



ESCOLA NAVAL



talant de bi-faire

Luis Miguel Rodrigues de Morais

***Integração da Experiência Humana na Gestão da
Manutenção e na Predição de Avarias e Necessidades de
Sobressalentes na Marinha.***

**Dissertação para obtenção do grau de Mestre em Engenharia Naval
Ramo de Mecânica**



Alfeite

2015



ESCOLA NAVAL

talant de bi-faire



Luis Miguel Rodrigues de Moraes

Integração da Experiência Humana na Gestão da Manutenção e na Predição de Avarias e Necessidades de Sobressalentes na Marinha.

Dissertação para obtenção do grau de Mestre em Engenharia Naval Ramo de Mecânica

Orientação de: 24285 CFR EN-MEC Ribeiro Parreira

O aluno Mestrando

O Orientador

Rodrigues de Moraes

Ribeiro Parreira

Alfeite, 2015

EPIGRAFE

*"I used to be on an endless run,
Believe in miracles because I'm one
I've been blessed with the power to survive
After all these years I'm still alive."*

The Ramones

DEDICATÓRIA

Ao meu pai Luis Morais, à minha mãe Silvana Rodrigues e ao meu irmão Rui Morais.

AGRADECIMENTOS

Em primeiro lugar agradeço aos meus pais, Luis Morais e Silvana Rodrigues, e ao meu irmão, Rui Morais, pelo apoio incondicional que sempre me proporcionaram, não só durante a realização desta dissertação mas também durante todo o meu percurso académico/militar. Agradeço pelo carinho, pela sabedoria e pela compreensão por todo o tempo de ausência nestes últimos anos. Estar-lhes-ei eternamente grato.

A todos os meus familiares que sempre apoiaram as minhas decisões e sempre me deram os melhores conselhos. A todos o meu muito obrigado.

Quero agradecer ao Sr. Engenheiro Valter Vairinhos pelos *inputs* e conhecimentos transmitidos durante o breve período que teve contacto com a minha dissertação. As suas orientações foram muito importantes e governaram toda a minha linha de pensamento.

Ao CFR EN-MEC Pires da Silva o meu sincero agradecimento pela preocupação constante em relação à minha dissertação.

Ao CFR EN-MEC Ribeiro Parreira pela orientação prestada em todo o processo de elaboração desta dissertação.

Quero agradecer ao 2TEN EN-MEC Tavares Pereira, ao GMAR Simões Ferreira e a toda a guarnição do N.R.P *Figueira da Foz* pelo apoio e preocupação demonstrados durante a minha curta passagem pelo navio. As experiências aí vividas ser-me-ão sempre úteis e espero cruzar-me com todos sem exceção, no mar, onde todo o bom marujo deve estar. A todos o meu muito obrigado.

Aos meus melhores amigos, Ricardo Bento, Rita Rodrigues e Elisabete Pires o meu muito obrigado por toda a amizade e por tudo o que já vivenciámos juntos até hoje. Usando uma só palavra: Orgulho.

RESUMO

A estatística clássica associa probabilidades apenas a variáveis aleatórias, enquanto que a estatística Bayesiana permite a associação de probabilidades a qualquer grau de crença ou incerteza sobre uma quantidade aleatória, evento ou hipótese. Esta abordagem leva à definição de probabilidades *à priori* e *à posteriori*. A primeira advém das informações que cada indivíduo traz consigo de experiências passadas e a outra é obtida à medida que novas experiências são realizadas e novos dados são adquiridos.

A aplicação de uma abordagem deste género na Marinha Portuguesa faz todo o sentido pois, os meios de que esta dispõe são operados constantemente e durante anos pelos seus militares. O uso da experiência adquirida por estes será uma grande mais-valia para a instituição no que respeita à aquisição de sobresselentes e novos equipamentos e na elaboração/atualização de políticas de manutenção.

Neste trabalho procurou-se aplicar este conceito na predição de avarias para os grupos eletrogéneos (GE's) das Fragatas da classe *Vasco da Gama*. Procedeu-se à elaboração de um questionário capaz de recolher a experiência adquirida pelos militares e técnicos responsáveis pela manutenção e condução deste equipamento. Usando a informação da experiência humana conjugada com os dados históricos, a utilização da inferência estatística Bayesiana permitiu retirar conclusões sobre o comportamento dessas avarias.

Foram feitas comparações entre os dois tipos de informação recolhidos (experiência pessoal e registos históricos) por forma a tentar perceber até que ponto existe coerência entre os dois e foram efetuadas as devidas simulações computacionais de modo a obter resultados e conclusões sólidas.

Por fim, foi proposto um modelo de integração desta abordagem com base nos conhecimentos adquiridos durante a elaboração de toda a investigação.

Palavras-chave: Inferência Bayesiana, Gestão da manutenção, Previsão de avarias, Marinha Portuguesa, Apoio à decisão, Experiência humana

ABSTRACT

The classical statistics associates probabilities with only random variables, whereas Bayesian statistics allows the association of probabilities with any degree of belief or uncertainty of a random quantity, event or hypothesis. This new approach leads to the definition of probabilities *à priori* and *à posteriori*. The first comes from the information that each individual brings from past experiences and the other is obtained as new experiments are carried out and new data is acquired.

The application of such an approach in the Portuguese Navy makes perfect sense, since the means at its disposal are operated constantly and for years by their military. Using the experience gained by them over their working time will be an added value for the institution, namely in the acquisition of spare parts and new equipment and in the preparation/updating of maintenance policies.

In this investigation the aim was to apply this concept to faults prediction in the electrical power generators of the *Vasco da Gama's* frigates class. It was carried out a preparation of a questionnaire that was be able to collect the experience acquired by the military and technicians responsible for the maintenance and operation of this systems. Using this information in parallel with the historical data, the use of statistical bayesian inference allowed to withdraw knowledge relatively to de fault behavior.

Were made some comparisons between the two kinds of information (personal experience and historical data) in order to understand if coherence between them exists, and were made some computational simulations to obtain solid and strong results/conclusions.

Lastly, it was proposed a model of integration of this new approach, based on acquired knowledge during the whole investigation.

Keywords: Bayesian Inference, Maintenance management, Fault prediction , Portuguese Navy, Decision support, Human knowledge

ÍNDICE

EPÍGRAFE	iii
DEDICATÓRIA.....	v
AGRADECIMENTOS	vii
RESUMO	ix
ABSTRACT	xi
Lista de figuras	xvii
Lista de acrónimos e abreviaturas	xix
Capítulo 1-Introdução	1
1.1.Enquadramento do tema	1
1.2. Justificação da escolha.....	3
1.3. Objetivos da dissertação	3
1.4. Metodologia	4
1.5. Organograma organizacional de todo o projeto.....	6
Capítulo 2 - Investigação bibliográfica e estado da arte	7
2.1. Os métodos Bayesianos: uma breve síntese histórica	7
2.2. Estatística Bayesiana e gestão da manutenção num contexto de escassez de dados.....	9
Capítulo 3 – Enquadramento teórico sobre estatística de Bayes e manutenção	11
3.1. Princípios Básicos da Estatística Bayesiana – Teorema de Bayes	11
3.2. O método MCMC (Monte Carlo Markov Chains) e sua importância... ..	14
3.3. Algoritmo de simulação <i>Metropolis</i> e <i>Metropolis-Hastings</i>	15
3.4. Função Verossimilhança	16
3.5. O Problema prático da especificação da distribuição <i>à Priori</i>	17

3.6. Procedimento geral para inferência Bayesiana: Posteriori	18
3.7. Abordagem à linguagem de programação “R”	19
3.8. Abordagem geral ao <i>software</i> WinBUGS	20
3.9. Sistema reparável e sistema não reparável	21
3.10. Taxa de falhas	23
3.11. Processos de Poisson	24
3.11.1. Processo de Poisson homogéneo (PPH).....	24
3.11.2. Processo de Poisson não homogéneo (PPNH).....	24
3.12. Teste de Laplace.....	25
3.13. Conceitos de manutenção vigentes na Marinha	26
3.13.1. Classificação por escalões	26
3.13.2. Classificação por tipologia	27
Capítulo 4 – Metodologia: Recolha e tratamento dos dados.....	29
4.1. Questionário.....	29
4.1.1. Critérios do questionário	30
4.1.2. Metodologia de elaboração do questionário.....	31
4.1.3. Critérios de escolha do equipamento alvo para a análise.....	31
4.2. Recolha de dados e o seu registo.....	32
4.2.1. Questionário pessoal	32
4.2.2. Dados dos registos DSM58 e DSM59	32
4.3. Tratamento dos dados	33
4.3.1. Questionário	33
4.3.2. Dados DSM 58	34
4.3.2.1 Estudo da tendência dos dados do N.R.P. <i>Vasco Gama</i>	36
4.4. Comparação do Questionário com dados DSM 58	38
4.4.1. Questão 2	39

4.4.2. Questão 3	39
4.4.3. Questão 4	40
4.4.4. Questão 5	41
4.4.5. Questão 6	42
Capítulo 5 – Inferência Bayesiana.....	43
5.1. Definição de um modelo para os dados DSM 58.....	44
5.2. Função de Verossimilhança.....	55
5.3. Tradução dos parâmetros do modelo em distribuições à priori	56
5.3.1. Priori sobre o parâmetro β	57
5.3.2. Priori sobre o parâmetro λ	58
5.4. Distribuição à Posteriori.....	59
Capítulo 6 – Resultados e discussão	61
6.1. Resultados GE1, N.R.P. VG	61
6.2. Resultados N.R.P. VG, AC e CR.....	66
6.3. Proposta de metodologia	68
Conclusão	69
Bibliografia.....	71
Apêndices	75
Apêndice A – Teste Laplace para os três navios.....	77
Apêndice B – Questionário	79
Apêndice C – Respostas ao questionário	81
Apêndice D – Código WinBUGS	83
Apêndice E – Resultados simulação MCMC	85

Lista de figuras

Figura 1: Organograma do projeto	6
Figura 2: Esquema representativo do processo de especificação de uma distribuição à priori hierárquica em função do objetivo da dissertação.	18
Figura 3: Exemplo de Modelo Gráfico retirado do WinBugs.....	20
<i>Figura 4: Curva da banheira resultante da união dos três tipos de taxa da falhas</i>	23
Figura 5: Estrutura da Manutenção na Marinha Portuguesa.....	27
Figura 6: Tabela resumo dos dados recolhidos através do questionário.....	34
Figura 7: Tabela de intervenções do corretivas para cada GE do N.R.P VG e respetivos intervalos de estudo.	36
Figura 8: Falhas no GE 1 em função do tempo (dias).....	37
Figura 9: Tabela comparativa de taxas de avarias resultantes do questionário e dos registos DSM 58.....	39
Figura 10: Falhas nos sistemas para os 4 GE's	40
Figura 11: Causas de avarias nos GEs do N.R.P VG	42
Figura 12: Gráfico Cullen and Frey demonstrando posição dos dados em relação a várias distribuições.	46
Figura 13: Distribuição Normal - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à direita).....	48
<i>Figura 14: Distribuição de Weibull - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à esquerda); Probabilidades empíricas vs Probabilidades teóricas (em baixo, à direita).</i>	49
Figura 15: Distribuição Gama - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição	

Acumulada teórica (em baixo, à esquerda); Probabilidades empíricas vs Probabilidades teóricas (em baixo, à direita).	50
<i>Figura 16: Distribuição Beta - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à esquerda); Probabilidades empíricas vs Probabilidades teóricas (em baixo, à direita).</i>	51
Figura 17: Função Densidade de Probabilidade (fdp) de weibull para o conjunto de dados (dias), com parâmetros $\beta= 0.769$ e $\lambda= 46.22$	53
Figura 18: Função Distribuição Acumulada (fda) de weibull para o conjunto de dados (dias), com parâmetros $\beta= 0.769$ e $\lambda= 46.22$	54
Figura 19: Gráfico de quantis para o modelo de Weibull com intervalo de confiança 95%	55
Figura 20: Histogramas da informação à priori (vermelho) e dos dados do GE1 (azul) sobrepostos	58
Figura 21: Esquema hierárquico para obtenção da priori do parâmetro de escala	59
Figura 22: Modelo WinBUGS para o caso em estudo	60
Figura 23: Ambiente WinBUGS mostrando as 3 ferramentas básicas para efetuar simulações	60
Figura 24: Tabela resumo dos valores dos parâmetros	61
Figura 25: Gráfico de densidade para o parâmetro beta (forma)	62
Figura 26: Gráfico de densidade para o parâmetro lambda (escala ou tempo característico)	62
Figura 27: Probabilidades à posteriori para vários intervalos de tempo de operação sem registrar avarias (em dias)	65
Figura 28: Probabilidades para os diferentes tempos de operação ininterrupta	65
Figura 29: Tabela resumo dos parâmetros estimados via MCMC para os 3 navios	67
Figura 30: Tabela resumo das probabilidades para os diferentes tempos de operação ininterrupta	67

Lista de acrónimos e abreviaturas

DN	Direção de Navios
GE	Grupo Eletrogéneo
MCMC	Monte Carlo Markov Chains
BUGS	Bayesian inference Using Gibbs Sampling
PPH	Processo de Poisson homogéneo
PPNH	Processo de Poisson não homogéneo
ROCOF	Rate of Occurrence Of Failure
SR	Sistema reparável
SNR	Sistema não reparável
CODA	Convergence Diagnosis and Output Analysis
N.R.P.	Navio da República Portuguesa
VG	Vasco da Gama
AC	Àlvares Cabral
CR	Corte Real
SICALN	Sistema de Informação de Configuração e Apoio Logístico dos Navios

Capítulo 1-Introdução

1.1.Enquadramento do tema

Ao longo dos últimos anos, a exigência na gestão de recursos aumentou consideravelmente, o mundo tornou-se muito mais competitivo e portanto também a manutenção tem passado por muitas mudanças organizacionais, tendo-se desenvolvido novas tecnologias e estratégias.

A análise de dados relativos ao funcionamento das máquinas e sistemas é, nos dias que correm, essencial e de extrema importância pois uma investigação bem concretizada e com a devida abordagem, permite que possamos estar perante uma redução dos custos no que toca à manutenção, assim como, um aumento da disponibilidade de determinado equipamento. É imperativo criar o conceito de manutenção adequado, que incide concretamente em garantir a operacionalidade dos sistemas no seu ciclo de vida, de forma eficaz e económica, por forma a atingir um patamar de excelência.

A integração da experiência humana na operação de máquinas e sistemas semelhantes é muito importante uma vez que significa que a organização aprende com o passado. Esta experiência poderia ser colocada ao serviço de aspetos cruciais da gestão tais como: predição de necessidades de sobressalentes, predição de avarias e adequação de políticas de manutenção.

Neste seguimento, existe um vasto leque de técnicas e abordagens que podem ser consideradas para encarar este problema. A estatística Bayesiana apresenta-se como sendo um método a considerar neste tipo de questões.

Por outro lado, a Estatística Bayesiana, baseada no conceito de probabilidade como grau de crença, na experiência e na veracidade de proposições que expressem essa experiência, permite, pelo menos conceptualmente, abordar este tipo de problema.

Atualmente, a aplicação generalizada deste tipo de estatística a problemas do tipo indicado é um fato. Isto só tem sido possível com base em importantes desenvolvimentos computacionais, nomeadamente no aparecimento de *softwares* específicos, de acesso livre e grátis, que permitem realizar os cálculos envolvidos. Basicamente, estes softwares tais como "R" e "WinBUGS" não estão a ser usados na Marinha Portuguesa, apesar de serem inteiramente grátis, de possuírem um grande potencial nestas temáticas e de estarem muito bem documentados.

Nesta dissertação faz-se pois uma tentativa de formular uma metodologia capaz de abordar a questão da recolha da experiência individual dos técnicos a respeito dos problemas identificados (avarias de material, ocorrências de consumos de sobressalentes, utilidade de operações de manutenção) e, usando a abordagem Bayesiana à inferência estatística, transformar essa informação em decisões úteis à predição de necessidades de sobressalentes e formulação de políticas de manutenção.

Torna-se claro que o que se tem em vista não é "um sistema" ou produto final capaz de realizar todas essas tarefas (demasiado vastas e difíceis) mas uma primeira tentativa na Marinha Portuguesa de abordar este tipo de problemas usando metodologia estatística adequada e instrumentos de *software* que são grátis, facilmente disponíveis, extremamente bem documentados mas que apesar disso não são usados nem ensinados. Porém, estudos recentes demonstraram consistentemente que, por exemplo a linguagem "R" está a ser a mais usada no mundo inteiro para realizar *data mining*.

1.2. Justificação da escolha

Nos dias que correm, em que cada vez mais as restrições económicas se fazem sentir, torna-se imperial adotar novas estratégias no que diz respeito à aquisição de sobresselentes para os mais variados sistemas de bordo das unidades navais. Tradicionalmente, a predição de necessidades de sobresselentes ou a formulação de políticas de manutenção tem sido feita com recurso a métodos e técnicas com escassa incorporação (comparando com as possibilidades) de experiência humana anterior. Uma das causas deste facto está na dificuldade em tratar as incertezas associadas a este tipo de necessidade e também à inexistência de instrumentos adequados. Porém, no campo estatístico, recentemente tornou-se possível usar inferência estatística em grande escala por terem sido resolvidos os problemas computacionais que anteriormente o impediam, através de recurso de acesso livre tais como Linguagem R, Winbugs, entre outros).

Por outro lado, num mundo competitivo onde cada vez mais se olha para as pessoas como parte integrante de uma grande equipa e não como um meio ou ferramenta, a experiência acumulada pelos profissionais, sejam da Marinha ou não, na condução de máquinas e sistemas de bordo deverá ser sempre considerada na tomada de decisão para a aquisição de qualquer tipo de sobresselente ou na construção de novas políticas de manutenção. Não há ninguém que detenha melhor conhecimento sobre um determinado equipamento que aquele que o opera constantemente.

1.3. Objetivos da dissertação

O objetivo desta dissertação é investigar a possibilidade da utilização da Inferência Bayesiana para incorporar a experiência humana no apoio à decisão na gestão da manutenção. Para tal, traçaram-se objetivos que resultaram nas seguintes questões a investigar e às quais se procurará dar resposta:

1. Que problemas teóricos, computacionais e práticos se põem quando se procura adotar a metodologia Bayesiana ao contexto da predição de avarias e conseqüente necessidade de sobressalentes na Marinha?
2. Considerando os modelos mais simples usados tradicionalmente na predição de avarias em equipamentos mecânicos, qual a possibilidade prática de traduzir em distribuições à *priori*, a experiência acumulada por engenheiros e outros técnicos na condução de determinados equipamentos?
3. Quais as possibilidades e quais os problemas inerentes à definição de uma metodologia que traduza os resultados da investigação realizada?

1.4. Metodologia

A metodologia que foi adotada na realização desta dissertação de mestrado seguiu a seguinte ordem lógica de acontecimentos:

- 1- Numa primeira fase, procedeu-se a uma recolha de informação relativa a programas informáticos que são utilizados nesta área de estudo, tendo-se encontrado as aplicações "R", "WINBUGS", "RStudio".
- 2- Seguidamente, procedeu-se à recolha de informação relativa à estatística Bayesiana, que é a base científica de toda a dissertação, procurando abordar os pontos essenciais que permitam ao leitor ficar com os conhecimentos básicos necessários para entender todo o processo. Nesta fase procurou-se também investigar sobre como melhor introduzir esta abordagem pioneira na Marinha Portuguesa, o que nos leva já a dar resposta à primeira questão desta dissertação.
- 3- Em seguida realizou-se o trabalho de campo propriamente dito. Recolheram-se os dados históricos dos registos da Direção de Navios (DN) relativos aos Grupos Eletrogéneos (GE's) das Fragatas de classe *Vasco da Gama* procedendo ao seu tratamento e estudo de tendências.
- 4- Numa quarta instância, procedeu-se à elaboração do questionário direcionado para obter a experiência de cada militar entrevistado no equipamento em estudo. Fez-se o tratamento dos dados recolhidos e o seu processamento estatístico básico.

- 5- Com a utilização dos softwares anteriormente referidos, procedeu-se a utilização das técnicas de estatística Bayesiana por forma a integrar a experiência acumulada dos técnicos com os registos históricos recolhidos na DN. Efetuaram-se várias simulações computacionais, por forma a retirar o máximo de informação e conhecimento possível com interesse para a instituição Marinha.
- 6- Por fim, procedeu-se a uma fase de interpretação crítica de todo o estudo e fez-se a análise profunda de todos os aspetos que integram este projeto, de forma a apresentar as conclusões que se encontram escritas nesta dissertação.

1.5. Organograma organizacional de todo o projeto



Figura 1: Organograma do projeto

Capítulo 2 - Investigação bibliográfica e estado da arte

Neste capítulo pretende-se dar a conhecer ao leitor, de forma resumida, o percurso que a estatística Bayesiana tem tomado ao longo da história até à atualidade. Numa segunda secção aborda-se igualmente a importância deste conceito num contexto onde existem poucos dados.

2.1. Os métodos Bayesianos: uma breve síntese histórica

Os métodos Bayesianos são hoje largamente utilizados em várias áreas científicas. Porém, é necessário recuar ao ano de 1763 para perceber a génese desta temática. Neste ano, foi publicado pela primeira vez um documento que fez referência ao que hoje chamamos de Teorema de Bayes. No seu artigo original, Thomas Bayes explicou a relação probabilística que daria origem a este teorema.

As técnicas Bayesianas geraram desde cedo algum interesse em outros grandes nomes da estatística como Laplace e Gauss, entre muitos outros académicos da altura. Porém, no início do século XX estes conceitos foram postos de parte pela maioria dos estatísticos que argumentavam que os métodos Bayesianos só poderiam resolver problemas simples onde a distribuição à *posteriori* pudesse ser escrita analiticamente. Isto exigia a escolha de *prioris* muitas vezes convenientes que nem sempre eram representativas do verdadeiro pensamento do analista. Além disto, os problemas mais complexos requeriam modelos mais elaborados onde o cálculo de integrais era incomportável (Carlin (1996)).

Desde o início do desenvolvimento da estatística até muito recentemente, houve sempre uma grande supremacia da inferência clássica, e o facto de se incorporar a informação *à priori* na análise, sob o enfoque Bayesiano, sempre gerou muita controvérsia em determinada fase do desenvolvimento da estatística em geral (Efron (1978), Lindley (1978), Smith (1984)). Porém, atualmente, este tipo de discussão parece não ser relevante, uma vez que as diferenças entre as duas abordagens estão bem compreendidas e as virtudes de cada uma delas são utilizadas conforme seja mais conveniente (Gamerman (1996)).

Na década de 80, com o aparecimento de computadores mais rápidos e acessíveis, a análise de dados teve um grande avanço e as limitações sobre a definição de distribuições à *priori* puderam ser colmatadas. Os métodos iterativos de Monte Carlo, como por exemplo o método MCMC (*Monte Carlo Markov Chains*), e respetivos algoritmos, como o de *Metropolis-Hastings*, tornaram-se populares entre estatísticos e o uso desta abordagem sofreu um grande avanço.

Num passado mais recente, um dos primeiros trabalhos utilizando os métodos Bayesianos foi o de Tsutakawa (1985), onde foi feita uma estimação das taxas de mortalidade por cancro. Quatro anos mais tarde, um outro estudo igualmente relevante foi publicado por Clayton (1989) onde se abordaram questões relativas à epidemiologia usando modelos Bayesianos hierárquicos.

Foi com base nestes e noutros trabalhos que, em 1992 Bernardinelli e Montomoli fizeram a análise da variação geográfica de risco de doenças, utilizando pela primeira vez o método MCMC como ferramenta.

Desde então, a estatística Bayesiana tem sido largamente utilizada em praticamente todas as áreas científicas. A área da manutenção de sistemas mecânicos não é exceção. Mais recentemente, muitos estudos e trabalhos têm sido publicados no que diz respeito à predição de avarias e comportamento das máquinas. Existem vários autores que seguem a linha de pensamento Bayesiana, dos quais se podem destacar Nicolai (2008), Mense (2012), Leitão e Prudência (1999) e Vassilis Katsouros (2013).

Com o atual contínuo desenvolvimento de capacidades computacionais, a Estatística Bayesiana apresenta-se como sendo um candidato forte na resolução destes e mais problemas. Esta abordagem ocupa cada vez mais espaço na comunidade científica e, segundo muitos autores, a previsão é que este seja o enfoque dominante num futuro próximo.

2.2. Estatística Bayesiana e gestão da manutenção num contexto de escassez de dados

A manutenção preventiva é um conceito extremamente intrínseco à sociedade em que vivemos. De todos os métodos de manutenção existentes é, sem dúvida, o mais usado nos vários planos de manutenção dos mais variados equipamentos e sistemas. Esta evidência provem do facto de que uma manutenção preventiva adequada evita, ou retarda, a falha total do equipamento ou sistema em questão, existindo desta forma menores gastos financeiros. De certa forma, a questão que se põe é "onde e com que frequência deverá ser feita a manutenção?". Muitas linhas foram já escritas sobre esta questão e muitos modelos foram criados, porém quase todos assumem, á partida, que a distribuição da probabilidade do tempo de operação até à falha é conhecida.

Por norma, "a grande parte dos modelos de otimização da manutenção consideram uma grande quantidade de dados. Contudo, em muitos casos esses dados não existem" (Pintelon e Gelders (1992)) e com a falta de informação histórica, e\ou informação pouco esclarecedora, sobre determinado equipamento ou sistema torna-se muito difícil afirmar algo sobre o seu comportamento futuro. Como agravante, e como diria Parlar (1991) "muito poucas páginas têm sido escritas na área da manutenção com informação incompleta".

Neste âmbito, surge a estatística Bayesiana que, devido às suas características, permite efetuar inferências sobre determinados equipamentos ou situações mesmo com uma quantidade reduzida de dados numa fase inicial, e considerando informação subjetiva que antes era descartada á partida.

Além disso, esta abordagem permite igualmente enriquecer o conhecimento já existente sobre os sistemas através da, por exemplo, incorporação da experiencia passada de técnicos e outros intervenientes na manutenção e condução de máquinas.

Capítulo 3 – Enquadramento teórico sobre estatística de Bayes e manutenção

O objetivo primário deste capítulo é reunir a informação bibliográfica necessária que permita ao leitor adquirir os conhecimentos teóricos básicos para melhor entendimento do que foi estudado. Os conceitos aqui abordados são apresentados de forma objetiva e simples e para um maior conhecimento sobre os temas abordados aconselha-se uma leitura mais aprofundada da bibliografia apresentada em cada secção.

3.1. Princípios Básicos da Estatística Bayesiana – Teorema de Bayes

Nesta secção pretende-se introduzir as ideias básicas da inferência Bayesiana de uma forma simplificada e objetiva. Para um tratamento mais aprofundado dos conceitos inerentes à inferência Bayesiana será necessário muito mais que umas curtas páginas, no entanto, atualmente, existe muita documentação relativa ao tema tal como Migon e Gamerman (1999) e Gelman, et al. (2003), para quem deseje aprofundar conhecimentos nesta área.

Muitos estudos têm vindo a ser desenvolvidos na área da estatística Bayesiana, principalmente nos últimos anos. Na base, a aplicação deste tipo de estatística consiste na utilização, mais ou menos complexa, do teorema de Bayes. Este teorema é uma consequência simples do conceito de probabilidade condicional e afirma que dados dois eventos A e B, a probabilidade condicional de acontecer B, sabendo que A ocorreu, podia ser expressa como

$$P(B|A) = \frac{P(B \cap A)}{P(A)} \quad (1)$$

Mas, a probabilidade que figura no numerador pode também ser escrita como

$$P(B \cap A) = P(A \cap B) = P(A|B).P(B)$$

E assim temos,

$$P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A)} \quad (2)$$

Atendendo agora ao denominador $P(A)$, este termo pode também ser desenvolvido. Se tivermos em conta que,

$$A \equiv A \cap S,$$

onde S é o espaço amostral, e considerando que o acontecimento B e o seu complementar B' são acontecimentos que cobrem exaustivamente o espaço amostral, então,

$$A \equiv A \cap S \equiv A \cap (B \cup B') \equiv (A \cap B) \cup (A \cap B')$$

Sendo que B e B' são acontecimentos mutuamente exclusivos,

$$(A \cap B) \cup (A \cap B') = P(A \cap B) + P(A \cap B')$$

E desta forma

$$P(A) = P(A \cap B) + P(A \cap B') = P(A|B)P(B) + P(A|B')P(B')$$

Substituindo na expressão (2) temos,

$$P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A|B)P(B) + P(A|B')P(B')} \quad (3)$$

em que o acontecimento B tem uma probabilidade *á priori* $P(B)$ de ocorrer e condiciona, de uma forma probabilística, a ocorrência do acontecimento A . A probabilidade condicional $P(B|A)$ corresponde à probabilidade de ocorrer B quando A já foi observado, ou seja, a probabilidade *à posteriori*.

A inferência Bayesiana é, num conceito geral, a aplicação deste teorema às mais variadas distribuições por forma a contornar problemas originados pela escassez de dados numa fase inicial. Contrariamente à inferência clássica, a inferência Bayesiana não faz a distinção entre variáveis aleatórias e os parâmetros de um modelo, ou seja, todos são tratados como sendo quantidades

aleatórias. Seguindo a linha de pensamento de Valle (2005) a inferência Bayesiana, na prática, pode ser explicada através do exemplo que se segue.

Consideremos "y" como sendo um vetor de observações e "θ" um vetor de parâmetros. Suponhamos que temos uma distribuição à priori $P[\theta]$, que representa a incerteza inicial acerca do vetor de parâmetros "θ" antes de que "y" seja observado, e uma probabilidade da função de verossimilhança do modelo $P[y | \theta]$. A especificação de $P[\theta]$ e $P[y | \theta]$ fornece um modelo probabilístico, para o qual, tal como foi visto acima,

$$P[y, \theta] = P[y|\theta] \cdot P[\theta] \quad (4)$$

Uma vez que os dados do vetor "y" contêm informação acerca dos parâmetros do vetor "θ", pode-se usar "y" para atualizar a informação acerca de "θ" determinando-se a distribuição condicional de "θ" sabendo "y", o que, usando o Teorema de Bayes, representa a distribuição dada por:

$$P[\theta|y] = \frac{P[y | \theta] \cdot P[\theta]}{P[y]} \quad (5)$$

onde,

$$P[y] = \sum_{\theta} P[y | \theta] \cdot P[\theta] = \int P[y | \theta] \cdot P[\theta] d\theta$$

Assim, temos que,

- $P[\theta|y]$ é a probabilidade da distribuição *à posteriori* dos parâmetros;
- $P[y | \theta]$ é a probabilidade da função de verossimilhança;
- $P[\theta]$ é a probabilidade da distribuição *à priori* de θ que representa a crença que temos sobre os parâmetros, antes de ter acesso aos dados;
- $P[y]$ é a probabilidade da função marginal de verossimilhança que funciona como constante de normalização da densidade da distribuição *à posteriori*.

Relativamente á função de verossimilhança abordaremos esse tema mais á frente. Para já, foquemos a atenção no denominador $P[y]$. Na grande maioria das aplicações práticas de interesse, o integral no denominador não é possível de resolver de forma analítica e conclusiva. Este foi, durante muitos anos, o grande entrave ao avanço da Estatística Bayesiana, uma vez que os cientistas sempre se deparavam com esta dificuldade. A utilização de métodos numéricos para a sua resolução foi também testada porém torna-se uma abordagem impraticável.

Contudo, o avanço das tecnologias computacionais das últimas décadas permitiram ultrapassar este obstáculo e atualmente utilizam-se métodos de simulação bastante eficazes que permitem a integração para, basicamente, todas as aplicações de interesse.

O método MCMC (Monte Carlo Markov Chains) é um destes métodos e é frequentemente utilizado para aproximar a distribuição á *posteriori*.

3.2. O método MCMC (Monte Carlo Markov Chains) e sua importância

Numa abordagem mais simplista do método de Monte Carlo os valores são gerados de uma forma independente e não existe uma preocupação em fazer convergir o algoritmo (método não iterativo), sendo que se considera apenas o tamanho da amostra, desde que este seja suficientemente grande para satisfazer as condições. No entanto, diz Muller (2008) que "em muitos problemas pode ser bastante difícil, ou mesmo impossível, encontrar uma densidade de importância que seja simultaneamente uma boa aproximação da densidade verdadeira e que seja fácil de ser amostrada".

Neste contexto surge o método de Monte Carlo com Cadeias de Markov (MCMC), uma alternativa aos métodos não iterativos em problemas complexos, que permite obter uma distribuição à *posteriori* bem como calcular estimativas amostrais de características dessa mesma distribuição. A diferença essencial a saber é que usando técnicas de simulação iterativas baseadas em cadeias de

Markov garantimos que os valores gerados não serão independentes e que irão convergir para uma distribuição de interesse.

De uma forma simples, uma simulação através de cadeias de Markov é usada quando não é possível amostrar θ diretamente de $[\theta]$. Por isso, faz-se este processo iterativamente criando várias sequências $\theta^1, \theta^2, \theta^3, \dots$, em que cada uma começa num determinado ponto θ^0 e depois, para cada t , é “desenhado” um θ^t proveniente de uma distribuição transitória $T_t(\theta^t|\theta^{t-1})$ que depende da iteração anterior θ^{t-1} . Assim, a cada iteração, a distribuição transitória é afinada e converge para uma distribuição estacionária, que será aproximada à distribuição *à posteriori* $[\theta|y]$ que pretendemos calcular.

Porém, obter a convergência correta da distribuição estacionária para que esta seja representativa da *posteriori* nem sempre é fácil. Para contornar este obstáculo vários algoritmos foram criados, sendo que dentro da vasta gama oferecida existem alguns que se destacam e são usados mais recorrentemente, como por exemplo o amostrador de Gibbs como demonstrado por Geman e Geman (1984) e o algoritmo de Metropolis-Hastings abordado por Hastings (1970). Aconselha-se a leitura de Geyer (1992) e Brooks (1998), para maiores detalhes sobre a metodologia MCMC.

3.3. Algoritmo de simulação *Metropolis* e *Metropolis-Hastings*

Segundo Gelman, et al. (2014) o algoritmo de simulação *Metropolis-Hastings* é na base uma família de métodos de simulação usando cadeias de Markov e que são bastante úteis quando se trata de obter amostragens de distribuições *à posteriori*. No algoritmo de *Metropolis-Hastings* um valor θ' é gerado de uma distribuição auxiliar e aceite com uma dada probabilidade. Se N for uma determinada distribuição de interesse então o novo valor θ' é aceite com probabilidade:

$$p(\theta, \theta') = \begin{cases} \min \left(1, \frac{\pi(\theta') q(\theta|\theta')}{\pi(\theta) q(\theta'|\theta)} \right) & \text{se } \pi(\theta) q(\theta'|\theta) > 0 \\ 1 & \text{se contrário} \end{cases}$$

Obviamente, em aplicações de inferência Bayesiana a distribuição de interesse N é a distribuição á *posteriori* e este mecanismo de correção garante a convergência da cadeia para uma distribuição de equilíbrio.

Suponha que a cadeia está no estado θ e um valor θ' é gerado de uma distribuição proposta $q(\cdot|\theta)$. Na grande parte das vezes, segundo Gamerman (1997), a distribuição proposta é dependente do estado atual da cadeia e $q(\cdot|\theta)$ é uma distribuição normal centrada em θ . Em termos práticos, o algoritmo de Metropolis-Hastings pode ser resumido nos seguintes passos:

1. Iniciar o contador de iterações $t = 0$ e especificar um valor inicial $\theta(0)$.
2. Gerar um novo valor θ' da distribuição $q(\cdot|\theta)$.
3. Calcular a probabilidade de aceitação $\alpha(\theta, \theta')$ e gerar $u \sim U(0,1)$.
4. Se $u \leq \alpha$ então aceitar o novo valor e fazer $\theta(t+1) = \theta'$, caso contrário rejeitar e fazer $\theta(t+1) = \theta$.
5. Incrementar o contador de t para $t + 1$ e voltar ao passo 2.

3.4. Função Verossimilhança

Nesta secção abordam-se alguns dos conceitos fundamentais da inferência Bayesiana, em particular os relativos à função de verossimilhança. Quando se traça um modelo para uma determinada amostra de dados, esse modelo representa e origina a função de verossimilhança.

Considere-se y como sendo um vetor de dados relativos a uma variável aleatória Y e θ um vetor de parâmetros do modelo sobre esses dados. A função de verossimilhança, ou simplesmente verossimilhança, para θ dado que os valores em y foram observados é $L(\theta|y)$.

A verossimilhança é na realidade a função da distribuição conjunta de todas as variáveis envolvidas no modelo, no entanto uma vez que se considera que os dados em y já foram observados, na verdade a verossimilhança é vista

como função dos parâmetros de interesse. Para cada valor do parâmetro, seja escalar ou vetorial, a verossimilhança é uma medida de similaridade com a amostra observada.

Para a determinação de uma função de verossimilhança o primeiro passo é analisar a natureza dos dados disponíveis, para perceber qual a melhor distribuição estatística que os representa. Estes dados reproduzem a evidência sobre os parâmetros de interesse.

3.5. O Problema prático da especificação da distribuição à *Priori*

A distribuição à *priori* constitui-se no único elemento novo na análise Bayesiana em relação à análise Clássica. A escolha das distribuições à *priori* é um tema de grande relevância e um dos grandes paradigmas da estatística Bayesiana. A grande crítica que se faz relativamente a este assunto é que existe a possibilidade de, na escolha desta distribuição, a pessoa poder escolher a distribuição que mais convém e o mais informativa possível, o que levará por sua vez a resultados favoráveis. Esta prática é sim possível, porém não deverá ser empregada. O que deve acontecer na escolha da distribuição à *priori* é selecionar uma o mais informativa e vaga possível desde que represente o estado atual de conhecimento sobre o caso em estudo. Zellner (1971) distingue dois tipos de informação à *priori*, uma baseada em dados passados e outra completamente subjetiva (não baseada em dados).

Na presença de dados experimentais previamente recolhidos (que é o caso desta investigação) ou quando baseada em fundamentos teóricos, a *priori* deve ser obtida de uma maneira científica (por formas funcionais). A importância na escolha da *priori* é maior quanto menor for a quantidade de dados experimentais, ou seja, a *priori* tende a ser dominada (uma vez que recebe menor peso) pela verossimilhança. Num caso extremo, se a *priori* receber um peso demasiado pequeno, as abordagens Clássica e Bayesiana são praticamente coincidentes. É importante realçar, entretanto, que atribuir probabilidade zero à *priori*, significa

atribuir zero também à *posteriori* pois, neste caso, sendo a *posteriori* = *priori* x verossimilhança, não há verossimilhança que faça a *posteriori* diferente de zero.

A literatura em torno da problemática da especificação de *prioris* é, devido ao seu fator crucial na inferência, muito vasta. Nesta investigação fez-se uso de distribuições à *priori* informativas (que representam conhecimento e incerteza antes de observar algum tipo de ocorrência) e hierárquicas. As *prioris* hierárquicas são muito usadas na prática e o seu conceito base consiste em denominar os seus parâmetros como híper-parâmetros que serão estimados recorrendo a outras distribuições ou informações. A metodologia de atribuição de distribuições à *priori*, nesta investigação, para os parâmetros dos modelos é resumida no esquema a seguir representado.



Figura 2: Esquema representativo do processo de especificação de uma distribuição à priori hierárquica em função do objetivo da dissertação.

3.6. Procedimento geral para inferência Bayesiana: Posteriori

Tendo os conceitos de Função de Verossimilhança e distribuição à *Priori* definidos o passo que se segue é determinar a distribuição à *posteriori* inferindo sobre os parâmetros considerados. O procedimento geral para realizar inferência Bayesiana resume-se a 5 pontos essenciais:

1. Obter evidências observacionais sobre o assunto em questão (por exemplo dados recolhidos através de algum tipo de sistema de recolha de informação);
2. Selecionar uma função de verossimilhança baseada nestas evidências (modelo);

3. Selecionar uma distribuição á priori (ou várias) que represente a crença ou conhecimentos sobre os parâmetros do modelo em estudo (questionário);
4. Atualizar os parâmetros da verossimilhança usando a/as *priori/s* e gerar uma distribuição á posteriori com novos parâmetros;
5. Proceder a várias iterações, tantas quanto necessárias, considerando sempre a distribuição á posteriori mais recente como a distribuição á *priori* da próxima iteração.

3.7. Abordagem à linguagem de programação "R"

"R" é uma linguagem de programação direcionada para a realização de cálculos estatísticos e criação de gráficos. Desenvolvida inicialmente por Ross Ihaka e Robert Gentleman no departamento de estatística da Universidade de Auckland, Nova Zelândia, esta linguagem rapidamente se alastrou a todo mundo sendo que na atualidade é amplamente usada entre estatísticos e *data miners* para o desenvolvimento dos seus projetos.

Além do "R" existe atualmente muita quantidade de *software* de programação, no entanto a grande parte deles apresenta licenças de elevados custos. O "R" é, à semelhança de muitos outros, um *software* para computação puramente estatística e construção de gráficos mas que apresenta a grande vantagem de ser livre, ou seja, isento de qualquer investimento monetário para a sua utilização. Este *software* pode ser descarregado e distribuído gratuitamente de acordo com a licença GNU e está disponível para as plataformas UNIX, Windows e MacOS. Além disso, é atualizado constantemente por vários acadêmicos de todo o mundo, a chamada comunidade R, e a sua capacidade de extensão e adaptação é enorme, uma vez que é possível a utilização de pacotes que contêm bibliotecas de funções para áreas de estudo bastante específicas. John Chambers (2008) escreveu no prefácio de seu livro que "Será que é proveitoso gastar tempo para desenvolver e estender habilidades em programação? Sim, porque o investimento vai contribuir para a sua habilidade em formular questões e para a confiança que você terá nas respostas".

Além das vantagens oferecidas a nível de programação, a utilização do "R" pode ser feita em vários ambientes o que permite ao utilizador escolher o que lhe permite maior confiança. No desenvolvimento desta dissertação foi utilizado o ambiente *RStudio* versão 3.1.2 de 2014. A vantagem principal deste em relação ao ambiente padrão do "R" é o facto de ser mais intuitivo e interativo permitindo escrever código, elaborar e chamar funções e desenhar gráficos, tudo em simultâneo e perfeitamente distinguido.

3.8. Abordagem geral ao *software* WinBUGS

O *software* WinBUGS desenvolvido por Spiegelhalter et al. (2000) é uma versão interativa para ambiente Windows do programa BUGS (Bayesian inference Using Gibbs Sampling). Esta aplicação permite a análise Bayesiana de modelos estatísticos complexos utilizando técnicas do método MCMC, assumindo um modelo de probabilidade completo, onde as quantidades desconhecidas são consideradas variáveis aleatórias.

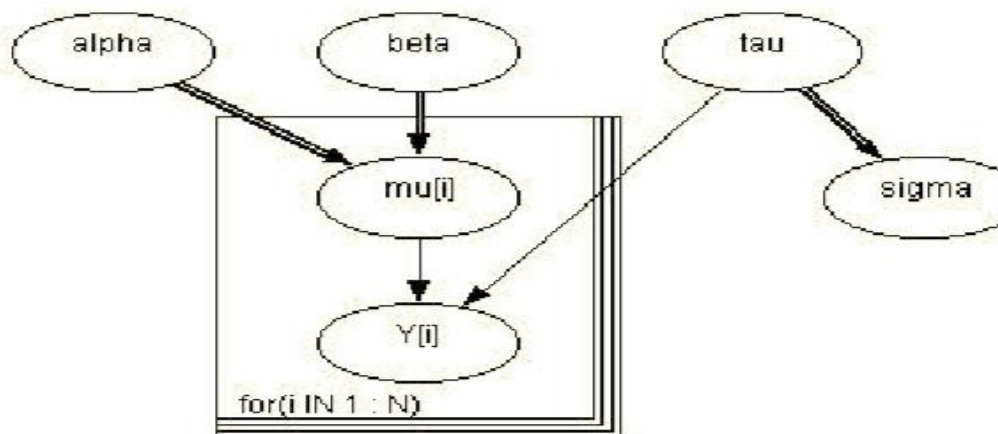


Figura 3: Exemplo de Modelo Gráfico retirado do WinBUGS

A utilização deste *software* é bastante vantajosa em relação aos restantes uma vez que permite a monitorização de qualquer função dos parâmetros do modelo fornecendo os valores amostrados de cada parâmetro bem como

resumos decorrentes da amostra obtida (média, desvio padrão e intervalo de confiança). Além disto é possível construir gráficos para analisar a trajetória da cadeia gerada permitindo assim entender e interpretar os resultados de uma forma o mais crítica possível.

Na utilização deste *software*, seguiu-se o algoritmo proposto por Mattos e Silva (2002):

1. Desenhar o modelo gráfico no WinBUGS;
2. Gerar o código-fonte a partir do modelo gráfico;
3. Inserir os dados do problema e valores iniciais;
4. Definir os tipos de diagnósticos de convergência a serem utilizados;
5. Executar o WinBUGS com um número qualquer de iterações e executar o comando *CODA*. Em seguida, verificar no *CODA* o número mínimo de iterações e o número de cadeias necessárias para proceder a indicação da convergência segundo os diagnósticos selecionados e seus parâmetros de análise;
6. Executar o WinBUGS para o modelo implementado empregando o número de iterações e o número de cadeias exigidos pelo *CODA* para os diagnósticos de convergência selecionados e gerar os arquivos de saída "Coda index", "Coda for chain 1", "Coda for chain 2" entre outros.
7. A partir dos resultados indicados para convergência obtidos executar novamente o WinBUGS para realização de inferências e monitoramento dos parâmetros desconhecidos e variáveis de interesse.

3.9. Sistema reparável e sistema não reparável

No âmbito deste estudo torna-se também essencial perceber a diferença entre estes dois tipos de sistemas. Um sistema reparável (SR) é definido como um conjunto de vários subsistemas ou componentes, que interagem entre si com o objetivo de desempenhar uma ou mais funções. Após cada falha estes são

reparados para desempenhar novamente a sua função. Resumidamente, segundo Ascher & Feingold (1984) um SR caracteriza-se estatisticamente como um sistema que, após cada falha, é reparado para total desempenho da missão, até à próxima falha.

Estes sistemas são frequentemente sujeitos a ações de manutenção, seja ela preventiva ou corretiva, podendo esta influenciar os intervalos de tempo entre falhas. Segundo O'Connor (2002) a fiabilidade para os SR, é a probabilidade de uma falha não ocorrer para um determinado período de interesse.

Por outro lado, um sistema não reparável (SNR) está normalmente associado aos componentes ou peças simples, cuja falha implica a sua inutilidade. Um fusível é um exemplo de um sistema não reparável. No caso dos componentes será importante o conhecimento da distribuição estatística que modela o seu tempo de vida, de forma a poder estimar a melhor periodicidade de substituição preventiva.

De forma sucinta, e seguindo a linha de pensamento de Ascher e Feingold (1984), um SR é recolocado ao serviço depois de sujeito a operações de manutenção efetuadas com o intuito de eliminar qualquer irregularidade detetada, enquanto que SNR é substituído por outro igual logo após a primeira falha, ou seja, a partir do momento em que deixa de realizar de forma satisfatória a função que lhe é destinada.

3.10. Taxa de falhas

A taxa de falhas $\lambda(t)$, também conhecida com ROCOF (Rate of Occurrence Of Failure), é um parâmetro de medida da fiabilidade. De uma forma simplificada, a taxa de avarias é o número de avarias por unidade de tempo.




Figura 4: Curva da banheira resultante da união dos três tipos de taxa de falhas¹

A taxa de falhas descreve a forma das falhas ao longo do tempo podendo ser crescente, decrescente ou constante. Se combinarmos as três no mesmo gráfico obtém-se a chamada “curva da banheira”, bastante conhecida na teoria da fiabilidade.

Esta curva é muitas vezes utilizada no estudo de fenómenos de avaria em componentes mecânicos por representar as 3 fases essenciais do tempo de vida dos mesmos.

¹ Portal Action. (5 de 02 de 2015). *ANÁLISE DO TEMPO DE FALHA*. Obtido de Portal Action: <http://www.portalaction.com.br/confiabilidade/analise-do-tempo-de-falha>

3.11. Processos de Poisson

Para uma correta análise do comportamento de determinado sistema reparável é necessário conhecer a ordem cronológica de ocorrências das falhas, e só conhecendo o comportamento aleatório, ou não, da ocorrência das falhas se pode saber o respetivo Processo de Poisson (Marques, Baptista, & Dias, 2009).

3.11.1. Processo de Poisson homogéneo (PPH)

Um Processo de Poisson Homogéneo caracteriza-se por uma taxa de falhas constante no tempo (ROCOF constante).

Um PPH define-se por uma sequência interminável de variáveis aleatórias positivas, independentes e identicamente distribuídas (i.i.d), sendo estas exponencialmente distribuídas. Um processo estocástico pontual $\{N(t), t \geq 0\}$ é um PPH se:

i. $N(0) = 0$

ii. $\{N(t), t \geq 0\}$ Incrementado de forma independente

iii. O número de falhas em qualquer intervalo Δt seguir uma distribuição de Poisson, com um valor médio dado por $m = \lambda_0 \times \Delta t$.

Deste modo, a probabilidade de ocorrerem n_f falhas num intervalo de tempo Δt é dada por:

$$P\{N(\Delta t) = n_f\} = \frac{e^{-m} m^{n_f}}{n_f!} \quad (8)$$

3.11.2. Processo de Poisson não homogéneo (PPNH)

Através do teste de Laplace é possível identificar facilmente os PPNH, sendo que sempre que se rejeita a hipótese nula se está perante um Processo de Poisson não Homogéneo. Assim sendo um PPNH caracteriza-se por uma taxa de falhas dependente do tempo, sempre que os intervalos entre falhas tendem a diminuir (ROCOF crescente) ou a aumentar (ROCOF decrescente). A taxa de falhas destes processos são caracterizadas por uma taxa de falhas dependente do tempo, e é representada pela seguinte expressão:

$$\rho(t) = \frac{dN(t)}{dt} \quad (9)$$

Onde $N[t]$, corresponde ao número de falhas acumuladas entre 0 e t .

3.12. Teste de Laplace

O teste de Laplace permite estudar, através de um teste de hipóteses, se uma taxa de avarias é constante ou apresenta tendência.

É importante mencionar que o modo de aplicação do Teste de Laplace varia consoante se trate de um teste limitado pelo tempo ou pelo número de falhas. Neste caso específico interessa o teste limitado pelo tempo:

Ho: Taxa de falhas constante

H1: Taxa de falhas não constante

α : Nível de significância

$$Z_0 = \sqrt{12 * nf} \left[\frac{\sum_{i=1}^{nf} \tau_i}{nf * T} - 0.5 \right] \quad (10)$$

em que:

nf = Número de componentes que falharam

T = Duração do ensaio

τ_i = Idade do sistema para a falha de ordem i

No pressuposto de um Processo de Poisson Homogéneo, se $Z_0 > Z_{\alpha/2}$ rejeitamos Ho.

Nestas circunstâncias, para valores de Z_0 fora do intervalo de confiança, valores negativos pronunciam a presença de um Processo de Poisson não

Homogéneo com tendência para Taxas de Falhas Decrescentes, e valores positivos Taxas de Falhas Crescentes.

3.13. Conceitos de manutenção vigentes na Marinha

A complexidade da manutenção a executar varia dependendo do sistema em causa. Por este motivo é necessário ter os recursos humanos e materiais que sejam capazes de operar em determinadas circunstâncias. Segundo a publicação de Marinha ILDINAV 802, a complexidade das manutenções é classificada como sendo de 1º, 2º ou 3º escalão. Relativamente à tipologia da manutenção a efetuar existe também uma classificação: manutenção preventiva e manutenção corretiva, com os respetivos subtipos.

3.13.1. Classificação por escalões

1. Manutenção de 1º Escalão:

As manutenções realizadas por este escalão, são as que tem um grau de complexidade menor em comparação com as restantes. As intervenções executadas traduzem-se em substituição de peças e componentes, pequenos ajustes e afinações possíveis com os meios técnicos de bordo. Os recursos humanos utilizados nestas intervenções são essencialmente pessoal pertencente à guarnição do navio em causa.

2. Manutenção de 2º Escalão:

O 2º escalão tem uma maior capacidade a nível da manutenção, além de fazer as operações referidas no 1º escalão, ainda está dotado de oficinas em terra que possibilitam melhores condições de operacionalidade. As operações que por motivos de complexidade ultrapassam os meios existentes a bordo são apoiadas por um reforço humano e oficial existente ou posto à disposição do comando administrativo para o qual o meio naval está destacado.

3. Manutenção de 3º Escalão:

Traduz os trabalhos que devido à profundidade da intervenção ou então à dimensão dos meios técnicos e oficiais a mobilizar, ultrapassam a capacidade de recursos existentes do comando administrativo. Devido à inexistência de tais meios, grande parte destas operações são levadas a cabo pela Arsenal do Alfeite, SA ou então por outra entidade fabril semelhante. Fazem parte desta categoria trabalhos cuja natureza requer apoio exterior, obtido maioritariamente pela direção técnica.

3.13.2. Classificação por tipologia

Dentro de cada escalão, a manutenção pode apresentar vários géneros distintos. A estrutura da manutenção na Marinha Portuguesa é descrita a seguir.

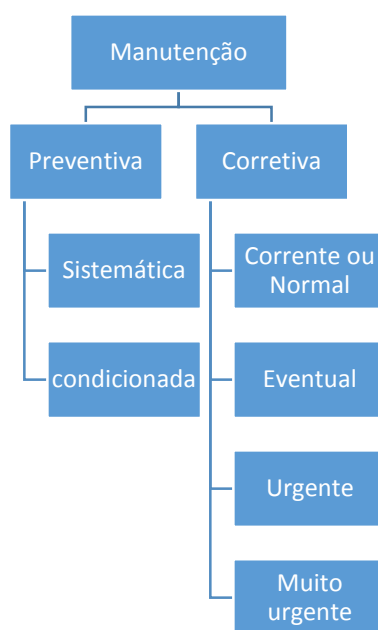


Figura 5: Estrutura da Manutenção na Marinha Portuguesa

1. Manutenção Preventiva

Tipo de manutenção que tem como objetivo minimizar o risco de falha do material, sendo realizada segundo intervalos de tempo pré-definidos. Consoante a sua incidência temporal, subdivide-se em:

- a. Manutenção sistemática – quando as operações são realizadas com determinada periodicidade, implicando normalmente, a indisponibilidade do equipamento.
- b. Manutenção condicionada- quando as operações a realizar decorrem da determinação do estado do material, por acompanhamento ou previsão de condições, efetuadas por métodos que não implicam por norma a indisponibilidade do equipamento intervencionado.

2. Manutenção Corretiva

É um conjunto de ações realizadas após a falha ou degradação do sistema e visa a reposição do sistema num estado operacional satisfatório. Este tipo de manutenção subdivide-se em quatro grupos, diferenciados consoante a sua prioridade:

- a. Manutenção Corrente ou Normal - manutenção corretiva referente à reparação de falhas que não afetam a segurança nem a operacionalidade dos meios navais ou dos seus sistemas ou equipamentos, e cuja natureza permite que sejam executadas nos períodos de imobilização destinados às ações de manutenção planeada.
- b. Manutenção Eventual - manutenção corretiva referente à reparação de falhas que afetam a segurança ou operacionalidade dos meios navais ou dos seus sistemas ou equipamentos, ou ainda o bem-estar do pessoal. Devido à sua natureza não permite que sejam executadas sem interferência nos seus planos de utilização, determinando a sua passagem a uma situação de indisponibilidade e a sua reparação fora dos períodos de imobilização destinados às ações de manutenção planeada.
- c. Manutenção Urgente - trabalhos de manutenção corretiva referentes a falhas que afetam a segurança ou operacionalidade dos meios navais ou dos sistemas ou equipamentos, ou ainda o bem-estar do pessoal, e cuja natureza permite que sejam executadas em curto espaço de tempo, não interferindo com os planos de utilização desses meios.

- d. Manutenção Muito Urgente - pequenos trabalhos de manutenção corretiva referentes a falhas que constituem perigo imediato para o material ou pessoal, e cuja natureza permite que sejam executados imediatamente, não interferindo com os planos de utilização dos meios navais.

Capítulo 4 – Metodologia: Recolha e tratamento dos dados

Neste capítulo ir-se-á incidir sobre os dados utilizados para a investigação, nomeadamente a sua recolha e tratamento para posterior utilização. Este capítulo divide-se em duas grandes secções. Uma dedicada ao questionário que foi elaborado e aplicado para recolher a experiência dos diferentes técnicos da Marinha Portuguesa e outra referente aos dados observacionais dos equipamentos em estudo neste trabalho (DSM58 e DSM59).

Uma vez que, antes de iniciar qualquer estudo, se torna imperativo conhecer a tendência dos dados disponíveis, neste capítulo inclui-se de igual forma uma análise gráfica e uma análise exploratória dos dados, que dão uma ideia geral do comportamento dos equipamentos. Estas serão complementadas com o teste de Laplace, mais esclarecedor, por forma a conhecer devidamente o comportamento dos sistemas em questão e de modo a identificar a presença de possíveis Processos de Poisson.

4.1. Questionário

As pessoas que lidam diariamente com equipamentos, ano após ano, desenvolvem uma perceção do estado dos componentes mais críticos, bem como das mudanças ocorridas no seu estado ao longo do tempo. Esta perceção é intuitiva e constitui uma fonte de informação valiosa e muitas vezes única para estimar o estado futuro de um componente ou sistema.

Logicamente, a formulação de um questionário para recolher dados da experiência dos técnicos com uma certa classe de material não é uma tarefa

simples. Principalmente quando se pretende posteriormente analisar cientificamente essas opiniões subjetivas.

Um questionário é, na sua forma mais geral, um conjunto de questões que têm o objetivo de gerar dados para todo o tipo de aplicações. A construção de um questionário segundo Aaker (2001) é uma "arte imperfeita" e por vezes obter os dados que se pretendem através deste não é uma tarefa tão simples como pode parecer. Porém, segundo este autor, existem alguns fatores como o bom senso e a experiência do pesquisador que podem contribuir para o sucesso e para evitar erros.

Neste projeto, a grande linha guia assenta na ideia de utilizar a experiência dos militares e técnicos da Marinha Portuguesa na predição de avarias e no processo de decisão relativamente á aquisição de sobresselentes e á criação/atualização de novas políticas de manutenção. Para tal, é claramente necessário recolher essa experiência e neste âmbito foi criado um pequeno questionário para os militares preencherem. Este questionário encontra-se no apêndice B.

4.1.1. Critérios do questionário

Como será de esperar, o questionário teria que satisfazer determinados critérios, que são essenciais para que a informação retirada através deste seja realmente útil. Os critérios considerados na elaboração deste questionário foram:

1. Objetividade: as questões colocadas deverão ser objetivas e sem qualquer tipo de ambiguidade. Deverão ter um único sentido e não vários;
2. Neutralidade: as questões deverão ser neutras, ou seja, não poderão influenciar as respostas;
3. Simplicidade: todas as questões deverão ser de fácil entendimento por parte do leitor não devendo existir termos demasiados difíceis.
4. Lógica: o encadeamento das questões deverá ser logico e, se possível, partir de aspetos mais gerais para os mais específicos. Deverá existir uma linha lógica de pensamento e encadeamento das ideias;

4.1.2. Metodologia de elaboração do questionário

Na elaboração deste questionário seguiu-se uma metodologia proposta por Aaker (2001). As várias etapas seguidas neste processo foram:

1. Planear o que vai ser avaliado: trata-se de clarificar o assunto e definir objetivos. Obter informações, se necessário, sobre o assunto em questão.
2. Formular as perguntas: realizar várias questões que aborem a totalidade do que se quer avaliar. Para cada assunto determinar o conteúdo de cada pergunta.
3. Definir o texto e ordem das questões: verificar se os critérios para o questionário são respeitados;
4. Testar o questionário: simular respostas ou utilizar uma pequena amostra para verificar a eficácia e eficiência do questionário;
5. Fazer correções: depois de avaliar e verificar falhas, proceder às devidas correções.

4.1.3. Critérios de escolha do equipamento alvo para a análise

Tendo os critérios e a metodologia de elaboração do questionário definidos, o passo seguinte seria escolher um equipamento sobre o qual este iria incidir.

Depois de uma análise extensiva sobre os vários equipamentos instalados a bordo das fragatas desta classe, chegou-se à conclusão que os equipamentos a serem utilizados seriam os Grupos eletrogéneos. São compostos por um alternador e um motor *diesel* da marca MTU modelo 8 V 396 TB 53. A análise focou-se prioritariamente no motor *diesel* e esta escolha teve como base vários aspetos, dos quais se destacam:

1. Grande número de horas de funcionamento deste equipamento;
2. Exige um acompanhamento constante por parte dos técnicos responsáveis;
3. Existe um vasto registo das intervenções efetuadas nestes equipamentos.
4. Grande número de sistemas auxiliares implícitos ao seu funcionamento, que são um bom objeto de estudo;

5. Maior simplicidade destes sistemas, relativamente aos motores principais;
6. Equipamento que abrange uma vasta área técnica em vários tópicos;
7. Equipamento que representa com grande confiança os problemas e avarias mais comuns em outros motores de combustão interna;

4.2. Recolha de dados e o seu registo

4.2.1. Questionário pessoal

Após a devida elaboração do questionário focado no Gerador MTU 8 V 396 TB 53 surge a necessidade de este ser aplicado. Para tal, selecionou-se um grupo de técnicos da Marinha Portuguesa que estejam ou tenham estado a prestar serviço a bordo de um ou mais navios desta classe. Os elementos escolhidos deveriam ser Oficiais e Sargentos e a sua escolha seguiu uma ordem específica de relevância.

Os primeiros elementos a serem selecionados, por razões óbvias, foram os que, atualmente, servem a bordo das fragatas da classe "Vasco da Gama". Estes elementos, pelo menos concetualmente, serão os que na atualidade detêm maior conhecimento sobre a instalação e terão maior facilidade em responder às questões colocadas. A escolha dos indivíduos não seguiu nenhum critério específico, sendo que a recolha de informação limitou-se a abordar pessoalmente cada militar, explicar-lhe a situação e o propósito do projeto e de seguida proceder á entrega em mão do questionário a preencher.

A tabela em apêndice C mostra as respostas dadas pelos inquiridos nas diversas questões colocadas, devidamente organizados em relação aos navios onde serviram.

4.2.2. Dados dos registos DSM58 e DSM59

De igual forma, tornou-se necessário recolher informação de registo relativamente às intervenções efetuadas nos Grupos eletrogéneos, bem como dos seus períodos de operação ao longo dos anos de serviço. Estes dados são de extrema importância uma vez que permitem estabelecer tempos de início e fim da análise estatística e permitem saber com elevada precisão todas as falhas que

foram ocorrendo ao longo deste período de análise selecionado. Este registo baseia-se essencialmente num impresso a ser preenchido pelas unidades responsáveis, o DSM 58, e tem as seguintes funções:

- Relato de intervenções preventivas
- Relato de intervenções corretivas (falhas)
- Relatório anual acerca dos equipamentos
- Relatos diversos
- Descrição de trabalhos a requisitar a organismos fabris
- Resumos de documentação técnica com relevo para o navio
- Requisição de trabalhos entre serviços de bordo

Está desenhado de modo a servir de auxiliar na preparação interna do trabalho pelas entidades fabris.

Um segundo impresso foi também usado, embora não na sua totalidade, para a recolha das horas de funcionamento dos geradores em questão. Trata-se do DSM 59 e foi de extrema importância uma vez que permitiu ter acesso ao número de horas de funcionamento de cada gerador individualmente e permitiu igualmente estabelecer as devidas fronteiras de início e fim do estudo.

4.3. Tratamento dos dados

4.3.1. Questionário

A informação obtida através do questionário não será tratada usando nenhum processo estatístico em específico. A recolha desta informação foi feita para, como se verá mais adiante, proceder à elaboração de uma distribuição *à priori*. Assim sendo, após tabelar as respostas obtidas no questionário fez-se um estudo por forma a verificar quais as respostas mais comuns nos 3 navios e verificar a existência, ou não, de algum tipo de padrão. Na tabela seguinte encontra-se resumida a informação, mostrando-se as respostas mais comuns para o questionário aplicado. Esta informação será usada posteriormente para efeitos de comparação com os dados do registo histórico.

Navio	Questão 2 (numero de ocorrências)	Questão 3 (Situação)	Questão 4 (Sistema)	Questão 5 (Causa)	Questão 6 (Tempo de operação estimado)
V.Gama	Em média 18	A navegar	Nenhum se destaca dos demais	Desgaste	Entre 2 semanas a 1 mês
A.Cabral	Em média 27	A navegar	Sist. Água salgada e Sist. Combustível	Corrosão	1 Mês
C.Real	Em média 14	A navegar	Sist. Água doce	Fadiga	1 Trimestre

Figura 6: Tabela resumo dos dados recolhidos através do questionário

4.3.2. Dados DSM 58

A análise de tendências é um processo que visa verificar, usando a metodologia dos testes de hipóteses, se os dados amostrais são ou não compatíveis com uma determinada população. Segundo Leitão (1999), o estudo destas tendências deverá ser sempre feito antes de se atribuir uma distribuição estatística a esses dados. Refere também que, este procedimento, deverá ser distinto consoante se esteja perante um sistema reparável (SR) ou um sistema não reparável (SNR).

Perante um SR, que é o caso deste estudo, a análise efetuada tem como objetivo indagar qual a tendência que a frequência de avarias apresenta, isto é, se há indícios estatísticos de taxa de avarias decrescente, constante ou crescente. A análise de tendência é efetuada através da aplicação do teste de Laplace cuja descrição foi feita no capítulo anterior.

Os dados retirados do DSM58 pertencem aos navios da classe *Vasco da Gama* e abrangem o período de 08 de Agosto de 2005 a 14 de Abril de 2015. O tratamento destes dados para posterior estudo seguiu uma metodologia específica que será explicada e exposta a seguir.

Em primeiro lugar, a incidência foi sobre as avarias. Nos registos DSM58 os registos seguem a classificação em três escalões, seguindo a política de manutenção da Marinha Portuguesa. Além desta divisão em escalões é também feita a classificação segundo o tipo de manutenção, sendo que as três classificações que aparecem nos registos são: manutenção corretiva, manutenção preventiva sistemática e manutenção preventiva condicionada.

Tendo estes pontos assentes, e em concordância com os objetivos desta dissertação, procedeu-se então ao tratamento dos dados. Entre todos, selecionaram-se apenas os correspondentes a ações de manutenção corretiva. A razão por trás desta escolha é relativa ao modo como o equipamento é afetado na sua operacionalidade. De fato, são apenas as manutenções corretivas que provocam a inoperacionalidade do equipamento em estudo e as que mais influenciam a sua atividade normal de funcionamento. Todas as outras ações de manutenção (preventiva sistemática ou condicionada) são efetuadas de forma planeada, uma vez que se sabe que o equipamento irá estar a ser intervencionado durante um período de tempo específico. Já nas manutenções corretivas, não existe um pré-aviso e acontecem de forma inesperada no tempo, haja ou não algum tipo de conhecimento ou desconfiança sobre o equipamento em questão. Poder-se-á ter uma grande certeza em relação ao equipamento, no entanto nunca será 100% correta.

Desta forma, para este estudo, foram apenas utilizadas as avarias relativas a manutenções corretivas, sejam de 1º, 2º ou 3º escalão. Para facilitar a análise, foi feita a divisão dos três navios e dentro de cada navio a divisão dos 4 geradores. Em algumas secções deste trabalho utilizam-se todos os dados em simultâneo e noutras teve-se em conta esta divisão e organização. No entanto, em cada secção esta questão será sempre esclarecida.

Os navios foram também identificados como navio N.R.P. VG, N.R.P. AC e N.R.P. CR e os geradores como gerador 1, 2, 3 e 4. Esta será a nomenclatura para todo o trabalho.

4.3.2.1 Estudo da tendência dos dados do N.R.P. *Vasco Gama*

Inicialmente o N.R.P. VG apresentava registo de 478 intervenções para os 4 geradores, compreendidas entre 08/08/2005 e 14/04/2015. Primeiramente procedeu-se à seleção das avarias correspondentes apenas a manutenções corretivas e desta forma o número de intervenções passou a ser de 169 compreendidas no período de 25/08/2005 a 13/04/2015. Posteriormente, a divisão ocorreu ao nível dos geradores, separando individualmente cada um de entre todos os registos. Com esta separação, e devido a algumas falhas no preenchimento dos registos, cada Grupo eletrogéneo tem um período de estudo diferente.

O resumo dos dados pode ser visto na figura seguinte. Importa lembrar que neste momento apenas consideramos o N.R.P. *Vasco da Gama*, um dos 3 da classe de navios estudados. Porém, para os restantes 2 navios o procedimento é similar.

<i>Gerador</i>	<i>Número de intervenções</i>	<i>Data de início</i>	<i>Data de fim</i>
<i>1</i>	51	25/08/2005	13/04/2015
<i>2</i>	48	25/08/2005	04/11/2014
<i>3</i>	31	02/01/2007	25/02/2015
<i>4</i>	39	25/08/2005	09/01/2015

Figura 7: Tabela de intervenções do corretivas para cada GE do N.R.P VG e respetivos intervalos de estudo.

Desta forma, e de modo a facilitar a perceção do comportamento das falhas, decidiu-se nesta fase utilizar uma análise gráfica, possibilitando uma rápida compreensão do desenvolvimento das ocorrências em função do tempo. Para complementar a informação gráfica recorreu-se também ao teste de Laplace descrito no capítulo anterior. O gráfico para o GE1 pode ser visto a seguir. Os restantes geradores deste navio e dos restantes foram estudados em conjunto e os resultados encontram-se em apêndice A.




Figura 8: Falhas no GE 1 em função do tempo (dias)

Observando o gráfico da figura 9 poder-se-á estimar, de forma grosseira, que a taxa de falhas não é constante uma vez que parece difícil ajustar uma reta ao conjunto de pontos. Prevê-se desta forma que o sistema segue um Processo de Poisson não Homogéneo.

Para confirmar esta situação procedeu-se ao teste de Laplace com os seguintes parâmetros:

Ho : Taxa de falhas constante

H1 : Taxa de falhas não constante

- $\sum_{i=1}^{nf} \tau_i = 87\,343 \text{ dias}$
- $nf = 51 \text{ avarias}$
- $T = 2788 \text{ dias}$

Calculando Z_0 vem,

$$Z_0 = \sqrt{12 * 51} \left[\frac{87\,346}{51 * 2788} - 0.5 \right]$$

$$Z_0 = 2.828$$

Para um nível de significância $\alpha = 5\%$ temos $Z_{\alpha/2} = Z_{0.025} = 1.96$

Como a condição $|Z_0| > Z_{\alpha/2}$ se verifica, rejeita-se H_0 , certificando assim as previsões gráficas anteriores e confirmando que o sistema segue um Processo de Poisson não Homogéneo.

Segundo O'Connor (1995), sempre que o valor de Z_0 obtido pela aplicação do teste de Laplace seja francamente positivo, $Z_0 > 1.96$, para um nível de significância de 5%, o teste revela-se formalmente conclusivo. Nesta situação, é plausível considerar a taxa de avarias crescente, ou seja, os tempos entre avarias, à medida que o tempo passa, tendem a ser sucessivamente mais pequenos, o que caracteriza o que é bem conhecido na teoria da fiabilidade como a fase 3 da curva "em forma de banheira", apresentada no capítulo anterior.

Nesta situação, em que o sistema se encontra na fase de degradação, importa saber qual será o comportamento num futuro próximo, sendo que uma das formas para tal se prende em inferir estatisticamente sobre os tempos entre avarias consecutivas por forma a prever as próximas falhas no sistema. Este processo será descrito detalhadamente mais adiante.

Este teste foi aplicado aos restantes GE's, porém não ao nível individual mas sim ao nível do navio (4 GE's), verificando-se que todos os navios seguem um PPNH com taxa de avarias crescente. Os resultados do teste encontram-se em apêndice A.

4.4. Comparação do Questionário com dados DSM 58

Nesta secção o objetivo primário é proceder a um confronto entre os dados do registo histórico com os dados recolhidos no questionário. Com esta comparação pretende-se observar até que ponto a perceção dos inquiridos vai de encontro ao que realmente sucedeu e foi registado. Para tal usar-se-á uma análise gráfica.

Nsta secção seguir-se-á a ordem das questões do questionário.

4.4.1. Questão 2

Em relação ao número de ocorrências corretivas, a percepção dos inquiridos aponta para 35 ocorrências no N.R.P. VG, 54 no N.R.P. AC e 29 no N.R.P. CR. Assume-se que, em média, cada elemento serviu a bordo dos navios 5 anos, sensivelmente 2 comissões de embarque (dado retirado através de conversas informais com os inquiridos). Tendo em conta estes aspetos e os registos DSM 58 apresenta-se a seguinte tabela com as taxas de avarias.

	N.R.P VG	N.R.P AC	N.R.P CR
Inquiridos	0.0192	0.0296	0.0159
	avarias/dia	avarias/dia	avarias/dia
Registo DSM58	0.0586	0.0724	0.0445
	avarias/dia	avarias/dia	avarias/dia

Figura 9: Tabela comparativa de taxas de avarias resultantes do questionário e dos registos DSM 58

Através da tabela vê-se que para todos os navios os inquiridos atribuíram uma taxa de avarias inferior à registada nos dados históricos. Por outro lado, comparando entre navios, observa-se que a percepção dos mesmos vai de encontro com a realidade observada. As maiores e menores taxas de avarias obtidas pelo questionário e pelos registos estão em concordância total, o que revela uma boa percepção das ocorrências por parte dos técnicos, embora que significativamente otimista em relação à realidade.

4.4.2. Questão 3

Em relação à situação do navio aquando das ocorrências as respostas são completamente conclusivas. A totalidade dos inquiridos revelou que a grande parte das ocorrências sucederam ou a navegar, ou com o navio atracado com

missão atribuída. Estes dados vão totalmente de encontro aos registos históricos das ocorrências.

4.4.3. Questão 4

O gráfico seguinte mostra o comportamento das falhas registadas no DSM58 para os 4 GE's do N.R.P VG em função dos vários sistemas que formam cada GE.




Figura 10: Falhas nos sistemas para os 4 GE's

A avaliação deste gráfico deve ser feita de uma forma meramente qualitativa e não quantitativa, ou seja, foi aplicada neste gráfico a mesma escala a todos os GE's, no entanto estes tiveram diferentes tempos de operação (exemplo: o GE 2 apresenta um total de avarias inferior ao GE1, no entanto o tempo de operação deste é 5 meses inferior) Assim, a comparação entre os diversos geradores, através deste gráfico, deverá ser feita no sentido de ver em simultâneo os 4 GE's e as distribuições das avarias pelos vários sistemas, e não como forma de comparação entre eles.

Verifica-se que dos vários sistemas, no geral os que tiveram mais ocorrências foram o sistema de combustível e o de água doce. O campo marcado como "outros componentes" tem igualmente um peso elevado e representa todos

os componentes intervencionados corretivamente que não pertencem diretamente aos sistemas apresentados, componentes tais como juntas, apoios, encanamentos, sensores, entre outros.

Da informação coletada através do questionário para N.R.P VG, segundo os inquiridos, nenhum sistema se destacou pela negativa em relação aos restantes, o que não revela uma perceção muito correta em relação à realidade. Visto que cerca de 45 % das ocorrências foram em apenas dois sistemas, o de combustível e o de água doce, seria de esperar uma maior tendência nas respostas dos inquiridos para estes mesmos sistemas.

Utilizando o mesmo método de comparação, observou-se que para o N.R.P AC a perceção é mais apurada. 37.3% das ocorrências registadas são relativas ao sistema de combustível. Apesar de não totalmente conclusiva, para este navio a perceção individual mostrou-se mais certa, visto que este sistema foi apontado pelos inquiridos como sendo problemático.

Para o N.R.P CR, 41.2% das ocorrências incidiram sobre o sistema água salgada o que vai contra as respostas coletadas no questionário para este navio. Mais uma vez, a perceção dos inquiridos revela-se fraca nesta questão.

4.4.4. Questão 5

Relativamente às causas das avarias traçou-se o gráfico da figura 12, onde se observa claramente que a maioria das ocorrências (46.5%) se deve aos fenómenos de desgaste e de fadiga. O campo marcado como "outras" representa as falhas de preenchimento do impresso DSM 58, e portanto os números apresentados para este campo representam falhas que poderão ser de qualquer um dos outros tipos. Por representarem 32.9% das causas, não deverão ser descartadas da análise.

A perceção dos inquiridos em relação a este tópico é bastante precisa. À questão 5 do questionário, 62.6% dos inquiridos em relação ao N.R.P VG apontaram como principais causas o desgaste e a fadiga, o que vai de encontro com os registos históricos.

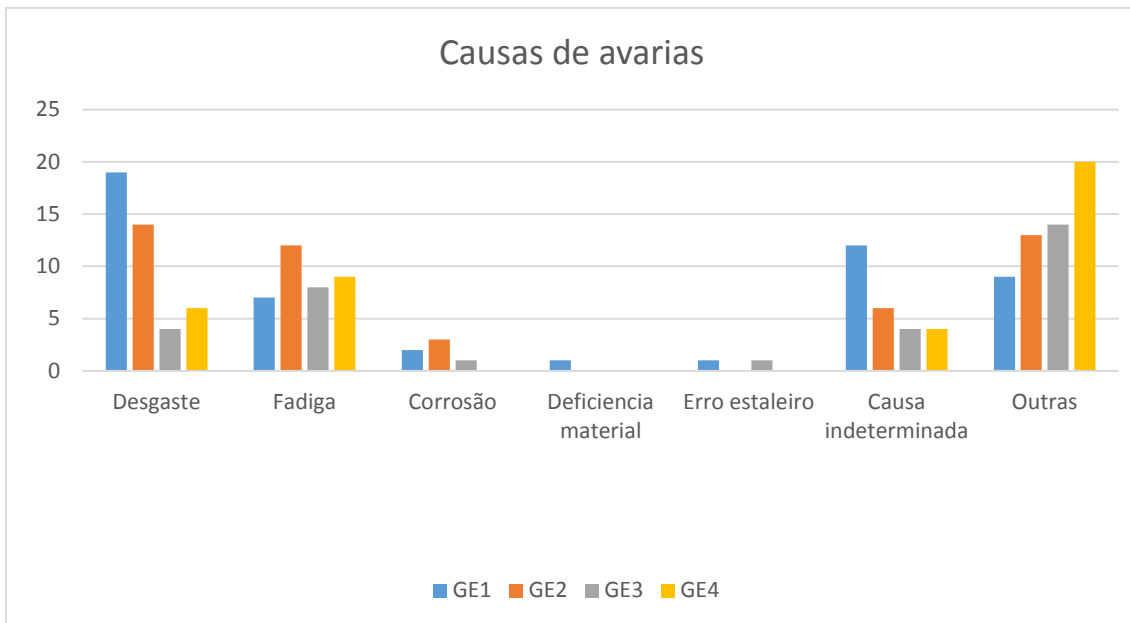


Figura 11: Causas de avarias nos GEs do N.R.P VG

4.4.5. Questão 6

Em relação a esta questão não será feita qualquer tipo de comparação, uma vez que os dados daqui provenientes serão utilizados mais tarde como objeto para a definição das distribuições à priori.

Capítulo 5 – Inferência Bayesiana

Como visto anteriormente, inferência estatística é uma ferramenta cujo objetivo principal é fornecer informação para a tomada de decisões. Para tal, é sempre necessário proceder à recolha de dados, quer sejam amostrais, experimentais ou observacionais. Por outro lado, inferência estatística Bayesiana, ou simplesmente inferência Bayesiana, além da informação contida nestes dados, considera igualmente informações prévias a essa recolha de dados. Essa informação prévia, sobre os parâmetros, é chamada de informação *à priori* e o objetivo último deste tipo de inferência estatística é obter a melhor combinação entre esta e os dados observacionais, usando o teorema de Bayes, gerando assim a informação *à posteriori* sobre os parâmetros, informação essa que, teoricamente, será mais apurada e levará a melhores decisões.

Neste capítulo ir-se-á de encontro com a questão 2 dos objetivos desta dissertação. Aplicando os conceitos da inferência Bayesiana pretende-se averiguar de que forma é possível integrar a experiência acumulada pelos profissionais da Marinha Portuguesa na análise de avarias dos equipamentos. Para tal, usar-se-á como auxiliar o GE1 do N.R.P. VG e respetivos dados.

Este capítulo está organizado em concordância com a sequência lógica da inferência Bayesiana, ou seja, em primeiro lugar procede-se à especificação de um modelo que representa os dados observacionais dos registos DSM 58 por forma a encontrar a distribuição estatística que melhor representa estes dados. Numa segunda fase procede-se à conceção de distribuições *à priori* sobre os parâmetros do modelo estipulado anteriormente e finalmente executa-se a obtenção das distribuições *a posteriori* dos parâmetros utilizando as técnicas e métodos abordados anteriormente.

Considera-se como unidade de medida o sistema “Grupo eletrogéneo (GE)”, visto que cada grupo de produção de energia elétrica funciona independentemente dos restantes existentes a bordo. Especificamente assume-se que um GE funciona como um conjunto de componentes em série, e que a falha de um único componente implica a falha do sistema. Define-se então falha

como a interrupção total do funcionamento do Grupo eletrogéneo e não como a interrupção de um ou vários componentes.

5.1. Definição de um modelo para os dados DSM 58

Nesta secção ir-se-á estabelecer uma metodologia para a criação de um modelo que define os dados empíricos (dados DSM) da melhor maneira. A tarefa de atribuir uma expressão teórica a um conjunto de dados nem sempre é linear. No estudo de tempos entre avarias de sistemas mecânicos é usual atribuir distribuições não negativas (visto que a variável "tempo" não pode ser negativa) tais como Exponencial ou Weibull. Porém, em muitos casos reais os dados obtidos são multimodais (dados que apresentam, por exemplo, dois picos acentuados) e atribuir uma distribuição teórica que represente devidamente estes dados torna-se uma tarefa mais complicada.

Uma noção importante a reter é que a inferência será feita no sentido de saber qual a perceção que os técnicos têm em relação ao sistema e como essa perceção\experiência pode ser integrada para futuras decisões.

Seguindo esta linha de pensamento, inferiu-se sobre o **tempo entre avarias** e não sobre a distribuição dessas mesmas avarias ao longo do período de operação dos GE's. Desta forma, conceptualmente, no final da análise obter-se-ão conclusões sobre o período de tempo mais suscetível de suceder entre duas avarias consecutivas para um futuro próximo do sistema, em função dos dados históricos de tempos entre avarias e dos dados percecionais dos indivíduos que operaram este mesmo sistema. Lembra-se que o questionário foi igualmente direcionado neste sentido (questão 6 obtém a perceção de cada inquirido em relação ao tempo estimado desde o presente até à próxima avaria).

Mantendo agora a atenção nos dados históricos e para perceber qual o modelo mais capaz de descrever estes tempos entre avarias procedeu-se ao estudo dos dados DSM 58 no *software RStudio*. Começou-se por fazer a transferência dos dados anteriormente tratados para o programa. O vetor mostrado a seguir, escrito em linguagem R, representa os tempos entre avarias (em dias), desde o início (25/08/2007) ao fim (13/04/2015) do período de teste para o Grupo Eletrogéneo 1 do N.R.P. VG, o que perfaz um total de 2788 dias de operação.

```
>tempoavarias<c(5,6,5,166,18,5,5,41,137,226,279,61,162,148,35,101,12,9  
2,90,145,17,20,6,2,5,69,85,36,7,88,24,29,17,8,300,35,11,3,  
17,25,7,49,3,109,31,6,14,12,8,2,4)
```

Fazendo uso dos diversos pacotes e funções disponíveis, escreveu-se o seguinte código:

```
> library(fitdistrplus)  
> library(logspline)  
> tempoavarias<c(5,6,5,166,18,5,5,41,137,226,279,61,162,148,35,101,12,2  
90,145,17,20,6,2,5,69,85,36,7,88,24,29,17,8,300,35,11,3,  
17,25,7,49,3,109,31,6,14,12,8,2,4)  
  
> tempoavariasbeta<-tempoavarias/max(tempoavarias)  
> descdist(tempoavarias, discrete = FALSE,boot=1000)  
> fit.norm <- fitdist(tempoavarias, "norm")  
> fit.beta <- fitdist(tempoavariasbeta,"beta",start=NULL,method="mme")  
> fit.weibull <- fitdist(tempoavarias,"weibull")  
> fit.gamma <- fitdist(tempoavarias,"gamma")  
  
> plot(fit.norm)  
> plot(fit.beta)  
> plot(fit.weibull)
```

```

> plot(fit.gamma)

> fit.beta$bic
> fit.weibull$bic
> fit.norm$bic
> fit.gamma$bic

```

A variável R “*tempoavarias*” é um vetor que representa os tempos entre cada avaria do total das 51 avarias registadas no GE1. A variável R “*tempoavariasbeta*” é outro vetor que representa igualmente os tempos de avarias, porém padronizado para uma distribuição Beta.

A primeira função utilizada foi a “*descdist()*” do pacote “*fitdistrplus*” que usa os dados em estudo e cria um gráfico “*Cullen and Frey*” que, através da comparação com uma distribuição normal, se torna uma ferramenta bastante útil para perceber, numa primeira fase, qual ou quais as melhores distribuições teóricas, de entre as várias possíveis, para o conjunto de dados em questão.

Gráfico Cullen and Frey

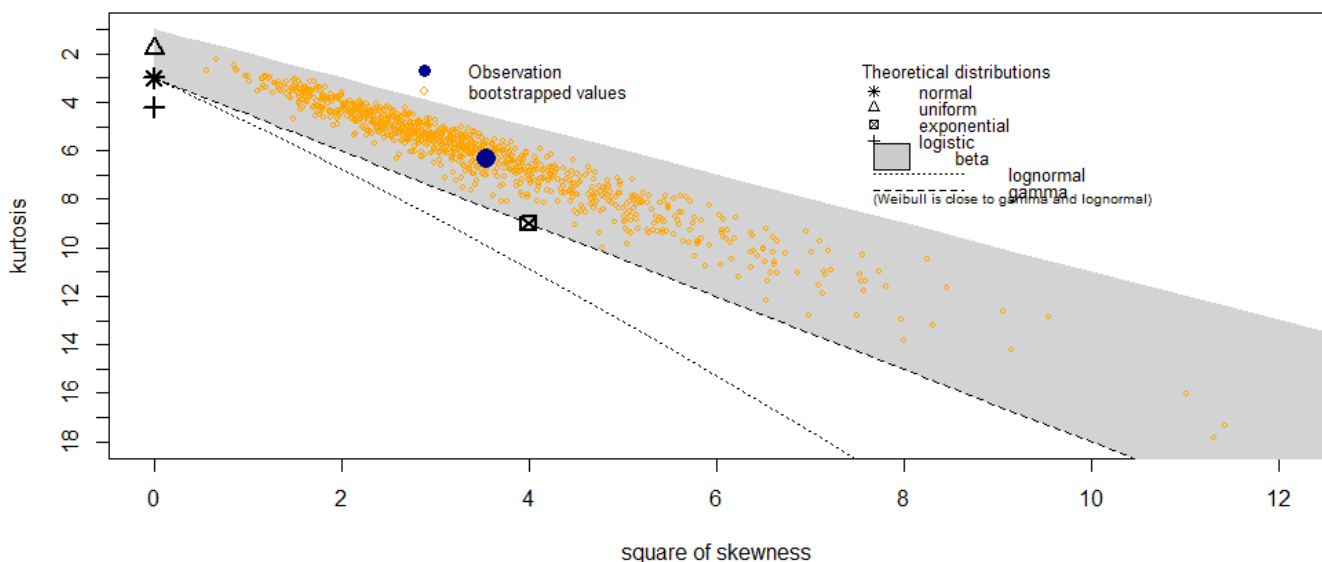


Figura 12: Gráfico Cullen and Frey demonstrando posição dos dados em relação a várias distribuições.

Analisando o gráfico observa-se que, de entre as várias distribuições teóricas, não existe nenhuma delas que represente os dados de tal forma significativa que nos leve a retirar conclusões definitivas. Porém, por observação, poderemos considerar que as distribuições Beta, Weibull e Gamma poderão ser representativas dos dados dos tempos entre avarias.

Desta feita, procedeu-se a uma análise mais profunda destas 3 distribuições candidatas a representar os dados. Usando a função "*fitdist()*" é possível fazer a modelação de uma distribuição teórica à escolha para o conjunto de dados pretendidos. Essa modelação é feita pelo método de estimação de máxima verossimilhança que, de uma forma genérica, estima os parâmetros da distribuição escolhida por forma a maximizar a probabilidade dos dados. Para um estudo mais aprofundado deste conceito aconselha-se a leitura de Muller (2015).

Decidiu-se também utilizar a distribuição Normal, embora não sendo uma das candidatas, para posteriormente servir como objeto de comparação na qualidade da modelação.

Começamos então por usar a distribuição Normal escrevendo as seguintes linhas de código:

```
> fit.norm <- fitdist(tempoavarias, "norm")  
> plot(fit.norm)
```

E obtendo desta forma os seguintes gráficos na figura 14.

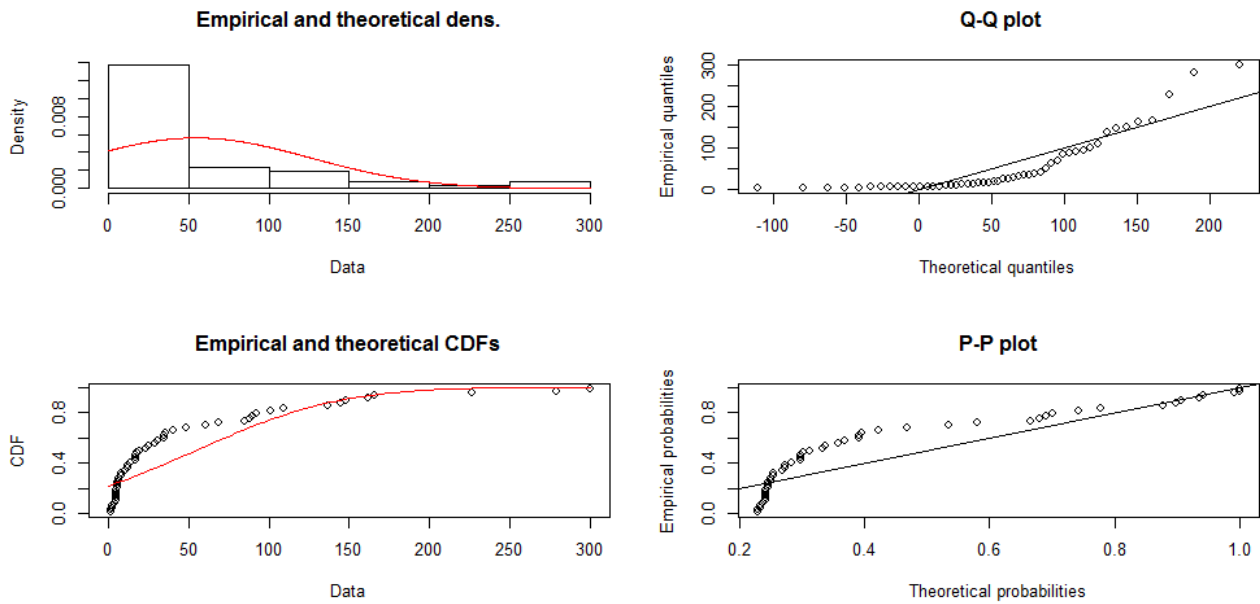


Figura 13: Distribuição Normal - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à direita)

Claramente, observando os 4 gráficos produzidos, se chega à conclusão de que os parâmetros de uma distribuição Normal não conseguem moldar-se às características dos dados apresentados. No gráfico superior esquerdo (Densidade empírica Vs Densidade teórica) a curva não representa certamente o conjunto de dados, e nos restantes 3 gráficos verifica-se claramente um afastamento muito significativo na tendência dos dados em relação às curvas e retas teóricas. A distribuição normal não representara um bom modelo.

Avançando para as 3 distribuições candidatas, vamos aplicar a mesma função para uma distribuição de Weibull:

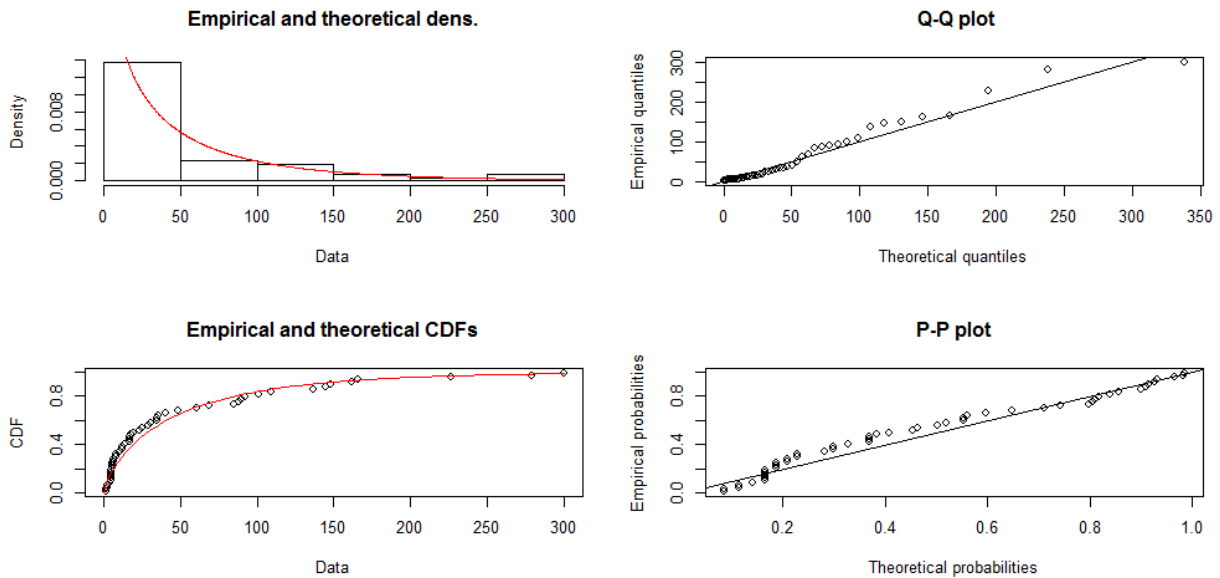


Figura 14: Distribuição de Weibull - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à esquerda); Probabilidades empíricas vs Probabilidades teóricas (em baixo, à direita).

Ao analisar estes 4 gráficos denota-se de imediato uma melhoria muito significativa na qualidade da modelação. No primeiro gráfico percebe-se que a curva teórica representa muito melhor os valores empíricos e nos restantes gráficos observa-se uma aproximação mais certa da curva aos pontos, embora com alguns desvios.

Passemos para a distribuição Gama. Aplicando novamente a função obtemos:

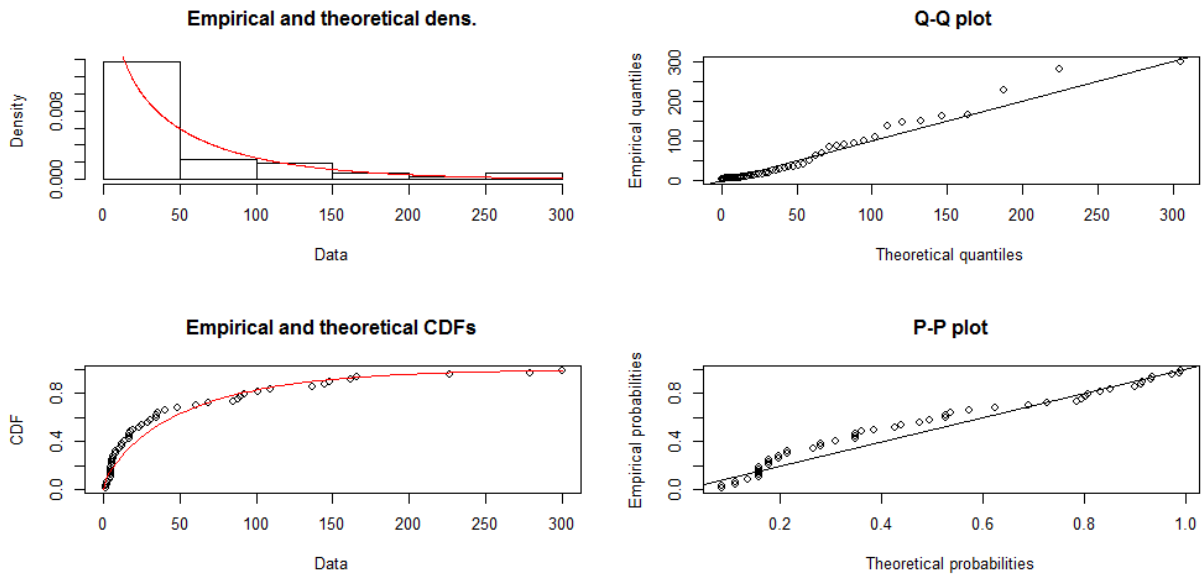


Figura 15: Distribuição Gama - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à esquerda); Probabilidades empíricas vs Probabilidades teóricas (em baixo, à direita).

A distribuição Gama apresenta-se como sendo uma distribuição bastante fiável e representativa dos dados empíricos, porém esta aproxima-se muito da distribuição de Weibull e este fato comprova-se também através da análise gráfica. Neste caso torna-se bastante difícil perceber visualmente qual das duas realmente representa melhor o conjunto de dados e neste seguimento procedeu-se a um outro teste disponível nos pacotes estatísticos do software RStudio.

As últimas linhas de código apresentadas no programa referido anteriormente desencadeiam o chamado *Bayesian information criterion* (BIC), um teste usado frequentemente em ambiente R para comparar modelos gerados por máxima verossimilhança e auxiliar na sua seleção.

Quando aplicado com diversas distribuições ao mesmo conjunto de dados, o menor valor do fator BIC produzido indica a distribuição que melhor se adequa aos dados em questão.

Desta forma calcula-se o fator BIC,

```
> fit.weibull$bic
[1]511.1552
> fit.Gamma$bic
[1]512.8926
```

e, atendendo a estes valores, conclui-se que o modelo utilizando a distribuição de Weibull representa melhor os dados, embora que muito tenuemente, em detrimento do modelo utilizando a distribuição Gama.

Por último, procedeu-se à modelação seguindo uma distribuição Beta, obtendo os seguintes gráficos:

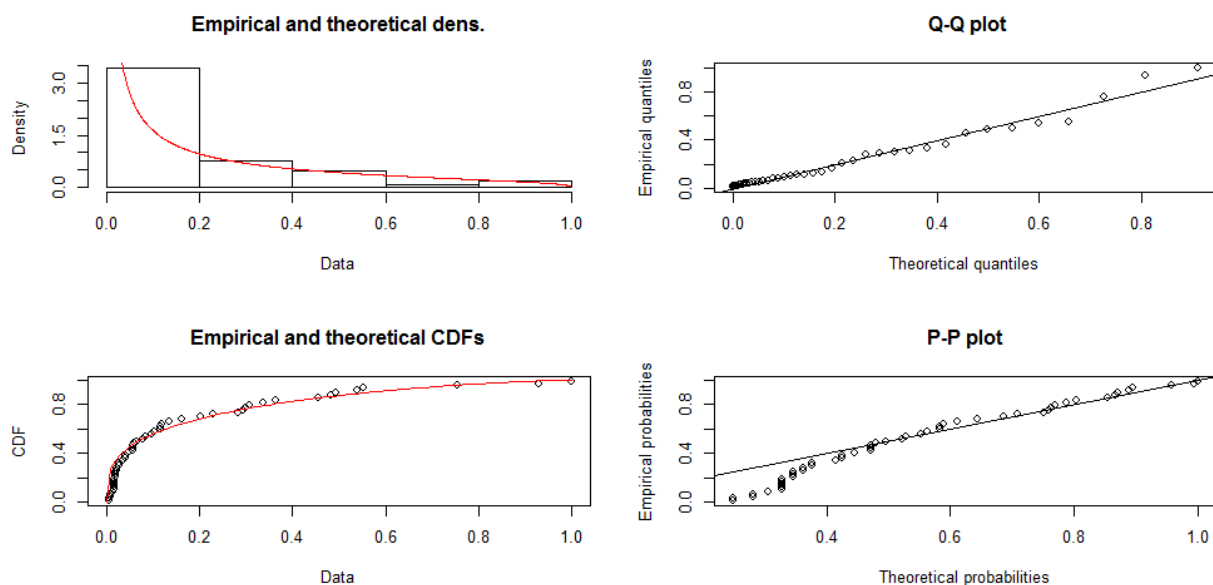


Figura 16: Distribuição Beta - Densidade empírica vs Densidade teórica (em cima, à esquerda); Quantis empíricos vs Quantis teóricos (em cima, à direita); função de Distribuição Acumulada dos dados empíricos vs Função de Distribuição Acumulada teórica (em baixo, à esquerda); Probabilidades empíricas vs Probabilidades teóricas (em baixo, à direita).

Observando os gráficos produzidos, pode afirmar-se que a distribuição beta representa grande parte dos dados com grande exatidão contudo, nas extremidades apresenta um grande desvio o que não se torna num aspeto favorável. Para reforçar esta assunção procedeu-se igualmente ao cálculo do

ator BIC para o modelo Beta,

```
> fit.beta$bic  
[1] Inf
```

obtendo-se o resultado "Inf" que significa infinito, obviamente superior ao valor de BIC obtido para o modelo de Weibull.

Tendo em conta estes resultados assumir-se-á que, de entre as várias distribuições disponíveis, Weibull é a que melhor se adequa ao conjunto de dados de tempos entre avarias.

Como complemento a esta análise, pode-se determinar os parâmetros da distribuição para que desta forma seja possível traçar os gráficos correspondentes. Assim, ter-se-á uma perceção visual dos tempos entre avarias relativos ao GE1 segundo esta distribuição. O método utilizado na estimação dos parâmetros é o método de máxima verossimilhança.

```
> tempoentreavarias<-c(5,6,5,166,18,5,5,41,137,226,279,61,162,148,35,101  
,12,92,90,145,17,20,6,2,5,69,85,36,7,88,24,29,17,8,300,35,11,3,17,25,7,49,3  
,109,31,6,14,12,8,2,4)  
  
> avaria<-c(1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18,19,20,21,22,23,24,  
25,26,27,28,29,30,31,32,33,34,35,36,37,38,39,40,41,42,43,44,45,46,47,48,4  
9,50,51)  
  
> fitdistr(tempoentreavarias, densfun="weibull",lower = 0.0001)  
  shape      scale  
 0.7693047 46.2299819  
( 0.0822281) ( 8.9202826)  
  
> fdp<-dweibull(tempoentreavarias, shape=0.769, scale = 46.22, log = T)  
  
> fda<-pweibull(tempoentreavarias, shape=0.769, scale = 46.22, lower.tail  
= TRUE, log.p = FALSE)  
  
> plot(fdp~ tempoentreavarias)  
  
> plot(fda~ tempoentreavarias)
```

O vetor "tempoentreavarias" representa os tempos entre avarias consecutivas durante o período de operação do GE1 (2788 dias). O vetor "avaria" representa os números das avarias. Usando o primeiro vetor, aplicou-se a função "fitdistr()" para estimar os valores dos parâmetros de Weibull por máxima verossimilhança para o conjunto de dados em questão, obtendo-se os seguintes valores para os parâmetros

- $\beta=0.769$, parâmetros forma
- $\lambda=46.22$, parâmetro de escala

Calculou-se os valores da função de densidade de probabilidade (fdp) usando "dWeibull()" e os valores da função de distribuição acumulada (fda) usando "pweibull()". Por último, desenhou-se os gráficos das duas funções usando a funcionalidade "plot()".

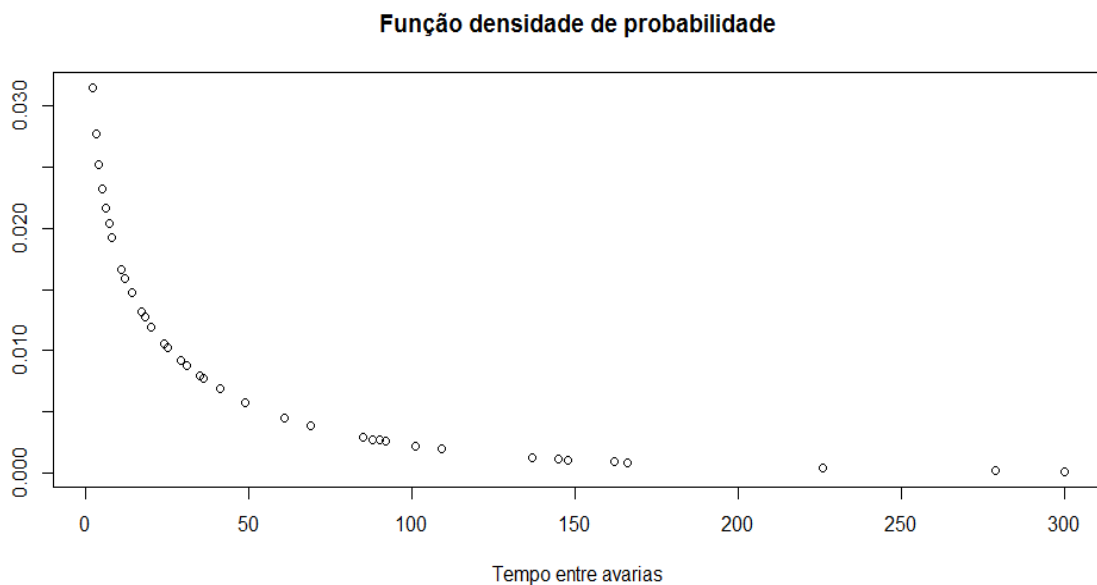


Figura 17: Função Densidade de Probabilidade (fdp) de weibull para o conjunto de dados (dias), com parâmetros $\beta= 0.769$ e $\lambda= 46.22$

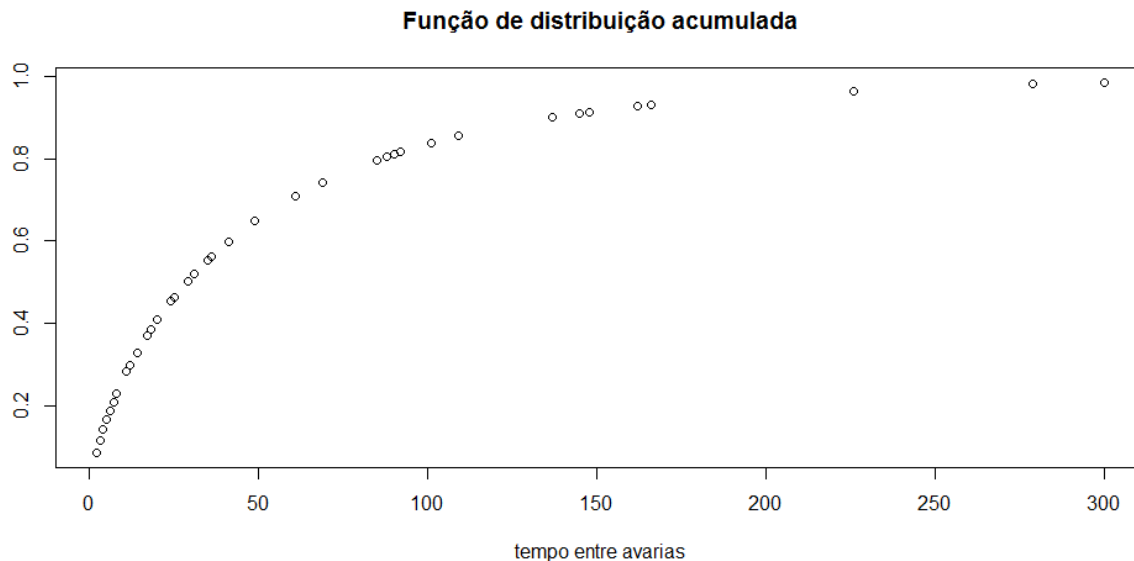


Figura 18: Função Distribuição Acumulada (fda) de weibull para o conjunto de dados (dias), com parâmetros $\beta= 0.769$ e $\lambda= 46.22$

Verifica-se através da observação destes dois gráficos que a grande maioria dos tempos entre avarias está compreendida no intervalo de 0 a 100 dias.

Usando a função "`qqplot()`" do mesmo pacote traçou-se um gráfico de quantis acrescentando os limites (linhas a tracejado) para um intervalo de confiança de 95%. A seguir mostra-se a linha de código,

```
> qqPlot(tempoentreavarias, distribution="weibull", shape
=0.769, scale=46.22,main="Gráfico de quantis",xlab="Quant
is de weibull",ylab="Dados avarias")
```

e o gráfico em questão, onde se verifica que maioritariamente todos os valores se encontram dentro do intervalo e que seguem a linha de tendência central, embora com alguns desvios. Assume-se que, apesar de não ser perfeito, o modelo representa com bastante confiança os dados.

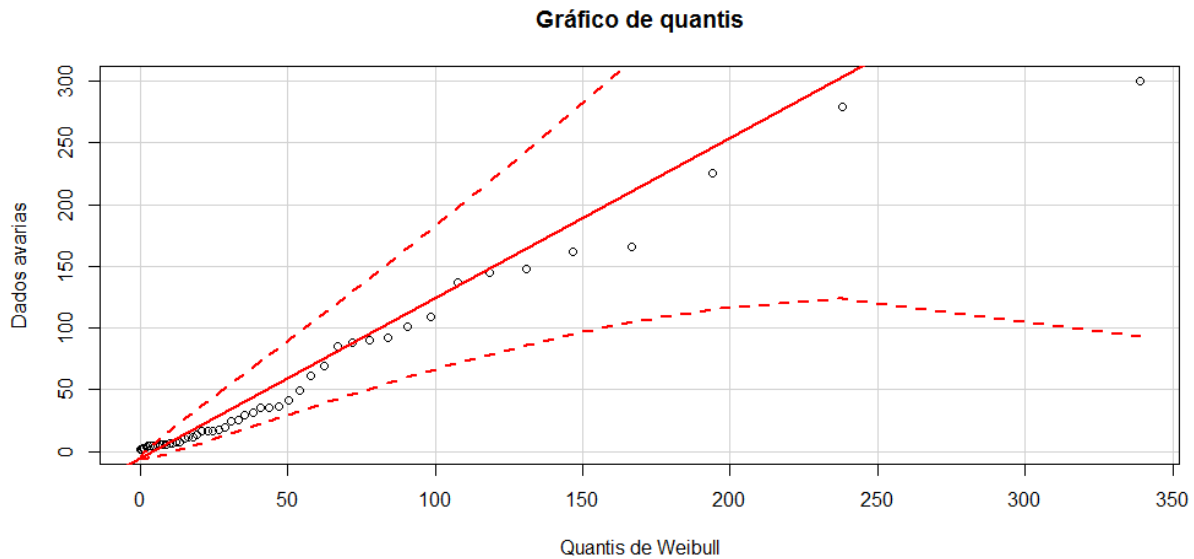


Figura 19: Gráfico de quantis para o modelo de Weibull com intervalo de confiança 95%

Muitas vezes uma distribuição teórica, dita *standard*, não consegue representar os dados de forma aceitável e é possível ajustar outras distribuições usando, por exemplo, o método *Power Law Process* (que pode ser visto em SEMATECH (2015)) no entanto nesta dissertação, considerando a modelação anterior, aceita-se a distribuição teórica como sendo suficientemente representativa do conhecimento empírico.

5.2. Função de Verossimilhança

Pode dizer-se que um primeiro passo em qualquer procedimento de inferência Bayesiana envolve o desenvolvimento da função de Verossimilhança.

Através do estudo na secção anterior garantiu-se que a distribuição de Weibull com dois parâmetros é na realidade o modelo estatístico mais indicado para descrever o comportamento das falhas, de entre as distribuições teóricas consideradas, e portanto a função de verossimilhança que representa a evidência relativamente ao GE1 pode ser modelada por uma distribuição de Weibull, $T \sim \text{Weibull}(\theta)$ onde T = tempo entre avarias consecutivas, θ é o vetor de

parâmetros para esta distribuição com λ =parâmetro de escala e β =parâmetro de forma e a sua função densidade de probabilidade é dada por:

$$f(t) = \frac{\beta}{\lambda} \left(\frac{t}{\lambda}\right)^{\beta-1} e^{-\left(\frac{t}{\lambda}\right)^\beta} \text{ com } t = 1,2,3, \dots$$

Desta forma, pode denotar-se a função de verossimilhança como

$$L(\theta) = \prod_1^n f(\theta, t) \quad (11)$$

onde o argumento da função θ é o vetor de parâmetros de interesse e n o número de ocorrências registadas.

5.3.Tradução dos parâmetros do modelo em distribuições à priori

Tendo a função de verossimilhança definida para os dados empíricos o próximo passo centra-se na informação do questionário. O objetivo desta secção é demonstrar a metodologia usada no processo de atribuição de distribuições *à priori* para o vetor de parâmetros de interesse do modelo escolhido, tendo como base a informação da experiência pessoal dos técnicos da Marinha Portuguesa, representativa da crença sobre o comportamento dos GE's.

Os dados obtidos através do questionário mostram tempos entre avarias consecutivas segundo a perceção dos inquiridos. Visto que os Grupos eletrogéneos são iguais em todos os navios desta classe, para esta investigação considera-se que a informação fornecida pelos inquiridos de um determinado navio é transversal aos restantes dois, ou seja, as *prioris* definidas para o GE1, GE2, GE3 e GE4 dos Navios VG,AC e CR vão beber informação ao mesmo vetor de dados resultante da questão 6 do questionário e que se apresenta a seguir:

infopriorinavios<-c(30,30,30,180,30,60,30,30,180,180,60,30,180,90,30,90,15,15,30,15,30,30,30,30,15,30,180,180,360,180,90,180)

Para que esta informação possa ser cruzada com a informação dos registos históricos é necessário traduzi-la em distribuições sobre os parâmetros β e λ do modelo Weibull.

Atendendo que as unidades do vetor acima apresentado (tempo entre avarias consecutivas) são as mesmas do parâmetro de escala λ (tempo característico entre avarias consecutivas) do modelo Weibull e atendendo que segundo o Teorema do Limite Central uma amostra superior a 30 poderá ser representada por uma distribuição Normal, atribuiu-se para a *priori* informativa sobre o parâmetro λ esta mesma distribuição estatística. Assim sendo, temos para o parâmetro de escala a *priori* conjugada com média e desvio-padrão desconhecidos:

$$[\lambda] \sim Normal(\mu, \sigma)$$

Para o parâmetro de forma β , visto este ser adimensional e os dados do questionário não fornecerem informação diretamente relevante sobre o mesmo, considerou-se uma *priori* não informativa resultando em,

$$[\beta] = Unif(a, b)$$

5.3.1. Priori sobre o parâmetro β

Considerando a distribuição Uniforme sobre estes parâmetros, torna-se necessário obter os parâmetros a e b , ou seja, os hiper-parâmetros. Visto que se pretende que a distribuição seja não informativa, é necessário obter um intervalo suficientemente vago para a distribuição mas que contenha todos os valores possíveis para o parâmetro.

Ajustando através do método de máxima verossimilhança uma distribuição de Weibull a cada um dos dois conjuntos de dados obtém-se os valores de $\beta_1=0.77$ para os dados observacionais e $\beta_2=1.10$ para os dados do questionário. Consideram-se estes valores como os limites inferior e superior para a

distribuição uniforme sobre o parâmetro de forma do modelo Weibull. Assim a *priori* não informativa fica,

$$[\beta] = Unif(0.77,1.10)$$

Foram também feitos alguns testes de tentativa e erro no WinBUGS antes de proceder às simulações, por forma a confirmar esta assunção.




Figura 20: Histogramas da informação à priori (vermelho) e dos dados do GE1 (azul) sobrepostos

5.3.2. Priori sobre o parâmetro λ

Como referido anteriormente, para este parâmetro considerou-se uma distribuição normal. Os parâmetros μ e σ desta distribuição deverão ser estimados tendo em conta o conhecimento transmitido pelos inquiridos. Para tal, foi necessário considerar vários patamares de hiper-parâmetros e para melhor perceção apresenta-se o seguinte esquema hierárquico.

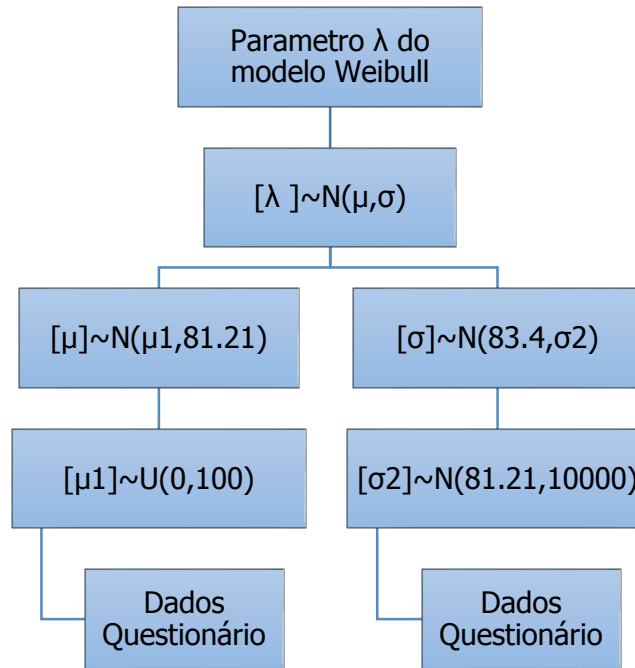


Figura 21: Esquema hierárquico para obtenção da priori do parâmetro de escala

A ideia geral é ir descendo na hierarquia de tal forma que a *posteriori* de um nível inferior seja a *priori* do nível superior imediatamente a seguir. Atribuir-se-ão os níveis necessários até chegar ao nível mais inferior onde seja possível as *prioris* serem não informativas permitindo assim recolher a informação proveniente do vetor dos dados percecionais.

Com a conclusão deste processo é possível verificar que, o vetor de parâmetros de interesse $\theta=(\beta,\lambda)$ passa a ser $\theta=(\beta,\mu,\sigma,\mu1,\sigma2)$. As *posterioris* serão obtidas para este novo vetor de parâmetros e desta forma ter-se-á o modelo Weibull à *posteriori* com os parâmetros de interesse atualizados e totalmente definido.

5.4.Distribuição à Posteriori

Tendo a função de verossimilhança e as distribuições à priori definidos o passo seguinte é obter a distribuição à *posteriori* dos parâmetros. Para tal, é empregue o método Markov Chain Monte Carlo (MCMC) mais especificamente o algoritmo Metropolis – Hastings. Aconselha-se a leitura de Geyer (1992) e Brooks (1998), para maiores detalhes sobre a metodologia MCMC.

Usando o *software WinBUGS* escreveu-se um modelo por forma a obter as densidades do vetor de parâmetros de interesse.

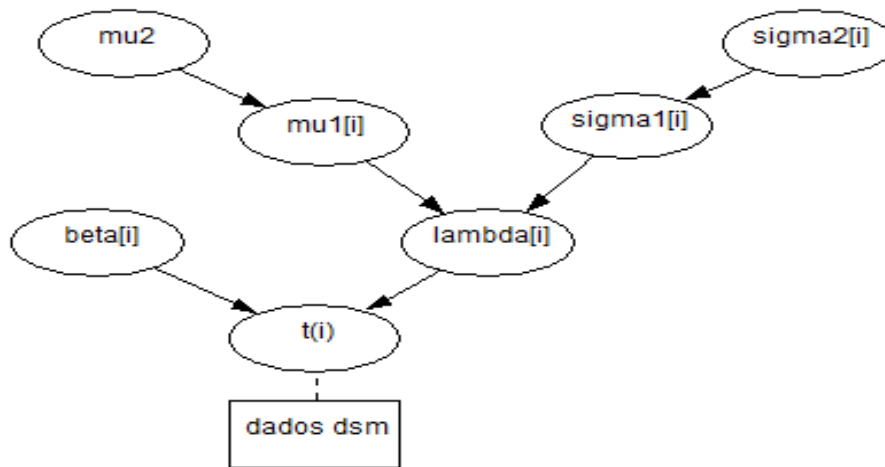


Figura 22: Modelo WinBUGS para o caso em estudo

Partindo deste modelo escreveu-se o código que se encontra em apêndice D e procedeu-se às simulações necessárias. Realizaram-se 11 000 iterações para cada parâmetro sendo que as primeiras 1000 foram descartadas para evitar o efeito dos valores iniciais sobre a cadeia (*Burn-in*).

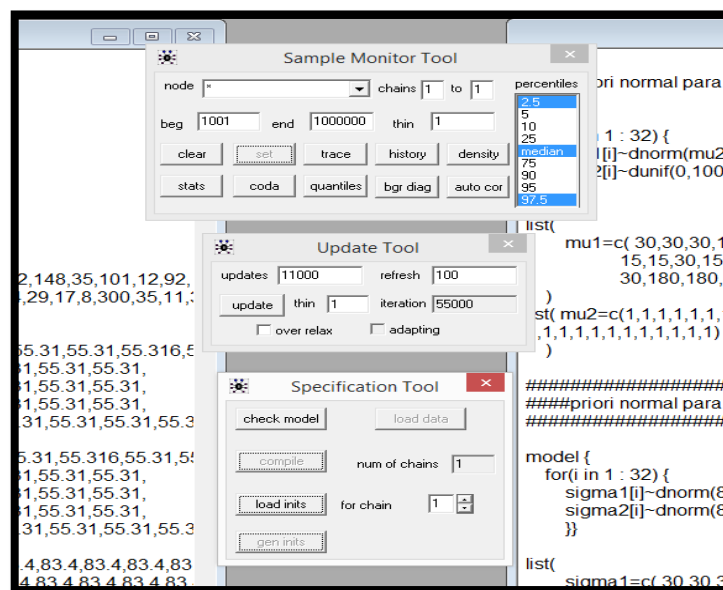


Figura 23: Ambiente WinBUGS mostrando as 3 ferramentas básicas para efetuar simulações

Capítulo 6 – Resultados e discussão

Neste capítulo numa primeira fase pretende-se demonstrar os resultados obtidos, através das simulações, para o GE1 do N.R.P. VG.

Posteriormente realiza-se a generalização para os restantes Grupos eletrogéneos, tendo em conta que a metodologia adotada para o GE1 pode ser generalizada aos restantes, com os devidos ajustes próprios de cada um. Estes ajustes não serão apresentados detalhadamente.

Numa terceira e última secção, este capítulo dedicar-se-á á proposta de uma metodologia para a integração desta abordagem na Marinha Portuguesa tendo em conta os conhecimentos adquiridos com esta investigação.

6.1.Resultados GE1, N.R.P. VG

Os resultados para a simulação MCMC dos parâmetros do modelo Weibull encontram-se tabelados em apêndice E e foram resumidos na seguinte tabela.

Parâmetro	Valor médio à posteriori
μ_2	55.31
σ_2	80.88
μ_1	55.0745
σ_1	83.3998
β	0.7798
λ	54.8449

Figura 24: Tabela resumo dos valores dos parâmetros

Nos seguintes gráficos é possível observar as densidades à *posteriori* para os parâmetros de interesse resultantes das simulações efetuadas.




Figura 25: Gráfico de densidade para o parâmetro beta (forma)




Figura 26: Gráfico de densidade para o parâmetro lambda (escala ou tempo característico)

Os valores de β e λ obtidos são os valores dos parâmetros à posteriori para uma distribuição de Weibull, ou seja, são os parâmetros da verossimilhança adotada atualizados com a informação à priori recolhida nos questionários. Esta nova distribuição representa o conhecimento que é possível obter em relação ao GE1 se aos seus dados históricos acrescentarmos a percepção dos técnicos responsáveis pela sua operação/manutenção.

Observa-se que o parâmetro de forma é bastante similar ao da verossimilhança, o que era espectável á partida, uma vez que a *priori* adotada para este parâmetro foi não informativa e que resultou num peso muito grande da verossimilhança em relação á priori.

O parâmetro de escala sofreu uma atualização significativa, sendo que o tempo característico entre avarias consecutivas aumentou consideravelmente após a inserção da percepção dos técnicos. Este facto deve-se inteiramente à priori adotada para este parâmetro que, sendo informativa, inseriu as crenças existentes à priori no processo de inferência.

Usando os valores dos parâmetros obtidos é possível traçar estimativas em relação á variável de interesse Tempo entre avarias consecutivas para o estado atual do sistema. Estas estimativas poderão ser consideradas na tomada de decisão para o processo de manutenção num futuro próximo de operação do GE1.

Retome-se o teste de Laplace e o estudo gráfico da tendência das avarias efetuado na seção 4.3.2.1 do capítulo 4 em relação ao GE1 onde se concluiu que a taxa de avarias é crescente e que este Grupo eletrogéneo se encontra na fase de desgaste. Por esta razão, é esperado que, à medida que o tempo passe, num futuro próximo de operação deste equipamento, o tempo entre avarias consecutivas seja cada vez menor.

Poder-se-ia facilmente calcular a probabilidade deste grupo eletrogéneo operar sem avarias nos próximos, digamos, 50 dias utilizando as informações de registo do DSM58.

Porém, uma vez que foi realizada a inferência Bayesiana onde se incluiu informação à *priori* sobre o equipamento, e tendo em conta que foi obtida uma distribuição à posteriori que contém mais informação que esses registos, é lógico usar esta última para obter as devidas estimativas.

Considere-se que se pretende saber qual a probabilidade de nos próximos 10 dias o GE1 operar interruptamente. Usando o seguinte código R é possível saber esse valor.

```
> weibpost<-1-pweibull(10,0.7798,54.8449)
> weibpost
[1] 0.76703
```

Existe, portanto, 76.7% de probabilidade de nos próximos 10 dias, tendo em conta o estado atual do equipamento, o GE1 operar sem ter nenhum tipo de ocorrência do tipo corretivo.

Considere-se agora que se pretende saber a mesma probabilidade para 30 dias (sensivelmente um mês). A probabilidade será de 53.5%, ou seja, menor que a anterior o que é obviamente espectável tendo em consideração que o equipamento se encontra em fase de desgaste.

Assim, seguindo este raciocínio, consideraram-se vários intervalos de tempo e calculou-se a probabilidade de o GE1 operar interruptamente nesses intervalos. Usou-se para tal o seguinte código R:

```
> t<-c(1,7,15,30,60,90,110,140,170,200,230,260,290,320,350,365)
> weibpost<-1-pweibull(t,0.7798,54.8449)
> plot(weibpost~t)
```

O vetor t representa vários tempos de operação interrompida e a variável "weibpost" calcula a probabilidade à *posteriori* para esse vetor segundo a distribuição de Weibull à *posteriori* obtida. A funcionalidade "plot()" permite traçar o gráfico dos resultados. A seguir mostra-se o gráfico e a tabela com os resultados obtidos.

Probabilidade à posteriori para vários intervalos de tempo entre avarias




Figura 27: Probabilidades à posteriori para vários intervalos de tempo de operação sem registrar avarias (em dias)

Tempo OP (dias)	Probabilidade	Tempo OP (dias)	Probabilidade	Tempo OP (dias)	Probabilidade
1	0.957	110	0.179	290	0.026
7	0.818	140	0.125	320	0.019
15	0.695	170	0.089	350	0.014
30	0.535	200	0.064	365	0.012
60	0.342	230	0.047		
90	0.230	260	0.035		

Figura 28: Probabilidades para os diferentes tempos de operação ininterrupta

Analisando a tendência dada pelo gráfico e os valores tabelados torna-se perceptível que a partir de um intervalo de tempo de 30 dias, as probabilidades começam a ser bastante reduzidas. Segundo a estimativa à *posteriori* pode afirmar-se que é bastante provável que o GE1 opere sem problemas até sensivelmente um mês de funcionamento constante. Já para intervalos de tempo superiores a probabilidade de não suceder nenhuma ocorrência é bastante reduzida. Para tal basta observar, por exemplo, a probabilidade para 90 dias de operação que corresponde a aproximadamente 23%. É realmente improvável que este GE opere neste período de tempo de forma consecutiva sem apresentar nenhum tipo de avaria corretiva.

6.2. Resultados N.R.P. VG, AC e CR

Nesta secção apresenta-se os resultados para os 3 navios da classe. A metodologia seguida é a generalização da anteriormente apresentada para o GE1 do N.R.P VG, porém aplicada aos 4 GE's em simultâneo para cada navio.

Não se fez qualquer estudo em relação à distribuição teórica que melhor representa os dados históricos, no entanto considera-se que a verossimilhança é igualmente representada por uma distribuição de Weibull dois parâmetros, por ser uma distribuição amplamente utilizada na modelação de fenómenos de avarias em equipamentos mecânicos, e pela semelhança que a distribuição das avarias dos 3 navios apresentam em relação às do GE1.

O código usado para as simulações MCMC na obtenção das distribuições à *posteriori* é o mesmo utilizado para o caso do GE1, com as devidas alterações específicas de cada navio.

Relembra-se que, nesta investigação, o conhecimento à priori se considera comum a todos os navios e portanto as *prioris* serão as mesmas.

A seguir apresentam-se os resultados para os dois parâmetros de interesse, na análise feita aos três navios.

Navio	Parâmetro β	Parâmetro λ
VG	<i>0.7745</i>	<i>54.7044</i>
AC	<i>0.7840</i>	<i>32.0715</i>
CR	<i>0.7815</i>	<i>61.963</i>

Figura 29: Tabela resumo dos parâmetros estimados via MCMC para os 3 navios

Tempo OP (dias)	Probabilidade			Tempo OP (dias)	Probabilidade			Tempo OP (dias)	Probabilidade		
	VG	AC	CR		VG	AC	CR		VG	AC	CR
1	0.956	0.934	0.961	110	0.179	0.075	0.209	290	0.026	0.004	0.035
7	0.816	0.735	0.834	140	0.126	0.044	0.151	320	0.019	0.003	0.027
15	0.693	0.574	0.719	170	0.090	0.026	0.111	350	0.014	0.002	0.021
30	0.534	0.387	0.567	200	0.065	0.016	0.082	365	0.013	0.001	0.018
60	0.342	0.197	0.377	230	0.048	0.010	0.062				
90	0.230	0.108	0.262	260	0.035	0.006	0.047				

Figura 30: Tabela resumo das probabilidades para os diferentes tempos de operação ininterrupta

Observa-se que os três navios apresentam um padrão semelhante, sendo que o N.R.P. CR demonstra ser o navio com maior capacidade de operar os seus grupos eletrogêneos durante mais tempo sem obter ocorrências corretivas. Pelo contrário, o N.R.P. AC aparenta ser o navio em piores condições, destacando-se negativamente dos outros dois.

No entanto, apesar das diferenças, todos os navios aparentam encontrar-se num nível relativamente baixo de fiabilidade uma vez que apresentam probabilidades extremamente baixas para períodos de operação superiores a sensivelmente 60 dias, o que pode ser bastante limitativo considerando o âmbito e duração típicos das missões efetuadas por esta classe de navios.

6.3.Proposta de metodologia

Tendo em conta os resultados obtidos com o uso da Inferência Bayesiana em relação aos grupos eletrogéneos dos navios da classe *Vasco da Gama*, propõe-se a seguinte metodologia de aplicação desta abordagem aos vários equipamentos mecânicos de bordo:

1. Criar questionários específicos para cada área técnica de bordo;
2. Em cada área técnica direcionar o questionário em várias secções para os diversos equipamentos existentes com máximo de pormenor possível sobre cada sistema ou componente;
3. Aplicar este questionário a cada militar da área, aquando da sua saída de bordo, no final da comissão;
4. Registrar esse conhecimento numa base de dados de registo da experiência individual dos técnicos;
5. Cruzar essa base de dados com a já existente relativamente aos dados do SICALN;
6. Aplicar a metodologia Bayesiana e retirar as devidas conclusões;
7. Iterar o processo para cada técnico ou grupo de técnicos que apresentem o seu conhecimento.

Conclusão

A experiência de cada técnico pode ser incluída no processo de previsão de avarias e tomada de decisão na aquisição de sobresselentes.

A perceção dos técnicos em relação ao tempo de vida útil entre avarias consecutivas é consideravelmente boa embora que otimista em relação á realidade observada nos últimos 8 anos de operação dos grupos eletrogéneos estudados.

É possível adotar esta metodologia a outros equipamentos mecânicos existentes a bordo, bastando para tal fazer as alterações necessárias intrínsecas a cada equipamento.

Existe a possibilidade de adotar esta metodologia aquando da aquisição de um novo equipamento. Normalmente, nesta fase existe pouca informação histórica sobre o seu comportamento e usando esta abordagem é possível retirar ilações significativas, bastando para isso obter a experiência adquirida por outros técnicos de outras instituições com o mesmo equipamento ou equipamentos semelhantes.

Esta metodologia permite que o conhecimento adquirido pelos profissionais não seja perdido e fique registado sendo constantemente atualizado e tornando-se numa fonte de informação com verdadeiro valor acrescentado para a instituição Marinha.

Os *softwares* requeridos para a aplicação desta abordagem são de alta qualidade e reconhecidos a nível mundial nas mais prestigiadas universidades. São grátis e extremamente bem documentados, não havendo necessidade de adquirir outros com licenças de utilização de preços elevados.

Bibliografia

- Aaker, D. A. (2001). The Value Relevance of Brand Attitude in HighTechnology. *Journal of Marketing Research*, 485-493.
- Andrew Gelman, J. B. (2003). *Bayesian Data Analysis*. Chapman and Hall.
- Approximate Bayesian computation via regression density estimation . (2012). *The ISI's Journal for the Rapid Dissemination of Statistics Research*, 1-15.
- Asher, H., & Feigold, H. (1984). *Reparable Systems Reliability - Modeling Inference, Misconceptions and their causes*. New York: Marcel Dekker Inc.
- B. C. Carlin, T. A. (1996). *Bayes and Empirical Bayes Methods for Data Analysis*. Londres: Chapman & Hall.
- Bernardo, J. M. (1981). *Bioestadística, una perspectiva Bayesiana*. Barcelona: Instar S.A.
- BERNARDO, J. M. (1997). A Decision Analysis Approach to Multiple-Choice Examinations. *International Workshop on Decision Analysis Applications*. Madrid: Royal Academy of Sciences.
- Bernardo, J. M. (2005). Intrinsic credible regions: an objective bayesian approach to interval estimation. Valencia: Sociedad de estadística e investigación operativa.
- Bernardo, J. M. (s.d.). *BAYESIAN STATISTICS* . Valencia: Departamento de Estadística, Facultad de Matemáticas.
- Brooks, S. P. (1998). Markov Chain Monte Carlo Method and Its Application. *Journal of the Royal Statistical Society. Series D (The Statistician)*, 69-100.
- Brooks, S. P. (1998). Markov Chain Monte Carlo Method and Its Application. *Journal of the Royal Statistical Society. Series D (The Statistician)*, 69-100.
- Chambers, J. (2008). *Software for Data Analysis*. NY: Springer.

- DORP, R. V., & MAZZUCHI, T. A. (2000). *SOLVING FOR THE PARAMETERS OF A BETA DISTRIBUTION*. Washington, DC: The George Washington University.
- Duda, R., & Hart, P. (2001). *Pattern Classification*. Canada: John Wiley and Sons.
- FAVORETTI, A. d. (1995). *Estimativas de parâmetros genético de características múltiplas através do método simples de Henderson*. Brasília: Pesquisa Agropecuária Brasileira.
- Gamerman, D., & Gamerman, D. (2006). *Markov Chain Monte Carlo: Stochastic Simulation for Bayesian Inference*. New York: Chapman and Hall.
- Geman, S., & Geman, D. (1984). *Stochastic Relaxation, Gibbs distribution and the Bayesian restoration of images*. IEEE.
- Geyer, C. (1992). *Practical markov chain monte carlo*. statistical science.
- Hastings, W. K. (1970). *Monte Carlo Sampling Methods Using Markov Chains and Their Applications*. Toronto: STOR.
- Hinkley, B. E. (1978). *Assessing the Accuracy of the Maximum Likelihood Estimator: Observed Versus Expected*. Reino Unido: Biometrika.
- Kypraios, T. (2015). *Introduction to Bayesian Statistics (And some computational methods)*. Obtido de maths: <http://www.maths.nott.ac.uk/~tk>
- Leitão, A., & Prudência, M. (1999). *Predição de Falhas no Apoio à Decisão na Gestão da Manutenção*. Bragança: Instituto Politécnico de Bragança.
- López, F. O. (2013). A Bayesian Approach to Parameter Estimation in Simplex Regression Model: A Comparison with Beta Regression. *Revista Colombiana de Estadística*, 1-21.
- Lynch, S. M. (2012). *Introduction to Applied Bayesian Statistics and Estimation for Social Scientists*. NY: Springer.

- Mense, B. A. (2012). *Bayesian Statistics Applied to Reliability Analysis and Prediction*. Tucson: Raytheon Missile Systems.
- Migon , H. S., & Gamerman, D. (1999). *Statistical Inference: An Integrated Approach*. John Wiley & Sons, Ltd.
- Moura, M., & Droguett, E. (2005). *Inferência Bayesiana para estimação da taxa de falha de bombas de*. Porto Alegre: ENEGEP.
- Muller, A. (2008). *Simulação estocástica e método Monte carlo*. Curitiba.
- Muller, M. L. (2015). *An R Package for Fitting Distributions*. Obtido de cran.r-project: <https://cran.r-project.org/web/packages/fitdistrplus/vignettes/paper2JSS.pdf>
- Nicolai, R. (2008). *Maintenance models for systems subject to measurable deterioration*. Amsterdão: Rozenberg Publishers.
- O´Connor, P. (1995). *Practical Reliability Engineering*. Jonh Wiley and Sons.
- Parlar. (1991). *Maintenance models for systems subject to measurable deterioration*. Valkenburg: Crasborn Graphic.
- Paul Blomstedta, R. G. (2014). Bayesianpredictivemodelingandcomparison ofoilsamples. *J.Chemometrics*, 52-59.
- Portal Action. (2015). *ANÁLISE DO TEMPO DE FALHA*. Obtido de Portal Action: <http://www.portalaction.com.br/confiabilidade/analise-do-tempo-de-falha>
- R Development Core Team. (2015). *R: A language and environment for statistical computing*. Obtido de R-project: <http://www.R-project.org/>.
- Resende, M. V. (2000). *INFERÊNCIA BAYESIANA E SIMULAÇÃO ESTOCÁSTICA (AMOSTRAGEM DE GIBBS) NA ESTIMAÇÃO DE COMPONENTES DE VARIÂNCIA E DE VALORES GENÉTICOS EM PLANTAS PERENES*. Colombo: Gráfica Radial.


- Ribas, A. (2015). *Um exemplo do algoritmo de Metropolis–Hastings aplicado a distribuição binomial*. Obtido de Recologia: <http://recologia.com.br/2013/08/um-exemplo-do-algoritmo-de-metropolis-hastings-aplicado-a-distribuicao-binomial/>
- Robin Nicolai, R. D. (2008). *Optimal Maintenance of Multi-component Systems: A Review*. Londres: Springer.
- SEMATECH, N. (2015). *NHPP Power Law*. Obtido de Engineering Statistics Handbook: <http://www.itl.nist.gov/div898/handbook/index.htm>
- Silva, R. d., & Mattos, N. (2002). *INFERÊNCIA BAYESIANA VIA SIMULAÇÃO ESTOCÁSTICA COM IMPLEMENTAÇÃO NO PROGRAMA WINBUGS*. Rio de Janeiro: SBPO.
- Silver, E. A., & Fiechter, C. N. (1995). Preventive maintenance with limited historical data. *EUROPEAN JOURNAL OF OPERATIONAL RESEARCH*, 125-144.
- Spiegelhalter, D., & et al. (2000). *WinBUGS – A Bayesian modelling*. London.
- Teixeira, P. S. (2010). *Modelação da Fiabilidade dos Geradores das Fragatas da Classe Vasco da Gama*. Lisboa: FCT.
- Vassilis Katsouros, V. P. (2013). A Bayesian Approach for Maintenance Action Recommendation . *International journal of prognostics and health managment*.
- Yildirim, I. (2012). *Bayesian Inference: Metropolis-Hastings Sampling*. New York: Department of Brain and Cognitive Sciences.
- Zellner, A. (1997). Chicago: University of Chicago.

Apêndices


- Apêndice A – Teste Laplace para N.R.P VG,AC e CR
- Apêndice B – Questionário
- Apêndice C – Respostas ao questionário
- Apêndice D – Código WinBUGS
- Apêndice E – Resultados simulação MCMC

Apêndice A – Teste Laplace para os três navios

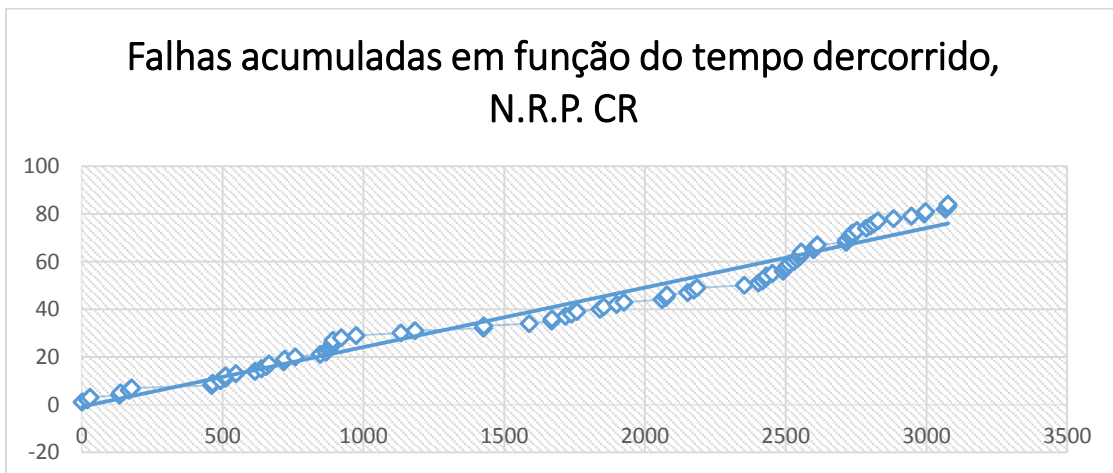
N.R.P VG: Teste Laplace: $|Z_0|=3.035$, Taxa de falhas crescente



N.R.P AC: Teste Laplace: $|Z_0|=2.61$, Taxa de falhas crescente



N.R.P CR: Teste Laplace: $|Z_0|=2.02$, Taxa de falhas crescente



Apêndice B – Questionário

QUESTIONÁRIO

Integração da Experiência Humana na Gestão da Manutenção e na Predição de Avarias e Necessidades de Sobressalentes na Marinha.

O presente questionário insere-se no âmbito de uma dissertação de mestrado do curso de Engenheiros Navais Ramo de Mecânica da Escola Naval.

O propósito deste questionário é proceder a recolha de informação pertinente proveniente da experiência dos profissionais da Marinha Portuguesa por forma a integrar esses conhecimentos nos Planos de manutenção de equipamentos e sistemas vigentes na atualidade.

Como não existe ninguém que tenha um conhecimento tão aprofundado sobre estas temáticas como os profissionais que são, ou já foram, responsáveis por estes equipamentos, apela-se para que responda a todas as questões da forma mais precisa e esclarecedora possível. Não existe uma resposta certa ou errada para estas questões, apenas a sua perceção e experiência técnica sobre o tema em questão.

O questionário é absolutamente anónimo e os dados obtidos serão utilizados exclusivamente no âmbito da investigação.

O seu contributo é indispensável para o sucesso deste trabalho de investigação, pelo que agradeço antecipadamente toda a disponibilidade e atenção despendidas.

Luis Miguel Rodrigues de Morais

ASPOF EN-MEC

QUESTÕES

1-Indique a sua unidade.

- N.R.P. Vasco da Gama
- N.R.P. Alvares Cabral
- N.R.P. Corte Real

2- Na sua percepção, durante o seu tempo de serviço, quantas ocorrências existiram no conjunto dos 4 grupos eletrogéneos?

3-Em que situação ocorreram a maioria dessas avarias?

1. *A navegar*
2. *Atracado com missão atribuída*
3. *Atracado sem missão atribuída*
4. *Em fabricos ou manutenção*
5. *Durante provas de porto ou de mar*

4- Na sua percepção, qual dos sistemas falhou mais vezes?

1. Sistema de água doce
2. Sistema de água salgada
3. Sistema de combustível
4. Sistema de óleo de lubrificação
5. Sistema de ar
6. Sistema elétrico
7. Outros elementos não pertencentes a nenhum dos anteriores

5-Atendendo à sua experiência pessoal, de entre as seguintes causas, qual a mais comum?

1. Corrosão
2. Desgaste
3. Fadiga
4. Mau estado geral devido ao uso
5. Defeito do material ou erro de montagem por parte do fabricante
6. Erro do estaleiro durante fabricos
7. Falha humana
8. Acidente

6-Na sua percepção, quanto tempo consegue este gerador operar sem receber nenhum tipo de intervenção corretiva?

1. Um dia
2. Uma semana
3. Duas semanas
4. Um mês
5. Um trimestre
6. Um semestre
7. Um ano
8. Mais de um ano

Apêndice C – Respostas ao questionário

Inquirido\Questão	1	2	3	4	5	6
1	VG	50	1	3	3	4
2	VG	40	2	7	2	4
3	VG	40	2	6	2	4
4	VG	40	1	1	2	3
5	VG	50	2	5	1	4
6	VG	20	1	2	1	5
7	VG	20	1	4	4	6
8	VG	40	1	6	3	4
9	VG	50	2	7	1	3
10	VG	25	1	4	2	3
11	VG	40	2	2	2	5
12	VG	25	2	5	3	6
13	VG	30	1	1	4	2
14	VG	30	1	1	4	6
15	VG	25	1	2	2	3
16	VG	30	2	3	2	2

Inquirido\Questão	1	2	3	4	5	6
1	AC	60	1	3	1	3
2	AC	40	1	3	1	3
3	AC	40	1	7	3	4
4	AC	50	1	3	1	3
5	AC	60	2	5	2	4
6	AC	80	1	2	3	4
7	AC	50	1	2	1	4
8	AC	60	1	2	2	4
9	AC	50	2	4	1	3

Inquirido\Questão	1	2	3	4	5	6
1	CR	20	1	1	2	4
2	CR	30	1	1	3	6
3	CR	40	1	6	3	6
4	CR	30	1	2	3	7
5	CR	40	1	1	2	6
6	CR	20	1	2	3	5
7	CR	20	1	4	3	6

Apêndice D – Código WinBUGS

```
#####  
#####MODELO WEIBULL#####  
#####  
model {  
  for(i in 1 : 51) {  
  
    t[i]~dweib(beta[i],lambda[i])  
    beta[i]~dunif(0.77,1.1)  
    lambda[i]~dnorm(mu1[i],sigma1[i])  
    mu1[i]~dnorm(55.31,81.21)  
    sigma1[i]~dnorm(83.4,80.88)  
  
  }  
  
list(  
  t=c( 5,6,5,166,18,5,5,41,137,226,279,61,162,148,35,101,12,92,  
  90,145,17,20,6,2,5,69,85,36,7,88,24,29,17,8,300,35,11,3,  
  17,25,7,49,3,109,31,6,14,12,8,2,4)  
)  
list(  
lambda=c(55.31,55.31,55.31,55.31,55.316,55.31,55.31,55.316,55.31,55.31,  
55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,  
55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,  
55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,  
55.31,55.31,55.31,55.31,55.316,55.31,55.31,55.31,55.31,55.31,55.31),  
  
mu1=c(55.31,55.31,55.31,55.31,55.316,55.31,55.31,55.316,55.31,55.31,  
55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,  
55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,  
55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,55.31,  
55.31,55.31,55.31,55.31,55.316,55.31,55.31,55.31,55.31,55.31,55.31),  
  
sigma1=c(83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,8  
3.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.  
4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,83.4,  
83.4,83.4,83.4,83.4,83.4,83.4,83.4),  
  
beta=c(0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,  
0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,  
0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,  
0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,  
0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78,0.78)  
)  
)
```

```
#####
#####PRIORI LAMBDA####CALCULO MU1#####
#####
```

```
model {
  for(i in 1 : 32) {
    mu1[i]~dnorm(mu2[i],81.21)
    mu2[i]~dunif(0,100)
  }
}
```

```
list(
  mu1=c( 30,30,30,180,30,30,30,30,180,180,90,30,180,90,30,90,
        15,15,30,15,30,30,30,30,15,
        30,180,180,360,180,90,180)
)
```

```
list( mu2=c(1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,1,
            1,1,1,1,1,1,1,1,1,1,1)
)
```

```
#####
#####PRIORI LAMBDA####CALCULO SIGMA2#####
#####
```

```
model {
  for(i in 1 : 32) {
    sigma1[i]~dnorm(83.44,sigma2[i])
    sigma2[i]~dnorm(81.21,10000)
  }
}
```

```
list(
  sigma1=c( 30,30,30,180,30,60,30,30,180,180,60,30,180,90,30,90,
           15,15,30,15,30,30,30,30,15,
           30,180,180,360,180,90,180)
)
```

```
list(
sigma2=c(80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,8
0.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.1,80.
1,80.1,80.1,80.1)
)
```

Apêndice E – Resultados simulação MCMC

node	mean	sd	MC error				
beta[1]	0.7733	0.003324	3.281E-5	beta[46]	0.7725	0.002483	2.144E-5
beta[2]	0.7725	0.002535	2.833E-5	beta[47]	0.7709	8.841E-4	8.072E-6
beta[3]	0.7733	0.003222	3.052E-5	beta[48]	0.7711	0.001085	1.16E-5
beta[4]	0.7701	7.067E-5	6.47E-7	beta[49]	0.7717	0.001757	1.94E-5
beta[5]	0.7707	6.821E-4	7.345E-6	beta[50]	0.7855	0.01507	1.288E-4
beta[6]	0.7732	0.003194	3.454E-5	beta[51]	0.7745	0.004491	4.397E-5
beta[7]	0.7733	0.003291	3.271E-5	lambda[1]	55.23	0.1579	0.00307
beta[8]	0.7703	2.781E-4	2.845E-6	lambda[2]	55.22	0.1547	0.002688
beta[9]	0.7701	8.527E-5	9.382E-7	lambda[3]	55.23	0.1542	0.002741
beta[10]	0.7701	5.323E-5	5.405E-7	lambda[4]	54.06	0.1537	0.002573
beta[11]	0.77	4.448E-5	4.648E-7	lambda[5]	55.08	0.1562	0.002523
beta[12]	0.7702	1.865E-4	1.734E-6	lambda[6]	55.23	0.1594	0.002937
beta[13]	0.7701	7.061E-5	6.692E-7	lambda[7]	55.23	0.1552	0.002622
beta[14]	0.7701	7.895E-5	7.386E-7	lambda[8]	54.89	0.157	0.002688
beta[15]	0.7703	3.368E-4	3.13E-6	lambda[9]	54.24	0.1582	0.002804
beta[16]	0.7701	1.12E-4	1.082E-6	lambda[10]	53.73	0.1564	0.002795
beta[17]	0.7711	0.001065	9.267E-6	lambda[11]	53.45	0.1554	0.002514
beta[18]	0.7701	1.23E-4	1.375E-6	lambda[12]	54.73	0.1595	0.002957
beta[19]	0.7701	1.268E-4	1.504E-6	lambda[13]	54.09	0.1574	0.002725
beta[20]	0.7701	8.292E-5	7.978E-7	lambda[14]	54.17	0.1547	0.002688
beta[21]	0.7707	7.11E-4	8.333E-6	lambda[15]	54.93	0.1574	0.002609
beta[22]	0.7706	6.079E-4	5.595E-6	lambda[16]	54.46	0.1567	0.003069
beta[23]	0.7725	0.00252	2.747E-5	lambda[17]	55.15	0.1559	0.003
beta[24]	0.7853	0.01502	1.657E-4	lambda[18]	54.52	0.1571	0.003253
beta[25]	0.7733	0.003198	3.02E-5	lambda[19]	54.53	0.1567	0.002837
beta[26]	0.7702	1.636E-4	1.53E-6	lambda[20]	54.19	0.1572	0.002724
beta[27]	0.7701	1.354E-4	1.312E-6	lambda[21]	55.1	0.1586	0.002528
beta[28]	0.7703	3.21E-4	3.519E-6	lambda[22]	55.06	0.1544	0.002176
beta[29]	0.7721	0.002054	1.956E-5	lambda[23]	55.21	0.1545	0.002379
beta[30]	0.7701	1.294E-4	1.272E-6	lambda[24]	55.27	0.1572	0.00254
beta[31]	0.7705	4.958E-4	5.098E-6	lambda[25]	55.23	0.1558	0.002911
beta[32]	0.7704	4.04E-4	3.618E-6	lambda[26]	54.67	0.1537	0.002617
beta[33]	0.7707	7.408E-4	8.024E-6	lambda[27]	54.57	0.1557	0.002893
beta[34]	0.7717	0.001733	1.837E-5	lambda[28]	54.92	0.1558	0.002685
beta[35]	0.77	4.063E-5	3.275E-7	lambda[29]	55.2	0.1542	0.002658
beta[36]	0.7703	3.24E-4	2.875E-6	lambda[30]	54.55	0.1545	0.002467
beta[37]	0.7712	0.001184	1.251E-5	lambda[31]	55.03	0.1586	0.003365
beta[38]	0.777	0.006965	6.163E-5	lambda[32]	54.98	0.1553	0.002729
beta[39]	0.7707	7.171E-4	6.497E-6	lambda[33]	55.1	0.1543	0.002638
beta[40]	0.7705	4.661E-4	5.06E-6	lambda[34]	55.19	0.155	0.002511
beta[41]	0.7721	0.002038	2.05E-5	lambda[35]	53.35	0.1556	0.002354
beta[42]	0.7702	2.31E-4	2.323E-6	lambda[36]	54.93	0.1561	0.002869
beta[43]	0.777	0.006872	6.036E-5	lambda[37]	55.15	0.155	0.002859
beta[44]	0.7701	1.053E-4	1.068E-6	lambda[38]	55.26	0.1552	0.00286
				lambda[39]	55.09	0.1552	0.002637
				lambda[40]	55.02	0.1576	0.002387

lambda[41]	55.2	0.1562	mu1[37]	55.23	0.1113
lambda[42]	54.83	0.1546	mu1[38]	55.28	0.1105
lambda[43]	55.26	0.1537	mu1[39]	55.2	0.1104
lambda[44]	54.41	0.1554	mu1[40]	55.17	0.1121
lambda[45]	54.97	0.1551	mu1[41]	55.26	0.1114
lambda[46]	55.21	0.1553	mu1[42]	55.06	0.1115
lambda[47]	55.12	0.1568	mu1[43]	55.28	0.1097
lambda[48]	55.15	0.1553	mu1[44]	54.85	0.1102
lambda[49]	55.19	0.1538	mu1[45]	55.14	0.1106
lambda[50]	55.27	0.1545	mu1[46]	55.26	0.1106
lambda[51]	55.24	0.1571	mu1[47]	55.21	0.1102
mu1[1]	55.27	0.112	mu1[48]	55.23	0.111
mu1[2]	55.26	0.1102	mu1[49]	55.25	0.1093
mu1[3]	55.27	0.1105	mu1[50]	55.29	0.1106
mu1[4]	54.68	0.1106	mu1[51]	55.28	0.1125
mu1[5]	55.2	0.1106	sigma1[1]	83.4	0.1118
mu1[6]	55.27	0.1132	sigma1[2]	83.4	0.1108
mu1[7]	55.27	0.1113	sigma1[3]	83.4	0.1114
mu1[8]	55.1	0.1119	sigma1[4]	83.4	0.1112
mu1[9]	54.77	0.112	sigma1[5]	83.4	0.1116
mu1[10]	54.51	0.1132	sigma1[6]	83.4	0.1122
mu1[11]	54.37	0.1112	sigma1[7]	83.4	0.1115
mu1[12]	55.01	0.1134	sigma1[8]	83.4	0.1104
mu1[13]	54.69	0.1111	sigma1[9]	83.4	0.1111
mu1[14]	54.73	0.1102	sigma1[10]	83.4	0.1112
mu1[15]	55.12	0.1118	sigma1[11]	83.4	0.1115
mu1[16]	54.88	0.1116	sigma1[12]	83.4	0.1109
mu1[17]	55.23	0.1106	sigma1[13]	83.4	0.1111
mu1[18]	54.91	0.1117	sigma1[14]	83.4	0.1125
mu1[19]	54.91	0.1122	sigma1[15]	83.4	0.1108
mu1[20]	54.74	0.1107	sigma1[16]	83.4	0.1095
mu1[21]	55.2	0.1129	sigma1[17]	83.4	0.112
mu1[22]	55.18	0.1104	sigma1[18]	83.4	0.1109
mu1[23]	55.26	0.1091	sigma1[19]	83.4	0.1114
mu1[24]	55.29	0.1118	sigma1[20]	83.4	0.1107
mu1[25]	55.27	0.1107	sigma1[21]	83.4	0.1106
mu1[26]	54.99	0.11	sigma1[22]	83.4	0.1119
mu1[27]	54.93	0.1111	sigma1[23]	83.4	0.1116
mu1[28]	55.11	0.1112	sigma1[24]	83.4	0.1118
mu1[29]	55.26	0.1102	sigma1[25]	83.4	0.1107
mu1[30]	54.93	0.11	sigma1[26]	83.4	0.1116
mu1[31]	55.17	0.1123	sigma1[27]	83.4	0.1114
mu1[32]	55.14	0.1104	sigma1[28]	83.4	0.1111
mu1[33]	55.2	0.1096	sigma1[29]	83.4	0.1122
mu1[34]	55.25	0.111	sigma1[30]	83.4	0.1115
mu1[35]	54.32	0.1109	sigma1[31]	83.4	0.1114
mu1[36]	55.12	0.111	sigma1[32]	83.4	0.1113

sigma1[33]	83.4	0.1116
sigma1[34]	83.4	0.1113
sigma1[35]	83.39	0.1121
sigma1[36]	83.4	0.111
sigma1[37]	83.4	0.1112
sigma1[38]	83.4	0.1115
sigma1[39]	83.4	0.1113
sigma1[40]	83.4	0.1106
sigma1[41]	83.4	0.1112
sigma1[42]	83.4	0.1116
sigma1[43]	83.4	0.1131
sigma1[44]	83.4	0.1115
sigma1[45]	83.4	0.1129
sigma1[46]	83.4	0.1118
sigma1[47]	83.4	0.112
sigma1[48]	83.4	0.1114
sigma1[49]	83.4	0.1113
sigma1[50]	83.4	0.111
sigma1[51]	83.4	0.1116

Resultado da simulação para as prioris

node	mean	sd			
mu2[1]	30	0.1109	mu2[21]	30	0.1107
mu2[2]	30	0.111	mu2[22]	30	0.1105
mu2[3]	30	0.1107	mu2[23]	30	0.11
mu2[4]	100	1.559E-4	mu2[24]	30	0.1112
mu2[5]	30	0.111	mu2[25]	15	0.1102
mu2[6]	60	0.1109	mu2[26]	30	0.11
mu2[7]	30	0.1109	mu2[27]	100	1.523E-4
mu2[8]	30	0.1115	mu2[28]	100	1.514E-4
mu2[9]	100	1.539E-4	mu2[29]	100	4.211E-5
mu2[10]	100	1.555E-4	mu2[30]	100	1.545E-4
mu2[11]	60	0.1106	mu2[31]	90	0.1122
mu2[12]	30	0.111	mu2[32]	100	1.513E-4
mu2[13]	100	1.551E-4			
mu2[14]	90	0.1094			
mu2[15]	30	0.1106			
mu2[16]	90	0.111			
mu2[17]	15	0.1111			
mu2[18]	15	0.1102			
mu2[19]	30	0.1111			
mu2[20]	15	0.1119			

sigma2[7]	81,07	0.00999
sigma2[8]	81,07	0.01007
sigma2[9]	80,74	0.01001
sigma2[10]	80,74	0.01
sigma2[11]	81,18	0.009926
sigma2[12]	81,07	0.01008
sigma2[13]	80,74	0.009989
sigma2[14]	81,21	0.00995
sigma2[15]	81,07	0.009926
sigma2[16]	81,21	0.01001
sigma2[17]	80,98	0.01006
sigma2[18]	80,98	0.01002
sigma2[19]	81,07	0.00993
sigma2[20]	80,98	0.009947
sigma2[21]	81,07	0.01006
sigma2[22]	81,07	0.01004
sigma2[23]	81,07	0.01001
sigma2[24]	81,07	0.01003
sigma2[25]	80,98	0.009964
sigma2[26]	81,07	0.01001
sigma2[27]	80,74	0.009963
sigma2[28]	80,74	0.009986
sigma2[29]	77,39	0.009912
sigma2[30]	80,74	0.01001
sigma2[31]	81,21	0.0101
sigma2[32]	80,74	0.009966