000	1.96	14	1000	1.35			
2	1250	2.87	5	1250	2.06	8	1250	2.11	11	1250	2.51	14	1250	1.80			
2	1500	3.75	5	1500	2.58	8	1500	2.40	11	1500	2.84	14	1500	2.55			
2	1750	4.42	5	1750	2.99	8	1750	2.78	11	1750	3.47	14	1750	2.83			
2	2000	4.99	5	2000	3.38	8	2000	3.02	11	2000	4.01	14	2000	3.39			
2	2250	5.51	5	2250	4.05	8	2250	3.29	11	2250	4.51	14	2250	3.72			
2	2500	6.07	5	2500	4.63	8	2500	3.75	11	2500	4.80	14	2500	4.09			
2	2750	6.64	5	2750	5.24	8	2750	4.16	11	2750	5.20	14	2750	4.83			
2	3000	7.16	5	3000	5.62	8	3000	4.76	11	3000	5.66	14	3000	5.41			
2	3250	7.78	5	3250	6.04	8	3250	5.16	11	3250	6.20	14	3250	5.76			
2	3500	8.42	5	3500	6.32	8	3500	5.46	11	3500	6.54	14	3500	6.14			
2	3750	8.91	5	3750	7.10	8	3750	5.81	11	3750	6.96	14	3750	6.51			
2	4000	9.28	5	4000	7.59	8	4000	6.24	11	4000	7.42	14	4000	6.88			
3	0	0.00	6	0	0.00	9	0	0.00	12	0	0.00	15	0	0.00			
3	250	0.71	6	250	0.36	9	250	0.51	12	250	0.39	15	250	0.51			
3	500	1.17	6	500	1.39	9	500	0.93	12	500	0.80	15	500	0.83			
3	750	1.73	6	750	1.95	9	750	1.57	12	750	1.35	15	750	1.29			
3	1000	1.99	6	1000	2.86	9	1000	1.96	12	1000	1.74	15	1000	1.52			
3	1250	2.53	6	1250	3.46	9	1250	2.59	12	1250	2.98	15	1250	1.91			
3	1500	2.97	6	1500	3.81	9	1500	3.29	12	1500	3.59	15	1500	2.27			
3	1750	3.30	6	1750	4.53	9	1750	3.61	12	1750	4.03	15	1750	2.78			
3	2000	3.94	6	2000	5.35	9	2000	4.11	12	2000	4.44	15	2000	3.42			
3	2250	4.16	6	2250	5.92	9	2250	4.60	12	2250	4.79	15	2250	3.78			
3	2500	4.45	6	2500	6.71	9	2500	4.91	12	2500	5.22	15	2500	4.11			
3	2750	4.89	6	2750	7.70	9	2750	5.34	12	2750	5.48	15	2750	4.38			
3	3000	5.27	6	3000	8.61	9	3000	5.84	12	3000	4.96	15	3000	4.63			
3	3250	5.69	6	3250	9.15	9	3250	6.40	12	3250	6.23	15	3250	5.38			
3	3500	6.02	6	3500	9.95	9	3500	6.84	12	3500	6.99	15	3500	5.84			
3	3750	6.45	6	3750	10.49	9	3750	7.20	12	3750	7.37	15	3750	6.16			
3	4000	6.88	6	4000	11.01	9	4000	7.88	12	4000	7.88	15	4000	6.62			

Tabela 1: Dados de degradação de laser

A modelagem deste tipo de situação prática se dá através dos modelos gerais de degradação. Estuda-se e modela-se a evolução da degradação y para os itens amostrais e,

indiretamente, infere-se sobre a distribuição dos tempos de falha dos itens populacionais e outras quantidades de interesse.

1.2 Organização do trabalho

O texto desta monografia está organizado da seguinte forma. Na Seção 2 delimita-se o objetivo principal, ou seja, o escopo do trabalho. Na Seção 3 apresenta-se a metodologia; de modo que a Seção 3.1 discorre sobre o arcabouço teórico do Modelo Geral de Degradação e dois métodos inferenciais para aplicações mais simples, com maior foco para o Método Aproximado; a Seção 3.2 detalha quantidades de interesse de duas funções distribuição de uso recorrente para inferência em análise de tempos de falha; e a Seção 3.3 descreve brevemente o Método Monte Carlo para construção de intervalos de confiança das quantidades de interesse das funções distribuição. Na Seção 4 realizam-se as análises dos dados de degradação de emissores de laser apresentados na Seção 1.1, além da discussão dos resultados. As considerações finais são apresentadas na Seção 5.

2 Objetivos

O objetivo principal deste trabalho é apresentar os modelos gerais de degradação e seus métodos de estimação para casos práticos mais simples. Posteriormente o método aproximado foi aplicado a dados de laser para melhor entendimento prático do mesmo.

3 Metodologia

Nesta seção são apresentados o Modelo Geral de Degradação e dois métodos distintos para realizar o procedimento de inferência, duas distribuições de probabilidade muito úteis para o contexto de confiabilidade de sistemas não reparáveis, e o Método Monte Carlo para construção de intervalos de confiança das quantidades de interesse.

3.1 Modelo Geral de Degradação

Cada unidade de uma amostra ou população de tamanho n é colocada sob teste com intuito de se observar uma característica associada à falha ao longo do tempo. Desta forma realizam-se as medidas de degradação, donde podem-se extrair os perfis de degradação das unidades. A degradação é representada por Y_{ij} , e o modelo é dado por:

$$Y_{ij} = D(t_{ij}, \beta_i) + \varepsilon_{ij}, \quad (3.1)$$

em que t_{ij} é o j -ésimo tempo de medição do i -ésimo item sob teste com $i = 1, 2, \dots, n$ unidades sob teste, $j = 1, 2, \dots, m_i$ tempos de medição da i -ésima unidade, β_i é um vetor de parâmetros da equação $D(t_{ij}, \beta_i)$ que modela os perfis de degradação de cada unidade i , e ε_{ij} é o erro do Modelo Geral de Degradação que é independente e identicamente distribuído (iid), com distribuição $N(0, \sigma_\varepsilon^2)$.

$D(t_{ij}, \beta_i)$ assume uma forma funcional (equação que descreve a degradação) que depende dos parâmetros, de modo que uma fração k dos efeitos do vetor beta pode variar entre as unidades (efeitos aleatórios e os erros ε_{ij}) e outra fração pode ser constante (efeitos fixos).

A fração de falhas no tempo t é a proporção de perfis de degradação que supera o limiar crítico D_f , o qual é pré-definido por fatores físicos, até o tempo t . Assim, a distribuição

do tempo de falha T para o modelo (3.1), é obtida como na equação (3.2):

$$\begin{aligned} F_{T|\boldsymbol{\beta},\boldsymbol{\theta}}(t|\boldsymbol{\beta},\boldsymbol{\theta}) &= P(T \leq t|\boldsymbol{\beta},\boldsymbol{\theta}) \\ &= P[D(t;\boldsymbol{\beta}) \geq D_f|\boldsymbol{\beta},\boldsymbol{\theta}], \end{aligned} \quad (3.2)$$

para medidas de degradação não decrescentes com o tempo. Em que F é a função distribuição acumulada (fda) dos tempos de falha, $\boldsymbol{\beta}$ é a matriz de parâmetros da equação $D(t;\boldsymbol{\beta})$ que modela conjuntamente os n perfis de degradação, e $\boldsymbol{\theta}$ é o vetor de parâmetros da distribuição dos efeitos $\boldsymbol{\beta}$.

Para medidas de degradação não decrescentes com o tempo utiliza-se a equação (3.3)

$$\begin{aligned} F_{T|\boldsymbol{\beta},\boldsymbol{\theta}}(t|\boldsymbol{\beta},\boldsymbol{\theta}) &= P(T \leq t|\boldsymbol{\beta},\boldsymbol{\theta}) \\ &= P[D(t;\boldsymbol{\beta}) \leq D_f|\boldsymbol{\beta},\boldsymbol{\theta}]. \end{aligned} \quad (3.3)$$

Em termos práticos a equação assumida para $D(t;\boldsymbol{\beta})$ não precisa ser não decrescente para se obter $P[D(t;\boldsymbol{\beta}) \geq D_f|\boldsymbol{\beta},\boldsymbol{\theta}]$, nem $D(t;\boldsymbol{\beta})$ precisa ser não crescente para se obter $P[D(t;\boldsymbol{\beta}) \leq D_f|\boldsymbol{\beta},\boldsymbol{\theta}]$.

Para estimação dos quantis da distribuição do tempo de falha T com base neste modelo de degradação é necessário estimar o vetor de efeitos fixos $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_q)'$ que indexa a distribuição do vetor de parâmetros da distribuição $\boldsymbol{\beta}$.

Quando os perfis de degradação assumem formas funcionais simples a distribuição $F_{T|\boldsymbol{\beta},\boldsymbol{\theta}}(t|\boldsymbol{\beta},\boldsymbol{\theta})$ pode ser obtida de forma analiticamente fechada. Se a forma funcional de $D(t_{ij};\boldsymbol{\beta}_i)$ é polinomial, e a dimensão do vetor $\boldsymbol{\beta}_i$ é maior que 1, a obtenção em forma analítica de $F_{T|\boldsymbol{\beta},\boldsymbol{\theta}}(t|\boldsymbol{\beta},\boldsymbol{\theta})$ torna-se complicada e a avaliação é feita numericamente.

3.1.1 Método Aproximado

Os passos para utilizar o método aproximado são relativamente simples. Para todas as unidades amostrais ajusta-se o modelo da equação (3.1), isto é:

$$Y_{ij} = D(t_{ij}, \boldsymbol{\beta}_i) + \varepsilon_{ij}.$$

Posteriormente, resolve-se $D(T_i, \beta_i) = D_f$, em relação a T_i , para cada unidade amostral, donde obtém-se \hat{T}_i 's, os “pseudo tempos de falha”. O número de unidades amostrais será igual ao número de “pseudo tempos de falha”. Assim, todas as unidades amostrais teriam experimentado o evento de falha quando se atingisse o limiar de falha D_f . Esses pseudo tempos de falha devem ser utilizados para estimar $F(t)$ através de técnicas tradicionais de análise de tempos de falha.

É importante deixar claro que, no caso do Método Aproximado, estima-se a equação $D(T_i, \beta_i)$ do modelo para cada perfil de degradação. Ou seja, o vetor de parâmetros β_i é composto apenas por efeitos fixos. Essa característica permite que o método seja de fácil aplicação, pois a maioria dos softwares estatísticos possuem bibliotecas para estimação de parâmetros de efeitos fixos de modelos lineares e não lineares. Este é o motivo pelo qual este texto optou pela aplicação deste método aos dados de emissores de laser.

3.1.2 Método Analítico

Para modelos simples a função $F(t)$ pode ser descrita como uma função dos parâmetros θ em forma fechada. Suponha uma degradação linear com intercepto nulo. Isto é, com função de degradação como na equação (3.4)

$$D_{ij}(t) = \beta_i t, \quad (3.4)$$

em que β_i é a taxa de degradação aleatória que distingue os perfis de degradação das unidades sob teste.

Seja D_f o limiar de degradação que é alcançado no tempo de falha T_i , então a equação (3.4) torna-se a equação (3.5):

$$D_f = \beta_i T_i \implies T_i = \frac{D_f}{\beta_i}. \quad (3.5)$$

Assuma que o coeficiente associado à taxa de degradação siga a distribuição Lognormal ($\beta_i \stackrel{iid}{\sim} \text{Lognormal}(\mu_\beta, \sigma_\beta)$), ou seja, $\theta = (\mu_\beta, \sigma_\beta)$. A partir da equação (3.5) é possível obter a fda de T como na equação (3.6):

$$\begin{aligned}
F(t|\boldsymbol{\theta}) &= P(T_i \leq t|\boldsymbol{\theta}) \\
&= P(D(t; \beta_i) > D_f|\boldsymbol{\theta}) \\
&= P(\beta_i t > D_f|\boldsymbol{\theta}) \\
&= P\left(\beta_i > \frac{D_f}{t} \middle| \boldsymbol{\theta}\right) \\
&\stackrel{\log(\beta_i) \stackrel{iid}{\sim} N(\mu_\beta, \sigma_\beta)}{=} 1 - \Phi_{nor}\left(\frac{[\log(D_f/t)] - \mu_\beta}{\sigma_\beta}\right) \\
&= 1 - \Phi_{nor}\left(\frac{-\log(t) - [\mu_\beta - \log(D_f)]}{\sigma_\beta}\right) \\
&= \Phi_{nor}\left(\frac{\log(t) - [\log(D_f) - \mu_\beta]}{\sigma_\beta}\right), \tag{3.6}
\end{aligned}$$

em que $\Phi_{nor}(\bullet)$ é a fda da distribuição normal padrão.

Nota-se da equação (3.6) que $T_i \stackrel{iid}{\sim} \text{Lognormal}(\mu_T = \log(D_f) - \mu_\beta, \sigma_T = \sigma_\beta)$. As quantidades de interesse devem ser extraídas da função distribuição de T_i .

Um apontamento importante sobre o método é que ele necessita que o software utilizado seja capaz de estimar parâmetros da equação $D(T_i, \beta_i)$ do modelo, com efeitos fixos e aleatórios do vetor β_i . Essa é uma diferença considerável em relação ao método aproximado, uma vez que é comum adotar-se distribuições de probabilidade não normais para os efeitos aleatórios e os softwares não possuem bibliotecas de estimação para modelos com efeitos aleatórios distintos da distribuição normal. Ainda, é necessário que se obtenha, analiticamente e de forma fechada, a distribuição de probabilidade de T_i a partir de β_i , o que nem sempre é possível. Uma vez que este texto visa a aplicação de um método mais simples, optou-se por apenas apresentar o método analítico para conhecimento do leitor de que existem outras possibilidades de estimação em modelos de degradação.

3.2 Funções Distribuições Úteis para este Estudo

Nesta seção apresentam-se duas distribuições de probabilidade flexíveis o suficiente para que seja possível realizar as análises dos dados de emissores de laser. As quantidades de interesse utilizadas para caracterizar a distribuição dos tempos de falha também são explicitadas nesta seção.

3.2.1 Distribuição Weibull

A função densidade de probabilidade (fdp) de uma variável aleatória $X \sim Weibull(\lambda, \delta)$ é dada pela equação (3.7):

$$f(t|\lambda, \delta) = \frac{\delta}{\lambda} \left(\frac{x}{\lambda}\right)^{\delta-1} e^{-\left(\frac{x}{\lambda}\right)^\delta}, \quad (3.7)$$

em que $(\lambda, \delta) > 0$, $x \geq 0$, são os espaços paramétricos dos parâmetros de escala e forma, e o espaço amostral de X , respectivamente. Se $\delta = 1$, então $X \sim Exponencial(\lambda)$.

A fda de X para o modelo Weibull é dada pela equação (3.8):

$$F(t|\lambda, \delta) = 1 - \exp \left\{ - \left(\frac{x}{\lambda} \right)^\delta \right\}. \quad (3.8)$$

A função de confiabilidade é dada pela equação (3.9):

$$R(x|\lambda, \delta) = \exp \left\{ - \left(\frac{x}{\lambda} \right)^\delta \right\}. \quad (3.9)$$

O percentil de ordem p é dado pela equação (3.10):

$$Q(p|\lambda, \delta) = \lambda [-\log(1 - p)]^{1/\delta}. \quad (3.10)$$

A esperança (ou tempo médio até a falha - MTTF, para o contexto deste texto) é dada pela equação (3.11):

$$E(X|\lambda, \delta) = MTTF = \lambda \Gamma \left(1 + \frac{1}{\delta} \right). \quad (3.11)$$

A variância é dada pela equação (3.12):

$$Var(X|\lambda, \delta) = \lambda^2 \left\{ \left(1 + \frac{2}{\delta}\right) - \left[\Gamma \left(1 + \frac{1}{\delta}\right) \right]^2 \right\}. \quad (3.12)$$

As funções nas equações 3.8, 3.9, 3.10, 3.11 e 3.12, são as quantidades de interesse mais usuais a serem inferidas para o contexto de aplicações práticas em análise de tempo de falha.

3.2.2 Distribuição Lognormal

A fdp de uma variável aleatória $X \sim Lognormal(\mu, \sigma)$ é dada pela equação (3.13):

$$f(x|\mu, \sigma) = \frac{1}{x\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{(\ln(x) - \mu)^2}{2\sigma^2} \right\}, \quad (3.13)$$

em que $-\infty \leq \mu \leq \infty$, $(\sigma, x) \geq 0$, são os espaços paramétricos dos parâmetros de locação e escala, e o espaço amostral de X , respectivamente.

A fda é dada pela equação (3.14):

$$F(x|\mu, \sigma) = \Phi_{nor} \left(\frac{[\log(D_f/t)] - \mu_\beta}{\sigma_\beta} \right). \quad (3.14)$$

A função de sobrevivência é dada pela equação (3.9):

$$R(x|\mu, \sigma) = 1 - \Phi_{nor} \left(\frac{[\log(D_f/t)] - \mu_\beta}{\sigma_\beta} \right). \quad (3.15)$$

O percentil de ordem p é dado pela equação (3.16):

$$Q(p|\mu, \sigma) = \exp \{ z_p \sigma - \mu \}, \quad (3.16)$$

em que $z_p = \Phi_{nor}^{-1}(p)$ é o percentil de ordem p da distribuição normal padrão.

A esperança é dada pela equação (3.17):

$$E(X|\mu, \sigma) = MTTF = \exp \left\{ \mu + \frac{\sigma^2}{2} \right\}. \quad (3.17)$$

A variância é dada pela equação (3.18):

$$Var(X|\mu, \sigma) = \exp [2\mu + \sigma^2] [\exp (\sigma^2) - 1]. \quad (3.18)$$

3.3 Monte Carlo para a construção de intervalos de confiança

O Método de Monte Carlo é uma técnica estatística que utiliza simulações para obter estimativas de parâmetros. Para a construção do intervalo de confiança, o método simula “s” amostras aleatórias da distribuição ou parâmetros desejados, com isso uma distribuição amostral, da qual obtém-se um intervalo de confiança.

É possível encontrar exemplos práticos aplicados em Robert e Casella (2004).

Para o contexto deste texto os Intervalos de Confiança são obtidos como a seguir.

Denote por $QI_{X|\boldsymbol{\theta}}(x)$ a quantidade de interesse característica da distribuição do tempo até a Falha com função densidade de probabilidade $f(x|\boldsymbol{\theta})$, tais como percentis, função fração de falha, confiabilidade, tempo médio até a falha, etc. Siga o procedimento abaixo para gerar as amostras Monte Carlo:

1. **Passo 1:** geração das amostras Monte Carlo

- (a) gere uma amostra X_1, \dots, X_n a partir de $f(x|\boldsymbol{\theta})$;
- (b) estime $\boldsymbol{\theta}$, a partir dessa nova amostra, através do estimador $\hat{\boldsymbol{\theta}}$ para obter $\hat{\boldsymbol{\theta}}_h$, em que $h = 1, \dots, s$, com s igual ao tamanho da amostra Monte Carlo que se deseja;
- (c) aplique $\hat{\boldsymbol{\theta}}_h$ em $QI_{X|\boldsymbol{\theta}}(x|\boldsymbol{\theta})$ e obtenha uma única amostra da quantidade de interesse $QI_{X|\boldsymbol{\theta}}(x|\hat{\boldsymbol{\theta}}_h)_h$;
- (d) repita o procedimento até obter uma amostra Monte Carlo de Tamanho s , isto é, $QI_{X|\boldsymbol{\theta}}(x|\hat{\boldsymbol{\theta}}_1)_1, \dots, QI_{X|\boldsymbol{\theta}}(x|\hat{\boldsymbol{\theta}}_s)_s$;

2. **Passo 2:** encontre os percentis $qi_{\alpha/2\%}$ e $qi_{1-\alpha/2\%}$, a partir da amostra $QI_{X|\boldsymbol{\theta}}(x|\hat{\boldsymbol{\theta}}_1)_1, \dots, QI_{X|\boldsymbol{\theta}}(x|\hat{\boldsymbol{\theta}}_s)_s$, para obter um Intervalo de Confiança percentílico com $(1 - \alpha)\%$ de Confiança para $QI_{X|\boldsymbol{\theta}}(x)$. Isto é, $IC[(1 - \alpha)\%, QI_{X|\boldsymbol{\theta}}(x)] = [qi_{\alpha/2\%}, qi_{1-\alpha/2\%}]$,

em que $(1 - \alpha)\%$ é o nível de confiança e $0 \leq \alpha \leq 1$.

4 Resultados e Discussão

Na Seção 3.2.2 foram apresentados os dados de degradação de emissores de laser.

A figura 1 apresenta os perfis de evolução da degradação para todas as unidades emissoras de laser. Este é um caso mandatório para uso dos modelos de degradação. As medidas de degradação correspondem aos círculos e as linhas que os conectam servem de referência para distinguir as diferentes itens sob teste. O limiar de degradação $D_f = 10\%$ associado à falha corresponde à linha tracejada vermelha. Repare que os perfis de degradação apresentam incrementos monótonos não decrescentes, então a obtenção da função distribuição através dos modelos de degradação se dá conforme a equação (3.2). Observe que apenas 3 emissores de laser possuem degradação que ultrapassa o limite pré-definido, e a primeira falha só ocorre entre 3250 horas e 3500 horas. Outra observação relevante é a de que os perfis são aproximadamente lineares no tempo, ou seja, a degradação cresce linearmente com o tempo, e por esse motivo a forma funcional adotada para descrever a degradação será linear.

4.1 Método Aproximado

De acordo com a primeira etapa da aplicação do Método Aproximado apresentado na Seção 3.1.1, com a informação dos perfis aproximadamente lineares da figura 1, a partir da equação (3.1) assume-se a forma funcional na equação (4.1):

$$D(t_{ij}, \beta_i) = \beta_i t, \quad (4.1)$$

do modelo geral de degradação na equação (4.2):

$$Y_{ij} = \beta_i t + \varepsilon_{ij}, \quad (4.2)$$

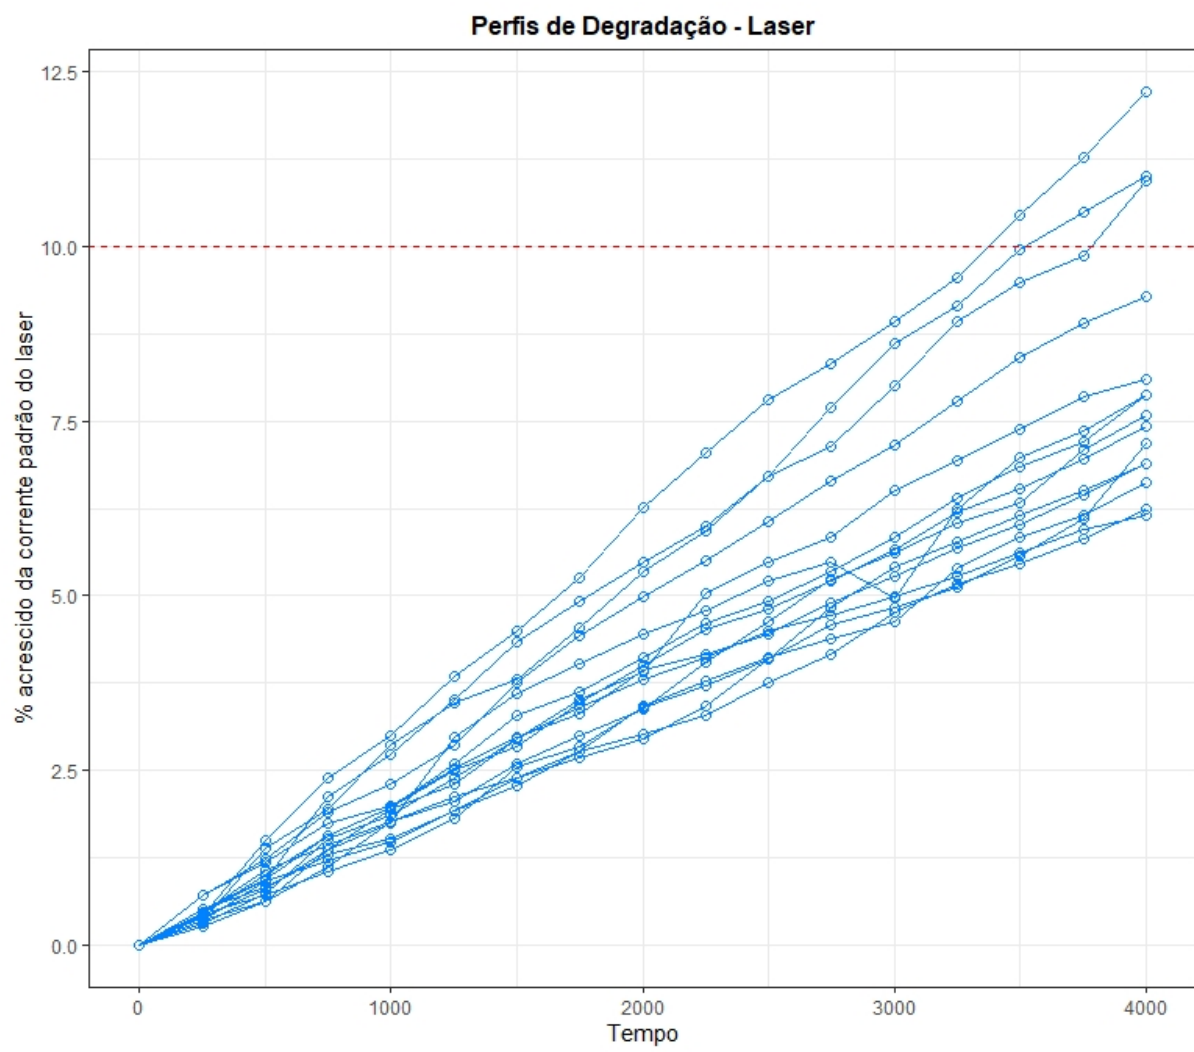


Figura 1: Perfis de Degradação

em que $\varepsilon_{ij} \stackrel{iid}{\sim} N(0, \sigma_\varepsilon^2)$, $i = 1, 2, \dots, n = 15$ unidades, $j = 1, 2, \dots, m_i = 17$ tempos de medição da i -ésima unidade, β_i é a taxa/velocidade de degradação de cada unidade i sob teste, e t_{ij} é o j -ésimo tempo de medição do i -ésimo item sob teste.

Note que a equação da reta de regressão $\beta_i t$ de todas as unidades sob teste possui intercepto igual a zero.

Para ajuste das retas $n = 15$ de regressão utilizou-se o Software R 4.3.2 (R Core Team, 2023). Mais especificamente, os ajustes encontram-se nas linhas de código do Anexo A, realizados através da função `lm()` do pacote nativo `stats`. Como todo procedimento estatístico inferencial e descritivo deste texto foi realizado no software supracitado, a partir desse ponto serão referenciadas apenas as funções e pacotes.

De posse das estimativas dos coeficientes de regressão de cada emissor de laser é possível estimar os “pseudo tempos de falha” \hat{T}_i s, então iguala-se $D(t_{ij}, \hat{\beta}_i) = D_f$ na equação (4.1), donde se obtém o estimador na equação (4.3):

$$D(t_{ij}, \hat{\beta}_i) = D_f = \hat{\beta}_i \hat{T}_i \implies \hat{T}_i = \frac{D_f}{\hat{\beta}_i}, \quad (4.3)$$

As estimativas obtidas pelo estimador na equação (4.3) podem ser acessadas pela execução dos códigos no Anexo A.

4.2 Ajuste dos Modelos Paramétricos

De posse das estimativas \hat{T}_i s obtidas pela equação (4.3) ajustam-se 3 modelos paramétricos para os “pseudo tempos de falha” a saber, os modelos $\hat{T}_i \stackrel{iid}{\sim} Exponencial(\lambda_e)$, $\hat{T}_i \stackrel{iid}{\sim} Weibull(\lambda_w, \delta_w)$ e $\hat{T}_i \stackrel{iid}{\sim} Lognormal(\mu_L, \sigma_L)$.

A Figura 2 apresenta as “Estimativas de Kaplan-Meier” **versus** “Estimativas dos Modelos Paramétricos” para a função de sobrevivência $R(T)$ avaliada nos “pseudo tempos de falha”. Se o modelo for adequado, então os pontos em vermelho no gráfico devem acompanhar a reta $x = y$, o que acontece para os modelos Weibull e Lognormal. Quanto mais próximos os pontos estiverem da reta $x = y$, melhor será a qualidade de ajuste, que parece ser o caso do Modelo Weibull.

Detalhes de métodos gráficos para avaliação de adequação e qualidade de ajuste no




Figura 2: $R(T)$: Kaplan-Meier versus Modelos Paramétricos (Exponencial, Weibull e Lognormal, respectivamente.)

contexto de dados confiabilidade (ou sobrevivência) podem ser encontrados em Freitas e Colosimo (1997) e Colosimo e Giolo (2021), referências que também discorrem sobre a estimação de a função de sobrevivência através do estimador de Kaplan-Meier. As estimativas de $R(T)$ foram obtidas das equações (3.9) e (3.15). As estimativas de Kaplan-Meier para $R(T)$ foram obtidas da função “survfit()” do pacote “survival” (THERNEAU, 2015). Para o ajuste dos modelos utilizou-se a função “survreg()” do mesmo pacote.

4.3 Quantidades de Interesse: Estimativas Pontuais e Intervalares

Na Seção 4.2 constatou-se que os melhores ajustes para os “pseudo tempos de falha” foram os dos modelos Weibull e Lognormal, isto é $\hat{T}_i \stackrel{iid}{\sim} Weibull(\hat{\lambda}_W = 5487,61; \hat{\delta}_W = 6,63)$ e $\hat{T}_i \stackrel{iid}{\sim} Lognormal(\hat{\mu}_L = 8,52; \hat{\sigma}_L = 0,20)$ respectivamente.

De posse das estimativas dos parâmetros das distribuições dos modelos ajustados é possível estimar a Confiabilidade no tempo 4500 horas, Tempo Médio até a Falha e Percentis $p\%$, com $p = (1, 5, 10, 50, 80)$, através das equações (3.9), (3.11) e (3.10), respectivamente, para o ajuste Weibull. Para o modelo Lognormal as mesmas quantidades de interesse são estimadas pelas equações (3.15), (3.17), (3.16). Os intervalos percentílicos de 95% de Confiança para as quantidades de interesse são obtidos através do procedimento Monte Carlo apresentado na Seção 3.3.

As estimativas das quantidades de interesse são apresentadas na Tabela 4.3. Observa-se que as estimativas para a distribuição Lognormal são ligeiramente maiores do que as da distribuição Weibull, o que já era esperado por conta dos pontos do método gráfico serem um pouco mais dispersos para o modelo Lognormal.

Para a distribuição Lognormal:

- o tempo médio até a falha dos lasers é de 5104,21 horas
- a fração de falha ao operar até 3109,59 horas é de 0,01, ou seja, 1% dos emissores de laser falha antes desse tempo. Ao operar até 3573,56 horas a fração de falha é de 0,05, ao operar até 3848,58 horas é de 0,10, ao operar até 4999,02 horas é de 0,5 e ao operar até 5935,78 horas é de 0,8.
- a probabilidade de um emissor de laser sobreviver além de 4500 horas é de 0,70.

Para a distribuição Weibull:

Tabela 2: Parâmetros - Método Aproximado

Medida	Estimativa	IC (95%)	Amplitude
R4500 - Lognormal	0,6968	(0,5058 ; 0,8910)	0,3852
MTTF - Lognormal	5104,2110	(4603,12 ; 5657,00)	1053,88
Percentil 1% - Lognormal	3109,59	(2604,20 ; 3852,90)	1248,70
Percentil 5% - Lognormal	3573,56	(3090,59 ; 4255,89)	1165,30
Percentil 10% - Lognormal	3848,58	(3382,95 ; 4480,99)	1098,04
Percentil 50% - Lognormal	4999,02	(4503,00 ; 5537,02)	1034,02
Percentil 80% - Lognormal	5935,78	(5232,16 ; 6632,16)	1400,01
R4500 - Weibull	0,7550	(0,6167 ; 0,8460)	0,2293
MTTF - Weibull	5095,815	(4670,87 ; 5507,07)	836,20
Percentil 1% - Weibull	2736,44	(2506,34 ; 2950,29)	443,95
Percentil 5% - Weibull	3495,55	(3197,71 ; 3766,48)	568,77
Percentil 10% - Weibull	3902,66	(3577,74 ; 4200,25)	622,52
Percentil 50% - Weibull	5173,09	(4747,44 ; 5594,86)	847,41
Percentil 80% - Weibull	5875,31	(5381,60 ; 6346,22)	964,62

- o tempo médio até a falha dos lasers é de 5095,82 horas;
- a fração de falha ao operar até 2736,44 horas é de 0,01; ao operar até 3495,55 horas é de 0,05; ao operar até 3902,66 horas é de 0,1; ao operar até 5173,09 horas é de 0,5; e ao operar até 5875,31 horas é de 0,8
- a probabilidade de um emissor de laser sobreviver além de 4500 horas é de 0,76.

Apesar das diferenças pontuais nas estimativas, os Intervalos de Confiança obtidos pelo Método de Monte Carlo se sobrepõem para ambos os modelos, o que significa que são estatisticamente iguais, então os resultados são igualmente satisfatórios. Contudo, observa-se que a amplitude dos intervalos de confiança para o ajuste Weibull é consistentemente menor para todas as estimativas. Cabe ao especialista da área adotar o modelo que faça melhor sentido prático. Em geral essa escolha perpassa a forma da função de risco de falha e propriedades físicas do item sob teste.

5 Considerações finais

O objetivo principal deste trabalho foi apresentar a metodologia e contexto de aplicação os Modelos Gerais de Degradação para casos mais simples.

Através do Modelo Geral de Degradação pelo Método Aproximado, para medidas de percentual de aumento da corrente de operação de emissores de laser, foi possível inferir sobre a distribuição dos tempos de falha dos mesmos. Pela visualização dos perfis de degradação poucas unidades de lasers atingiam o limiar de falha $df = 10\%$ definido, situação clássica para aplicação dos Modelos Gerais de Degradação.

Alguns modelos paramétricos foram ajustados aos “pseudo tempos de falha”, de modo que os mais adequados foram os modelos Weibull e Lognormal. O modelo Weibull apresentou o melhor ajuste. As estimativas das quantidades de interesse e seus intervalos de confiança, no que tange aos modelos Weibull e Lognormal, permitiram extrair as seguintes informações inferenciais:

O tempo médio até a falha estimado foi pontualmente superior na distribuição Lognormal, assim como a maior parte dos percentis analisados. A probabilidade de um emissor de laser sobreviver além de 4500 horas é de 0,76, enquanto na distribuição Weibull é de 0,7.

Apesar das diferenças pontuais nas estimativas, os Intervalos de Confiança obtidos pelo Método de Monte Carlo se sobrepõem para ambos os modelos, o que significa que são estatisticamente iguais. Entretanto, observou-se que a amplitude dos intervalos de confiança para o ajuste Weibull é consistentemente menor para todas as estimativas. O especialista em emissores de laser fica imbuído da escolha de qual modelo utilizar.

Referências

- COLOSIMO, E. A.; GIOLO, S. R. *Análise de sobrevivência aplicada*. [S.l.]: Editora Blucher, 2021.
- FREITAS, M. A.; COLOSIMO, E. A. *Confiabilidade: análise de tempo de falha e testes de vida acelerados*. [S.l.]: Escola de Engenharia da UFMG/Fundacao Christiano Ottoni, 1997.
- MEEKER, W.; ESCOBAR, L. A. *Statistical Methods for Reliability Data*. 1. ed. [S.l.]: Wiley Series in Probability and Statistics: New York, 1998.
- NIKULIN, M. et al. *Advances in degradation modeling*. [S.l.]: Springer, 2010.
- R Core Team. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2023. Disponível em: <<https://www.R-project.org/>>.
- ROBERT, C.; CASELLA, G. *Monte Carlo Statistical Methods*. 2. ed. [S.l.]: Springer, 2004.
- SHAHRAKI, A. F.; YADAV, O. P.; LIAO, H. A review on degradation modelling and its engineering applications. *International Journal of Performability Engineering*, v. 13, p. 299–314, 05 2017.
- THERNEAU, T. M. *A Package for Survival Analysis in S*. [S.l.], 2015. Version 2.38. Disponível em: <<https://CRAN.R-project.org/package=survival>>.

ANEXO A – Primeiro anexo

```
1 #####PACOTES####
2
3 install.packages('survival')
4 install.packages('ggplot2')
5 install.packages('gridExtra')
6 install.packages('grid')
7 install.packages('flexsurv')
8 install.packages('lme4')
9 install.packages('nlme')
10
11 library(survival)
12 library(ggplot2)
13 library(gridExtra)
14 library(grid)
15 library(flexsurv)
16 library(lme4)
17 library(nlme)
18
19 #####Funções####
20
21 #Funções - Lognormal
22
23 Lognormal.R4500 = function(x,y){
24   fit_L = survreg(Surv(x,y) ~ 1, dist = "lognormal")
25   sig_L = fit_L$scale
26   mi = fit_L$icoef
27   m_L = mi[1]
```

```

28   Rt_L = pnorm(-(log(4500)-m_L)/sig_L)
29   Rt_L
30 }
31 Lognormal.MTTF = function(x,y){
32   fit_L = survreg(Surv(x,y) ~ 1, dist = "lognormal")
33   sig_L = fit_L$scale
34   mi = fit_L$icoef
35   m_L = mi[1]
36   MTTF_L = exp(m_L+(sig_L^2)/2)
37   MTTF_L
38 }
39 Lognormal.Perc1 = function(x,y){
40   fit_L = survreg(Surv(x,y) ~ 1, dist = "lognormal")
41   sig_L = fit_L$scale
42   mi = fit_L$icoef
43   m_L = mi[1]
44   Z1 = qnorm(0.01)
45   Perc.1_L = exp(Z1*sig_L+m_L)
46   Perc.1_L
47 }
48 Lognormal.Perc5 = function(x,y){
49   fitL = survreg(Surv(x,y) ~ 1, dist = "lognormal")
50   sigL = fitL$scale
51   mi = fitL$icoef
52   mL = mi[1]
53   Z5 = qnorm(0.05)
54   Perc5L = exp(Z5*sigL+mL)
55   Perc5L
56 }
57 Lognormal.Perc10 = function(x,y){
58   fitL = survreg(Surv(x,y) ~ 1, dist = "lognormal")
59   sigL = fitL$scale
60   mi = fitL$icoef
61   mL = mi[1]
62   Z10 = qnorm(0.1)

```

```

63   Perc10L = exp(Z10*sigL+mL)
64   Perc10L
65 }
66 Lognormal.Perc50 = function(x,y){
67   fitL = survreg(Surv(x,y) ~ 1, dist = "lognormal")
68   sigL = fitL$scale
69   mi = fitL$icoef
70   mL = mi[1]
71   Z50 = qnorm(0.5)
72   Perc50L = exp(Z50*sigL+mL)
73   Perc50L
74 }
75 Lognormal.Perc80 = function(x,y){
76   fitL = survreg(Surv(x,y) ~ 1, dist = "lognormal")
77   sigL = fitL$scale
78   mi = fitL$icoef
79   mL = mi[1]
80   Z80 = qnorm(0.8)
81   Perc80L = exp(Z80*sigL+mL)
82   Perc80L
83 }
84
85 #Funções - Weibull
86 Weibull.Rt = function(x,y){
87   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")
88   sigW = mfit_W$scale
89   mi = fitW$icoef
90   mW = mi[1]
91   shape = 1/sigW
92   scale = exp(mW)
93   RtW = exp(-(4500/scale)^shape)
94   RtW
95 }
96 Weibull.MTTF = function(x,y){
97   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")

```

```

98   sigW = mfit_W$scale
99   mi = fitW$icoef
100  mW = mi[1]
101  shape = 1/sigW
102  scale = exp(mW)
103  MTTFW = scale*gamma(1+(1/shape))
104  MTTFW
105 }
106 Weibull.Perc1 = function(x,y){
107   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")
108   sigW = mfit_W$scale
109   mi = fitW$icoef
110   mW = mi[1]
111   shape = 1/sigW
112   scale = exp(mW)
113   Perc1W = scale*(-log(1-0.01))^(1/shape)
114   Perc1W
115 }
116 Weibull.Perc5 = function(x,y){
117   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")
118   sigW = mfit_W$scale
119   mi = fitW$icoef
120   mW = mi[1]
121   shape = 1/sigW
122   scale = exp(mW)
123   Perc5W = scale*(-log(1-0.05))^(1/shape)
124   Perc5W
125 }
126 Weibull.Perc10 = function(x,y){
127   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")
128   sigW = mfit_W$scale
129   mi = fitW$icoef
130   mW = mi[1]
131   shape = 1/sigW
132   scale = exp(mW)

```

```

133   Perc50W = scale*(-log(1-0.1))^(1/shape)
134   Perc50W
135 }
136 Weibull.Perc50 = function(x,y){
137   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")
138   sigW = mfit_W$scale
139   mi = fitW$icoef
140   mW = mi[1]
141   shape = 1/sigW
142   scale = exp(mW)
143   Perc50W = scale*(-log(1-0.5))^(1/shape)
144   Perc50W
145 }
146 Weibull.Perc80 = function(x,y){
147   fitW = survreg(Surv(x,y) ~ 1, dist = "weibull")
148   sigW = mfit_W$scale
149   mi = fitW$icoef
150   mW = mi[1]
151   shape = 1/sigW
152   scale = exp(mW)
153   Perc80W = scale*(-log(1-0.8))^(1/shape)
154   Perc80W
155 }
156
157
158
159 # Função para estimação dos intervalos de confiança via Monte Carlo
160 IC = function(x){
161   quantile(x, c(0.025,0.975))
162 }
163
164 # Função para calcular a amplitude dos intervalos de confiança via Monte Carlo
165 amplitude=function(y){y[2]-y[1]}
166
167 #Monte Carlo - Lognormal

```



```

168 MC_l = function(est, censura, media, variancia, n, amostra){
169   tempos = vector("numeric", n)
170   estimativas = vector("numeric", amostra)
171   for (i in 1:amostra) {
172     tempos = rlnorm(n, media, variancia)
173     estimativas[i] = est(tempos, censura)
174   }
175   estimativas
176 }
177
178 #Monte Carlo - Weibull
179 MC_W = function(est, censura, forma, escala, n, amostra){
180   tempos = vector("numeric", n)
181   estimativas = vector("numeric", amostra)
182   for (i in 1:amostra) {
183     tempos = rweibull(n, forma, escala)
184     estimativas[i] = est(tempos, censura)
185   }
186   estimativas
187 }
188
189 #####LEITURA DOS DADOS####
190 # Os dados estão disponíveis no sítio: https://drive.google.com/ (cont.)
191 # file/d/1qbH1qgFsDQX16_9bVWoMVcviiq0h9Kj/view?usp=sharing
192
193 dados <- read.delim("CAMINHO/DesgLaser.txt")
194
195 View(dados)
196 df = 10
197
198 #####PLOTANDO O PERFIL DA MEDIDA DE DEGRADAÇÃO####
199 ggplot(dados) +
200   aes(x = Tempo, y = Desgaste, group = Unidade) +
201   geom_point(shape = "circle open", colour = "#0082FF", size = 2) +
202   geom_line(colour = "#0082FF") +

```

```

203   labs(x = "Tempo", y = "% acrescido da corrente padrão do laser",
204         title = "Perfis de Degradação - Laser") +
205   theme_bw() +
206   geom_hline(yintercept = 10, linetype = "dashed", color = "red") +
207   theme(
208     plot.title = element_text(size = 12L,
209                               face = "bold",
210                               hjust = 0.5)
211   )
212   set.seed(123)
213   #####TESTE DE VIDA CONVENCIONAL: AJUSTE LOGNORMAL####
214
215   # Esse será o vetor que irá receber os coeficientes.
216   coeficientes_Lognormal = vector("numeric", 15)
217   # Para estimar os pseudos tempos de falha, colocamos os coeficientes da
218   # regressão no vetor definido anteriormente
219   for (i in 1:15){
220     coeficientes_Lognormal [i] = lm(dados$Desgaste ~ dados$Tempo - 1,
221     subset = dados$Unidade==i)$coef
222   }
223   # Vetores e matrizes que serão utilizados para guardar os pseudo
224   # tempos de falha.
225   pseudos.tf_L = df/coeficientes_Lognormal
226   pseudos.tf_Ld = matrix(pseudos.tf_L, ncol = 1)
227   pseudos.tf_Ld
228
229   # Vetor com a codificação de censura e falha (nesta base todos são falhas)
230   b = 1
231   status = rep(b,15)
232
233   # Teste de vida para Lognormal
234   mfit_L = survreg(Surv(pseudos.tf_L, status) ~ 1, dist = "lognormal")
235   summary(mfit_L)
236
237   # Definindo variáveis para sigma e mu estimados da Lognormal, obtidos

```

```

238
239 # anteriormente.
240 sigma_L = mfit_L$scale
241 mu_L = mfit_L$coefficients[1]
242
243 # Armazenando os percentis
244 Z1 = qnorm(0.01)
245 Z5 = qnorm(0.05)
246 Z10 = qnorm(0.1)
247 Z50 = qnorm(0.5)
248 Z80 = qnorm(0.8)
249
250 ##RESULTADO##
251 # Obtendo resultados de sobrevivência, média e percentis estimados
252
253 # - Método Aproximado#
254
255 R4500.Aproximado_L = pnorm(-(log(4500)-mu_L)/sigma_L)
256 MTTF.Aproximado_L = exp(mu_L+(sigma_L^2)/2)
257 Percentil1.Aproximacao_L = exp(Z1*sigma_L+mu_L)
258 Percentil5.Aproximacao_L = exp(Z5*sigma_L+mu_L)
259 Percentil10.Aproximacao_L = exp(Z10*sigma_L+mu_L)
260 Percentil50.Aproximacao_L = exp(Z50*sigma_L+mu_L)
261 Percentil80.Aproximacao_L = exp(Z80*sigma_L+mu_L)
262
263 #####TESTE DE VIDA CONVENCIONAL: AJUSTE WEIBULL####
264
265 # Esse será o vetor que irá receber os coeficientes.
266 coeficientes_Weibull = vector("numeric", 15)
267 # Para estimar os pseudos tempos de falha, colocamos os coeficientes
268 # da regressão no vetor definido anteriormente
269 for (i in 1:15){
270   coeficientes_Weibull[i] = lm(dados$Desgaste ~ dados$Tempo - 1,
271     subset = dados$Unidade==i)$coef
272 }

```

```

273 # Vetores e matrizes que serão utilizados para guardar os pseudo
274 # tempos de falha.
275 pseudos.tf_W = df/coeficientes_Weibull
276 pseudos.tf_Wd = matrix(pseudos.tf_W, ncol = 1)
277 pseudos.tf_Wd
278
279 # Teste de vida para Weibull
280 mfit_W = survreg(Surv(pseudos.tf_W, status) ~ 1, dist = "weibull")
281 summary(mfit_W)
282
283 # Definindo variáveis para sigma e mu estimados da Weibull, obtidos
284 # anteriormente.
285 sigma_W = mfit_W$scale
286 mu_W = mfit_W$coefficients[1]
287
288 # Parâmetros
289 shape_W = 1/sigma_W
290 scale_W = exp(mu_W)
291
292 ##RESULTADOS##
293 # Obtendo resultados de sobrevivência, média e percentis estimados
294 # - Método Aproximado.
295
296 R4500.Aproximado_W = exp(-(4500/scale_W)^shape_W)
297 MTTF.Aproximado_W = scale_W*gamma(1+(1/shape_W))
298 Percentil1.Aproximacao_W = scale_W*(-log(1-0.01))^(1/shape_W)
299 Percentil5.Aproximacao_W = scale_W*(-log(1-0.05))^(1/shape_W)
300 Percentil10.Aproximacao_W = scale_W*(-log(1-0.10))^(1/shape_W)
301 Percentil50.Aproximacao_W = scale_W*(-log(1-0.50))^(1/shape_W)
302 Percentil80.Aproximacao_W = scale_W*(-log(1-0.80))^(1/shape_W)
303
304 ###Kaplan-Meier####
305 #Teste de aderência p/ Weibull e lognormal - Plot de resíduos aderência
306
307 #Ajuste via Kaplan-Meyer

```

```

308 ajustkm=survfit(Surv(pseudos.tf_L, status)~1)
309 ajustkm
310
311 #Ajuste exponencial
312 ajust_exp=survreg(Surv(pseudos.tf_L, status)~1,dist="exponential")
313 summary(ajust_exp)
314 alpha_exp=exp(ajust_exp$coefficients[1])
315
316 #Organizando as estimativas de cada ajuste numa tabela
317 time = ajustkm$time
318 stkm<-ajustkm$surv
319 ste<-exp(-time/alpha_exp)
320 stw<-exp(-(time/exp(mu_W))^(1/sigma_W))
321 stln<-pnorm((-log(time)+mu_L)/sigma_L)
322 stall = as.data.frame(cbind(time,ste, stkm, stw, stln))
323 stall
324
325 #Gráficos para o ajuste
326 dqqe<-ggplot(stall) +
327   geom_point(aes(x=stkm, y=ste),col="red",size=4) +
328   geom_abline(slope=1, intercept=0) +
329   xlim(c(0, 1)) +
330   ylim(c(0, 1)) +
331   labs(y="Rw(t): Exponencial",
332        x="S(t): Kaplan-Meier",
333        title = "")+
334   theme_bw()
335 dqqw<-ggplot(stall) +
336   geom_point(aes(x=stkm, y=stw),col="red",size=4) +
337   geom_abline(slope=1, intercept=0) +
338   xlim(c(0, 1)) +
339   ylim(c(0, 1)) +
340   labs(y="Rw(t): Weibull",
341        x="S(t): Kaplan-Meier",title = "")+
342   theme_bw()

```

```

343 dqqln<-ggplot(stall) +
344   geom_point(aes(x=stkm, y=stln),col="red",size=4) +
345   geom_abline(slope=1, intercept=0) +
346   xlim(c(0, 1)) +
347   ylim(c(0, 1)) +
348   labs(y="Rw(t): Lognormal",
349        x="S(t): Kaplan-Meier",
350        title = "")+
351   theme_bw()
352
353 grid.arrange(dqqe, dqqw, dqqln, ncol=3)
354 grid.text("Sobrevivência: Kaplan-Meier x Modelos Paramétricos",
355 x = unit(0.5, "npc"), y = unit(0.98, "npc"),
356          gp = gpar(fontsize = 10, fontface = "bold", col = "black"))
357
358 ##### IC VIA MONTE CARLO #####
359
360 #Lognormal(mu = mu_L & sigma = sigma_L) - número de simulações = 10000
361
362 MC_1.4500 = MC_1(Lognormal.R4500, status, mu_L, sigma_L, 15, 10000)
363 MC_1.MTTF = MC_1(Lognormal.MTTF, status, mu_L, sigma_L, 15, 10000)
364 MC_1.1 = MC_1(Lognormal.Perc1, status, mu_L, sigma_L, 15, 10000)
365 MC_1.5 = MC_1(Lognormal.Perc5, status, mu_L, sigma_L, 15, 10000)
366 MC_1.10 = MC_1(Lognormal.Perc10, status, mu_L, sigma_L, 15, 10000)
367 MC_1.50 = MC_1(Lognormal.Perc50, status, mu_L, sigma_L, 15, 10000)
368 MC_1.80 = MC_1(Lognormal.Perc80, status, mu_L, sigma_L, 15, 10000)
369
370 #IC
371
372 MC_1.4500.IC = IC(MC_1.4500)
373 MC_1.MTTF.IC = IC(MC_1.MTTF)
374 MC_1.1.IC = IC(MC_1.1)
375 MC_1.5.IC = IC(MC_1.5)
376 MC_1.10.IC = IC(MC_1.10)
377 MC_1.50.IC = IC(MC_1.50)

```

```

378 MC_1.80.IC = IC(MC_1.80)
379
380 #RESULTADOS
381
382 MC_1.4500.IC
383 MC_1.MTTF.IC
384 MC_1.1.IC
385 MC_1.5.IC
386 MC_1.10.IC
387 MC_1.50.IC
388 MC_1.80.IC
389
390 #amplitude ICs
391
392 amplitude(MC_1.4500.IC)
393 amplitude(MC_1.MTTF.IC)
394 amplitude(MC_1.1.IC)
395 amplitude(MC_1.5.IC)
396 amplitude(MC_1.10.IC)
397 amplitude(MC_1.50.IC)
398 amplitude(MC_1.80.IC)
399
400
401 #Weibull (gamma = shape_W & lambda = scale_W)
402 # - número de simulações = 10000
403
404 MC_w.4500 = MC_W(Weibull.Rt, status, shape_W, scale_W, 15, 10000)
405 MC_w.MTTF = MC_W(Weibull.MTTF, status, shape_W, scale_W, 15, 10000)
406 MC_w.1 = MC_W(Weibull.Perc1, status, shape_W, scale_W, 15, 10000)
407 MC_w.5 = MC_W(Weibull.Perc5, status, shape_W, scale_W, 15, 10000)
408 MC_w.10 = MC_W(Weibull.Perc10, status, shape_W, scale_W, 15, 10000)
409 MC_w.50 = MC_W(Weibull.Perc50, status, shape_W, scale_W, 15, 10000)
410 MC_w.80 = MC_W(Weibull.Perc80, status, shape_W, scale_W, 15, 10000)
411
412 #IC

```

```
413
414 R.4500.MC_W.IC = IC(MC_w.4500)
415 MTTF.MC_W.IC = IC(MC_w.MTTF)
416 MC_W.1.IC = IC(MC_w.1)
417 MC_W.5.IC = IC(MC_w.5)
418 MC_W.10.IC = IC(MC_w.10)
419 MC_W.50.IC = IC(MC_w.50)
420 MC_W.80.IC = IC(MC_w.80)
421
422 #RESULTADO
423
424 R.4500.MC_W.IC
425 MTTF.MC_W.IC
426 MC_W.1.IC
427 MC_W.5.IC
428 MC_W.10.IC
429 MC_W.50.IC
430 MC_W.80.IC
431
432 #amplitude ICs
433
434 amplitude(R.4500.MC_W.IC)
435 amplitude(MTTF.MC_W.IC)
436 amplitude(MC_W.1.IC)
437 amplitude(MC_W.5.IC)
438 amplitude(MC_W.10.IC)
439 amplitude(MC_W.50.IC)
440 amplitude(MC_W.80.IC)
```