



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.12.19.55-TDI

**INOVAÇÕES EM MODELOS DE CARGA E DESCARGA
E EM ALGORITMOS POR FILTRO DE PARTÍCULAS
PARA A PREDIÇÃO DE FALHAS (EOD, EOL, RUL) EM
BATERIAS DE LÍTIO-ÍON PARA SATÉLITES**

Roberta de Cássia Ferreira Porto

Tese de Doutorado do Curso de Pós-Graduação em Engenharia e Tecnologia Espaciais/Engenharia e Gerenciamento de Sistemas Espaciais, orientada pelo Dr. Marcelo Lopes de Oliveira e Souza, aprovada em 06 de agosto de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/458SMDH>>

INPE
São José dos Campos
2021

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE
Coordenação de Ensino, Pesquisa e Extensão (COEPE)
Divisão de Biblioteca (DIBIB)
CEP 12.227-010
São José dos Campos - SP - Brasil
Tel.:(012) 3208-6923/7348
E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Coordenação-Geral de Ciências da Terra (CGCT)

Membros:

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação (CPG)
Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia, Tecnologia e Ciência Espaciais (CGCE)
Dr. Rafael Duarte Coelho dos Santos - Coordenação-Geral de Infraestrutura e Pesquisas Aplicadas (CGIP)
Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon
Clayton Martins Pereira - Divisão de Biblioteca (DIBIB)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Divisão de Biblioteca (DIBIB)
André Luis Dias Fernandes - Divisão de Biblioteca (DIBIB)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA
E INOVAÇÕES



sid.inpe.br/mtc-m21d/2021/08.12.19.55-TDI

**INOVAÇÕES EM MODELOS DE CARGA E DESCARGA
E EM ALGORITMOS POR FILTRO DE PARTÍCULAS
PARA A PREDIÇÃO DE FALHAS (EOD, EOL, RUL) EM
BATERIAS DE LÍTIO-ÍON PARA SATÉLITES**

Roberta de Cássia Ferreira Porto

Tese de Doutorado do Curso de Pós-Graduação em Engenharia e Tecnologia Espaciais/Engenharia e Gerenciamento de Sistemas Espaciais, orientada pelo Dr. Marcelo Lopes de Oliveira e Souza, aprovada em 06 de agosto de 2021.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34T/458SMDH>>

INPE
São José dos Campos
2021

Dados Internacionais de Catalogação na Publicação (CIP)

Porto, Roberta de Cássia Ferreira.

P838i Inovações em modelos de carga e descarga e em algoritmos por filtro de partículas para a predição de falhas (EOD, EOL, RUL) em baterias de lítio-íon para satélites / Roberta de Cássia Ferreira Porto. – São José dos Campos : INPE, 2021.

xxxi + 240 p. ; (sid.inpe.br/mtc-m21d/2021/08.12.19.55-TDI)

Tese (Doutorado em Engenharia e Tecnologia Espaciais/Engenharia e Gerenciamento de Sistemas Espaciais) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

Orientador : Dr. Marcelo Lopes de Oliveira e Souza.

1. Modelos de carga e descarga. 2. Algoritmos por filtro de partículas. 3. Prognóstico/predição de falhas. 4. Fim de carga. 5. fim de vida. I.Título.

CDU 629.7.045:629.78



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).



INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

Serviço de Pós-Graduação - SEPGR

**DEFESA FINAL DE TESE DE ROBERTA DE CÁSSIA FERREIRA PORTO
BANCA Nº 195/2021 , REG 114693/2015.**

No dia 06 de agosto de 2021, às 14h, por teleconferência, o(a) aluno(a) mencionado(a) acima defendeu seu trabalho final (apresentação oral seguida de arguição) perante uma Banca Examinadora, cujos membros estão listados abaixo. O(A) aluno(a) foi APROVADO(A) pela Banca Examinadora, por unanimidade, em cumprimento ao requisito exigido para obtenção do Título de Doutor em Engenharia e Tecnologia Espaciais/Engenharia e Gerenciamento de Sistemas Espaciais. O trabalho precisa da incorporação das correções sugeridas pela Banca e revisão final pelo(s) orientador (es)

Título Novo: "INOVAÇÕES EM MODELOS DE CARGA E DESCARGA E EM ALGORITMOS POR FILTRO DE PARTÍCULAS PARA A PREDIÇÃO DE FALHAS (EOD, EOL, RUL) EM BATERIAS DE LÍTIO-ÍON PARA SATÉLITES"

Membros da banca:

Dr. Walter Abrahão dos Santos - Presidente - INPE

Dr. Marcelo Lopes de Oliveira e Souza – Orientador – INPE

Dr. Renato Oliveira de Magalhães – Membro Interno – INPE

Dr. Fernando José de Oliveira Moreira – Membro Externo - Embraer

Dr. Alexandre Carvalho Leite – Membro Externo – Instituto Federal Fluminense-IFF



Documento assinado eletronicamente por **Walter Abrahão dos Santos, Pesquisador(a) em Ciência e Tecnologia**, em 10/08/2021, às 09:53 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Renato Oliveira de Magalhães, Chefe da Divisão de Eletrônica Espacial e Computação substituto**, em 10/08/2021, às 10:41 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **fernando jose de oliveira moreira (E), Usuário Externo**, em 10/08/2021, às 10:57 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **marcelo lopes de oliveira e souza (E), Usuário Externo**, em 10/08/2021, às 13:35 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alexandre Carvalho Leite (E), Usuário Externo**, em 17/08/2021, às 10:09 (horário oficial de Brasília), com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site <http://sei.mctic.gov.br/verifica.html>, informando o código verificador **7935325** e o código CRC **9F1535F8**.

“A maior recompensa para o trabalho do homem não é o que se ganha, mas o que ele nos torna.”

John Ruskin

Dedico este trabalho à minha família e aos amigos pelo incentivo constante.

Em especial, à minha cara amiga Juliana Padilha (in memoriam) que tão cedo partiu e deixou saudades; e ao meu amado esposo Robson.

AGRADECIMENTOS

Primeiramente a Deus, pelo dom da Vida, pelas oportunidades e possibilidades que colocaste à minha frente. Pela paciência e tolerância com a qual recebeste minhas orações e por Tua preciosa proteção.

“Senhor, sou muito grata por cada pessoa que colocastes em meu caminho. Eu sei que jamais teria colocado um ponto final na última página deste trabalho sem a Tua valiosa contribuição e de cada um dos Teus filhos. Sei que jamais poderei retribuir na mesma proporção a todos que contribuíram com meu crescimento desde que ingressei ao INPE e com o desenvolvimento deste trabalho. Sei também que sou muito falha e, com o tempo, poderei esquecer; mas o Senhor jamais se esquecerá. Por este motivo, peço que Tuas bênçãos sejam continuamente derramadas sobre cada um daqueles que eu mencionar.”

Agradeço ao INPE, pela oportunidade; e a todos os professores do Curso ETE/CSE, pelos conhecimentos compartilhados e orientações durante todo o período desse Curso de Doutorado em Engenharia e Tecnologias Espaciais.

Em especial, destaco dois que carregarei para sempre no coração: 1) Dr. Otavio Bogossian (*in memoriam*) que foi um excelente professor e amigo, pessoa admirável que tão cedo partiu e 2) meu orientador, Dr. Marcelo Lopes de Oliveira e Souza, que, além de ser um excelente professor e orientador, é uma pessoa excepcional, a quem dedico enorme gratidão e admiração. A ele, que sempre me motivou durante todo esse período, que acreditou mesmo quando nem eu mesma acreditava que teríamos resultados, minha gratidão por todo auxílio e conhecimento que me transmitiu. O seu auxílio e contribuição para o meu crescimento foi muito além do ramo acadêmico, foi para a Vida. E, claro que não poderia deixar de agradecer à sua esposa, Dra. Rose Mary Almeida Lopes, que acompanhou essa trajetória, gratidão pela paciência, conselhos e carinho.

Aos membros da Banca Examinadora, Dr. Renato Oliveira de Magalhães, Dr. Fernando José de Oliveira Moreira, Dr. Walter Abrahão dos Santos, e Dr. Alexandre Carvalho Leite por terem atendido ao convite, dispondo de seu tempo e conhecimento para analisar este trabalho e pelas contribuições e validações.

Agradeço aos membros suplentes, Dra. Ana Paula de Sá Santos Rabello e Dr. Jairo Eduardo Moraes Siqueira pela participação nesta defesa de tese, pelos comentários e apoio.

À CAPES e ao CNPq, pelo apoio financeiro que tornou possível finalizar essa etapa.

Expresso também meus sinceros agradecimentos às secretárias Edleusa (ETE/CSE), Valdirene (ETE/CMC) e Juliana (PSG) que sempre foram solícitas e atenciosas. Aos profissionais da Biblioteca do INPE e do Serviço de Informação e Documentação - SESID, em especial, à Sra. Simone Del Ducca, pela disponibilidade e auxílio à finalização e publicação deste trabalho.

Agradeço aos muitos colegas e amigos que fiz neste período de doutoramento, em especial: Ana Paula, Paula Renata, Sérgio Penna, Graziela Maia, André Ivo, Juliana Padilha (*In memoriam*), Ítalo, Jorge, Julian, Eloy Oliveira e Joyce.

Agradeço aos meus amigos e familiares que puderam entender e aceitar a minha ausência: foi difícil para mim me ausentar em momentos em que gostaria de estar junto e aproveitar a presença de vocês. Em especial, meus queridos pais José Henrique e Sebastiana, meus sobrinhos (as), meus afilhados (as) e meus irmãos, o de sangue e os de coração.

Por último, mas não menos importante, agradeço ao meu esposo Robson, cuja presença e apoio foram mais que constantes. Um grande amigo, pessoa de extrema paciência, que soube me dar ânimo nos momentos difíceis e que agora divide comigo a felicidade e o alívio desta conquista.

RESUMO

Cada vez mais, as organizações estão desenvolvendo sistemas com crescente complexidade e/ou alta integração para atender a missões cada vez mais exigentes, em ambientes cada vez mais hostis, mas que os tornam cada vez mais propensos a falhas. Isto é especialmente verdadeiro com seus itens críticos como fontes de energia e baterias, para: 1) assegurar operações normais e até autônomas; 2) permitir manobras degradadas e até de sobrevivência. Para conciliar essas necessidades e dificuldades crescentes, os tratamentos de anomalias, erros, falhas, e falências nos componentes utilizados e/ou subsistemas vêm crescendo progressivamente através das abordagens de: 1) Prevenção de falhas, 2) Tolerância a falhas, e 3) Correção de falhas. Correntemente, e devido ao crescimento explosivo e aos custos decrescentes da Computação e da Comunicação, a abordagem de Prognóstico/ Predição de falhas está em ascensão na comunidade científica, com métodos que possibilitam aumentar a Dependabilidade (Confiabilidade, Manutenibilidade, Disponibilidade, Segurança contra Acidentes, Segurança contra Intrusões, etc.) e a Suportabilidade (Manutenibilidade, Confiabilidade, Disponibilidade, Adaptabilidade, Acessibilidade, etc.) dos sistemas, a autonomia das missões, etc. Por isso, este trabalho estuda, detalha e inova modelos de carga e descarga e algoritmos por filtro de partículas para a predição de falhas (EOD, EOL, RUL) em baterias de Lítio-Íon usáveis em satélites artificiais. Para isto, o trabalho: 1) revisa a literatura disponível; 2) seleciona e equaciona modelos de carga e descarga de baterias de Lítio-Íon usáveis em satélites artificiais; 3) detalha os modelos de baterias, explicitando pontos de melhoria e inovação; 4) implementa estas melhorias/inovações junto ao Filtro de Partículas; e 5) compara os resultados obtidos aplicando medidas de desempenho. As inovações implementadas ao modelo de bateria resultam em melhor acurácia e precisão no modo *off-line*; e uma das inovações empregadas possibilita a aplicação do algoritmo no modo *on-line*. A alteração para o modo *on-line* manteve boa acurácia e precisão; e o aprimoramento do modelo permitiu diminuir o número de partículas do método facilitando a redução da complexidade, memória e tempo de resposta após acionar a estimativa; ou seja, facilitando um ganho computacional. Este, e outros ganhos devem ser seriamente considerados, pois sistemas embarcados tem várias restrições, em especial as que envolvem complexidade e custo computacional.

Palavras-chave: modelos de carga e descarga; algoritmos por filtro de partículas; prognóstico/predição de falhas; fim de carga; fim de vida; vida útil remanescente; baterias de Lítio-Íon.

INNOVATIONS IN CHARGE AND DISCHARGE MODELS AND IN PARTICLE FILTER ALGORITHMS FOR FAULT PREDICTION (EOD, EOL, RUL) IN LITHIUM-ION BATTERIES FOR SATELLITES

ABSTRACT

Increasingly, organizations are developing systems with growing complexity and/or high integration, to meet missions even more demanding, in environments even more hostiles, but that turn them even more fail prone. This is especially true with their critical items to: 1) ensure normal and even autonomous operations; 2) allow degraded and even survival maneuvers, as power supplies and batteries. To reconcile these needs and difficulties, the treatment of anomalies, errors, faults and failures in their components and/or subsystems has grown progressively through the approaches of: 1) Fault Prevention, 2) Fault Tolerance, and 3) Fault Correction. Currently, due to the explosive growth and decreasing costs of Computation and Communication, the approach of 4) Fault Prognosis/Prediction is ascending in the scientific community with methods that make it possible to increase system Dependability (Reliability, Maintainability, Availability, Safety, Security, etc.) and Supportability (Maintainability, Reliability, Availability, Adaptability, Accessibility, etc.), mission autonomy, etc. Therefore, this work studies, details and innovates charge and discharge models and particle filter algorithms for fault prediction (EOC, EOL, RUL) in Lithium-Ion batteries for satellites. To do this, the work: 1) reviews the available literature; 2) selects and equates charging and discharging models of Lithium-Ion batteries usable in artificial satellites; 3) details the battery models pointing out points of improvement and innovation; 4) implements these improvements/innovations with the particle filters; and 5) compares the results obtained by applying performance measures. The innovations implemented in the battery model result in better accuracy in *off-line* mode. One of the innovations employed eases the application of the algorithm in *on-line* mode. The change to the *on-line* mode maintained good accuracy and precision. and the model improvement allowed reducing the number of particles in the method, resulting in reduced complexity, memory and response time after triggering the estimate, that is, there was a computational gain. These and other gains must be considered seriously, as embedded systems have several restrictions, especially those involving computational complexity and cost.

Keywords: charge and discharge models; particle filter algorithms; fault prognosis/prediction; end of charge; end of life; remaining useful life; Lithium-Ion batteries.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1: Árvore da Dependabilidade.....	9
Figura 2.2: Curva de Falhas conhecida como "Curva da Banheira".....	13
Figura 2.3: Relação entre as quatro abordagens para melhorar a Dependabilidade.	19
Figura 2.4: Características das abordagens 1 e 2 na melhoria da Dependabilidade.	23
Figura 2.6: Diversas possibilidades de aplicações com sensores.....	30
Figura 2.7: Categorização das abordagens de tratamento de falhas.....	33
Figura 2.8: Resumo das técnicas utilizadas em Dados e Modelos.	33
Figura 2.9: Tendência da Falha.....	35
Figura 2.10: Técnicas existentes para abordagem com dados por métodos estatísticos.	36
Figura 2.11: Ciclo do prognóstico enfatizando a acurácia.....	40
Figura 2.12: Ciclo do prognóstico enfatizando a precisão.....	41
Figura 2.13: Esquema de uma célula eletroquímica.	52
Figura 2.14: Comparação de densidade de energia em relação ao tamanho e massa.....	55
Figura 2.15: Influência da densidade de corrente sobre a curva de descarga.	58
Figura 2.16: Influência da eficiência coulombiana sobre a capacidade disponível durante a descarga.	59
Figura 2.17: Decomposição do perfil de descarga de (baterias) Li-Íon em componentes diferentes.	59
Figura 2.18: Curva de voltagem de descarga de uma célula de NiMH de 9,5 A.h.60	
Figura 2.19: Descarga de uma célula de Li-Íon de 2,4 A.h a 3 diferentes correntes constantes.	61
Figura 2.20: Curva de voltagem de descarga de uma célula de NiMH indicando regiões lineares não lineares.....	61
Figura 2.21: Exemplos genéricos de envelhecimento de células.....	62

Figura 2.22: Ajuste do modelo para os processos de descarga e auto-recarga de (baterias) Li-Íon.	62
Figura 3.1: Identificação do escopo do trabalho de tese.	64
Figura 3.2: Propagação de partículas.	66
Figura 4.1: Representação gráfica das Equações (4.1) e (4.2).	74
Figura 4.2: Representação gráfica da etapa de predição pelo estimador bayesiano.	76
Figura 4.3: Representação gráfica separada da Equação (4.4) para dois pontos.	76
Figura 4.4: Representação gráfica superposta da Equação (4.4) para dois pontos.	77
Figura 4.5: Comparação de três funções densidade de probabilidade.	83
Figura 4.6: Processo de replicação de partículas.	89
Figura 4.7: Fluxograma de filtragem de partículas genérico.	90
Figura 4.8: Passos de um filtro de Partículas SIR genérico.	90
Figura 5.1: Modelo para o processo de descarga e auto recarga.	97
Figura 5.2: Modelo original (M1a) de Randles, a parâmetros concentrados de uma célula.	99
Figura 5.3: Modelo rearranjado (M1b) de Randles, a parâmetros concentrados de uma célula.	100
Figura 5.4: Modelo renotado (M1c) de Randles, a parâmetros concentrados de uma célula.	101
Figura 5.5: Decomposição dos perfis de descarga (da bateria) de Lítio-Íon. .	106
Figura 5.6: Diferença entre SOC e SOH.	109
Figura 5.7: SOH ao longo do tempo, EOD, EOL e RUL.	109
Figura 5.8: Influência de η_c sobre a capacidade de carga durante as ciclagens.	110
Figura 5.9: Influência da corrente no ciclo de descarga.	111
Figura 6.1: Testes de prognósticos de bateria no Centro de Excelência de Prognósticos Ames da NASA.	116
Figura 6.2: Estrutura de dados das baterias de Lítio-Íon.	117

Figura 6.3: Estrutura de dados para a) carga e b) descarga das baterias de Lítio-Íon.	117
Figura 6.4: Fluxograma do algoritmo do filtro de Partículas adotado.	134
Figura 6.5: Fluxograma da Reamostragem pelo Filtro de Partículas.	135
Figura 6.6: Teorema da Transformação Integral	136
Figura 6.7: Predições da RUL para EOD e EOL para bateria B0005.....	138
Figura 6.8: Predições da RUL para EOD.	139
Figura 6.9: Predições da RUL para EOL para as baterias B0005, B0007 e B0030.....	140
Figura 6.10: Diagrama das predições EOL e EOD.....	143
Figura 7.1: Regras de Euler Avançada e Atrasada.	147
Figura 7.2: Regra do Trapézio.....	147
Figura 7.3: Aproximação da corrente $I(t)$ pela sua média $I_{média(t_k;t_i)}$ no intervalo $[t_k;t_i]$	151
Figura 7.4: Gráficos mostrando a Aceitação Ideal e a Aceitação Não Ideal realizados usando a equação provida por Hartley & Janette (2005).	159
Figura 7.5: Ação preditiva sem melhorias (caso 0).	165
Figura 7.6: Resultado após a implementação de melhorias do Caso 1, para $i = 20$ e 40	166
Figura 7.7: Resultado após a implementação de melhorias do Caso 1, para $i = 20, 40$ e 60	167
Figura 7.8: Predições realizadas referente caso 2.	168
Figura 7.9: Resultado após a implementação de melhorias do Caso 3, para $i = 20, 40$ e 60	170
Figura 7.10: Resultado após a implementação de melhorias do Caso 4a, para $i = 20, 40$ e 60	172
Figura 7.11: Resultado após a implementação de melhorias do Caso 4b, para $i = 20, 40$ e 60	172
Figura 7.12: Detalhe do resultado após a implementação de melhorias do Caso 4b para $i = 20, 40$ e 60	173
Figura 7.13: Resultado após a implementação de melhorias do Caso 5.	174
Figura 7.14: Predições da referência sem melhorias para $i=30,120$ e 165	176

Figura 7.15: Predições $i=30,120$ e 165 com melhorias do Caso 6.	176
Figura 7.16: Resultado da análise do Caso 7 para BAT B0005 (ciclo 5).....	178
Figura 7.17: Resultado da análise do Caso 7 no último ciclo de descarga, para BAT B0005.	178
Figura 7.18: Resultado da análise do Caso 8 no quinto ciclo de descarga para BAT B0030.	179
Figura 7.19: Resultado da análise do Caso 8 no penúltimo ciclo de descarga para BAT B0030.....	180
Figura 7.20: Resultado da análise do Caso 8 para a BAT B0007, no décimo ciclo de descarga.	182
Figura 7.21: Resultado da análise do Caso 8 para aBAT B0007, no último ciclo de descarga.....	183
Figura 7.22: Resultado da análise do Caso 8 para a BAT B0018, no quarto ciclo de descarga.....	184
Figura 7.23: Resultado da análise do Caso 8 para a BAT B0018, no último ciclo de descarga.....	184
Figura 7.24: Resultado do algoritmo original aplicado para BAT B0030 nos tempos iniciais.....	186
Figura 7.25: Resultado do algoritmo inovado aplicado para BAT B0030 nos tempos iniciais.....	186
Figura 7.26: Predição com 100 partículas.	189
Figura 7.27: Predição com 20 partículas.	189
Figura 7.28: Predição com 20 partículas no detalhe.	190
Figura 7.29: Ciclo do prognóstico enfatizando a acurácia.	193
Figura 7.30: Ciclo do prognóstico enfatizando a precisão.	193
Figura 7.31: Distância prognóstica e acurácia.....	194
Figura 7.32: Evolução do α_1 a) antes das melhorias e b) após.	195
Figura 7.33: Evolução do α_2 a) antes das melhorias e b) após	196
Figura 7.34: Evolução do α_3 a) antes das melhorias e b) após.	196
Figura 7.35: Evolução do α_4 antes das melhorias.	196
Figura 7.36: Evolução do α_4 após as melhorias.	197
Figura 7.37: Evolução do α_5 a) antes das melhorias e b) após.	197

Figura 7.38: Estimativa de EOL usando o modelo EOL sem modificações (B0005).	199
Figura 7.39: Estimativa de EOL usando o modelo EOL sem modificações (B0030).	199
Figura 7.40: Convergência do algoritmo antes de correção de Q_n	201
Figura 7.41: Convergência do algoritmo após correção de Q_n	201
Figura 7.42: Estimativa de EOL usando o modelo EOL com correção de Q_n	202
Figure 2.10: Simple resistive cell model.	228
Figure 2.11: RC circuit representing diffusion within a cell.	229
Figure 2.12: Voltage across parallel RC circuit due to a step change in current (Hartley & Lorenzo, 2002).	229
Figure 2.13: Linear circuit model for NiMH cell as described by Eveready Company (2001).	231
Figure 2.14: Voltage discharge curve for a (9.5) NiMH cell indicating linear and nonlinear regions.	231
Figure 2.15: Circuit model including a capacitor representing capacity of the cell.	232
Figure 2.16: Circuit model including self-discharge resistor.	232
Figure 2.17: Circuit model including Warburg impedance.	233
Figure 2.18: Circuit model including constant phase element.	233
Figura B.1: Contato feito com Dr. Kai Goebel.	234
Figura B.2: Resposta ao contato realizado com o link aos dados.	234
Figura B.2: Representação geométrica de 3 fatores.	238
Figura B.3: Comparação experimento fatorial completo e experimento fatorial fracionado pela metade.	240

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1: Categorias de Severidade.....	16
Tabela 2.2: Resumo das abordagens de tratamento de falhas.....	39
Tabela 2.3: Descrição de alguns algoritmos mais utilizados para prognóstico com suas principais vantagens e desvantagens.	43
Tabela 2.3: Conclusão.	44
Tabela 2.4. Comparação dos algoritmos enfatizados.	49
Tabela 2.5: Aplicações de prognósticos a sistemas.....	50
Tabela 2.6: Comparação das principais características dos tipos de baterias.	56
Tabela 2.7: Vantagens e desvantagens dos modelos para baterias.	57
Tabela 3.1: Vantagens e desvantagens de uma bateria de Lítio-Íon.	69
Tabela 5.1 Repertório de falhas de baterias de Lítio-Ion.....	96
Tabela 7.1: Planejamento das comparações.	163
Tabela 7.2: Erro relativo, Caso 1.....	166
Tabela 7.3: Erro relativo, Caso 2.....	169
Tabela 7.4: Erro relativo, Caso 3.....	170
Tabela 7.5: Erro relativo, Caso 4b.....	173
Tabela 7.6: Erro relativo, Caso 5.....	175
Tabela 7.7: Erro relativo, Caso 6.....	175
Tabela 7.8: Erro relativo, Caso 7 para BAT (B0005).	177
Tabela 7.9: Erro relativo, Caso 8 para BAT (B0030).	181
Tabela 7.10: Erro relativo, Caso 9 para BAT (B0007).	183
Tabela 7.11: Erro relativo, Caso 9 para BAT (B0018).	185
Tabela 7.12: Erro para o Caso 10 para BAT B0005 e B0018.	187
Tabela 7.13: Erro Absoluto para diferentes números de partículas.....	190
Tabela B.1 – Matriz experimental de um delineamento fatorial 2 ³	238

LISTA DE SIGLAS E ABREVIATURAS

AC	<i>Alternating Current</i> (Corrente Alternada)
ALT	Teste de Vida Acelerada
AR	<i>AutoRegressive</i> (Auto-Regressivo)
ARIMA	<i>AutoRegressive Integrated Moving Average</i> (Auto-Regressivo Integrado de Médias Móveis)
ARMA	<i>AutoRegressive Moving Average</i> (Auto-Regressivo de Médias Móveis)
ASIR	<i>Auxiliary Sampling Importance Resampling</i> (Amostragem Auxiliar; e Reamostragem por Importância)
ATD	<i>Advanced Technology Development</i> (Desenvolvimento de Tecnologia Avançada)
BMS	<i>Battery Management System</i> (Sistema de Gerenciamento de Bateria)
DC	<i>Direct Current</i> (Corrente Contínua)
DOD	<i>Deep Of Discharge</i> (Profundidade De Descarga)
EIS	Espectroscopia De Impedância Eletroquímica
EKF	<i>Extended Kalman Filter</i> (Filtro de Kalman Estendido)
EOC	<i>End of Charge</i> (Fim de Carga)
ESP	<i>Electronic Stability Program</i>
ETA	<i>Event Tree Analysis</i>
FDI	<i>Failure Detection and Isolation</i>
FDIR	<i>Failure Detection, Isolation and Recovery</i>
PDF	Função Densidade de Probabilidade
FMEA	<i>Failure Modes and Effects Analysis</i>
FMECA	<i>Failure Modes, Effects and Criticality Analysis</i>
FTA	<i>Fault Tree Analysis</i>
HiL	<i>Hardware-in-the-Loop</i>
INPE	Instituto Nacional de Pesquisas Espaciais
IS	<i>Importance Sampling</i> (Amostragem por Importância)
KF	<i>Kalman Filter</i> (Filtro de Kalman)
Lead-Acid	Chumbo-Ácido
Li-Íon	Lítio-Íon

MA	<i>Moving Average (Média Móvel)</i>
MC	Monte Carlo
MTBF	<i>Mean Time Between Failures</i>
MTTF	<i>Mean Time to Failure</i>
MTTR	<i>Mean Time to Repair</i>
NASA	<i>National Aeronautics and Space Administration</i>
Ni-Cd	Níquel-Cádmio
Ni-MH	Níquel Metal-Hidreto
OCV	<i>Open Circuit Voltage (Tensão de Circuito Aberto)</i>
PCDU	<i>Power Conditioning & Distribution Unit</i>
PF	<i>Particle Filter (Filtro de Partículas)</i>
PHM	<i>Prognostics and Health Management</i>
PHM	<i>Prognostics and Health Monitoring</i>
PSS	<i>Power Supply Subsystem</i>
RAM	<i>Reliability, Availability and Maintainability</i>
RBD	<i>Reliability Block Diagram</i>
RUL	<i>Remaining Useful Life</i>
RUC	<i>Remaining Useful Charge</i>
SIR	<i>Sampling Importance Resampling (Amostragem; e Reamostragem por Importância)</i>
SMC	Monte Carlo Sequencial
SOC	<i>State of Charge (Estado de Carga)</i>
SOF	<i>State of Function (Estado de Funcionamento)</i>
SOH	<i>State of Health (Estado de Saúde)</i>
UKF	<i>Kalman Filter Unscented (Filtro de Kalman Neutro)</i>
Voc	<i>Open Circuit Voltage (Tensão de Circuito Aberto)</i>

LISTA DE SÍMBOLOS

\bar{A}	Mean Availability (Disponibilidade Média)
λ	Taxa de falhas
R_E	Resistência eletrolítica
Z_w	Impedância de Warburg
R_{CT}	Resistência à transferência de carga
I	Intensidade de corrente elétrica
E_0	tensão entre dos terminais da bateria após a carga, em circuito aberto, e antes da descarga
E	Tensão da célula
E_i	Tensão da célula medida no instante de tempo t_i de índice i
ΔE_{sd}	Perda de tensão devida à descarga de prateleira
ΔE_{rd}	Perda de tensão devida ao esgotamento do reagente celular
ΔE_{mt}	Perda de tensão devida à resistência interna à transferência de massa
t	Instante de tempo
i	Índice do instante/do intervalo de amostragem $t_i \in [t_i; t_{i+1}] \subset [t_k; t_{k+1}]$
J	Índice da partícula com estado x_i , $i = 1, 2, \dots, N_s$
k	Índice do ciclo de descarga $[t_k ; t_{k+1}]$ de $E(t_k)=E_0$ até $E(t_{k+1})=E_{eod}$
T_s	Período de amostragem das medidas $T_s = t_{i+1} - t_i$ dentro de $[t_k ; t_{k+1}]$ tal que $\Delta t_k = t_{k+1} - t_k \cong i_{max} \cdot T_s$
$\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5$	Parâmetros do modelo de transição de estados de EOD
Q_i	Capacidade de descarga atual da bateria
Q_{nom}	Capacidade de descarga nominal da bateria
Q, C	Capacidade de descarga instantânea da bateria
Q_0 ou C_0	Carga inicial da bateria
η_C	Eficiência coulombiana de ciclo para ciclo
Δt_k	Duração do ciclo k de carga e descarga da bateria
β_1 e β_2	Parâmetros do modelo de transição de estados de EOL
w, v, ψ, φ	Ruídos gaussianos, independentes, com médias zero e desvios

	padrão ajustados
N_{eff}	Tamanho efetivo da amostra
N_{tres}	Limiar utilizado para avaliar o tamanho da amostra
N_s	Número de partículas
f_s	Frequência de amostragem das medidas $f_s = 1/T_s$ dentro de Δt_k

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Contexto e motivações	2
1.2 Objetivo.....	4
1.3 Originalidade, generalidade e utilidade.....	4
1.4 Organização deste trabalho.....	4
2 CONCEITOS BÁSICOS E REVISÃO DA LITERATURA	7
2.1 Dependabilidade.....	7
2.2 Os atributos da Dependabilidade.....	10
2.2.1 Confiabilidade	10
2.2.2 Manutenibilidade.....	11
2.2.3 Disponibilidade.....	12
2.3 Ameaças à Dependabilidade de sistemas: falhas	12
2.3.1 Tipos de falhas.....	16
2.4 Meios de melhorar a Dependabilidade de sistemas	17
2.4.1 Propriedades e métricas/métodos para a melhoria da Dependabilidade 19	
2.5 Prognóstico de falhas	24
2.5.1 Uso de sensores	27
2.5.1.1 Desempenho do sistema do sensor.....	31
2.5.1.2 Custos.....	32
2.5.2 Abordagens de tratamento de falhas	32
2.5.2.1 Abordagens de tratamento de falhas baseadas em dados.....	34
2.5.2.2 Abordagens de tratamento de falhas baseadas em modelos	37
2.5.2.3 Abordagens de tratamento de falhas baseadas em experiências....	37
2.5.2.4 Abordagens de tratamento de falhas híbridas ou de fusão.....	38
2.5.3 Medidas de avaliação e desempenho.....	40
2.6 Algoritmos para prognóstico	42
2.6.1 Média Móvel Auto Regressiva Integrada – ARIMA (<i>AutoRegressive Integrated Moving Average</i>)	45

2.6.2	Filtro de Kalman (<i>Kalman Filter</i> – KF)	46
2.6.2.1	Filtro de Kalman Estendido (<i>Extended Kalman Filter</i> - EKF)	47
2.6.2.2	Filtro de Kalman Neutro (<i>Unscented Kalman Filter</i> - UKF)	47
2.6.3	Filtros bayesianos	48
2.6.3.1	Filtros de Partículas (<i>Particle Filter</i> – PF).....	48
2.7	Prognóstico aplicado a sistemas	50
2.7.1	Baterias	50
2.7.1.1	Características de baterias	53
2.7.1.2	Tipos de baterias	54
2.7.1.3	Modelos de baterias.....	56
3	FORMULAÇÃO DO PROBLEMA E ABORDAGENS PARA A SUA SOLUÇÃO.....	63
3.1	Abordagem por Teoria e Análise	64
3.2	Abordagem por modelagem e simulação	67
3.3	Abordagem por observação/experimentação	68
3.4	Sistema escolhido para estudo: baterias	68
4	ADOÇÃO E EQUACIONAMENTO DO FILTRO DE PARTÍCULAS	71
4.1	Estimação	71
4.2	Estimação bayesiana.....	72
4.2.1	Amostragem por importância	80
4.2.2	Filtro de partículas.....	87
5	ADOÇÃO E EQUACIONAMENTO DOS MODELOS DAS BATERIAS LÍTIO- ÍON93	
5.1	Repertório de falhas em baterias.....	93
5.1.1	Redução da capacidade de carga.....	94
5.1.2	Redução da potência	95
5.2	Modelagem	96
5.2.1	Modelo para o Fim de Descarga (EOD - <i>End-Of-Discharge</i>)	103
5.2.2	Modelo para o Fim de Vida (EOL - <i>End-of-life</i>)	108
6	IMPLEMENTAÇÃO E COMPARAÇÃO DOS MODELOS M2 E M3.....	115
6.1	Banco de dados utilizados	115
6.1.1	Configuração experimental dos dados utilizados	117

6.1.2	Organização da estrutura de dados	119
6.2	EOD e EOL segundo Saha e Goebel (2009)	120
6.2.1	Modelo de transição do estado EOD:.....	122
6.2.2	Modelo de medição do EOD:	122
6.2.3	Modelo de transição de estados do EOL:	123
6.2.4	Modelo de medição do EOL:.....	123
6.3	EOD e EOL segundo Arachchige et al (2017)	124
6.3.1	Modelo de transição de estado do EOD:.....	127
6.3.2	Modelo de medição do EOD:	128
6.3.3	Modelo de transição de estado do EOL:	128
6.3.4	Modelo de medição do EOL:.....	129
6.4	Algoritmo do filtro de partículas com os modelos M2 e M3.....	130
6.5	Comparação entre os resultados de Saha e Goebel (2009) (M2) e de Arachchige et al (2017) (M3)	137
7	APROXIMAÇÕES E LIMITAÇÕES DE M2 E M3, MELHORIAS E INOVAÇÕES EM M4.....	145
7.1	Aproximações e limitações dos modelos M2 e M3 para EOD	145
7.1.1	1ª Aproximação/Limitação (AL1): na medida da capacidade de descarga máxima Q_k e no estado de carga SOC_{i+1} , via regras de integração numérica nas Equações (7.6) e (7.7)	146
7.1.2	2ª. Aproximação/Limitação (AL2): na medida da capacidade de descarga máxima Q_k , via intervalo de integração numérica da Equação (7.6) 148	
7.1.3	3ª. Aproximação/Limitação (AL3): no estado de carga SOC_{i+1} , via 2ª parcela da Equação (7.7)	148
7.1.4	4ª. Aproximação/Limitação (AL4): no estado de carga SOC_{i+1} , via 2ª parcela da Equação (7.11)	149
7.1.5	5ª. Aproximação/Limitação: No parâmetro, via Equação (7.14).....	151
7.2	Melhorias/Inovações (MIs) adotadas no modelo M4 e implementadas no seu algoritmo.....	153

7.2.1	1ª. Melhoria/Inovação (MI1): na medida da capacidade de descarga máxima Q_k , e no estado de carga SOC_{i+1} , via regras de integração numérica nas Equações (7.6) e (7.7).....	153
7.2.2	2ª. Melhoria/Inovação (MI2): na medida da capacidade de descarga máxima Q_k listada no banco de dados; e, talvez, via intervalo de integração numérica da Equação (7.6) e sua propagação.....	154
7.2.3	3ª. Melhoria/Inovação (MI3): no estado de carga SOC_{i+1} via 2ª. parcela da Equação (7.7).....	156
7.2.4	4ª. Melhoria/Inovação (MI4): no estado de carga SOC_{i+1} , via 2ª. parcela da Equação (7.11).....	157
7.2.5	5ª. Melhoria/Inovação (MI5): no parâmetro, via Equação (7.14)	157
7.3	Avaliação e comparação de resultados dos modelos M2, M3, M4 para EOD	160
7.3.1	1ª. Avaliação e Comparação (AC1): usando o Erro Relativo (Relative Error - RE) e o Erro Absoluto Médio (Mean Absolute Deviation - MAD)	161
7.3.2	2ª. Avaliação e Comparação (AC2): usando o número de partículas, a acurácia e precisão, e a carga computacional	187
7.3.3	3ª. Avaliação e Comparação (AC3): usando a acurácia e precisão, a distância prognóstica e o tempo de resposta	192
7.3.4	Evolução dos estados com as melhorias	195
7.4	Melhorias e Inovações na convergência e nas predições de EOL	197
7.4.1	6ª. Aproximação/Explicação (MI6): na capacidade de descarga inicial Q_0 , na convergência inicial e nas predições de EOL.....	198
8	CONCLUSÕES.....	203
8.1	Principais dificuldades encontradas.....	203
8.2	Direções futuras:.....	205
	REFERÊNCIAS BIBLIOGRÁFICAS	209
	GLOSSÁRIO	223
	ANEXO A – Seção 2.3.1 da tese de Hartman II (2008)	227
A.1	Introdução	227
2.3	Electrochemical cell: dynamic models	227
2.3.1	Electric circuit models.....	227

ANEXO B -CONTATO COM o DR. KAI GOEBEL PARA DADOS DE PROGNÓSTICO	234
ANEXO C - Projeto e Análise de Experimentos	236
C.1 Introdução.....	236
B.6 Técnicas de projeto e análise de experimentos	236
B.6.1 Planejamento fatorial	236
B.6.2 Planejamento fatorial fracionado.....	239

1 INTRODUÇÃO

A demanda por sistemas cada vez mais sofisticados, com alta complexidade, integração, funcionalidades, segurança, sustentabilidade e outros requisitos de suma importância, vem causando aumentos de prazos, custos, qualidade, funções na fabricação. A complexidade desses sistemas é tal que o mau funcionamento de uma de suas partes integradas pode afetar ou degradar a funcionalidade e até a utilidade do sistema complexo. A complexidade é um fator que aumenta o problema de diagnosticar falhas nos aspectos elétricos e eletrônicos de um item (sistema, subsistema, equipamento ou componente) e o dificulta cada vez mais (PRISACARU, 2017; AMOR-SEGAN, 2011). Muitas falhas ocorrem devidas a distúrbios ou interações no nível do sistema que são difíceis de interpretar e diagnosticar usando o diagnóstico existente no nível do componente (AMOR-SEGAN, 2011). Esses fatos evidenciam a necessidade de trabalhar a Dependabilidade: Confiabilidade (*Reliability*), Manutenibilidade (*Maintainability*), Disponibilidade (*Availability*), Segurança contra Acidentes (*Safety*), Segurança contra Intrusões (*Security*), etc.: e a Suportabilidade: Manutenibilidade, Confiabilidade, Disponibilidade, Adaptabilidade (*Adaptability*), Acessibilidade (*Acessibility*), etc., do sistema.

A capacidade de: 1) prevenir/evitar (SOUZA; CARVALHO, 2005); ou diagnosticar (detectar, isolar e identificar) para: 2) suportar/tolerar (SOUZA; CARVALHO, 2005) ou 3) atenuar/corrigir (SOUZA; PORTO, 2016) as falhas de um componente ou subsistema com base em seus estados anteriores e atuais e nos dados operacionais disponíveis, tem sido um tópico de pesquisa de alta prioridade há algumas décadas (ROEMER; NWADIOGBU; BLOOR, 2011). Atualmente, a capacidade de 4) predizer/prognosticar falhas e monitorar a saúde é um assunto crescente, principalmente na manutenção de sistemas complexos e/ou altamente integrados e está sendo aplicado a uma ampla variedade de problemas e sistemas, como aeronáuticos, espaciais, automotivos, eletrônicos e mecânicos.

Para atender aos requisitos de Dependabilidade e Suportabilidade, é necessário tratar um número crescente de falhas dos

dispositivos/equipamentos. Os fabricantes estão investindo cada vez mais no monitoramento da saúde do sistema, com o objetivo de: 1) neutralizar as consequências da alta complexidade e integração dos sistemas; e 2) tratar falhas de maneira *a priori* e informada. Com o uso dos dados de sensores, eles realizam: 1) o monitoramento e avaliação do estado de saúde dos componentes do sistema; 2) a estimativa da Vida Útil Remanescente (*Remaining Useful Life* - RUL; 3) a gestão e tomada de decisão; e 4) o início de ações que possam mitigar ou mesmo impedir a ocorrência da falha ou mesmo a falência do sistema.

1.1 Contexto e motivações

Com a evolução das tecnologias evidenciou-se a grande necessidade de previsão/prognóstico de falhas dos componentes utilizados em produtos, subsistemas e sistemas em geral. A indústria aeroespacial estimulou e desenvolveu produtos e ferramentas cada vez mais poderosas. Uma das mais relevantes é a Dependabilidade (*Dependability-D*), que inclui a análise de Confiabilidade (*Reliability-R*), Manutenibilidade (*Maintainability-M*), e Disponibilidade (*Availability-A*), entre outras capacidades de suma importância. Para garantir sistemas “dependáveis” são utilizadas uma série de métodos, propriedades, ferramentas e abordagens para realizar a: 1) Prevenção/Evituação de Falhas, 2) Suporte/Tolerância a Falhas, 3) Atenuação/Correção de Falhas e, até mesmo, o tratamento de falhas antes de sua incidência no sistema, i.e., a/o 4) Predição/Prognóstico de Falhas.

Nas últimas décadas, abordagens de Prevenção, Tolerância e Correção de Falhas foram amplamente estudadas e exploradas. Em contrapartida, a abordagem de Predição de Falhas, também conhecida como abordagem para Prognóstico de Falhas é um assunto ascendente na comunidade científica. Isto porque, quando aplicada à indústria, inclui técnicas e análises que possibilitam aumentar a Disponibilidade dos sistemas, a produtividade e reduz custos com Manutenção.

São muitas as motivações para realizar a predição de falhas algumas estão listadas a seguir:

- 1) Os sistemas estão se tornando cada vez mais complexos e/ou altamente integrados, integrando várias tecnologias e operando em ambientes extremamente exigentes com pouca ou nenhuma manutenção;
- 2) A complexidade e integração dos sistemas resultam em funções de maior complexidade. Isto ocorre porque a execução de determinada função pode ser integrada e/ou tão complexa que exige mais do sistema. Um exemplo simples para esta questão é o sistema de frenagem preditiva descrito na Seção 2.5.1; onde o sistema necessita de várias variáveis de sensores para executar a frenagem de forma segura e efetiva;
- 3) Os usuários de produtos e serviços estão mais exigentes e menos tolerantes a falhas. As funcionalidades extras de um produto são tão importantes quanto a função principal. Ex.: sistemas de som, internet e GPS de um automóvel. Embora não seja possível dar o mesmo tratamento de criticidade às funções extras do sistema, as falhas devem ser mapeadas a fim de identificar a viabilidade de tratamento;
- 4) As motivações 1 e 2 colaboram para o aumento de falhas nos sistemas que podem causar grandes perdas econômicas, danos críticos e/ou até catastróficos, como por exemplo, a falha de um avião em operação ou um submarino, ou ainda, um satélite;
- 5) Os algoritmos de prognóstico são importantes para identificar os indícios precursores de falhas incipientes. Considerando o risco relacionado às funções executadas desses sistemas, a antecipação de uma falha é realmente útil: uma interpretação correta do padrão de degradação precursor de uma falha, de fato, pode auxiliar em tomadas de decisões visando o aumento da disponibilidade e Confiabilidade e Disponibilidade do sistema e na redução de custos;
- 6) O aumento da autonomia das missões, proporcionando rapidez para o diagnóstico e para tomadas de decisões antecipadas perante falhas e, redução de custos em monitoramento de estações terrenas.

Estas motivações evidenciam que o gerenciamento das falhas, o monitoramento, e as predições são questões de alta complexidade, custo e risco, necessitando serem muito bem avaliados.

1.2 Objetivo

O objetivo desta tese é estudar, detalhar e inovar modelos de carga e descarga e algoritmos por filtro de partículas para a predição de falhas (EOD, EOL, RUL) em baterias de Lítio-Íon usáveis em satélites artificiais.

1.3 Originalidade, generalidade e utilidade

A originalidade desta Tese está em inovar modelos de carga e descarga e algoritmos por filtros de partículas, sob as mesmas condições, que os da literatura disponível; e se possível, com carga computacional reduzida, que permitam embarcá-lo/migrá-lo de solo a bordo em benefício da autonomia da missão visando agilidade do prognóstico e redução de custos. (conforme a Motivação 6).

A generalidade desta Tese está no fato de o algoritmo poder ser estendido a outros sistemas e/ou equipamentos que utilizem baterias de Lítio-Íon e até de baterias de outras químicas. Sabemos que hoje essa tecnologia é extremamente utilizada em equipamentos eletrônicos inclusive portáteis, sistemas de lançamento e até satélites.

A utilidade desta Tese está no fato de o algoritmo poder ser aplicado em tais sistemas, especialmente nos projetos de satélites do INPE.

1.4 Organização deste trabalho

O Capítulo 1 apresenta a introdução, o objetivo, assim como os requisitos de originalidade, generalidade e utilidade, e a organização desta Tese.

O Capítulo 2 apresenta os conceitos básicos e a revisão da literatura. Neste capítulo foi feito o estudo, integração e conexão dos conceitos de prognóstico e suas variáveis, seus filtros, assim como conceitos, informações e modelos a respeito do sistema de aplicação (baterias).

O Capítulo 3 apresenta a formulação do problema e as abordagens para sua solução.

O Capítulo 4 apresenta a seleção e equacionamento dos filtros utilizados.

O Capítulo 5 apresenta a seleção, equacionamento e implementação dos modelos de bateria M1, M2, e M3.

O Capítulo 6 apresenta as informações a respeito do banco de dados utilizados, assim como as condições dos testes e apresenta a aplicação dos modelos M2 e M3 à predição de EOD e EOL com o uso de filtros de partículas pelos autores Saha e Goebel (2009) e Arachchige et al (2017); e seus resultados, visando compará-los e expor suas aproximações e limitações que, posteriormente, serão conjecturadas e explicadas, melhoradas e inovadas no Capítulo 7.

O Capítulo 7 apresenta: 1) as aproximações e limitações, conjecturas e explicações, melhorias e inovações implementadas no modelo M4 para a predição de EOD e EOL; 2) os resultados e discussões das predições de M2, M3, e M4, para EOD e EOL nas mesmas condições e em mais de 10 casos 4) as avaliações e comparações desses resultados e discussões segundo 3 grupos de critérios.

O Capítulo 8 apresenta as conclusões e direções futuras.

2 CONCEITOS BÁSICOS E REVISÃO DA LITERATURA

Neste Capítulo os conceitos básicos são apresentados e complementados por definições adicionais.

2.1 Dependabilidade

Dependabilidade é um termo muito utilizado na década de 80 e 90 em sistemas de computadores, em softwares. No entanto, é relativamente novo em Engenharia de Sistemas e, nos últimos anos vem ganhando destaque na Engenharia e Garantia do Produto.

Dependabilidade é uma métrica vetorial composta por outras métricas escalares que são extremamente importantes para a tomada de decisões. (SOUZA; PORTO 2016). Pode ser interpretada como uma métrica do quanto se pode depender tecnicamente, economicamente, socialmente etc., da condição de funcionamento de um componente em um ou mais instantes durante a missão; isto é, indica a qualidade do serviço prestado por um sistema e a confiança no serviço prestado.

No seu sentido mais amplo, Dependabilidade pode ser definida como a ciência da dependência sob condições incertas. Compreende: 1) o conhecimento dessas incertezas, 2) a respectiva avaliação, a sua predição, medição e seu controle. Ou ainda, a Dependabilidade tenta capturar todos os aspectos voltados à qualidade e quantidade das funções desempenhadas. Ela começa pelas capacidades/métricas escalares técnicas (como por exemplo Confiabilidade, Manutenibilidade, Disponibilidade), mas também reconhece que não bastam apenas estas. Desta forma, essa capacidade/métrica vetorial é adaptável e personalizável buscando capturar os aspectos gerenciais, de segurança, políticos, jurídicos etc.

As métricas escalares que podem compor a Dependabilidade geralmente são: Confiabilidade (*Reliability*), Manutenibilidade (*Maintainability*), Disponibilidade (*Availability*), Segurança contra Acidentes (*Safety*), Segurança contra Intrusões

(*Security*), *Capacidade (Capability)*, *Durabilidade (Durability)*, etc. (VILLEUMER, 1992; SOUZA; PORTO 2016). Estes atributos estão intensamente relacionados de tal forma que, se um atributo não cumprir os seus requisitos, a Dependabilidade estará seriamente ameaçada. E, como mencionado, a Dependabilidade é uma métrica adaptável e personalizável podendo incluir mais ou menos atributos. Na indústria o termo Dependabilidade tem sido reconhecido pelo acrônimo RAM (*Reliability, Availability and Maintainability*).

Outras três definições de autores e anos diferentes são destacadas abaixo. Estas possuem diferentes complementos à definição acima e ajudam a delinear a Dependabilidade:

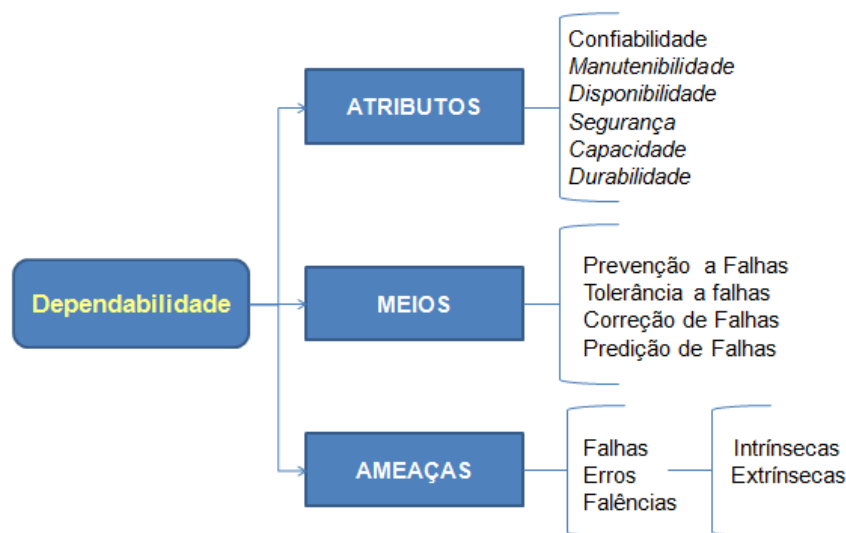
- De acordo com Lafraia (2001), a Dependabilidade pode ser expressa como: a probabilidade de um componente iniciar ou ocupar um dos seus modos de operação durante uma missão específica ou desempenhar as funções associadas aos modos de operação solicitados. É um complemento do ponto de vista técnico;
- Rabello (2016) apresenta a Dependabilidade sob a ótica da Garantia do Produto: “**Dependabilidade** é um aspecto essencial em qualquer projeto da área espacial contribuindo para a qualidade global do produto final”. É um complemento do ponto de vista da qualidade e gerencial, abordando não somente o conceito de Dependabilidade, mas também sobre o programa de Dependabilidade para missões espaciais. Orienta para as definições e escolhas de itens e materiais, direciona a análise de riscos e os pontos fracos do projeto;
- Avizienis, et al. (2004) discute os conceitos fundamentais de Dependabilidade aplicados a sistemas de computação. Neste documento são salientados os conceitos que se aplicam a sistemas espaciais. Avizienis, et al. (2004) faz uma divisão de Dependabilidade em três partes: 1) os atributos de Dependabilidade; 2) as ameaças (obstáculos para alcançar a Dependabilidade); e 3) os meios para alcançá-la, divisão ilustrada com adaptações na Figura 2.1. Esta

definição embora seja voltada à Computação, ajuda a adaptar e unificar as definições já apresentadas e criar uma visão geral e delineada de Dependabilidade.

A Figura 2.1 enfatiza que a Dependabilidade de um sistema só pode ser alcançada de forma integral se forem tratadas as ameaças (*fault, error, failure*), de forma *a priori*, buscando utilizar os meios necessários para tal tratamento. Os meios de tratar as ameaças também são conhecidos como abordagens de Confiabilidade ou Dependabilidade. No entanto, essas abordagens devem ser trabalhadas buscando atender os atributos de Dependabilidade (Confiabilidade, Manutenibilidade, etc).

Os conceitos considerados básicos e necessários para a compreensão deste trabalho estão na Figura 2.1. Esta esclarece de forma qualitativa um dos porquês de trabalhar o prognóstico de falhas e o quão ligados estão estes conceitos.

Figura 2.1: Árvore da Dependabilidade.



Fonte: Adaptado de Avizienis et al. (2004).

2.2 Os atributos da Dependabilidade

Como mencionado anteriormente, a Dependabilidade é composta por várias métricas. Geralmente na literatura são destacadas as Métricas Confiabilidade (*Reliability*), *Manutenabilidade (Maintainability)*, *Disponibilidade (Availability)*, *Segurança contra Acidentes (Safety)* e *Segurança contra Intrusões (Security)*.

- **Confiabilidade** é a capacidade de um item executar a função necessária sob condições e tempo prescritos;
- **Manutenabilidade** é a capacidade de um item ser mantido ou restaurado para um estado em que pode executar sua função sob condições e tempo prescritos;
- **Disponibilidade** é a capacidade de um item estar em estado disponível para executar uma função necessária;
- **Segurança contra Acidentes:** é geralmente medida pela probabilidade de uma entidade 'E', sob dadas condições, não causar eventos catastróficos ou críticos acidentalmente, estado onde a medida do risco de ferir pessoas ou causar danos é menor ou limitado a um risco aceitável. (VILLEMEUR, 1992);
- **Segurança contra Intrusões:** é a capacidade de o sistema operar sem falhas catastróficas intencionalmente; ou ainda, é a probabilidade de que o sistema não incorrerá em falhas catastróficas intencionalmente em um intervalo de tempo pré-determinado.

2.2.1 Confiabilidade

De acordo com Lewis (1996), Souza e Carvalho (2005), o atributo **Confiabilidade** é medido por meio da *probabilidade* do sistema funcionar sem ocorrência de falhas, durante um período de tempo e sob determinadas condições de operação, quantificando o sucesso da missão.

Segundo Souza e Porto (2016), a Confiabilidade tem a intenção de:

- ✓ Capturar os requisitos de Confiabilidade de todos os interessados (*stakeholders*) de um produto, processo, etc.;
- ✓ Desdobrá-los em especificações para todas as fases do desenvolvimento;
- ✓ Fornecer meios de análise para a verificação das fases e para a validação e certificação do produto, processo, etc.

A Confiabilidade do sistema depende de vários fatores como a qualidade, a idade dos componentes e a complexidade do sistema analisado. Ela fornece informações probabilísticas sobre o comportamento do sistema no futuro, baseando em informações probabilísticas sobre o comportamento do sistema no passado, ao longo do tempo e dos componentes. Para a determinação da Confiabilidade é relevante considerar o tempo de utilização do sistema, as características do ambiente, assim como as condições de utilização e o desempenho. (LAFRAIA, 2001; SOUZA; CARVALHO, 2005).

2.2.2 Manutenibilidade

De acordo com Souza e Porto (2016) e Lafraia (2001), **Manutenibilidade** é a *probabilidade* de que um dispositivo ou sistema será *mantido* ou *restaurado* à condição operacional em um determinado período de tempo com *procedimentos* e *recursos previstos*.

Quando aplicada a um componente de um sistema, **Manutenibilidade** é uma propriedade não somente da concepção, mas também da instalação no sistema. É expressa como uma probabilidade, refletindo a *incerteza* no *tempo exigido* para as operações de manutenção. É importante não confundir Manutenibilidade com Manutenção do item, ressaltando que:

Manutenção é “o conjunto de ações, procedimentos e recursos previstos destinados a manter ou recolocar um item na condição operacional”. A Manutenibilidade incorpora a manutenção para sistemas reparáveis.

A Manutenibilidade deve incorporar, durante as fases de concepção e desenvolvimento, aspectos como: métodos, informações e pessoal requerido para o diagnóstico em cada fase, procedimentos (plano de voo, troca de componentes, alterações no circuito impresso, soldas, etc.), ferramentas, etc.

2.2.3 Disponibilidade

Esta métrica pode ser classificada em Disponibilidade Média (*Mean Availability*) e Disponibilidade Pontual (*Point Availability*). Disponibilidade Média é interpretada como a Disponibilidade Operacional, durante o período de vida útil. É a proporção do tempo de atividade do sistema (tempo total em que o sistema está disponível) dividido pelo tempo total de operação (tempo total) (RELIAWIKI, 2017).

$$\bar{A} = \frac{Uptime}{Total\ time} \quad (2.1)$$

Disponibilidade Pontual é a capacidade de um item estar em estado disponível para executar uma função necessária, definida como a probabilidade de um sistema ser capaz de exercer a sua função requerida em um determinado instante de tempo.

O atributo Disponibilidade tem grande consequência em muitas missões, pois o sistema deve exercer a função requerida no instante exato de solicitação como, por exemplo, uma aeronave que é carregada e programada para partir; ou um míssil balístico o qual pode ser ordenado a ser lançado em qualquer momento; ou, ainda, um *no-break* hospitalar em qualquer situação de interrupção ou variação da energia elétrica. *A Disponibilidade depende claramente da Confiabilidade e da Manutenibilidade de cada sistema.*

2.3 Ameaças à Dependabilidade de sistemas: falhas

Este tópico é destinado à terminologia relacionada a falhas. É particularmente difícil uma definição que abranja em si o entendimento comum sobre estes


termos, de maneira universal. Por isto, a seguir são dadas as definições escolhidas que serão tomadas como terminologia ao longo deste documento.

A definição de **falha** em Confiabilidade seria o insucesso parcial no funcionamento do produto. Isermann (2006) complementa com outra definição mais abrangente e clara para **falha (fault)**, como: “um desvio não permitido de ao menos uma propriedade ou característica do sistema de sua condição padrão, usual, aceitável”.

Lafraia (2001) apresenta a definição de **taxa relativa de falhas** (representada por λ) em Confiabilidade como: “a frequência relativa com que as falhas ocorrem, num certo intervalo de tempo, medida pela percentagem de falhas para cada hora de operação ou número de operações do sistema ou componente”. Isso indica a necessidade de entender e definir os tipos de falhas a fim de trabalhar o sistema estudado para que não venha a falhar em operação.

A taxa relativa de falhas dos produtos ao longo do tempo de um componente ou sistema é modelada de uma maneira geral pela “**Curva da Banheira**” (“*Bathtub Curve*”). Esta curva associa as Fases do Ciclo de Vida do componente (I- Mortalidade Infantil, II- Vida Útil e III- Desgaste ou Envelhecimento) aos possíveis valores da taxa de falhas, como mostra a Figura 2.2.

Figura 2.2: Curva de Falhas conhecida como "Curva da Banheira".



Existem muitos termos referentes a falhas e de grande importância para a análise de sistemas. Abaixo são destacados:

Erro (*Error*) pode ser interpretado como a discrepância observada entre uma variável medida e uma faixa aceitável para o valor esperado desta variável. Um erro é tipicamente um sintoma para a existência de uma falha em algum artefato (GLINZ, 2014).

Sintoma da Falha é qualquer alteração da percepção normal do sistema. É uma manifestação e/ ou sinalizador observável da falha.

Assinatura (*Signature*) da Falha é o rastro da falha feito a partir de um conjunto de sintomas, pelo qual é possível identificar qual falha ocorreu, por exemplo, no espectro de frequências, que pode ser usado para a identificação da falha. (TEIXEIRA, 2007).

Causa da Falha - causa presumivelmente associada a um determinado modo de falha (ECSS, 2009).

Modo de Falha – É a maneira ou forma como o item falha. A anormalidade de desempenho do item, o leva a ser classificado como falho (SGOBBA, 2016).

Criticidade da Falha - Uma medida combinada da severidade de um modo de falha e sua probabilidade de ocorrência (ECSS, 2009).

Efeito da Falha - Consequência de um modo de falha de certo item na operação, função ou status do item (ECSS, 2009).

Propagação da Falha - Evento físico ou lógico causado por falha interna do produto que pode levar a falhas externas. Ou seja, os modos de falha que podem se propagar para as interfaces (ex. da nave para a carga útil) (ECSS, 2009; SGOBBA, 2016).

Repertório de Falhas - é o conjunto das falhas que devem ser estudadas e tratadas. É a especificação básica para o desenvolvimento de um Sistema de Detecção e Diagnóstico de Falhas.

Efeito Final - Consequência de um modo de falha, endereçado a um item, no funcionamento, função ou estado do produto sob investigação e suas interfaces (ECSS, 2009).

Falência (*Failure*) - é definida como a interrupção permanente da habilidade do sistema de realizar uma determinada função sob condições de operação específicas. E pode ser classificada em:

- **Falência Insignificante ou Menor (*Insignificant/Minor Failure*):** Qualquer falha que poderia causar degradação menor nas funções de desempenho do sistema ou da missão, sem qualquer dano considerável à vida ou a um componente do sistema;
- **Falência Significante ou Maior (*Significant/Major Failure*):** Qualquer falha que poderia causar degradação maior nas funções de desempenho do sistema ou missão, com qualquer dano considerável à vida ou a um componente do sistema;
- **Falência Crítica (*Critical Failure*):** Qualquer falha que poderia causar a perda da missão, que poderia causar lesões incapacitantes, mas não fatais ou doenças ocupacionais temporárias; dano crítico a propriedades públicas ou privadas; dano crítico ao sistema de voo e interface ou as instalações terrestres e/ou dano crítico ao meio ambiente;
- **Falência Catastrófica (*Catastrophic Failure*):** Qualquer falha que poderia causar potencialmente a perda de vidas, lesões incapacitantes ou doenças ocupacionais permanentes, perda do sistema de voo e interface, perda de instalações do lançamento, perda do sistema e/ou efeitos ambientais altamente prejudiciais. (LEITE, 2007; VILLEMEUR,1992; ECSS, 2009a; 2009b).

Cada instituição adapta a classificação das categorias de Severidade para atender às necessidades específicas de cada programa. Estas classificações de Severidade são apresentadas, para cada Programa do INPE, nos documentos de Requisitos da Garantia do Produto, conforme a Tabela 2.1.

Tabela 2.1: Categorias de Severidade.

Categoria de Severidade	Efeito no Subsistema
Catastrófica	Perda do tempo de vida do Subsistema maior que 50%
Crítica	Perda do tempo de vida do Subsistema entre 25% e 50%
Significante ou Maior	Perda de qualquer equipamento redundante
Insignificante	Outros

Fonte: ECSS (2009a e 2009b).

Itens Críticos - são os itens cujas falhas são ameaças potenciais para o desempenho, qualidade, dependabilidade e segurança de um sistema, podendo atingir várias unidades (subsistema, equipamento, componente, material, processo e função).

Um item (componente, equipamento, subsistema ou sistema) é considerado item crítico quando seu modo de falha for identificado como “*Single Point Failure*” (termo geralmente traduzido por “Ponto de Falha Único” ou “Ponto Único de Falha” ou ainda “Ponto Crítico de Falha”) juntamente com, pelo menos, uma classificação de severidade do efeito da falha identificada como catastrófica, crítica ou maior (ECSST, 2009) No entanto, caso o item tenha uma altíssima confiabilidade ou probabilidade de ocorrência muito baixa este pode não ser considerado crítico;

Outra maneira de identificar um item como crítico é quando um dos seus modos de falha possuir consequências de falha classificadas como catastróficas.

2.3.1 Tipos de falhas

Dos vários tipos de falhas, neste documento são destacados os tipos:

- **Falhas Simples** - são aquelas que atingem somente um parâmetro ou componente por vez;

- **Ponto Único de Falha ou Ponto de Falha Único (*Single Point Failure*):** É a falha de um item que pode resultar na falha irrecuperável do sistema e não é compensada através de redundância ou procedimento operacional alternativo (MIL-STD-1629, 1983);
- **Falhas Múltiplas ou Compostas** - são aquelas que atingem vários parâmetros ou componentes simultaneamente, podendo se propagar e afetar mais de um parâmetro do sistema;
- **Falhas de Modo Comum** - são duas ou mais falhas do mesmo Modo de Falha, devidas a uma única causa;
- **Falhas Abruptas** - são falhas repentinas de um componente;
- **Falhas Incipientes** - são falhas que ocorrem lentamente em um componente;
- **Falhas Latentes** - são falhas ocultas, que não são imediatamente detectáveis;
- **Falhas Intermitentes** – São a perda de algumas funções ou alguma característica em um produto por um período limitado; este, subsequentemente, recupera a sua função. (QI; GANESAN; PECHT; 2008).

2.4 Meios de melhorar a Dependabilidade de sistemas

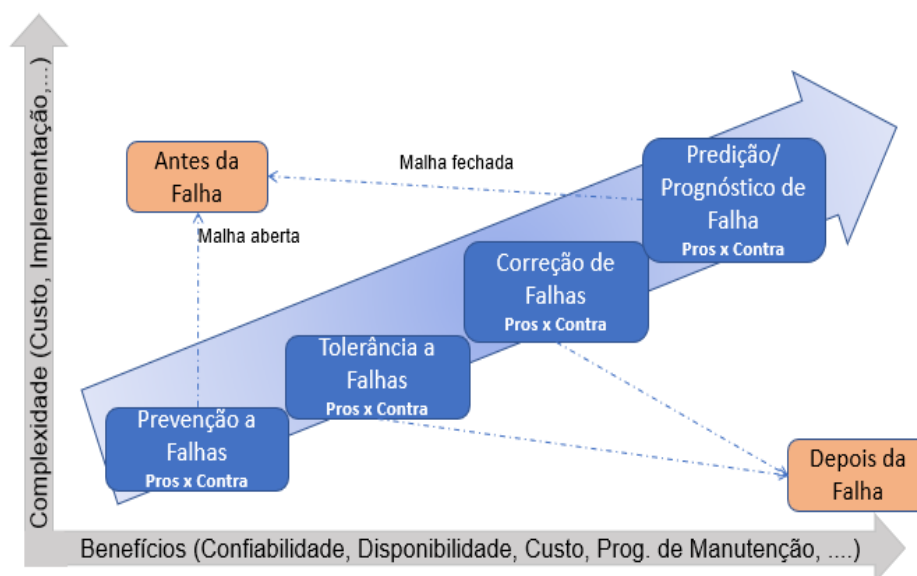
Para melhorar a Dependabilidade de sistemas é necessário o estudo e controle dos possíveis erros (*errors*), falhas (*faults*), defeitos (*defects*) e falências (*failures*). Existem quatro abordagens que trabalham o sistema com uso de métodos, propriedades e ferramentas para realizar a prevenção, tolerância, correção e até o predição da falha no sistema antes que esta ocorra. Essas abordagens são:

- **1) Prevenção/Evituação de Falhas (*Fault Avoidance*)** – Abordagem que tenta impedir a ocorrência ou introdução de falhas. Envolve a seleção de métodos de projeto e de tecnologias adequadas para os seus componentes;

- **2) Tolerância/Suporte a Falhas** (*Fault Tolerance*) – Abordagem que fornece o serviço esperado mesmo na presença de falhas. Tolerância à ocorrência da falha;
- **3) Correção/Atenuação de falhas** (*Fault Correction*) – Abordagem que expressa a capacidade do sistema eliminar ou contornar as falhas, voltar ao estado correto de operação;
- **4) Predição/Prognóstico de falhas** (*Fault Prediction/Prognostic*) – Abordagem que procura a determinação do tipo, tamanho, localização da falha antes mesmo que ela ocorra e não permite que incida.

A Figura 2.3 mostra a relação entre as quatro abordagens para melhorar a Dependabilidade de sistemas. A primeira e a quarta abordagens tratam o sistema antes da falha ocorrer. A primeira ocorre em malha aberta, utiliza métodos e técnicas (que serão mencionados a seguir) a fim de prevenir a falha. A segunda e a terceira abordagens são utilizadas após a ocorrência da falha. A segunda é trabalhada nas fases de projeto para garantir níveis que possam contornar a falha. A terceira utiliza técnicas e métodos para que o sistema volte ao estado normal de funcionamento após a falha. Já a quarta abordagem ocorre em malha fechada, utiliza dados do próprio sistema, por meio de sensores, para monitorar os parâmetros a fim de obter uma predição de: 1) quando e 2) onde pode ocorrer a falha. Esta proporciona a opção de tratar e/ou gerenciar ações para que a mesma não ocorra, a depender dos requisitos da missão. Esta abordagem também trata em prever a Vida Útil Remanescente (*Remaining Useful Life - RUL*) do sistema. Algumas das técnicas e métodos utilizados nessas abordagens são descritas a seguir.

Figura 2.3: Relação entre as quatro abordagens para melhorar a Dependabilidade.



2.4.1 Propriedades e métricas/métodos para a melhoria da Dependabilidade

São muitas as propriedades e métricas utilizadas em sistemas que ajudam na produção de sistemas “dependáveis”. As propriedades e métricas enfatizadas neste documento são: Redundância, Cobertura, Tempo Médio até a Falha (MTTF), Tempo Médio entre Falhas (MTBF), Tempo Médio para Reparo (MTTR), Detecção e Isolação/Identificação de Falhas (FDI), e Detecção, Isolação/Identificação de Falhas e Recuperação/Reconfiguração/Reposição/Reparo do Sistema (FDIR).

Redundância (*Redundancy*) é a propriedade de um dispositivo ou sistema ter mais do que um meio de executar sua função, sob um **gerenciamento da redundância**, sendo essa uma das técnicas utilizadas para aumentar a Confiabilidade, ou seja, tornar o sistema tolerante a falhas. Esta propriedade permite tolerar uma falha de um ou mais componentes, sem comprometer o funcionamento do sistema. A redundância do sistema não implica necessariamente haver componentes extras dentro do sistema (**Redundância Física/por Hardware**), mas implica que o mesmo fornece mais de uma forma

de derivar e processar a informação desejada (**Redundância Analítica ou Informacional/por Software**).

Um sistema que não tem redundância é chamado de **Simplex**. Quando se analisa essa configuração mais simples, que é o modo sem redundância (*Simplex*), a análise se limita em avaliar o funcionamento de cada componente, pois, se todos os componentes funcionarem, então o sistema operará sem falhas. Pode-se mensurar individualmente o grau de falha de cada componente e o impacto de cada componente no funcionamento do sistema.

Componentes redundantes podem ser operados em duas maneiras diferentes no sistema: A Redundância Ativa (*Active Redundancy*) e a Redundância em Espera (*Standby Redundancy*).

- **Redundância Ativa** se refere a uma configuração do sistema em que todos os componentes estão em funcionamento durante todo o período de operação. Neste caso, os conjuntos de componentes redundantes podem ser utilizados para verificar a consistência no seu funcionamento. Neste caso não há necessidade de chavear para o elemento redundante ou desconectar a unidade que falhou. A ECSS-Q-ST-30-02C (2009) resume-o como “*Estado em que todos os meios para realizar uma função requerida se destinam a funcionar simultaneamente*”;
- A **redundância em Espera** é a que os componentes redundantes ficam inoperantes até ser necessário; e, somente após a necessidade (devido à falha), são colocados em serviço a partir de chaveamento.

Cobertura (Coverage) é a propriedade de um sistema que define sua capacidade de tolerar falhas de um subconjunto específico de componentes.

Sistemas redundantes podem ser concebidos para fornecer uma cobertura para falhas de alguns dos seus componentes, mas não todas elas. Um sistema pode também ser concebido para cobrir a primeira falha de um componente de certo tipo, mas não o segundo. A cobertura fornecida por um sistema é uma

descrição específica do seu nível de redundância (SOUZA; CARVALHO, 2005; RELIASOFT COPORATION, 2010).

Tempo Médio até a Falha (*Mean Time to Failure – MTTF*) Este pode ser interpretado como o tempo esperado para a falha de sistemas não reparáveis.

Souza e Porto (2016) afirmam que este conceito se aplica em situações que não admitem reparos (contexto espacial), caso em que seria mais significativo chamar de “*tempo médio de operação esperado*”. É, naturalmente, possível e provável que o tempo médio para a primeira falha de um componente (MTTF) seja diferente do tempo médio para a outra falha (MTBF), após uma falha e reparação. Isto depende “se o componente reparado ficou tão bom quanto um novo”, ou seja, se as suas características ao longo da vida após o reparo são essencialmente as mesmas que para um componente novo do mesmo tipo. Na prática, raramente se tem informações suficientes para distinguir MTBF de MTTF (SOUZA; CARVALHO, 2005).

Tempo Médio entre Falhas (*Mean Time Between Failures - MTBF*) É um indicador comum de Confiabilidade de componentes e sistemas. É definido no contexto em que o equipamento de missão que falhou é reparado (sistemas com possibilidade de manutenção) e devolvido para serviço. Nesse contexto, MTBF é o tempo esperado que o componente irá executar corretamente sua função até a próxima falha.

$$MTBF = \frac{1}{\lambda}, \quad \lambda = \text{taxa de falhas} \quad (2.2)$$

Tempo Médio para Reparo (*Mean Time to Repair - MTTR*) Este é o tempo esperado para o dispositivo ou sistema retornar ao serviço após um chamado de manutenção. Não é utilizado no contexto espacial.

Detecção e Isolação/Identificação de Falhas (*Failure Detection, Isolation/Identification - FDI*) Esta é a função de detectar a ocorrência de

falhas de componentes em sistemas operacionais e isolar ou identificar o componente que falhou. FDI implica um processo de tomada de decisão. É implementado em algumas formas de sistemas tolerantes a falhas, mas não em todos.

Detecção, Isolação/Identificação de Falhas e Recuperação/Reconfiguração/Reposição/Reparo do Sistema (*Failure Detection, Isolation/Identification and System Recovery/Reconfiguration/Replace/Repair - FDIR*)
Esta é a propriedade FDI adicionada da função de recuperar/reconfigurar/substituir/reparar o componente que falhou.

Em geral, muitos métodos/ferramentas são utilizados para trabalhar as abordagens de Prevenção a Falhas, Tolerância a Falhas, Correção de Falhas e Predição de Falhas. Igualmente, muitos métodos, ferramentas e abordagens são usados para analisar o impacto das falhas na Confiabilidade do sistema. Dos muitos métodos se destacam:

- Análise da Árvore de Falhas (FTA – *Fault Tree Analysis*);
- Análise dos Modos e Efeitos de Falhas (FMEA – *Failure Modes and Effects Analysis*);
- Análise dos Modos, Efeitos e Criticidade de Falhas (FMECA – *Failure Modes, Effects and Criticality Analysis*);
- Análise da Árvore de Eventos (ETA – *Event Tree Analysis*);
- Diagrama de Blocos de Confiabilidade (RBD – *Reliability Block Diagram*);
- Análise de Markov (*Markov Analysis*).

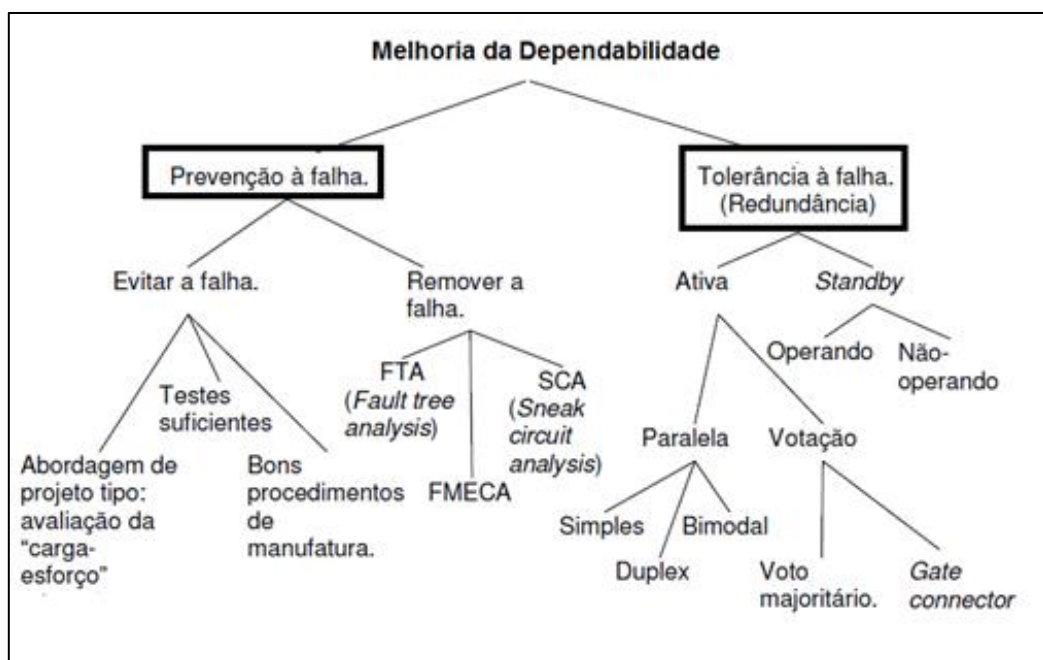
Usualmente esses métodos são complementares, pois alguns são utilizados em conjunto para definir quais falhas merecem mais atenção. Estes métodos/ferramentas são extremamente úteis e vêm sendo utilizados há muitas décadas; no entanto, estes focam na preservação do sistema em modo normal de operação. Em uma análise *a priori*, essas ferramentas são muito utilizadas na primeira abordagem de Confiabilidade (Prevenção à Falhas).

A abordagem de Prevenção de Falhas foca em evitar a falha e/ou eliminar as falhas ou as fontes propícias a falhar com bons procedimentos de manufatura, métodos de projeto, testes para detectar possíveis falhas precoces e removê-las, etc. A Prevenção de Falhas está relacionada com a verificação do projeto, onde se utilizam os vários métodos já citados neste documento. Mesmo realizando esta abordagem a fim de evitar falhas, ainda podem ocorrer falhas inesperadas; então, para um projeto mais robusto a abordagem de Tolerância a Falhas é aplicada ao sistema. Esta tem por objetivo que o sistema tenha mais de um meio de realizar certas funções, para que, mesmo com alguma parte falhada, o sistema possa cumprir com sucesso sua missão. Ver Figura 2.4.

Na Figura 2.4 são apresentadas as características de duas abordagens de Confiabilidade: Prevenção de Falhas e Tolerância a Falhas, sendo estas amplamente utilizadas para melhoria da Confiabilidade em desenvolvimento de projetos.

O foco deste trabalho está na quarta abordagem de Confiabilidade que será destacada no próximo tópico.

Figura 2.4: Características das abordagens 1 e 2 na melhoria da Dependabilidade.



Fonte: Adaptado de Asenek, Sweeting e Ward (2017).

2.5 Prognóstico de falhas

Prognóstico é uma palavra que consiste das palavras gregas *pro* e *gnosis*, traduzidas pela habilidade em adquirir conhecimento (*gnosis*) a respeito de eventos, antes (*pro*) que estes ocorram. Segundo Vachtsevanos (2006), “é a habilidade de prever precisamente a RUL de um componente ou subsistema com futura falha”.

Prognóstico é uma tecnologia usada para monitorar a degradação do sistema, prever quando a falha pode ocorrer e melhorar a confiabilidade do sistema; e, quando aplicada ao mundo da manutenção, fornecer uma estratégia econômica para a manutenção programada (SUTHARSSAN et al., 2017).

Como já mencionado, o interesse em prognóstico de falhas para sistemas, subsistemas, equipamentos componentes, etc., assim como na manutenção de sistemas complexos e/ou altamente integrados tornou-se um assunto de destaque nas organizações e comunidades científicas. E está sendo aplicado a uma ampla variedade de problemas e sistemas aeronáuticos, espaciais, automotivos eletrônicos e mecânicos, o que fez crescer uma área chamada Prognóstico e Gerenciamento da Saúde (*Prognostics and Health Management - PHM*). PHM é uma estrutura que oferece soluções abrangentes e individualizadas para gerenciar a saúde do sistema. As tecnologias desta área reduzem os custos de manutenção dos produtos e processos com o uso de atividades voltadas ao diagnóstico e prognóstico. O objetivo principal destas atividades é fornecer informações para a tomada de decisões visando melhorias de desempenho, confiabilidade, manutenção e segurança.

Mudanças no comportamento do sistema sugerem problemas futuros. Para garantir o estado do sistema e como este irá evoluir com o tempo, existem os sistemas de Prognóstico e Monitoramento de Saúde (*Prognostics and Health Monitoring- PHM*) (WALD, 2010; SUTHARSSAN, 2017). Para não confundir os termos, neste trabalho a sigla PHM será utilizada para tratar de Prognóstico e Gerenciamento da Saúde.

A capacidade de: 1) evitar (SOUZA; CARVALHO, 2005); ou detectar e isolar/identificar (diagnosticar) para: 2) tolerar (SOUZA; PORTO, 2016) ou 3) corrigir (SOUZA; PORTO, 2016) as falhas de um componente ou subsistema com base em: a) seus estados anteriores e atuais e b) nos dados operacionais disponíveis, tem sido um tópico de pesquisa de alta prioridade há algumas décadas (ROEMER; NWADIOGBU; BLOOR, 2001).

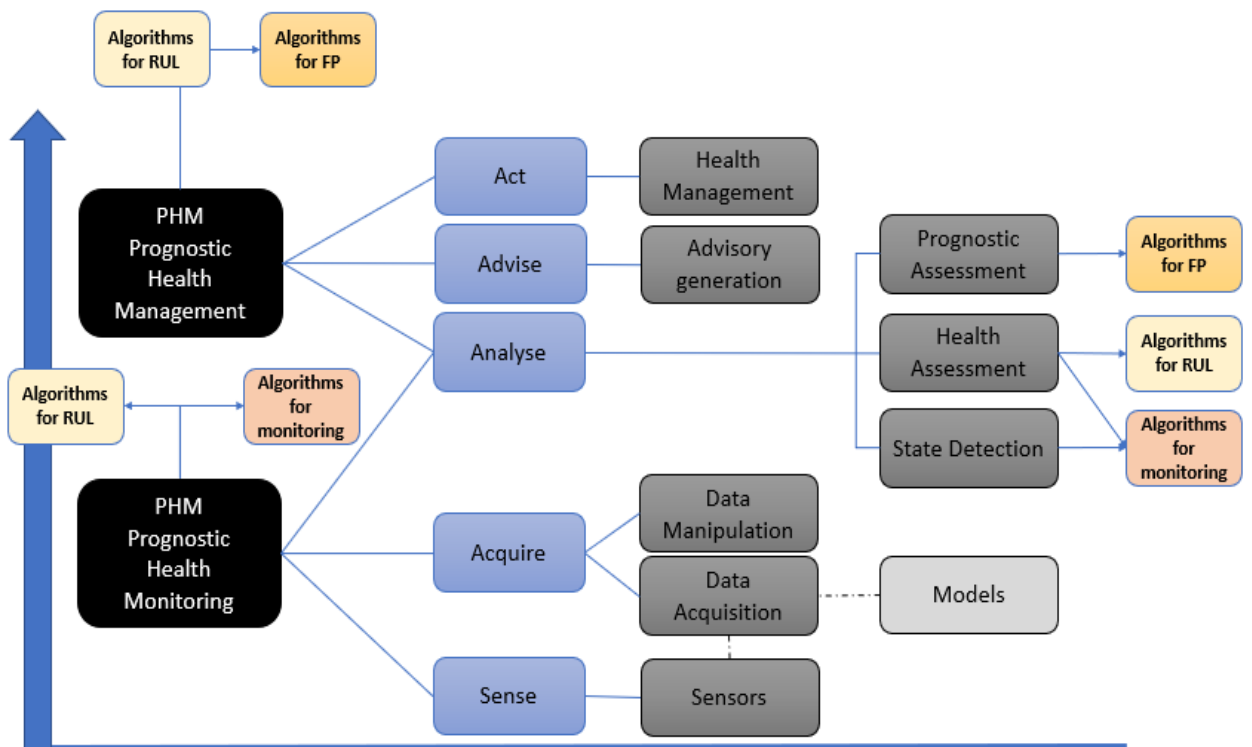
Para atender aos requisitos de Dependabilidade e Suportabilidade, é necessário tratar um número crescente de falhas. Os fabricantes estão investindo cada vez mais no monitoramento da saúde dos sistemas. Para alcançar um PHM efetivo e eficaz, é necessário avaliar a saúde atual de um componente, muitas vezes monitorar o estado de saúde para detectar falhas antes de ocorrerem danos. O monitoramento da saúde é realizado para detectar a degradação subjacente, avaliar e propiciar contramedidas para impedir as falhas em desenvolvimento e evitar que falhas catastróficas ocorram.

Segundo a visão deste trabalho, o processo de prognóstico se resume em: 1) “ver”, 2) “julgar”, e 3) “agir” (como o da Igreja Católica). A Figura 2.5 detalha esse processo, que pode ser adaptado e aplicado também aos algoritmos de predição; mostra também onde estão mais presentes o Monitoramento e o Gerenciamento Prognóstico da Saúde; e onde os principais algoritmos atuam neste processo. O sistema começa em:

- “Ver”: no diagrama representado por “Sense” e “Acquire”, onde o sistema irá usar os sensores e/ou modelos para a aquisição de dados necessários e/ou a manipulação deles;
- “Julgar”: no diagrama representado por “Analyse” e “Advise”, onde são feitas a detecção e avaliação do estado de saúde, assim como a avaliação prognóstica, e são geradas também as possíveis ações;
- “Agir”: no diagrama representado por “Act”, onde são tomadas (ou não) as decisões cabíveis ao sistema levando em conta os requisitos e objetivos da missão.

A Figura 2.5 traduz o objetivo principal do monitoramento da saúde do sistema, que é: a) neutralizar as consequências da alta complexidade e/ou integração dos sistemas e b) tratar falhas de maneira *a priori* e informada. Com o uso de dados dos sensores, eles realizam: 1) o monitoramento e a avaliação do estado de saúde dos componentes do sistema; 2) a estimativa da RUL; 3) a gestão e a tomada de decisão; e 4) o início de ações que possam mitigar ou mesmo impedir a ocorrência da falha ou mesmo a falência do sistema. O prognóstico atua na propagação virtual da falha atua em prever quando o sistema atingirá um nível de desempenho insatisfatório; e assim faz a estimativa de quando o item não funcionará mais dentro das especificações indicadas.

'Figura 2.5: Visão geral do sistema prognóstico.



Fonte: Adaptado de IEEE (2017).

2.5.1 Uso de sensores

Conforme já mencionado e corroborado por Carillo (2017), nos últimos anos, os sistemas tornaram-se cada vez mais complexos e/ou altamente integrados, e o número de sensores nos sistemas, como por exemplo, numa aeronave, aumentou drasticamente. Essa complexidade e/ou integração do sistema e essa multiplicidade de sensores resultaram em dados cada vez mais numerosos, complexos; e tornaram cada vez mais crítica a capacidade de extrair, organizar e analisar dados.

O uso de sensores tem sido amplamente adotado devido ao alto poder da Computação e da Comunicação, assim como ao atual baixo custo de componentes eletrônicos, o que colaborou para o impulsionamento das técnicas de prognóstico. Os sensores são utilizados para monitorar as condições operacionais, desempenho, ciclos de carregamento etc. de um item, ver Figura 2.6. Alterações no comportamento do sistema sugerem problemas futuros. Portanto, existem sistemas de monitoramento e predição de saúde para estimar o estado do sistema e como ele evoluirá com o tempo. (SUTHARSSAN et al, 2017; WALD et al, 2010).

O desempenho exigido do sistema do sensor deve ser considerado durante a análise da aplicação. Os atributos de desempenho relevantes incluem: acurácia, sensibilidade, precisão, resolução, faixa de medição, repetibilidade, linearidade, incerteza, tempo de resposta, tempo de estabilização (CHENG; AZARIAN; PECHT, 2008).

Dependendo da complexidade e/ou integração do produto monitorado, é possível monitorar milhares de parâmetros em todo o ciclo de vida do produto para fornecer as informações necessárias para o prognóstico. Para avaliar com precisão a saúde e prever a RUL, é fundamental monitorar os parâmetros. Geralmente os parâmetros a serem monitorados incluem: parâmetros de desempenho (por exemplo, fluxo, velocidade de rotação do motor); características físicas (por exemplo, deslocamento angular, fase e torque); parâmetros elétricos (por exemplo, tensão, corrente, resistência e impedância); condições ambientais (por exemplo, temperatura, pressão, vibração, umidade e

campo magnético) e condições operacionais (por exemplo, frequência de uso, gravidade do uso, e tempo de uso) (DONG et al, 2019; CHENG, AZARIAN, e PECHT, 2008 e CHENG, TOM, THOMAS e PECHT, 2010).


De acordo com Pecht (2008), parâmetros a serem monitorados em uma implementação de monitoramento para PHM podem ser selecionados com base em seu relacionamento com funções cruciais para a segurança. Isto visa controlar e prevenir falhas catastróficas, que podem impedir a conclusão da missão ou falhas maiores, que podem resultar em períodos longos de inatividade. A seleção também se baseia no conhecimento dos parâmetros críticos estabelecidos por experiências anteriores, dados de falhas de campo em produtos similares e por testes de qualificação. Métodos mais sistemáticos, como FMEA, podem ser usados para determinar parâmetros que precisam ser monitorados.

O uso de sensores para prognóstico de falhas foi estendido a vários setores e aplicações, como, por exemplo, no setor automotivo (BOSH, 2018a; BOSH, 2018b; THORAT; THORVE; UPASE; DHUPAR, 2016). Um dos muitos exemplos desse setor é o sistema de frenagem de emergência automática (BOSH, 2018b; THORAT; THORVE; UPASE; DHUPAR, 2016). Este sistema utiliza sensores para melhorar a segurança e a confiabilidade da frenagem dos veículos. Este sistema preditivo de frenagem de emergência é ativado quando o motorista liga o veículo. Ele fornece suporte aos motoristas, ajudando-os a evitar colisões, independentemente da velocidade. O sistema consiste em: 1) Programa Eletrônico de Estabilidade (ESP – *Electronic Stability Program*), responsável por monitorar a trajetória dos veículos e atuar individualmente sobre os freios, ativando cada um na medida correta para manter o veículo sob controle; 2) sensor de radar de longo alcance; 3) sensor de radar de médio alcance; 3) câmera de vídeo estéreo; 4) radar/vídeo combinados e 5) câmera multifuncional.

Como já mencionado, complexidade e/ou integração são fatores que aumentam o desafio em diagnosticar falhas nos sistemas. A Figura 2.5 mostra um exemplo de muitas aplicações para monitoramento de saúde de um

automóvel. A Figura 2.6 exemplifica as inúmeras possibilidades para o uso de sensores no setor automotivo. Pense em qualquer coisa que liga/desliga, abre/fecha, requer transferência de energia, iluminação, partida, medição ou detecção; desde leituras no painel de instrumentos à medição de líquido de arrefecimento, freio, pára-brisa, água no combustível, pressão dos pneus e emissões. Existem muitas possibilidades de adquirir dados através de sensores e monitorar variáveis de interesse.

Figura 2.6: Diversas possibilidades de aplicações com sensores.



Fonte: Standex Electronics (2019)..

2.5.1.1 Desempenho do sistema do sensor

Segundo Pecht (2008), o desempenho exigido do sistema de sensores deve ser considerado durante a análise da aplicação. Os atributos de desempenho relevantes incluem: acurácia, sensibilidade, precisão, resolução, faixa de medição, repetibilidade, linearidade, incerteza, tempo de resposta, tempo de estabilização, a saber:

Acurácia: medida pela proximidade/concordância/diferença entre a medição e o valor real da variável medida;

Sensibilidade: medida pela variação da saída em relação a uma certa variação na entrada (inclinação da curva de calibração);

Precisão: medida pelo número de dígitos significativos nos quais uma medida pode ser mensurada com confiabilidade;

Resolução: medida pela alteração mínima da entrada necessária para produzir uma alteração detectável na saída;

Faixa de medição: medida pelo intervalo entre os valores máximo e mínimo da variável que podem ser medidos;

Repetibilidade: medida pela proximidade/concordância/diferença entre os resultados de medições sucessivas do mesmo parâmetro realizadas sob as mesmas condições de medição;

Linearidade: medida pela proximidade da curva de calibração com uma linha reta correspondente ao comportamento teórico;

Incerteza: medida pela faixa de valores que contém o valor verdadeiro da quantidade medida;

Tempo de resposta: medida pelo tempo que um sensor leva para reagir a uma determinada entrada;

Tempo de estabilização: medida pelo tempo que um sensor leva para atingir uma saída em estado estacionário após a exposição a uma entrada estável.

2.5.1.2 Custos

De acordo com Pecht (2008), a seleção do sistema de sensores adequado para uma determinada aplicação PHM deve incluir uma avaliação dos custos. A avaliação de custos deve abordar o custo total, incluindo a compra, instalação, manutenção e substituição de sensores.

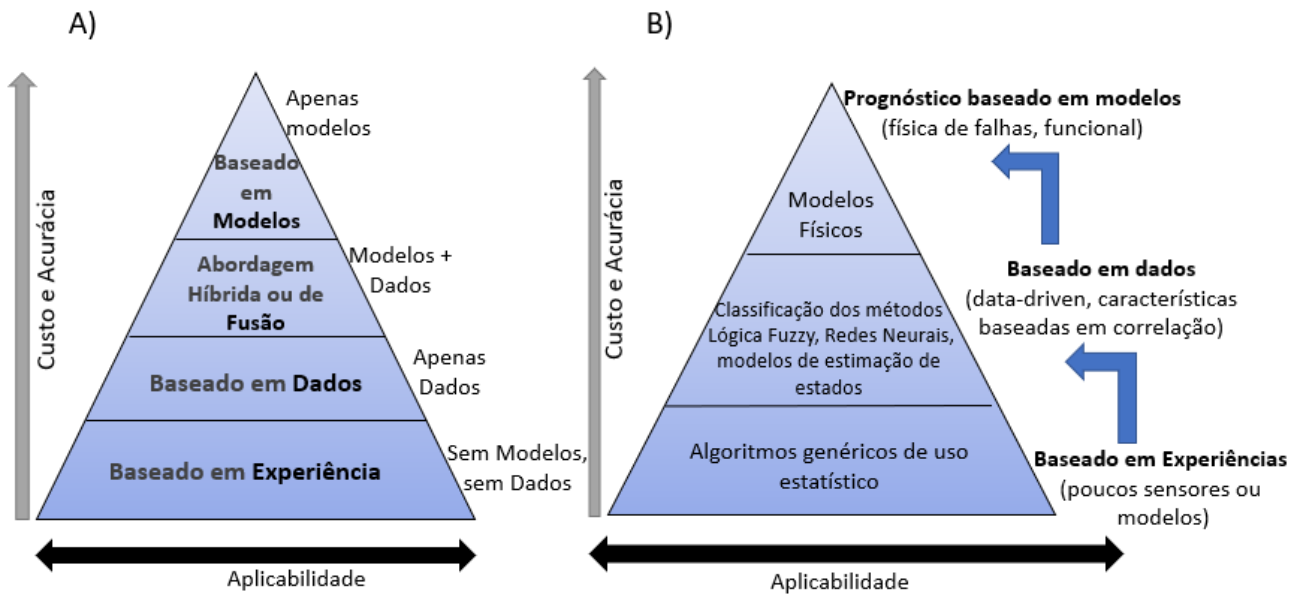
Os métodos de prognóstico e gerenciamento de saúde (PHM) para esses produtos são mais complexos, porque mais parâmetros precisam ser monitorados e mais elementos são necessários. Nesse caso, o custo total pode diferir consideravelmente para diferentes estratégias de integração de sistemas de sensores (PECHT, 2008; CHENG; TOM; THOMAS; PECHT, 2010).

2.5.2 Abordagens de tratamento de falhas

Existem muitas técnicas diferentes que são utilizadas em abordagens de tratamento de falhas para prognóstico. Vachtsevanos (2006) as categoriza em 1) Abordagem baseada em dados; 2) Abordagem baseada em modelos; e 3) Abordagem baseada em experiência. Sutharssan (2017) destaca apenas três abordagens de prognósticos: 1) Abordagem baseada em dados; 2) Abordagem baseada em modelos; e 3) Abordagem híbrida ou de fusão, que seria a fusão das duas primeiras abordagens. O autor considera que a 4) Abordagem baseada em experiência (referenciada por Vachtsevanos, 2006) se encontra dentro de (1).

A Figura 2.7 relaciona as abordagens com os aspectos de aplicabilidade, acurácia e custo. As abordagens mais próximas do topo da pirâmide possuem maior acurácia e custo no desenvolvimento; no entanto, perdem em generalidade, pois tornam-se mais específicas.

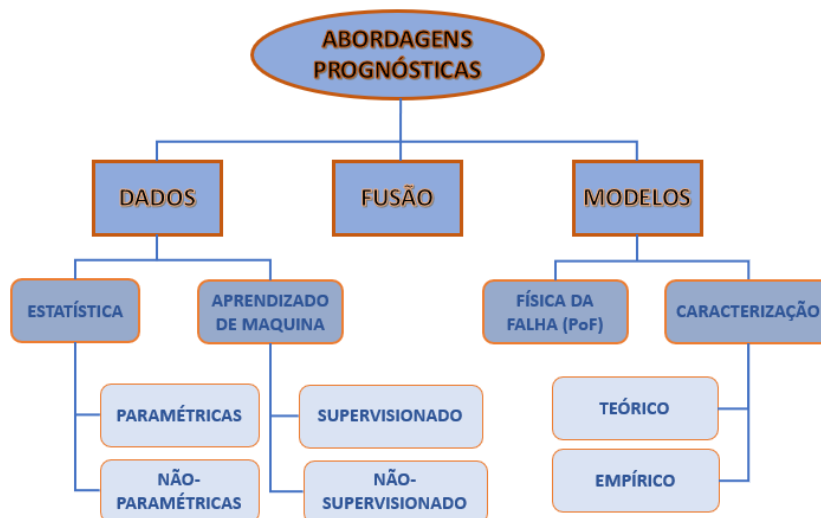
Figura 2.7: Categorização das abordagens de tratamento de falhas.



Fonte: Adaptado de: a) Sutharssan (2017) e b) Vachtsevanos (2006).

Embora exista a caracterização de quatro abordagens, resumidas na Figura 2.7a, para tratamento de falhas voltadas ao prognóstico, este trabalho irá considerar apenas Modelos+Dados, a abordagem híbrida ou de fusão. A Figura 2.8 mostra de forma reduzida as técnicas utilizadas em Dados e Modelos.

Figura 2.8: Resumo das técnicas utilizadas em Dados e Modelos.



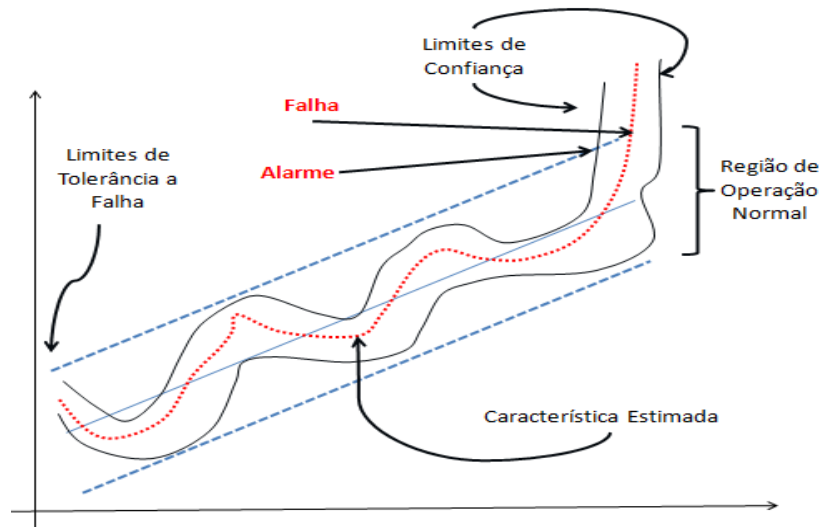
2.5.2.1 Abordagens de tratamento de falhas baseadas em dados

As abordagens baseadas em dados usam dados históricos para aprender automaticamente um comportamento do sistema. São consideradas como abordagens de "caixa preta" (*black box*) para prognósticos, uma vez que não exigem modelos de sistema ou conhecimento específico do sistema para iniciar os prognósticos. Usualmente, podem ser classificadas em técnicas estatísticas e de aprendizado de máquina, conforme a Figura 2.8. As técnicas estatísticas podem ser paramétricas ou não paramétricas; já as técnicas de aprendizagem de máquinas podem ser: por aprendizagem supervisionada, onde os dados do teste estão disponíveis ou por aprendizagem sem supervisão, onde os dados do teste não estão disponíveis. (SUTHARSSAN, 2017; SCHWABACHER, 2005).

Os dados históricos e/ou de monitoração são utilizados para aprender o comportamento do sistema e fazer o prognóstico. Esta abordagem apresenta boa precisão e aplicabilidade, como mostra a Figura 2.7, é indicada para sistemas complexos, quando o modelo matemático do item (componente, equipamento, subsistema ou sistema) é desnecessário ou difícil de deduzir. (VACHTSEVANOS, 2006; SUTHARSSAN, 2017).

Para as abordagens baseadas em dados, é necessário ter dados históricos e conhecimentos do desempenho operacional, valores de limites críticos e suas margens. As técnicas conduzidas por dados dependem completamente da análise de dados obtidos de sensores e exploram sinais operacionais ou relacionados ao desempenho que podem indicar a saúde do sistema monitorado. Esta abordagem se baseia na predição de estados e na avaliação da tendência da falha, mostrada na Figura 2.9, a partir de um critério ou limiar de falha. Considerando duas fases: 1) Estimação/detecção do estado de saúde do item (como por exemplo, degradação); 2) Predição/Extrapolação do estado do item até que atinja um limite de falha (previamente definido). (SIMEÓN, 2015; SUTHARSSAN, 2017).

Figura 2.9: Tendência da Falha.



Fonte: Adaptado de Vachtsevanos (2006).

As principais técnicas existentes para abordagem com dados por métodos estatísticos são apresentadas na Figura 2.10. SUTHARSSAN (2017) apresenta três técnicas e procedimentos que podem ser utilizadas para o problema de a abordagem depender longo tempo de aprendizagem, são elas:

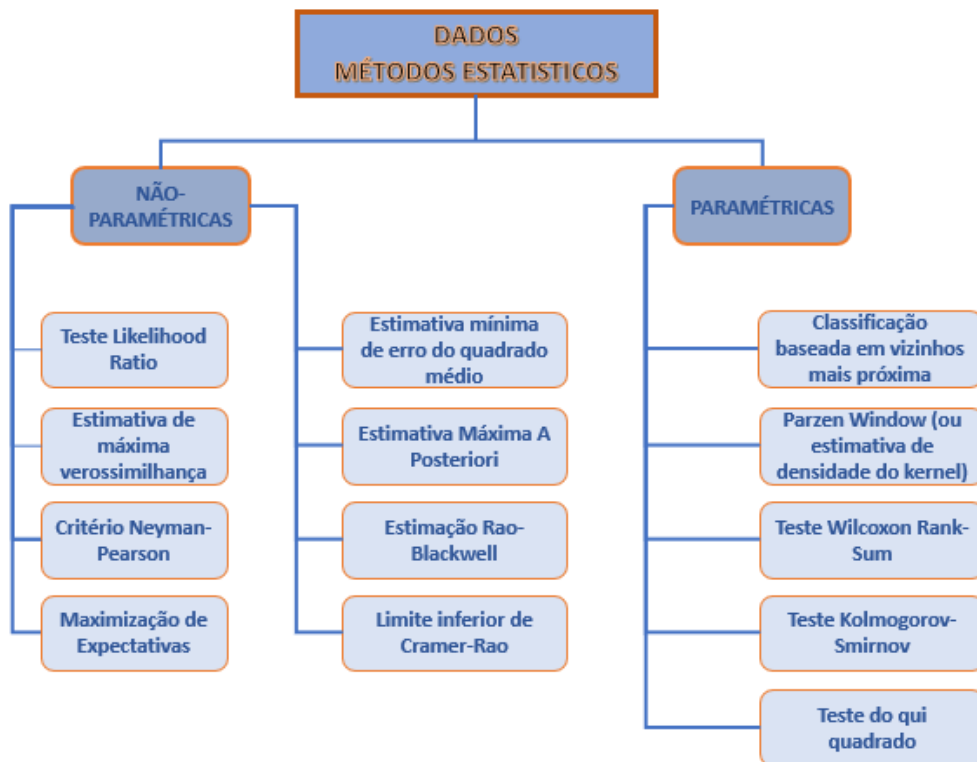
Simulações com Hardware-in-the-Loop (HiL): simulação usada para testar um produto ou sistema real conectando-o ao hardware que aplica cargas simuladas como em uma aplicação real. É rápida e possui baixo custo de implementação. É possível controlar vários parâmetros de falha (isto é, operacional e ambiental). HiL também é usado para desenvolver, testar e validar algoritmos e desenvolver métricas para prognósticos;

Teste de Vida Acelerada (ALT - Accelerated Life Test): utilizado para que o produto falhe mais rapidamente do que em condições normais de operação. Aplica-se uma condição de estresse acelerada (elevada), responsável por um mecanismo de falha particular. ALT torna-se um método importante no desenvolvimento dos prognósticos. Várias condições

ambientais e de carregamento podem ser aplicadas de forma independente para acelerar falhas;

Aprendizagem *on-line* (aprendizado semi-supervisionado / não supervisionado): a aprendizagem *on-line* baseia-se no pressuposto de que um novo sistema de dados de desempenho representa o sistema saudável; e que eles não falham por um determinado período de tempo. Esse tipo de abordagem também pode ser chamado de aprendizagem semi-supervisionada ou não supervisionada.

Figura 2.10: Técnicas existentes para abordagem com dados por métodos estatísticos.



Fonte: Adaptado de Pecht (2008).

2.5.2.2 Abordagens de tratamento de falhas baseadas em modelos

As abordagens baseadas em modelos usam equações matemáticas que modelam e preveem a falha física e, por isso, às vezes são referidas como abordagens por “Física da Falha” (*Physics of Failure*). Tem necessidade de conhecer os mecanismos de falha, geometria do sistema, propriedades do material e as cargas externas que são aplicadas ao sistema. (SIMEÓN, 2015; SUTHARSSAN, 2017).

Simeón (2015) classifica os modelos em modelos analíticos e modelos de espaço de estados. Os modelos analíticos são baseados em equações matemáticas e filtragem estocástica. Os modelos de espaço de estado são modelos de processo e observação, consistem em parâmetros que necessitam ser identificados por experimentos e dados empíricos.

Um modelo matemático com acurácia pode beneficiar o processo de prognóstico, onde a diferença entre a saída de um modelo matemático e a saída real do sistema pode ser usada para encontrar anomalias, avarias, distúrbios etc. A predição da RUL e os alertas iniciais para falhas podem ser feitos utilizando a diferença entre o modelo e os valores de dados para um parâmetro de desempenho.

2.5.2.3 Abordagens de tratamento de falhas baseadas em experiências

De acordo com a Figura 2.7, esta abordagem possui baixo custo de implementação e grande aplicabilidade; no entanto, tem baixa precisão.

Esta abordagem faz a correlação entre o conhecimento do especialista e a experiência de engenharia com situações observadas, históricos de medições e relato de falhas para a predição da RUL. Ou seja, relaciona-se com a coleta e armazenamento de informações de especialistas em assuntos. Uma interpretação baseada em parâmetros de confiabilidade é desenvolvida usando uma abordagem baseada no conhecimento para reunir informações de

feedback para análise do conjunto. Os dois métodos mais usados são os Sistemas Especialistas e a Lógica Nebulosa (*Fuzzy*) (ambos dependem de conhecimento de especialistas) (SIMEON, 2015; BUI, 2015).

A vantagem dos métodos de prognóstico baseados na experiência é que seu uso é baseado em uma função de confiabilidade simples em vez de modelos matemáticos complexos. No entanto, esses métodos podem ser inadequados para sistemas complexos, porque os comportamentos dos sistemas complexos podem ser relativamente imprevisíveis, desafiadores e demorados para serem executados. Um investimento substancial na coleta de dados, desenvolvimento de sistemas, sistemas de informação, *backup* de dados e reorganização é necessário para essa abordagem (BUI, 2015).

2.5.2.4 Abordagens de tratamento de falhas híbridas ou de fusão

Abordagens Híbridas ou por Fusão são abordagens de prognóstico resultantes da fusão de duas ou mais abordagens, gerando combinações das abordagens apresentadas aqui. O objetivo da abordagem híbrida é superar as limitações e desvantagens das demais abordagens e tenta buscar uma acurácia e precisão significativas, de tal forma que a aplicação, para o sistema empregado, obtenha resultado melhor que as demais abordagens individualmente. No entanto, ainda é difícil avaliar esse resultado; na maioria das vezes, o resultado é um pouco inferior à abordagem por modelos, como mostra a Figura 2.7 a.

A combinação de modelos com dados permite quantificar o comportamento do sistema usando princípios físicos e matemáticos para alcançar a predição da RUL com acurácia e precisão satisfatórias.

Sutharssan (2017) declara que, **para uma análise em tempo real, a abordagem híbrida pode não ser adequada, pois requer recursos computacionais significativos.**

A Tabela 2.2 apresenta de forma resumida a descrição conceitual das abordagens, assim como suas principais vantagens e desvantagens. É importante salientar que a abordagem de tratamento de falhas depende também do sistema ou equipamento a ser tratado. Quanto mais genérico for a abordagem, mais difícil será obter acurácia e precisão significativas.

Quando as abordagens são descritas, muito se fala da acurácia e precisão dos métodos empregados. Essas são algumas das medidas de avaliação e desempenho das abordagens e algoritmos a serem utilizados.

Tabela 2.2: Resumo das abordagens de tratamento de falhas.

Abordagens	Conceito	Vantagens	Desvantagens
Baseada em modelos	Modelo analítico da função de degradação do sistema. Requer conhecimento dos mecanismos de falha, geometria do sistema, propriedades do material e as cargas externas que são aplicadas ao sistema.	Boa acurácia nos resultados de prognóstico. São capazes de incorporar a compreensão analítica do sistema monitorado.	O modelo de degradação não é facilmente obtido. Dificuldade de aplicação a sistemas complexos.
Baseada em dados	Baseado na exploração de sintomas e indicadores de degradação. A evolução futura dos sintomas é determinada usando métodos estatísticos ou de IA. Utiliza o monitoramento de dados direto ou indireto, mediante indicadores (observados, medidos ou calculados). Há necessidade de dados monitorados ou históricos.	São rápidos para implementar e computacionalmente mais eficientes em relação a outras técnicas. Compensação entre aplicabilidade e precisão. São capazes de transformar dados ruidosos de alta dimensão em informações dimensionais mais baixas para decisões diagnósticas / prognósticas.	Tempo de aprendizado, e disponibilidade de um sistema de monitoramento de condição. O nível de confiança da predição depende da disponibilidade dos dados empíricos ou históricos. São altamente dependentes da quantidade e qualidade dos dados operacionais do sistema
Baseado em Experiência	Exploração das funções de probabilidade ou processos estocásticos de degradação, onde os parâmetros são determinados por especialistas ou por dados de experiência armazenados.	Facilidade na implementação, caso haja experiências suficientes e significativas.	As funções de probabilidade são específicas para cada conjunto de componentes. Resultados de prognóstico de baixa precisão.
Híbridas	Resultado da fusão de duas ou mais abordagens descritas anteriormente. Também conhecida na literatura como “abordagem de fusão”.	Aproveita o melhor das Abordagens individuais.	Em algumas aplicações não é trivial a fusão de duas ou mais abordagens. Alguns casos demandam recursos computacionais significativos.

Fonte: Adaptado de Simeón (2015), Sutharssan (2017) e Tahan (2017).

2.5.3 Medidas de avaliação e desempenho

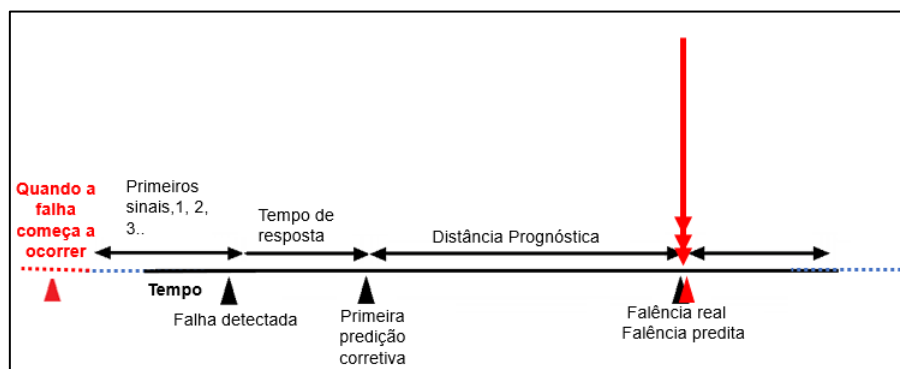
Antes de abordar os algoritmos utilizados para realizar o prognóstico, é importante mostrar que existem atributos-chave para avaliar o sistema prognóstico. ou seja, avaliar a abordagem de tratamento da falha por meio de um algoritmo de prognóstico adequado para determinado item.

Algumas das métricas apresentadas neste capítulo serão utilizadas no Capítulo 7 para a avaliação do algoritmo.

O padrão IEEE Std 1856 (2017) apresenta algumas medidas de desempenho que devem ser utilizadas para a avaliação de desempenho:

- **Correção** (*Correctness*) - por definição, a avaliação de desempenho refere-se à noção de avaliação da correção de uma saída do sistema em relação à especificação desejada;
- **Acurácia** (*Accuracy*) - é uma medida do desvio de uma saída de prognóstico do estado atual do sistema em relação a uma verdade medida, observada ou inferida (Figura 2.11). Especificamente, a acurácia predita é uma medida quantitativa do erro entre o fim da vida útil predita e a EOL observada do componente/sistema monitorado. Deve ser medido através da comparação de resultados prognósticos e de diagnóstico a partir da verdade do solo medida usando várias métricas (IEEE Std 1856, 2017; SAXENA et al, 2010 e SAXENA, SANKARARAMAN, e GOEBEL, 2014);

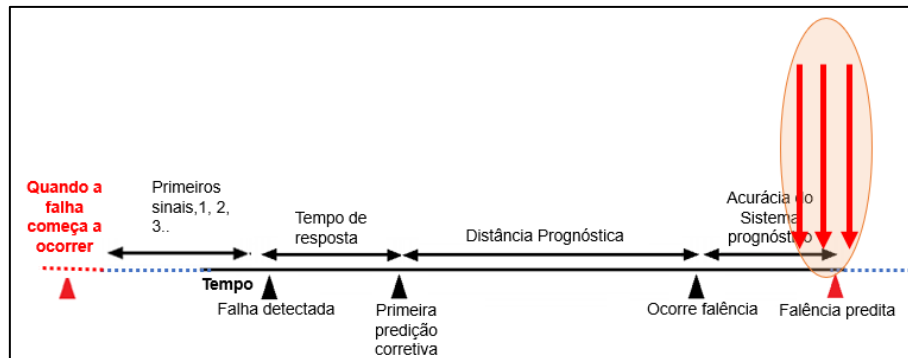
Figura 2.11: Ciclo do prognóstico enfatizando a acurácia.



Fonte: Adaptado de IEEE (2017).

- **Precisão** (*Precision*) - é uma medida da dispersão entre saídas de prognóstico / predição do (mesmo) estado atual do sistema em relação a uma verdade do solo medida, observada ou inferida (Figura 2.12);

Figura 2.12: Ciclo do prognóstico enfatizando a precisão.



Fonte: Adaptado de IEEE (2017).

- **Oportunidade** (*Timeliness*): refere-se aos aspectos relacionados ao tempo de disponibilidade e até à usabilidade das predições. Ele mede a rapidez com que um algoritmo de predição produz suas saídas, em comparação com os efeitos de falha que estão mitigando (SAXENA; SANKARARAMAN; GOEBEL, 2014) É caracterizada por:
 - **Horizonte de Predição** (*Prediction Horizon*): a medida de quão antes do evento de falha real, um sistema de prognóstico produz uma predição correta (especificações de produto) da EOL ou EOD para poder implementar uma decisão e resposta acionáveis, como parte da atividade de gerenciamento de saúde. Para prognósticos, é medido como **horizonte prognóstico ou distância prognóstica** no momento em que uma predição é feita (Figuras 2.11, 2.12). (SAXENA et al, 2010; SAXENA; SANKARARAMAN; GOEBEL, 2014; JOHNSON, 2011);
 - **Tempo de Resposta da Predição** (*Prediction Response Time*): a medida da rapidez com que a função prognóstica produz uma saída correta, a partir de um determinado conjunto de medidas do

sistema. Isso inclui o tempo que leva para um algoritmo convergir para um nível de desempenho razoável (Figuras 2.11, 2.12) (SAXENA et al, 2010; SAXENA; SANKARARAMAN; GOEBEL, 2014);

- **Confiança** (*Confidence*): é uma medida de confiança (ou, inversamente, uma medida de incerteza) na saída de um sistema PHM. Para funções de detecção e diagnóstico, ele é calculado através de, mas não limitado a, métricas de robustez, sensibilidade e incerteza. Para prognósticos, é especificado incluindo a estimativa da incerteza nas previsões e a estabilidade das previsões ao longo do tempo, além de medidas de sensibilidade e robustez (SAXENA et al, 2010; SAXENA; SANKARARAMAN; GOEBEL, 2014).

2.6 Algoritmos para prognóstico

É possível encontrar na literatura uma numerosa variedade de algoritmos e aplicações. Isso se deve ao fato de ser um assunto que vem sendo muito estudado e explorado. Alguns dos algoritmos mais utilizados para ações de prognóstico encontrados na literatura são apresentados na Tabela 2.3, apontando uma descrição resumida deles e destacando suas vantagens e desvantagens.

Tabela 2.3: Descrição de alguns algoritmos mais utilizados para prognóstico com suas principais vantagens e desvantagens.

Algoritmo	Descrição	Vantagens	Desvantagens
Filtro de partículas	- Abordagem bayesiana para obter a estimativas de estado que representem a função densidade de probabilidade de uma trajetória de estado definida por amostras de partículas recursivas.	- É aplicável a sistemas não lineares e ruídos não gaussianos ; - Tem alta precisão quando comparado com outros algoritmos de filtragem; - A amostragem espacial e sequencial ajuda a incrementar a precisão e evitar a degeneração.	- Os modelos da dinâmica do sistema e de medição precisam ser definidos; - O maior custo computacional para sistemas de alta dimensão ou com mais partículas.
Filtro de Kalman	- Técnica que estima o estado de um processo e minimiza a covariância da estimativa incorporando medidas relativas ao estado.	- É capaz de estimar o estado atual e prever os estados futuros; - Corrige a estimativa com a última medida para manter a covariância mínima do erro de estado.	- Os modelos do sistema e de medida precisam ser definidos; - Os níveis de ruídos em ambos os modelos podem afetar o desempenho e estabilidade do algoritmo; - Trabalha unicamente com sistemas lineares e ruídos gaussianos .
Mapas Auto-Organizáveis	- Representa uma característica do espaço multidimensional em um espaço de baixa dimensão preservando as propriedades da topologia do espaço de entrada.	- Método de aprendizado não supervisionado ; - Boa capacidade de visualização.	- Falta de um algoritmo padrão para determinar a estrutura e a forma do mapa.
Redes Bayesianas	- Ferramenta gráfica acíclica para representar a estrutura da relação de interdependência condicional e as distribuições de probabilidade entre variáveis de um sistema.	- Reduz o número de parâmetros para apreender a estrutura de domínio através da marginalização das distribuições de probabilidade condicional; - Visualiza a dependência entre cada par de variáveis.	- O aprendizado de uma estrutura desconhecida pode ser complexo ; - É necessária certa quantidade de conhecimento a priori do domínio.
Redes Neurais Artificiais	- Modela e simula funções e estruturas de redes neurais biológicas; - Aprendizagem de conhecimento mediante modelagem das relações complexas entre entradas e saídas na busca de padrões nos dados.	- Para sistemas complexos onde envolve comportamento não linear e processo instável; - Sistema adaptativo.	- Inexistência de métodos padrões para determinar a estrutura da RNA; - Requer altos recursos computacionais .

continua

Tabela 2.3: Conclusão.

Algoritmo	Descrição	Vantagens	Desvantagens
Auto-Regressivo de Média Móvel (ARMA)	- Consiste de duas partes: a parte AR = Auto Regressiva, e a parte MA = Média Móvel, para a modelagem e previsão de valores futuros em dados de séries temporais.	- Aplicável a sistemas lineares e invariantes no tempo com comportamento estacionário; - Requer pequena quantidade de dados históricos.	- Não fornece boa previsão em grandes intervalos de tempo; - Limitado a processos dinâmicos e estacionários.
Lógica Nebulosa (Fuzzy)	- Representa e processa incertezas de modo a fazer um sistema complexo administrável; - Tolerância a incertezas e pode utilizar linguagem vaga para oferecer robustez, modelo tolerante falhas ou previsão quando não estão disponíveis entradas precisas.	- Pode lidar com dados incompletos, ruidosos ou imprecisos; - Útil no desenvolvimento de modelos de dados incertos; - Mais compatível como o processo de raciocínio humano do que a abordagem simbólica tradicional. - Adequado para sistemas complexos e/ou desconhecidos.	- Impraticável quando funções de pertinência são complicadas de determinar.
Máquina de Vetor Suporte	- Projeta o espaço de características em um espaço de alta dimensão por uma função kernel; - Encontra um hiperplano de separação otimizada no espaço projetado para maximizar a fronteira de decisão.	- Obtém melhor precisão em decisões devido à sua fronteira de decisão maximizada; - Eficiente para um grande conjunto de dados e análise em tempo real.	- Não possui um método padrão para escolha da função kernel, o qual é um processo chave para SVM.
Modelo oculto de Markov	- Modelo estatístico, onde o modelo do sistema é assumido como de Markov com parâmetros do espaço de estados desconhecidos.	- Pode ser usado para diagnóstico de degradação e falha em sinais não estacionários e sistemas dinâmicos; - Adequado para múltiplos modos de falha.	- Inadequado quando os estados de falha não são observáveis ; - Demanda grande quantidade de dados para uma modelagem precisa.

Saha, Goebel e Christophersen (2009) fazem um estudo comparativo usando uma abordagem híbrida para previsão de RUL aplicados a baterias de Lítio-Íon. Os autores utilizam ARIMA, EKF e PF e dados de baterias para tal abordagem. Eles mostram que para tal aplicação o método ARIMA não incorpora nenhuma física do processo no cálculo (método orientado apenas a dados), e além de outros problemas, acaba com **grandes margens de incerteza** que o tornam

inadequado para previsões de longo prazo. O EKF apesar de robusto contra a **não estacionariedade**, sofre com a incapacidade de acomodar efeitos não modelados e **pode divergir rapidamente**. O PF demonstrou ser **adequado** para várias fontes de incertezas, pois define fdps entre parâmetros e variáveis.

Daigle, Saha e Goebel (2012) fazem uma revisão sobre abordagens de filtragem não linear com aplicação a prognósticos, incluindo o Filtro de Daum (não detalhado neste trabalho), o Filtro de Kalman Neutro e o Filtro de Partículas. A aplicação e resultados são em cima de um sistema específico: uma bomba centrífuga. Para essa aplicação o UKF superou o PF, foi mais fácil de ajustar e teve complexidade computacional menor que o PF.

A Tabela 2.3 e tais estudos sugerem enfatizar os seguintes algoritmos:

2.6.1 Média Móvel Auto Regressiva Integrada – ARIMA (*AutoRegressive Integrated Moving Average*)

Essa abordagem se trata de uma técnica para modelagem. É uma generalização da média móvel auto regressiva ou ARMA, comentada na Cont. da Tabela 2.3 (BOX; JENKINS, 1976). Esses modelos são ajustados aos dados de séries temporais para caracterizar os dados de forma mais eficiente que o ARMA e estimar pontos futuros da série.

Teoricamente, qualquer série temporal que não contenha nenhuma tendência ou da qual a tendência foi removida pode ser representada como consistindo em duas partes, uma parte autodeterminada e um componente de perturbação. A parte auto determinística da série pode ser estimada a partir de seu próprio passado por um modelo Auto Regressivo (AR) com número de termos suficiente, p , enquanto o componente de perturbação (os resíduos do modelo AR) pode ser modelado por uma média móvel (MA) com um número suficientemente grande de elementos, q .

Basicamente o algoritmo segue os passos de Identificação, Estimativa e Verificação. 1) Identificação: verifica se a série é suficientemente estacionária (livre de tendência e sazonalidade) e especifica o número apropriado de termos

auto regressivos e termos médios móveis da função de auto correlação e da função de auto correlação parcial. 2) Estimativa: estima os parâmetros e os termos de AR e MA, geralmente por análise de regressão e 3) Verificação: verifica se o modelo se ajusta bem aos dados históricos. O modelo é usado para estimar todos os valores existentes na série. Diz-se que ele se encaixa bem na série se as diferenças entre os valores reais e os valores previstos forem pequenas o suficiente e suficientemente aleatórias.

2.6.2 Filtro de Kalman (*Kalman Filter* – KF)

O Filtro de Kalman, desenvolvido por Rudolf Earl Kalman em 1959-1960s, é uma teoria que usa a formulação de sistemas lineares no espaço de estados, uma maneira eficiente de resolver recursivamente o problema ótimo linear (KALMAN, 1985).

O Filtro de Kalman é um conjunto de equações matemáticas que constituem um processo recursivo eficiente de estimação, uma vez que o erro de estado médio quadrático é minimizado. Através da observação das variáveis denominadas “variáveis de observação” outras variáveis, não observáveis, denominadas “variáveis de estado” podem ser estimadas eficientemente. Podem ser estimados os estados passados – Alisamento (*Smoothing*), o estado presente – Filtragem (*Filtering*), e os estados futuros - Predição (*Prediction*).

Segundo Daum (2005), apesar de sua grande eficiência e aplicações, a acurácia do Filtro de Kalman não é boa para algumas aplicações práticas, por várias razões, incluindo: 1) não linearidades nas equações que descrevem o sistema físico, 2) mau condicionamento da matriz de covariância e 3) imprecisão ou modelos incompletos do problema físico subjacente.

2.6.2.1 Filtro de Kalman Estendido (*Extended Kalman Filter- EKF*)

A maioria das aplicações reais não são lineares e/ou nem gaussianas. Para esses problemas utilizam-se aproximações. O Filtro de Kalman Estendido é uma aproximação muito utilizada. O problema de um filtro “linear” é que todas as funções têm que ser lineares ($f(\cdot)$, $g(\cdot)$, $h(\cdot)$) em x e o problema de ser “gaussiano” significa que todos os ruídos são Gaussianos. O que o EKF faz é aproximar $f(\cdot)$, $g(\cdot)$ e $h(\cdot)$ com séries de Taylor de primeira ordem avaliadas na estimativa atual de x .

Segundo Daum (2005), na verdade, não existe "O EKF", mas existem centenas de variedades de EKFs. Ou seja, diferentes Filtros de Kalman Estendidos podem ser projetados usando algumas artimanhas da engenharia: 1) sistemas de coordenadas diferentes; 2) fatorações diferentes da matriz de covariância 3) correções da série Taylor de segunda ordem (ou ordem maior) na predição do vetor de estado e/ou atualização da medida; 4) iteração da atualização do vetor de estado usando medições; 5) ordens diferentes com as quais usar medidas escalares para atualizar o vetor de estado; 6) ajuste dos ruídos do processo [etc.] e 7) combinações de todas as opções acima a fim de melhorar o desempenho do EKF.

De fato, os truques citados acima podem resultar em melhorias significativas para o desempenho do filtro, mas nem sempre obtém sucesso; algumas vezes até o pioram.

2.6.2.2 Filtro de Kalman Neutro (*Unscented Kalman Filter- UKF*)

Segundo Daum (2005), o EKF é baseado em uma aproximação linear das equações não lineares que descrevem o problema físico, enquanto o Filtro de Kalman Neutro (UKF) não usa essa aproximação linear. Mas, usa uma aproximação mais precisa para avaliar as integrais multidimensionais exigidas pela teoria. Essa aproximação é semelhante à quadratura de Gauss-Hermite para aproximação numérica de integrais multidimensionais. O UKF assume que a densidade de probabilidade do vetor de estado é gaussiana, e essa

densidade é amostrada em vários pontos **cuidadosamente selecionados** para aproximar as integrais multidimensionais necessárias.

2.6.3 Filtros bayesianos

Esta abordagem de filtros numéricos é adequada para aplicações não-lineares e cenários não-gaussianos. Quando comparados com os filtros como, por exemplo, o Filtro de Kalman Estendido (EKF) a principal vantagem é que eles não confiam em qualquer técnica de linearização ou aproximação analítica. Em vez disso, ele usa a simulação de Monte Carlo (MC) para obter uma solução aproximada, quando a solução exata é difícil de obter, exceto nos casos lineares e gaussianos.

2.6.3.1 Filtros de Partículas (*Particle Filter* – PF)

Na abordagem do Filtro de Partículas (PF) a Função Densidade de Probabilidade (fdp) do estado é aproximada por um conjunto de partículas (pontos) representando valores amostrados do espaço de estado desconhecido e um conjunto de pesos associados que indicam massas discretas de probabilidade. As partículas são geradas e atualizadas recursivamente a partir de: 1) um modelo de processo não linear que descreve a evolução no tempo do sistema em análise; 2) um modelo de medição; 3) um conjunto de medidas disponíveis; e 4) uma estimativa *a priori* do estado em fdp. Em outras palavras, o FP é uma técnica para implementar um filtro bayesiano recursivo usando simulações de Monte Carlo (MC) e, como tal, é conhecido como Método Sequencial de MC (SMC).

A Tabela 2.4 apresenta uma comparação dos algoritmos enfatizados.

Tabela 2.4. Comparação dos algoritmos enfatizados.

	FILTRO DE KALMAN ESTENDIDO	FILTRO DE KALMAN NEUTRO	FILTRO DE PARTÍCULAS
ESTATÍSTICAS PROPAGADAS PELO ALGORITMO	Filtro de Kalman Estendido	Filtro de Kalman Neutro	Filtro de Partículas
PREVISÃO DE ESTATÍSTICAS DE UM TEMPO DE MEDIÇÃO PARA O PRÓXIMO	Vetor de médias e Matriz de covariância.	Vetor de médias e Matriz de covariância.	Função Densidade de Probabilidade completa, mas condicionada às medições
CORREÇÃO DAS ESTATÍSTICAS NO MOMENTO DA MEDIÇÃO	Aproximação linear da dinâmica.	Aproximação das integrais multidimensionais usando uma "transformação neutra".	Integração por Monte Carlo usando amostragem espacial e temporal.
ACURÁCIA DA ESTIMATIVA DO VETOR DE ESTADO	Aproximação linear das equações de medição.	Aproximação das integrais multidimensionais usando uma "transformação neutra".	Amostragem da Função Densidade de Probabilidade condicional por Monte Carlo, usando amostragem espacial e temporal; e, eventualmente, reamostragem.
COMPLEXIDADE COMPUTACIONAL DO ALGORITMO EM TEMPO REAL	Às vezes, boa, mas geralmente ruim, em comparação com a precisão ideal teoricamente.	Muitas vezes, fornece uma melhoria significativa em relação ao EKF, mas às vezes não.	Desempenho ideal para problemas de baixa dimensão; mas pode ser altamente subótimo para dimensões altas, limitadas pela velocidade do computador em tempo real.

Fonte: Adaptado de Daum (2005).

2.7 Prognóstico aplicado a sistemas

São muitas as aplicações de prognósticos a sistemas encontradas na literatura. A Tabela 2.5 apresenta algumas.

Tabela 2.5: Aplicações de prognósticos a sistemas.

Aplicação	Referências
<i>Baterias</i>	Dickerson et al. (2015); Arachchige, Perinpanayagam, Jaras (2017); Sankavaram et al. (2009); Saha, Goebel (2009); Torchio (2017); Zou et al. (2015); Zhang, Lee (2011); Brondani (2015); Goebel et al (2008); Zhang (2016); Matos (2011).
<i>Ferramenta de corte em torneamento</i>	Silva (2008).
<i>Aplicações espaciais/satélites</i>	Bottone, Lee, O'Sullivan, Spivack (2008); Zaidan et al. (2015); Wang (2013); Belmonte, Dalla Vedova, Maggiore (2015); Chunhua, Hua, Kai, (2015); Gayarre Peña, (2015); Qin, Zhang (2017); Yairi, et al (2017); Cardenuto (2017); Li, Hu (2017).
<i>Rolamento</i>	BUI (2015).
<i>Válvula pneumática</i>	Daigle, Goebel (2009).
<i>Atuador eletromecânico</i>	Belmonte, Dalla Vedova, Maggiore (2015); Brown et al (2013).

2.7.1 Baterias

Baterias atualmente são componentes essenciais para o bom funcionamento de uma série de equipamentos. A falha deste componente pode causar um desempenho reduzido, um comprometimento operacional e/ou até falhas catastróficas, principalmente em sistemas espaciais que dificilmente permitem manutenções. As baterias são um dos sistemas mais estudados em termos de prognósticos.

Segundo Magalhães (2012), baterias usualmente estão entre os itens que possuem tempo de vida mais curta em sistemas espaciais, isto porque são

submetidas a condições extremas de funcionamento, principalmente em órbitas baixas. Neste tipo de órbita, mais de 5000 ciclos de carga e descarga acontecem anualmente. Conseqüentemente, monitorar e gerenciar o Estado de Saúde (*State Of Health-SOH*) da bateria torna-se um fator importante em satélites espaciais.

As baterias são acumuladoras de energias, utilizados tanto para armazenar energia quanto para entregar energia quando necessário (TORCHIO, 2017). A bateria é constituída por uma ou mais células eletroquímicas, que podem ser conectadas: 1) em série, 2) em paralelo, ou ainda 3) em série/paralelo (combinação de ambas).


Nas células da bateria, a energia química armazenada é convertida em energia elétrica através de reações eletroquímicas. Uma célula eletroquímica é formada por dois eletrodos: 1º) um ânodo que possui polaridade negativa, e 2º) um cátodo que possui polaridade positiva, estes são separados por um eletrólito. Durante a fase de descarga o ânodo libera elétrons para o circuito, enquanto o cátodo recebe elétrons do circuito. Já na fase de carregamento da bateria, os processos químicos são revertidos. Os elétrons têm origem a partir de reações eletroquímicas e são chamados de espécies eletroativas. Torchio (2017) define cada um dos termos mencionados nesse processo de conversão de energia através de reações químicas:

- **Ânodo** – é o eletrodo que está sujeito à reação de oxidação (os elétrons saem do eletrodo para um circuito externo) durante as condições de operação da célula. Comumente, o ânodo é usado para identificar o eletrodo negativo;
- **Cátodo** - o cátodo é o eletrodo que está sujeito à reação de redução (os elétrons entram no eletrodo retirados de um circuito externo) durante as condições de operação da célula. Comumente o cátodo é usado para identificar o eletrodo positivo;
- **Eletrólito** - é um meio de transporte que permite a entrada de íons entre os dois eletrodos. Pode ser líquido ou sólido;

- **Separador** - é uma camada porosa isolante que evita possíveis curtos-circuitos entre os eletrodos, enquanto permite que os íons passem através dele.

Bondani (2015) afirma que: “Em contraste com a corrente elétrica no sistema externo, o transporte de carga entre cátodo e ânodo dentro do eletrólito é feita através de íons. Geralmente, a corrente no eletrólito consiste no movimento de íons negativos e positivos.” A Figura 2.13 apresenta um esquema simplificado de uma célula eletroquímica.

Figura 2.13: Esquema de uma célula eletroquímica.



Fonte: Adaptado de Daniel e Besenhard (2013).

Existem muitas especificações de baterias. Uma das características consideradas de grande relevância esta relacionada à capacidade da bateria ser carregada ou não. Esta característica as categoriza em: 1) baterias primárias, quando o dispositivo não é recarregável, a reação eletroquímica é irreversível e 2) baterias secundárias, quando o dispositivo é recarregável e podem ser descarregada e carregadas várias vezes (TORCHIO, 2017; DANIEL; BESENHARD, 2013).

2.7.1.1 Características de baterias

A seguir a definição de outros termos comuns e importantes, é fornecida, termos estes que serão bastante utilizados no decorrer deste trabalho:

- **Tensão da Célula** (*Cell Voltage*): é a diferença entre os potenciais dos eletrodos sob condições genéricas de carga (TORCHIO, 2017). Aqui será $E(t)$;
- **Tensão de Circuito Aberto** (*Open Circuit Voltage - OCV*): é a tensão entre os eletrodos de uma célula que não está sob condições de carga (TORCHIO, 2017). Aqui será tensão entre os terminais da bateria após a carga, em circuito aberto, e antes da descarga $V(t_k)=E(t_k)=E_0$;
- **Tensão de Corte** (*Cut Off Voltage*): quando a OCV é igual à Tensão de Corte, a célula está totalmente descarregada. Este valor varia de acordo com a composição da bateria (TORCHIO, 2017). Aqui será E_{eod} ;
- **Nível de Corte** (*Cut Off Level*): é o valor limite inferior de carga em que a bateria consegue fornecer uma tensão necessária para um sistema (PORCIUNCULA, 2012). Aqui será Q_{eod} ;
- **Estado de Saúde** (*State Of Health - SOH*): mede a capacidade de uma bateria de fornecer um desempenho específico, em comparação com os que vêm de uma bateria nova do mesmo tipo. Dado que vários fenômenos podem concorrer para degradar o desempenho da bateria, um índice capaz de contabilizar tais perdas pode ser útil no monitoramento das condições operacionais e no diagnóstico de possíveis situações de falha. Este índice também é utilizado para avaliar o nível de envelhecimento da bateria (TORCHIO, 2017; ZOU et al, 2015). Aqui será $SOH(t_k)=Q(t_k)/Q(t_0)$;
- **Estado de Carga** (*State of Charge – SOC*): mede a quantidade de carga disponível dentro de um eletrodo. Geralmente é representado por meio da razão entre a concentração real de íons e a capacidade máxima permitida dentro de um eletrodo. Esse índice é comumente usado para

contabilizar a carga restante de uma célula (TORCHIO, 2017). Aqui será $SOC(t_i) = Q(t_i) / Q(t_k)$;


- **Ciclos de uso** (*Usage Cycles*): contam o número de vezes que uma bateria pode ser carregada e descarregada, antes que o índice SOH caia abaixo de um valor limite. Normalmente, a ultrapassagem de tal valor determina a incapacidade da bateria em fornecer desempenho operacional adequado (TORCHIO, 2017). Aqui será $k \in \{0, 1, 2, \dots, n\}$;
- **Tempo de vida** (*Life Time*): Intervalo de tempo decorrido até que a bateria atinja um nível inferior de carga (nível de corte) o que impede a bateria exercer suas funções. Aqui será $\Delta t = t_{eol} - t_i$.

2.7.1.2 Tipos de baterias

As baterias secundárias são normalmente categorizadas pelos materiais ativos usados em suas células que, por sua vez, influenciam o desenvolvimento e as características de sistemas de baterias. Dentre as principais tecnologias de baterias, podem-se citar as tecnologias: Chumbo-Ácido (*Lead-Acid*), Níquel-Cádmio (*Ni-Cd*), Níquel Metal-Hidreto (Ni-MH) e Lítio-Íon (Li-Íon).

A Figura 2.14 faz a comparação de diferentes tecnologias de baterias em relação às densidades de energia volumétricas e específicas e relacionam os tamanhos e massas destas células.

Figura 2.14: Comparação de densidade de energia em relação ao tamanho e massa.



Fonte: Epec Engineered Technologies (2018).

Baterias de Níquel-Cádmio eram amplamente utilizadas na década de 60 para aplicações espaciais; e, devido ao aumento de missões espaciais, muitas agências governamentais financiaram estudos para compreender os fenômenos ocorridos em baterias. Esta tecnologia continua sendo utilizada em aplicações espaciais devido à sua robustez, ao grande número de ciclos de carga e descarga e por possuir boa capacidade em suportar longos períodos de armazenamento (MAGALHÃES, 2012).

Atualmente, as baterias de Lítio-Íon são extremamente utilizadas em equipamentos eletrônicos portáteis. Mas, nos anos 90, já era comum encontrar esta tecnologia em uso em eletrônicos; e, no final dos anos 90, iniciou-se a utilização no fornecimento de sistemas de lançamento e de satélites (NASA, 2009). Um exemplo disto pode ser encontrado na publicação de Dudley (1998), onde ele apresentou um estudo sobre o uso de baterias de Lítio-Íon no setor espacial. Dudley (1998) enfatiza as características desta tecnologia, apresenta as vantagens e desvantagens para o setor espacial, assim como o esforço da ESA até a data no desenvolvimento de programas com o uso destas baterias.

A Tabela 2.6 apresenta uma comparação dos tipos de baterias em relação a alguns parâmetros de grande importância.

Tabela 2.6: Comparação das principais características dos tipos de baterias.

	Lead-Acid	Ni-Cd	Ni-MH	Li-Íon
Custo	Baixo	Médio	Alto	Muito alto
Energia (Wh-Kg¹)	30-50	50-80	40-100	160
Tensão por célula (V)	2	1.25	1.25	3,6
Corrente de carga	Baixa	Muito Baixa	Moderada	Alta
Número de ciclos	200-500	1000	1000	1200
Auto descarga por mês	Baixa (5%)	Moderada (20%)	Alta (30%)	Baixa (10%)
Tempo mínimo de carga (h)	8-16	1 – 1.5	2 – 4	2 – 4
Impacto ambiental	Alto	Alto	Baixo	Baixo

Fonte: Adaptado de Valseira-Naranjo et al (2009).

2.7.1.3 Modelos de baterias

A modelagem do comportamento das baterias é complexa, devido aos efeitos não lineares de descarga. Por exemplo, duas importantes propriedades da bateria: 1) tensão, medida em Volts (V); e 2) capacidade, geralmente medida em Ampère-Hora (Ah). O produto destas duas grandezas fornece a quantidade de energia armazenada na bateria. No caso ideal, a tensão permaneceria constante durante a descarga, com uma queda instantânea para zero quando a bateria estivesse á vazia. A capacidade ideal seria constante para todas as correntes de descarga, e toda a energia armazenada na bateria seria usada. Esta representação é teórica. Na prática, geralmente, a corrente de descarga não é constante no tempo, ou seja, as operações de descarga têm características não lineares, que influenciam diretamente no tempo de vida da bateria (SILVA et al, 2013; JONGERDEN, 2008). Segundo Magalhães (2014), a

bateria a ser modelada é composta de três aspectos distintos, porém acoplados entre si: o elétrico, o químico e o térmico.

É possível encontrar na literatura diversos modelos distintos para descrever o comportamento de uma bateria, podendo citar os modelos eletroquímicos, modelos de circuitos elétricos equivalentes e modelos matemáticos (modelos estocásticos e modelos analíticos). Dentre os modelos citados os modelos eletroquímicos e de circuitos equivalentes são os mais utilizados. A Tabela 2.7 apresenta uma descrição de cada modelo ressaltando as vantagens e desvantagens.

Tabela 2.7: Vantagens e desvantagens dos modelos para baterias.

<i>Modelos</i>	<i>Descrição</i>	<i>Vantagens</i>	<i>Desvantagens</i>
<i>Eletroquímicos</i>	São baseados nos processos químicos que ocorrem na bateria. Os modelos descrevem esses processos de bateria em grande detalhe	Costumam ter um bom grau de detalhe e precisão.	Exigem muitos ajustes e informações de parâmetros, são complexos, costumam ser específicos a uma determinada tecnologia, difíceis de configurar.
<i>Circuitos elétricos equivalentes</i>	trabalham com as propriedades elétricas da bateria, utilizando uma combinação de fontes de tensão, resistores e capacitores para a simulação de descarga da bateria.	Bom equilíbrio entre complexidade e eficiência. Simples	os modelos são menos precisos, com um erro de aproximadamente 10%.
<i>Modelos matemáticos</i>	Utilizam equações para modelar o desempenho da bateria. Modelos Analíticos descrevem as principais propriedades da bateria por meio de um conjunto menor de equações. Os Modelos Estocásticos modelam de forma mais abstrata. O processo de descarga; e o efeito de recuperação são descritos como processos estocásticos.	Podem ser estendidos para diferentes tipos de baterias.	computacionalmente mais eficientes e exigíveis,

Fonte: Adaptado de Jongerden e Haverkort (2008) e Matos (2011).


De especial importância para esta Tese são as referências Randles (1947), Huggins (2008), Hartman II (2008), Saha e Goebel (2009), e Arachchige et al. (2017), Gabrielli (2019), e alguns modelos, a saber:

Huggins (2008) trata de:

Materials Science principles that underlie the behavior of advanced electrochemical storage systems, i.e., batteries. [...] emphasis is placed upon underlying principles that are applicable across the spectrum of materials that are of interest as electrochemically active components in advanced batteries: the electrodes and the electrolyte.


Aquele livro apresenta inúmeros dados experimentais (composições, geometrias, curvas, etc.), e modelos (eletroquímicos, circuitos equivalentes, matemáticos) progressivamente mais complexos baseados em tais princípios e dados. Seu importantíssimo Capítulo 1, apresenta as Figuras 1.14 e 1.8 e seus n modelos, que são as fontes das Figuras 2 e 3 de Saha e Goebel (2009), e das nossas Figuras 2.15 e 2.16. A 1ª. fundamenta a Figura 5 de Saha e Goebel (2009), fonte (?) da Figura 2 de Arachchige et al (2017) e da nossa Figura 2.17. A 1ª e a 2ª. fundamentam os 2 modelos (de EOC, EOL) matemáticos (analíticos e estocásticos) contínuos e discretos no tempo feitos (?) por aqueles, estendidos por estes, e usados e melhorados nos Capítulos 4-6 desta Tese.

Figura 2.15: Influência da densidade de corrente sobre a curva de descarga.




Fonte: Huggins (2008).

Figura 2.16: Influência da eficiência coulombiana sobre a capacidade disponível durante a descarga.



Fonte: Huggins (2008).

Figura 2.17: Decomposição do perfil de descarga de (baterias) Li-Íon em componentes diferentes.




Fonte: Saha e Goebel (2009).

Hartman II (2008) apresenta “a methodology for using cycling data collected from several similar electrochemical cells to generate an aging model that predicts how the parameters in a first-principles dynamic model of a cell will change as the cell ages”.

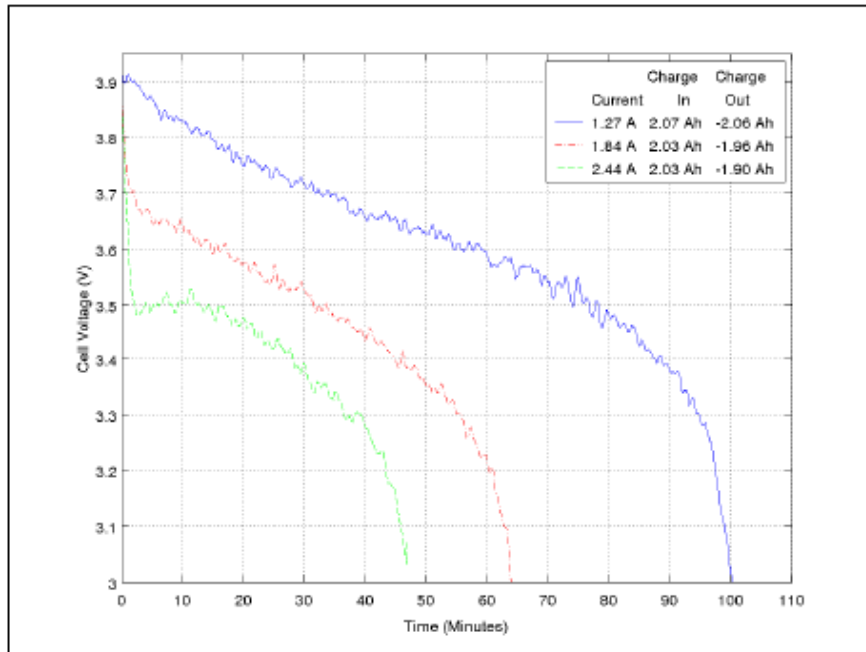
Aquela Tese apresenta inúmeros dados experimentais (composições, geometrias, curvas, etc.), e modelos (eletroquímicos, circuitos equivalentes, matemáticos) progressivamente mais complexos baseados em tais princípios e dados. Seu importantíssimo Capítulo 2 apresenta as Figuras 2.1, 2.6, 2.14 e 2.20 (esta com regiões A,B,C,D) e seus n modelos, fontes das nossas Figuras 2.18, 2.19, 2.20 e 2.21; A 1^a., 2^a., e 3^a., são similares à Figura 1.14 de Huggins (2008), à Figura 2 de Saha e Goebel (2009) e à nossa Figura 2.15; a 4^a. nas suas regiões A e B, é similar à Figura 1.8 de Huggins (2008), à Figura 3 de Saha e Goebel (2009), e à nossa Figura 2.16. Isto será considerado nos Capítulos 4-7 desta Tese.

Figura 2.18: Curva de voltagem de descarga de uma célula de NiMH de 9,5 A.h.




Fonte: Hartmann II (2008).

Figura 2.19: Descarga de uma célula de Li-Íon de 2,4 A.h a 3 diferentes correntes constantes.




Fonte: Hartmann II (2008).

Figura 2.20: Curva de voltage de descarga de uma célula de NiMH indicando regiões lineares não lineares.



Fonte: Hartmann II (2008).


Figura 2.21: Exemplos genéricos de envelhecimento de células.



Fonte: Hartmann II (2008).

Aquela Tese modela apenas a descarga. Já Saha e Goebel (2009), mencionando Huggins (2008), modelam também a auto-recarga parcial no descanso (*relaxation periods*) e mostram sua a Figura 6, fonte da nossa Figura 2.22. Isto será considerado em alguns ciclos nos Capítulos 4-7 desta Tese.

Figura 2.22: Ajuste do modelo para os processos de descarga e auto-recarga de (baterias) Li-Íon.



Fonte: Saha e Goebel (2009).

3 FORMULAÇÃO DO PROBLEMA E ABORDAGENS PARA A SUA SOLUÇÃO

O objetivo deste capítulo é formular o problema e delinear a sua solução, com base nos conceitos básicos e na literatura disponível, conforme o Capítulo 2.

O problema que se pretende solucionar é estudar, detalhar e inovar modelos de carga e descarga e algoritmos por filtros de partículas para a predição de falhas (EOD, EOL, RUL) em baterias de Lítio-Íon usáveis em satélites artificiais.

A solução adota três grandes áreas de estudos (Figura 3.1), detalhadas adiante, a saber:

- (A) adota o prognóstico de falhas (EOC, EOL, RUL), conforme a Tabela 2.5, por filtros de partículas, conforme as Tabelas 2.3 e 2.4. Como já explorado no Capítulo 2, **esta abordagem é acurada**, extremamente vasta, e vem sendo enfatizada com a evolução das normas e estudos que vem sendo desenvolvidas e refinadas;
- (B) adota baterias de Li-Íon, conforme a Figura 2.14 e a Tabela 2.6. A escolha deste equipamento depende não apenas da sua importância e utilidade para satélites de pequeno e médio porte e outros sistemas, mas da **disponibilidade de bancos de dados experimentais**;
- (C) adota uma abordagem híbrida (modelos e dados) conforme a Tabela 2.2, usando modelos matemáticos (analíticos e estocásticos) conforme a Tabela 2.7, **estudados na e comparáveis com a literatura disponível**, cf o Capítulo 2, para os prognósticos voltados às Baterias de Li-Íon escolhidas.

Figura 3.1: Identificação do escopo do trabalho de tese.



As abordagens a serem utilizadas neste trabalho são: 1) Teoria e Análise; 2) Modelagem e Simulação e 3) Observação/Experimentação.

3.1 Abordagem por Teoria e Análise


A abordagem por Teoria e Análise neste trabalho será alcançada com a utilização de filtros e métodos estatísticos. Como mencionado no Capítulo 2, na literatura é possível encontrar uma grande variedade de algoritmos trabalhos aplicados a uma variedade de sistemas para abordagens prognósticas, o que dificulta a escolha da teoria e análise a ser adotada. No entanto, por meio da leitura e análise dos resultados de vários trabalhos aplicados e trabalhos de comparações de técnicas citados no Capítulo 2, sobretudo nas Tabelas 2.2 e 2.3, optou-se por utilizar métodos de filtragem não linear às baterias de Li-Íon.

Segundo Daum (2005), o problema de filtragem não linear é estimar o valor do vetor do estado $x(t)$, n dimensional no tempo t , dado um conjunto de medições ruidosas, $z_k = \{z(t_1), z(t_2), \dots, z(t_i)\}$, as medições são feitas em momentos discretos. Cada medida $z(t_i)$ no tempo t_i é um vetor de dimensão m . Assume-se que; 1) o estado $x(t)$ evolui no tempo de acordo com uma dada equação diferencial: $\frac{dx}{dt} = f(x, t) + g(x, t)w(t)$, onde $w(t)$ é um ruído de processo (geralmente, mas não necessariamente assume-se ser branco); e que 2) as medições ruidosas estão relacionadas a $x(t)$ por uma função conhecida: $z_i = h(x(t_i), v(t_i), t_i)$ na qual v é o ruído de medição (geralmente, mas não necessariamente assume-se ser branco). As funções $f(\cdot)$, $g(\cdot)$ e $h(\cdot)$ podem não ser lineares em x , e é por isso que chamamos isso de problema de filtragem "não linear". O $w(t)$ gera uma função densidade de probabilidade $f(x(t), t)$, à medida que o estado estendido $(x(t), t)$ se propaga no espaço de estados estendido $(x(t), t)$, a partir de uma condição inicial $(x(t_0), t_0)$.

Este problema é similar ao que ocorre com a propagação de uma nuvem de detritos espaciais a partir de uma fragmentação inicial, com distribuição de densidades relativas equivalentes à fdp. Mesmo que os detritos sejam inicialmente distribuídos segundo uma fdp gaussiana esférica (com excentricidade "e" zero) e tenha simetria de revolução perfeitamente distribuída, os pontos serão propagados sob a Lei do Inverso do Quadrado da Distância que rege o movimento dos corpos. Ao propagar a fdp, esta é deformada e gera uma elipse progressivamente desfigurada ("bananóide"), como é possível visualizar pela Figura (3.2).

Este processo é similar ao do Filtro de Partículas, método de filtragem selecionado para auxiliar na tratativa do problema selecionado, que amostra uma quantidade de pontos (partículas) de uma distribuição qualquer e propaga cada um exatamente de um instante inicial t_0 para um instante t_1 , ajusta uma função, reamostra e propaga novamente de t_1 a t_2 , etc. O PF utiliza amostragem, ajuste e propagação.

Figura 3.2: Propagação de partículas.



Neste trabalho foi selecionado o Filtro de Partículas para aplicações de estimativa de EOL e EOD, pois alguns estudos apontam para o PF como técnica mais acurada que outros filtros, como por exemplo o UK, independentemente do modelo, conforme o Capítulo 2, sobretudo as Tabelas 2.2 e 2.3 (WALKER; RAYMAN; WHITE, 2015; SAHA; GOEBEL; CHRISTOPHERSEN, 2009; JOUIN et al, 2016; DAIGLE; SAHA; GOEBEL, 2012).

Outras razões para utilizar filtros de partículas são: 1) estes utilizarem modelos M2 e M3 que já foram avaliados com essa técnica; 2) melhorias e inovações serão propostas no modelo M4; e implementadas no seu algoritmo; 3) seus resultados serão comparados nas mesmas condições.

Podem-se destacar alguns autores como Daigle, Saha e Goebel (2012); Saha, Goebel e Christophersen (2009); Jouin et al (2016), Walker, Rayman, White (2015), Saha, B. et al 2011. Jouin et al (2016) fez uma revisão sobre PF para prognóstico, levantando as vantagens e desvantagens do uso de PF para muitas aplicações prognósticas. Segundo Jouin et al (2016), o PF é considerado por muitos como o estado da arte para prognóstico baseado em abordagens híbridas e são adequados para resolver o problema da estimativa em tempo real, uma vez que incorporam dados de processo. E os outros autores citados e uma diversidade de outros mais, mostram que o Filtro de Kalman Neutro (*Unscented*), assim como o Filtro de Partículas devem ser mais

explorados em abordagens prognósticas; no entanto, o PF tem se destacado nas aplicações utilizadas. E, apesar dos resultados dependerem em grande parte da aplicação utilizada, no caso de baterias, esses filtros usualmente têm gerado os melhores resultados até o momento.

Informações e resultados de trabalhos publicados, em especial os da equipe de prognóstico da NASA e o Padrão ECSS (2017) foram significativos para auxiliar na escolha das técnicas (algoritmos e medidas de avaliação de desempenho). Um exemplo é o trabalho de Saha, Goebel, Christophersen (2009) que compara alguns algoritmos para estimação de RUL em baterias. Eles apontam que o PF é adequado para lidar com várias fontes de incertezas para baterias de Lítio-Ion, uma vez que definem distribuições de probabilidade entre parâmetros e variáveis. O PF é uma ferramenta excelente para rastrear o estado de um sistema; e, comparado com FKU, se sobressai no esforço computacional para obter solução exata.

Conforme as Figuras 2.11 e 2.12, os atributos de avaliação adotados são: 1) Oportunidade (Tempo de Resposta e Horizonte de Predição) aceitável (“X”) para auxiliar e possibilitar a tomada de decisão antecipada; 2) Correção (Acurácia e Precisão) de bom nível (“Y”), para auxiliar e possibilitar a tomada de decisão certa; 3) Menor carga computacional possível, possibilitando futuramente, através de estudos de viabilidade e melhorias, a discussão de uma possível implementação de tal algoritmo a bordo de satélites ou em outros sistemas; 4) Baixa demanda por dados em variedade e frequência, para baratear experimentos de aquisição de dados.

3.2 Abordagem por modelagem e simulação

A abordagem por Modelagem e Simulação neste trabalho será alcançada com o uso de modelos para gerar dados artificiais para uma abordagem híbrida. Neste caso um modelo de bateria foi adotado e será descrito em detalhes no Capítulo 5. A originalidade deste trabalho está nas melhorias implementadas no modelo EOD.

3.3 Abordagem por observação/experimentação

A abordagem por observação/experimentação neste trabalho será alcançada com a utilização de dados experimentais de baterias. Foi utilizado um conjunto de dados de baterias de Lítio-Íon do repositório de dados de Prognóstico da NASA.

3.4 Sistema escolhido para estudo: baterias

O dispositivo selecionado foi uma bateria de Li-Íon, usável em uma Unidade Condicionadora e Distribuidora de Potência (*Power Conditioning & Distribution Unit-PCDU*): Esta escolha é motivada e justificada por:

- 1) Ser um equipamento/componente de alta importância para satélites de pequeno e médio porte, pois o Subsistema de Suprimento de Energia (PSS – “*Power Supply Subsystem*”) é um dos subsistemas de maior relevância para o sucesso da missão de um satélite (PORTO,2018);
- 2) Atualmente, serem componentes essenciais para o bom funcionamento de uma grande variedade de equipamentos. As aplicações que se beneficiem com o uso de baterias estão cada vez mais presentes na vida cotidiana, de fones de ouvido, celulares, computadores a veículos elétricos, satélites, etc.;
- 3) A falha deste componente pode causar desempenho reduzido, comprometimento operacional e/ou até falhas críticas ou catastróficas;
- 4) O item 3 ocorre especialmente em sistemas espaciais devido à dificuldade em realizar manutenção;
- 5) Houve casos de falhas em baterias nos satélites do INPE (CBERS 2), o que nos motiva a ter um bom entendimento da degradação do desempenho deste sistema o que pode melhorar a confiabilidade dos satélites (MAGALHÃES, 2014; PORTO,2018);
- 6) É um sistema que admite modelos, no entanto, não lineares;

- 7) Disponibilidade de dados confiáveis e disponíveis para tal equipamento. Atualmente esta é uma das maiores dificuldades para desenvolver estudos em aplicações híbridas.

O tipo de bateria adotado para o estudo foi a tecnologia Lítio-Íon, devido à disponibilidade de dados. No entanto, considerando as vantagens e desvantagens das baterias de Lítio-Íon, assim como o cenário atual para aplicações em equipamentos eletrônicos portáteis e espaciais, pode-se dizer que as baterias de Lítio-Íon parecem uma das tecnologias de bateria mais importantes para o presente e o futuro. A Tabela 3.1 enfatiza algumas de suas vantagens e desvantagens.

Tabela 3.1: Vantagens e desvantagens de uma bateria de Lítio-Íon.

Vantagens	Desvantagens
Geralmente são mais leves que outros tipos do mesmo tamanho (são feitas de Lítio leve e Carbono).	A vida útil ou a validade diminui com o envelhecimento, mesmo que não sejam usadas, ao contrário de outras químicas. Ou seja, a partir do tempo de fabricação, independentemente do número de ciclos, a capacidade da bateria irá diminuir gradualmente. *1
Tem alta densidade de energia: muita energia pode ser armazenada em suas ligações atômicas (Lítio é altamente reativo)	Podem ser severamente danificadas por descarga profunda, isto é, descarregando-as abaixo do limite mínimo de tensão recomendado pelo fabricante.
A baixa taxa de auto-descarga mantém sua carga por longos períodos de tempo.*2	Em consequência ao tópico acima, as baterias de íons de Lítio vêm com um circuito de bordo para gerenciar a bateria. Isso as torna ainda mais caras.
Não possuem efeito memória, o que significa não precisam ser completamente descarregadas antes de recarregar a fim de manter a capacidade total de carga como acontece com as de NiCd.	Mais sensíveis a altas temperaturas que a maioria das outras químicas. O armazenamento e as condições operacionais quentes fazem com que se degradem muito mais rapidamente do que normalmente.
Possui um ciclo de vida longo, podendo lidar com centenas de ciclos de carga e descarga sem degradação significativa da capacidade.	Considerada menos segura comparada a NiCd ou NiMH, pois o ânodo produz calor durante o uso, enquanto o cátodo produz Oxigênio (não para todas as químicas de íons de Lítio). O Lítio sendo altamente reativo pode combinar com este Oxigênio, levando à possibilidade de a bateria pegar fogo.

*1 Isso ocorre devido a um aumento na resistência interna, o que torna o problema mais acentuado em aplicações de alta corrente do que as de baixa corrente.

*2 A auto-descarga é causada pelo fluxo iônico e eletrônico residual através de célula, mesmo quando não há corrente externa sendo desenhado.

Fonte: Huggins (2008); Buchmann (2001; Saha, Goebel e Poll, (2009).

4 ADOÇÃO E EQUACIONAMENTO DO FILTRO DE PARTÍCULAS

Neste Capítulo, apresentam-se: 1) o refraseamento matemático do problema, incluindo 2) a teoria e os modelos matemáticos adotados. Isto é considerado uma parte da solução, pois nele há 3) uma série de parâmetros desconhecidos que precisam ser estimados. Segundo Saha e Goebel (2009), mesmo após 4) a estimação destes parâmetros, estes podem não ser diretamente aplicáveis ao conjunto de testes, pois os valores podem diferir de uma bateria para outra e, até mesmo, de um ciclo para outro de uma mesma bateria. Ainda há a possibilidade de os parâmetros variarem dentro de um ciclo.

4.1 Estimação

Pode-se refrasear o problema formulado considerando-o como um problema de estimação (de EOC, EOL, e RUL). Problemas de estimação têm n opções: 1) no futuro (predição=*prediction*), no presente (filtragem=*filtering*), no passado (alisamento=*smoothing*), 2) a partir de dados (usualmente de tensão entre os terminais, corrente através dos terminais, temperatura da célula) e/ou modelos (das baterias de Li-Ion); 3) após (*off-line*) ou durante (*on-line*) sua obtenção; 4) implementados em batelada=lote (*batch*) ou recursivamente= sequencialmente (*sequentially*); 5) considerando (ou não) dinâmicas e medidas não lineares, variantes no tempo e incertas. Tais opções criam n métodos de estimação, como os atribuídos a Gauss, Wiener, Kalman, Daum, etc., suas m variantes, linearizações, extensões, combinações, etc. Um de tais métodos, o Filtro de Partículas (FP), será a solução adotada para o estimador. Segundo Orlande et al. (2012), o Filtro de Partículas (FP), assim como os Filtros de Kalman (FK) podem ser vistos como um caso particular da Estimação Bayesiana, objetivando reduzir os erros dos sinais medidos. Assim, para apresentação do método é necessário apresentar a seguir, a **Estimação Bayesiana** e a **Amostragem por Importância** utilizada para compor o **Filtro de Partículas**.

4.2 Estimação bayesiana

Dentre os n métodos de estimação, destaca-se a Estimação Bayesiana. Esta é feita pelo estimador bayesiano: 1) cujo **preditor** prediz os valores futuros dos parâmetros e outras variáveis de estado a partir de modelos de propagação e suas estimativas iniciais; e 2) cujo **corretor** atualiza tais valores com base em modelos de medição e nas medidas de variáveis de saída. Pode-se iniciar com 1 ou 2, usualmente com 1, como na solução adotada para o estimador.

A Estimação Bayesiana objetiva: 1) **predizer** uma estimativa da variável desconhecida, utilizando todas as informações (modelos) e observações (medidas) disponíveis (anteriores) *a priori* (passadas); e 2) **corrigir** tal estimativa da variável desconhecida, utilizando todas as informações (modelos) e observações (medidas) correntes (atuais) *a posteriori* (presentes); e assim, 3) reduzir suas incertezas. Ou seja: 1) as informações e observações *a priori* são usadas para predizer tal estimativa; 2) esta, as informações e observações *a posteriori*, são combinadas via uma função de verossimilhança, a fim de corrigir tal estimativa da variável desconhecida. Ou seja, esta correção é dada pela capacidade dessa função de inferir sobre x a partir de modelos e de um conjunto de observações z (ORLANDE et al., 2012; STRATONOVICH, 1960).

Em geral, estimadores bayesianos são métodos sequenciais de Monte Carlo fundamentados em simulações para a estimação sequencial da função densidade de probabilidade (pdf) *a posteriori* $p(x_k | z_{0:k})$ (isto é, baseada na história das variáveis de saída=medidas $z_{0:k}$,) de variáveis de estado x_k sob uma dinâmica não linear, variante no tempo e incerta.

Em particular, estimadores bayesianos usualmente assumem que as equações de estado podem ser modeladas como um **processo de Markov de primeira ordem**, com as saídas sendo **condicionalmente independentes** e com **pdfs supostamente conhecidas**. Num caso discreto, não linear, invariante no tempo, as equações de propagação e medição do estado que descrevem o sistema são:

$$x_{i+1} = f(x_i) + \omega_i \quad (4.1)$$

$$z_i = h(x_i) + v_i \quad (4.2)$$

onde x_i é o vetor de estado no instante t_i com índice i , $f(\cdot)$ é a função não linear de transição do estado, z_i é o vetor de saída (de medidas ou observações) no instante t_i com índice i , $h(\cdot)$ é a função não linear de observações e ω_i e v_i são representações de distribuições de ruídos de processo e de medida, respectivamente. Os ruídos são supostamente independentes.

A Figura 4.1 apresenta graficamente as Equação (4.1) e (4.2), onde:

1a) na Equação (4.1), podem haver vários valores de x_i que conduzam ao mesmo valor de $f(x_i)$; da mesma forma, na Equação (4.2) podem haver vários valores de x_i que conduzam ao mesmo valor de $h(x_i)$ (**$f(\cdot)$ e $h(\cdot)$ são sobrejetoras**);

1b) na Equação (4.1), pode até haver um valor de $f(x_i)$ que não seja conduzido por algum valor de x_i ; da mesma forma, na Equação (4.2), pode até haver um valor de $h(x_i)$ que não seja conduzido por algum valor de x_i (**$f(\cdot)$ e $h(\cdot)$ são injetoras**).

Em ambos os casos, as funções **$f(\cdot)$ e $h(\cdot)$ não serão bijetoras=biunívocas=invertíveis**; então, existirá a incerteza pela 1a) indeterminação ou 1b) inexistência de x_i .

E, quando os ruídos são adicionados, as duas fontes de incerteza ω_i e v_i são plurívocas, pela aleatoriedade introduzida pelos ruídos; ou seja:

2a) na Equação (4.1), podem haver vários valores de ω_i que conduzam cada valor de $f(x_i)$ a vários valores de x_{i+1} ; da mesma forma, na Equação (4.2) podem haver vários valores de v_i que conduzam cada valor de $h(x_i)$ a vários valores de z_i ;

2b) na Equação (4.1), pode até haver um valor de x_{i+1} que não seja conduzido de algum valor de $f(x_i)$ por algum valor de ω_i ; da mesma

forma, na Equação (4.2), pode até haver um valor de z_i que não seja conduzido de algum valor de $h(x_i)$ por algum valor de v_i .

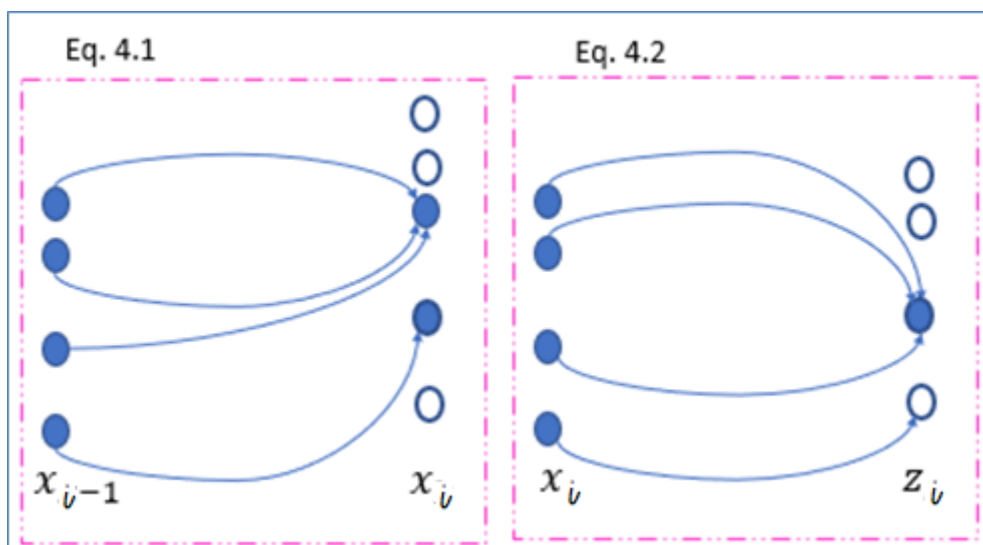
Em ambos os casos, os ruídos ω_i e v_i serão plurívocos; então, existirá a incerteza pela 2a) indeterminação ou 2b) inexistência de x_i .

Estes casos mostram que não há indeterminação ou inexistência em problemas diretos no modelo causal; mas elas podem haver em problemas inversos, onde ocorre a inversão de causalidade: as funções podem não ser inversíveis; e, no caso de o serem, podem ter infinitas soluções.

Ou seja, podem haver dois problemas na volta: 1) $f(\cdot)$ e $h(\cdot)$ não serem bijetoras=biunívocas=inversíveis e, 2) os ruídos ω_i e v_i , serem plurívocos. Desta forma, 1) e 2) juntos podem produzir dupla indeterminação ou inexistência.

Por exemplo, considere $f(x_i) = x^2$, $h(x_k) = x^4$, e $\omega_i \in [-1, +1]$, $v_i \in [-2; +2]$. Estas funções são sobrejetoras: as inversões dessas funções não são unívocas; e, mesmo que fossem, as aleatoriedades desses ruídos criam infinitas possibilidades; ou seja, por causa dessas duas razões o caminho de volta é extremamente difícil de determinar.

Figura 4.1: Representação gráfica das Equações (4.1) e (4.2).



O principal objetivo do estimador bayesiano é estimar o estado x_i a partir de todas as medidas disponíveis $z_{0:i}$, o que significa, da perspectiva bayesiana, construir a pdf *a posteriori* $p(x_i|z_{0:i})$. De acordo com Chen (2003) para realização da estimação bayesiana de x_i , dados os modelos de estados expressos pelas Equações (4.1) e (4.2), é necessário encontrar a pdf $p(x_i|z_{0:i})$. Esta estimação deve ser feita de forma recursiva usando etapas de predição e atualização da estimativa semelhantes às etapas de propagação e medição do estado mostradas nas Equações (4.1) e (4.2).

As Figuras 4.2, 4.3 e 4.4 ilustram graficamente o que ocorre na etapa de predição pelo estimador bayesiano.

Na etapa de predição, o estimador bayesiano busca encontrar os caminhos de volta de z_{i-1} a todos os possíveis x_{i-1} ; e os caminhos de ida de todos os possíveis x_{i-1} a x_k passando por x_{i-1} , conforme a Figura 4.2. A Figura 4.2a é a inversão de causalidade da Equação (4.2) e a Figura 4.2b) é a Equação (4.1) no sentido causal. O mesmo z_{i-1} pode ser gerado por um ou mais pontos de x_{i-1} . Nas Figuras 4.3 e 4.4 os valores de x_{i-1} e z_{i-1} estão no mesmo instante t_{i-1} . Devido à inversão da Equação (4.2) e da aleatoriedade do ruído v_i , há mais de um caminho possível. A Equação (4.4) é um contador dessas possibilidades=caminhos. O resultado da integral (Equação 4.3) é a soma das probabilidades de todos os caminhos possíveis para obter x_i partindo de z_{i-1} passando por todos os possíveis x_{i-1} , conforme mostra a Figura 4.3 para dois pontos diferentes; e a Figura 4.4 para esses dois pontos numa mesma representação.

Figura 4.2: Representação gráfica da etapa de predição pelo estimador bayesiano.




Figura 4.3: Representação gráfica separada da Equação (4.4) para dois pontos.





Figura 4.4: Representação gráfica superposta da Equação (4.4) para dois pontos.



Por isso, é necessário encontrar, inicialmente, a pdf $p(x_i|z_{0:i-1})$ do estado x_i , $i=1, \dots$, dadas as observações desde o instante t_1 até o instante t_{i-1} . Digamos que no instante t_{i-1} tenhamos a pdf $p(x_{i-1}|z_{0:i-1})$. Essa pdf é definida como a priori, uma vez que é uma distribuição para o estado baseada na informação anterior à ocorrência da medição nesse instante.

Na etapa de predição, i.e., no tempo t_{i-1} , o modelo do sistema na Equação (4.1) é usado para obter a pdf $p(x_i|z_{0:i-1})$ anterior à medida no tempo t_i por meio da equação de Chapman-Kolmogorov (CHEN, 2003, GORDON, 1993):

$$p(x_i|z_{0:i-1}) = \int p(x_i|x_{i-1}, z_{0:i-1})p(x_{i-1}|z_{0:i-1})dx_{i-1} =$$

$$p(x_i|z_{0:i-1}) = \int \left(\frac{p(x_i, x_{i-1}, z_{0:i-1})}{p(x_{i-1}, z_{0:i-1})} \right) p(x_{i-1}|z_{0:i-1}) dx_{i-1} =$$

$$p(x_i|z_{0:i-1}) = \int \frac{p(x_i, x_{i-1})p(z_{0:i-1})}{p(x_{i-1})p(z_{0:i-1})} p(x_{i-1}|z_{0:i-1})dx_{i-1} =$$

$$p(x_i|z_{0:i-1}) = \int p(x_i|x_{i-1})p(x_{i-1}|z_{0:i-1})dx_{i-1} \quad (4.3)$$

A aproximação realizada na Equação (4.3) $\left(\frac{p(x_i, x_{i-1}, z_{0:i-1})}{p(x_{i-1}, z_{0:i-1})} = \frac{p(x_i, x_{i-1})p(z_{0:i-1})}{p(x_{i-1})p(z_{0:i-1})}\right)$ só é possível supondo x_{i-1} e $z_{0:i-1}$ independentes assim como os ruídos ω_i e v_i descritos nas Equações (4.1) e (4.2).

Por meio da Equação (4.3) podemos escrever $p(x_i|z_{0:i-1})$ na dependência de outras pdfs condicionais, uma conhecida $p(x_i|x_{i-1})$ e outra desconhecida $p(x_{i-1}|z_{0:i-1})$, mas que pode ser encontrada recursivamente devido ao conhecimento da condição inicial $p(x_0|z_0)$. Sabendo que usualmente não há medições ($z_{-\infty:0}$) antes e até no tempo inicial ($k = 0$), a condição inicial para propagação na solução adotada para o estimador é:

$$p(x_0|z_0) = p(x_0) \quad (4.4)$$

Na etapa de atualização, i.e., no instante t_i , quando as medidas z_i são recebidas, a pdf condicional *a posteriori*, $p(x_i|z_{0:i})$, pode ser encontrada utilizando o teorema de Bayes; $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$. Primeiro, encontra-se $p(x_i)$ pela Equação (4.5). Segundo, encontra-se a pdf condicional *a posteriori* $p(x_i|z_{0:i})$ é expressa pela Equação (4.6) (ARULAMPALAM, 2002, CHEN, 2003, GORDON, 1993):

$$p(x_k) = \frac{p(x_i|z_{0:i-1})p(z_{0:i-1})}{p(z_{0:i-1}|x_i)} \quad (4.5)$$

$$p(x_i|z_i) = \frac{p(x_i, z_i)}{p(z_i)} = \frac{p(z_i|x_i)}{p(z_i)}p(x_i) = \frac{p(z_i|x_i)}{p(z_i)} \cdot \frac{p(x_i|z_{0:i-1})p(z_{0:i-1})}{p(z_{0:i-1}|x_i)}$$

Sabendo que as observações no instante i são dadas por z_i , logo $p(z_i) = p(z_i, z_{i-1})$; pode-se substituí-la acima, obtendo-se:

$$p(x_i|z_i) = \frac{p(z_i, z_{0:i-1}|x_k) p(x_k|z_{0:i-1})p(z_{0:i-1})}{p(z_i, z_{0:i-1}) p(z_{0:i-1}|x_i)} =$$

$$p(x_i|z_i) = \frac{p(z_i, z_{0:i-1}, x_i) p(x_i, z_{0:i-1})p(z_{0:i-1})}{p(x_i)p(z_i, z_{0:i-1}) p(z_{0:i-1})p(z_{0:i-1}|x_i)} \quad (4.6)$$

Utilizando o teorema de Bayes na Equação (4.6) ou na linha anterior, temos (CHEN, 2003; GORDON, 1993):

$$p(x_i|z_i) = \frac{p(z_{0:i-1}|(x_i, z_i)) p(x_i|z_{0:i-1})p(z_i|x_i)}{p(z_i|z_{0:i-1}) p(z_{0:i-1}|x_i)} \quad (4.7)$$

Como $p(z_{0:i-1}|(x_i, z_i)) = p(z_{0:i-1}|x_i)$, logo:

$$p(x_i|z_i) = \frac{p(z_i|x_i) p(x_i|z_{0:i-1})}{p(z_i|z_{0:i-1})} \quad (4.8)$$

As pdfs envolvidas na Equação (4.8) são necessárias, conhecidas ou obteníveis já que, por hipótese, as perturbações ω_i na dinâmica e os ruídos v_i nas medições são independentes, a saber:

- a. a pdf de $p(z_i|x_i)$, obténível pela Equação (4.2), é a pdf de v_i somada com $h(x_i)$;
- b. a pdf de $p(x_i|z_{0:i-1})$, expressa pela Equação (4.4), precisa da pdf $p(x_i|x_{i-1})$, que é a pdf de w_k somada com $f(x_{i-1})$, e da estimativa de $p(x_{i-1}|z_{0:i-1})$.

- c. Com os valores da estimativa inicial ($p(x_0|z_0)$), pode-se estimar $p(z_i|z_{0:i-1})$ de forma recursiva:

$$p(z_i|z_{0:i-1}) = \int p(z_i|x_i)p(x_i|z_{0:i-1}) dx_i \quad (4.9)$$

Substituindo a Equação (4.9) na Equação (4.8), podemos expressar a pdf a *posteriori* obtida após a etapa de atualização como (CHEN, 2003, GORDON, 1993):

$$p(x_i|z_i) = \frac{p(z_i|x_i)p(x_i|z_{0:i-1})}{\int p(z_i|x_i)p(x_i|z_{0:i-1}) dx_i} \quad (4.10)$$

As relações de recorrência descritas nas Equações (4.3) e (4.10) formam a base para calcular a Estimativa Bayesiana ótima. No entanto, essas integrais raramente são de natureza analítica, sendo aproximadas em estimadores bayesianos subótimos, como feito no Filtro de Partículas da Seção 4.2.2.

4.2.1 Amostragem por importância

A técnica de Amostragem por Importância (IS) do Inglês *Importance Sampling* é uma técnica de simulação que: 1) amostra valores de x_i , segundo uma distribuição conhecida $q(x_i|z_{0:i})$, para aproximar os valores de x_i segundo uma distribuição desconhecida $p(x_i|z_{0:i})$; e 2) pode reduzir o viés e a variância dos erros entre esses valores de x_i . Esta técnica foi inicialmente apresentada por Kahn e Marshall em 1953, dentre três métodos: 1) correlação das amostras, 2) **amostragem por importância** e 3) estimação estatística. Estes três métodos foram propostos para solucionar o problema da baixa eficiência dos cálculos de Monte Carlo (KAHN; MARSHALL, 1953).

Segundo Vianna (2020) e Gordon (1993), em muitas aplicações, a estimativa da média $\bar{\theta}$ de uma função $\theta_i = f(x_i)$, condicionada à distribuição $p(x_i|z_{0:i})$ dadas as observações $z_{0:i} \in \mathbb{R}^d$, pode ser necessária, e pode obtida por:

$$\bar{\theta}_i = E_p[f(x_i|z_{0:i})] = \int_{x_i \in D} f(x_i)p(x_i|z_{0:i})dx_i \quad (4.11)$$

onde E_p é a esperança pela distribuição por observações $z_{0:i}$, i é o índice das observações $z_{0:i}$, D o espaço de valores de x_i gerado por $z_{0:i}$ (na Equação 4.1, $x_{i+1} = f(x_i) + \omega_i$; e na Equação 4.2, $z_i = h(x_i) + v_i$). Por questões práticas, considera-se que as distribuições de w_i e v_i são gaussianas com médias zero e variâncias ajustáveis.

De acordo com Chen (2003), a partir da distribuição $p(x_i|z_{0:i})$ podem-se sortear amostras aleatórias de x_i ; e, com a média amostral de x_i , estimar $\bar{\theta}$. Porém, na prática, a distribuição $p(x_i|z_{0:i})$ pode não ser conhecida ou, simplesmente, não caracterizar adequadamente a função $\theta_i = f(x_i)$, o que resulta na inviabilidade ou imprecisão da média $\bar{\theta}$. Para contornar este problema, pode-se utilizar o que se chama de **distribuição por importância** $q(x_i|z_{0:i})$, que é uma pdf mais próxima possível da distribuição por observações $p(x_i|z_{0:i})$ **dentro do domínio D**. E, a partir desta nova pdf, é feita uma amostragem de x_i , ou seja, sorteiam-se N_s amostras aleatórias de x_i , $i = 1, \dots, N_s$ a partir de $q(x_i|z_{0:i})$ ao invés de $p(x_i|z_{0:i})$; e depois, em (4.11), é feito uma correção por um fator de peso, para assegurar que o estimador da esperança $\bar{\theta}$ não é viesado. Esta é uma tática que torna possível o cálculo da média $\bar{\theta}_i$ sem viesar os valores de x_i . Ou seja, a ideia é utilizar uma pdf $q(x_i|z_{0:i})$ para amostrar x_i em vez de utilizar $p(x_i|z_{0:i})$.

Segundo Gordon (1993), o objetivo da amostragem por importância é encontrar a esperança ($\bar{\theta}_i$) de uma função $\theta_i = f(x_i)$ da variável aleatória x_i ,

condicionada às=dadas as medidas $z_{0:i}$ (Equação 4.11). Sabendo que $p(x_i|z_{0:i}) > 0$ para todo $x_i \in D$, se $q(x_i|z_{0:i})$ for uma função de importância positiva no espaço D , ao colocá-la em (4.11) obter-se-á:

$$\begin{aligned}\bar{\theta}_i &= E_p[f(x_i)|z_{0:i}] = \int_{x \in D} f(x_i) \frac{p(x_i|z_{0:i})}{q(x_i|z_{0:i})} q(x_i|z_{0:i}) dx_i \\ &= E_q \left[f(x_i) \frac{p(x_i|z_{0:i})}{q(x_i|z_{0:i})} \right]\end{aligned}\quad (4.12)$$


onde E_q é a esperança pela distribuição por importância $q(x_i|z_i)$. Assim, a variável aleatória x_i passa a ter aproximadamente a distribuição por importância $x_i \sim q(x_i|z_i)$, o que possibilita o cálculo da esperança da média condicional ($\bar{\theta}_i$).

De acordo com Arulampalam et al (2002), a distribuição por importância $q(x_i|z_{0:i})$ não necessita ser positiva em todos os pontos; é suficiente que seja $q(x_i|z_{0:i}) > 0$ quando $f(x_i)p(x_i|z_{0:i}) \neq 0$. O subconjunto do domínio D da função $q(x_i|z_{0:i})$, onde $q(x_i|z_{0:i}) > 0$ é definido como \mathcal{Q} , o que pode ser escrito como $\mathcal{Q} = \{x_i \in D | q(x_i|z_{0:i}) > 0\}$. Desta forma, se $x_i \in \mathcal{Q}$, $f(x_i)p(x_i|z_{0:i}) \neq 0$.

Arulampalam et al (2002) afirmam que a amostragem por importância não deve ser usada descuidadamente. Embora possamos diminuir a variância de $\bar{\theta}_i$ usando uma função de importância $q(x_i|z_{0:i})$ “boa”, também podemos tornar a variância arbitrariamente grande escolhendo uma função de importância $q(x_i|z_{0:i})$ “ruim”, isto é, que aumente a variância de $\bar{\theta}_i$. Ou seja, se se escolher uma função de amostragem cuja pdf $q(x_i|z_{0:i})$ seja muito parecida com a forma de $p(x_i|z_{0:i})$, se poderá reduzir bastante a variância, o que significa que se poderá usar menos amostras. No entanto, se se escolher uma função de amostragem cuja pdf $q(x_i|z_{0:i})$ seja muito diferente de $p(x_i|z_{0:i})$, se poderá aumentar a variância de $\bar{\theta}_i$. A Figura 4.5 mostra exemplos de pdfs que

reduzem ou aumentam a variância geral e compara três funções densidade de probabilidade $q(x_i|z_{0:i})$ candidatas a aproximar uma pdf $p(x_i|z_{0:i})$. A pdf à direita fornece redução de variação em relação à pdf uniforme no centro. No entanto, usar a pdf à esquerda aumentaria significativamente a variância em relação à amostragem uniforme simples.

Figura 4.5: Comparação de três funções densidade de probabilidade.



Fonte: Wojciech Jarosz (2008).

Segundo Viana (2020), logo, se $x_i \in D \cap Q^c$, em que Q^c é o conjunto do domínio D de $q(x_k|z_{0:k})$ complementar a Q , tem-se que $f(x_k) = 0$ uma vez que $x \notin Q$ implica que $f(x)p(x|z_{0:i}) = 0$, e $p(x|z_{0:i}) \neq 0$ visto que $x \in D$. Enquanto se $x \notin D \cap Q^c$ tem-se que $p(x|z_{0:i}) = 0$ em razão de $x \notin D$. Desta forma:

$$\begin{aligned}
\hat{\theta} &= E_q \left[f(x) \frac{p(x|z_n)}{q(x|z_n)} \right] \\
&= \int_{x \in Q} \frac{f(x)p(x|z_n)}{q(x|z_n)} q(x|z_n) dx = \int_{x \in Q} f(x)p(x|z_n) \\
&= \int_{x \in D} f(x)p(x|z_n) dx + \int_{x \in Q \cap D^c} f(x)p(x|z_n) dx \\
&\quad - \int_{x \in D \cap Q^c} f(x)p(x|z_n) dx \cong \int_{x \in D} f(x)p(x|z_n) dx \\
&= E_p[f(x)|z_n] = \bar{\theta}_i \tag{4.13}
\end{aligned}$$

Ao inserir a distribuição por importância, o valor esperado não sofre grandes alterações. A estimativa $\bar{\theta} = E_p[\theta(x_i)|z_i]$ pode ser aproximada considerando a amostragem por importância $q(x_i|z_i)$, de várias formas:

1ª. aproximação: Se for possível obter amostras de x_i , segundo uma distribuição conhecida $q(x_i|z_i)$ que aproxime uma distribuição desconhecida $p(x_i|z_i)$, então:

$$\begin{aligned}
\bar{\theta}_i = E_p[f(x_i^j)|z_{0:i}] &\cong \hat{\theta} = \frac{1}{n} \sum_{j=1}^n \frac{f(x_i^j)p(x_i^j|z_{0:i})}{q(x_i^j|z_{0:i})} = \frac{1}{n} \sum_{j=1}^n f(x_i^j)w(x_i^j), \\
w(x_i^j) &\triangleq \frac{p(x_i^j|z_{0:i})}{q(x_i^j|z_{0:i})} \tag{4.14}
\end{aligned}$$

onde a função densidade de probabilidade, $q(x_i|z_{0:i})$ é uma função densidade amostrável e $w(x_i^j)$ é um fator de correção, denominado **peso por importância**. Essa aproximação segue a Lei dos Grandes Números, que é um teorema fundamental da Teoria da Probabilidade, descrevendo o resultado da

realização de um experimento repetidas vezes. Este teorema diz que após realizar o experimento repetidas vezes, a média amostral dos resultados $\hat{\theta}_i$ tende ao valor esperado θ à medida que mais tentativas n são realizadas:

$$P\left(\hat{\theta}_i = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \frac{f(x_i)p(x_i|z_{0:k})}{q(x_i|z_{0:i})} = \bar{\theta}_i\right) = 1 \quad (4.15)$$

nesse caso P é a medida da probabilidade.

2ª. aproximação: Outra maneira de aproximar amostras de x_i é realizando a autonormalização dos pesos obtidos pela amostragem por importância, resultando em:

$$w(x^j_i) = \frac{w(x^j_i)}{\sum_{i=1}^n w(x^j_i)} \quad (4.16)$$

Neste caso, uma aproximação discreta da probabilidade a posteriori $p(x_i|z_{0:i})$ pode ser obtida pelo somatório de todos os elementos de massa normalizados:

$$p(x_i|z_{0:i}) \approx p(x|z_{0:i}) = \sum_{j=1}^n w(x^j_i) \delta(x - x^j_i) \quad (4.17)$$

Segundo Arulampalam et al (2002), ao particularizar essas condições no Filtro de Partículas, essa autonormalização é utilizada para a estimativa dos estados do sistema dinâmico a partir das saídas (medidas), uma vez que para obter a pdf *a posteriori* (Equação 4.10) é necessário o numerador e denominador da

Equação (4.10) que são os mesmos para todas as ($n=N_s$) partículas, pois todas tiveram a mesma observação.

3ª. aproximação: De acordo com Chen (2003), se não for possível obter amostras de x_i , segundo uma distribuição conhecida $q(x_i|z_{0:i})$ que aproxime as amostras de x_i segundo uma distribuição desconhecida $p(x_i|z_{0:i})$, então outra amostragem segundo uma distribuição $r(x_i|z_{0:i})$ com propriedades semelhantes às de $p(x_i|z_{0:i})$ deverá ser usada e seus pesos normalizados. Após vários cálculos e simplificações, a equação final é:

$$\tilde{\theta} = \frac{\frac{1}{n} \sum_{j=1}^n f(x_i^j) w(x_i^j)}{\frac{1}{n} \sum_{j=1}^n w(x_i^j)} \quad (4.18)$$

Segundo Arulampalam et al (2002) e Chen (2003), a **Amostragem por Importância tem como vantagens:** 1) melhora a precisão em pequenos tamanhos de amostras simuladas, pois pode permitir a redução da variância, 2) oferece redução na carga computacional, ou seja, reduz o tempo de execução das simulações e 3) se mostra útil quando os valores reais dos parâmetros são extremos. Em contrapartida, **um dos grandes problemas** com os algoritmos de Amostragem por Importância é que a variância de seus pesos de importância aumenta com o tempo, o que faz com que os pesos tendam a zero. Isso é conhecido por **degeneração dos pesos das partículas**, a qual deve ser evitada ou controlada rapidamente. Isso ocorre devido às flutuações dos pesos em função da evolução das iterações onde, após algumas iterações, algumas partículas têm um peso alto, tornando as outras amostras desprezíveis. A degeneração resulta em um grande esforço computacional direcionado à etapa atualização das partículas.

De acordo com Arulampalam et al (2002), Chen (2003) entre outros autores, para resolver o problema da degeneração, é usada a abordagem de

Amostragem; e **Amostragem; e Reamostragem por Importância Sequencial**, do Inglês, *Sampling Importance Resampling* (SIR). Ou seja, realizar a reamostragem no algoritmo, replicar as partículas com pesos maiores ou de maior importância (próximo a 1) e eliminar aquelas com pesos menores, que, por sua vez, apresentam pouco efeito nas estimativas.

4.2.2 Filtro de partículas

Dentre as n implementações do estimador bayesiano, destaca-se o Filtro de Partículas (FP) por tratar sistemas com dinâmicas e medidas não lineares, variantes no tempo e incertas. Baseados nos Capítulos 2 e 3, sobretudo em: Saha e Goebel (2009); Saha, Goebel e Christophersen (2009); Saha, Goebel, Poll e Christophersen (2007); Saha, Goebel, Poll e Christophersen (2009); e pela dinâmica não linear, variante no tempo e incerta das baterias de Li-Íon, pode-se adotar o Filtro de Partículas (*Particle Filter* - PF) como método de solução.


O método é baseado em representações e propagações de funções densidades de probabilidade por amostras compostas por N_s estados simultâneos $x_i^{(j)}$ ($j = 1, \dots, N_s$) (“partículas”, de massa pontual), que podem ser aplicadas a qualquer modelo de espaço de estados e que são mais gerais que os métodos tradicionais de filtragem (Gauss, Kalman, Daum, etc.).

Segundo Chen (2003) e Arulampalam et al (2002), o Filtro de Partículas é uma técnica de Monte Carlo para solução de problemas de estimação de estados. A ideia é representar a pdf de interesse e necessária *a posteriori* por meio de um conjunto de (N_s) amostras aleatórias $x_i^{(j)}$ ($j = 1, \dots, N_s$), chamadas de partículas com pesos associados $w_i^{(j)}$ ($j = 1, \dots, N_s$), e calcular as estimativas com base nessas amostras e pesos. À medida que o número de amostras é aumentado, esta caracterização torna-se uma representação equivalente à função densidade de probabilidade *a posteriori*, e a solução se aproxima da estimativa ótima bayesiana.

De acordo com Chen (2003), tradicionalmente o Filtro de Partículas inicia-se a partir de uma amostra de número N_p para o vetor de estados baseando-se na pdf do estado inicial $p(x_0)$, supostamente conhecida. Os possíveis estados do processo são as partículas, que podem ser representados como pontos no espaço $x_i^{(j)}$ ($j = 1, \dots, N_s$), onde N_s é o número de partículas do sistema. Cada amostra tem um peso correspondente $w_i^{(j)}$ ($j = 1, \dots, N_s$) os quais são calculados a partir da função de verossimilhança. A função de verossimilhança irá comparar os valores simulados com os valores medidos, sendo então possível estimar a distribuição *a posteriori* a partir desse conjunto de partículas aleatórias com pesos atribuídos. Assim, para cada instante de tempo ($i = 1, 2,$) propagam-se as partículas para o próximo instante por meio da Equação (4.1) de evolução do processo.

A Figura 4.6 ilustra o processo da replicação de partículas da região de alta concentração. As partículas representam a distribuição *a posteriori*: próximo ao valor esperado da distribuição, haverá uma região com alta concentração de partículas; e, para regiões mais afastadas desses valores, a concentração será menor; nestas, os pontos são chamados de *outliers*.

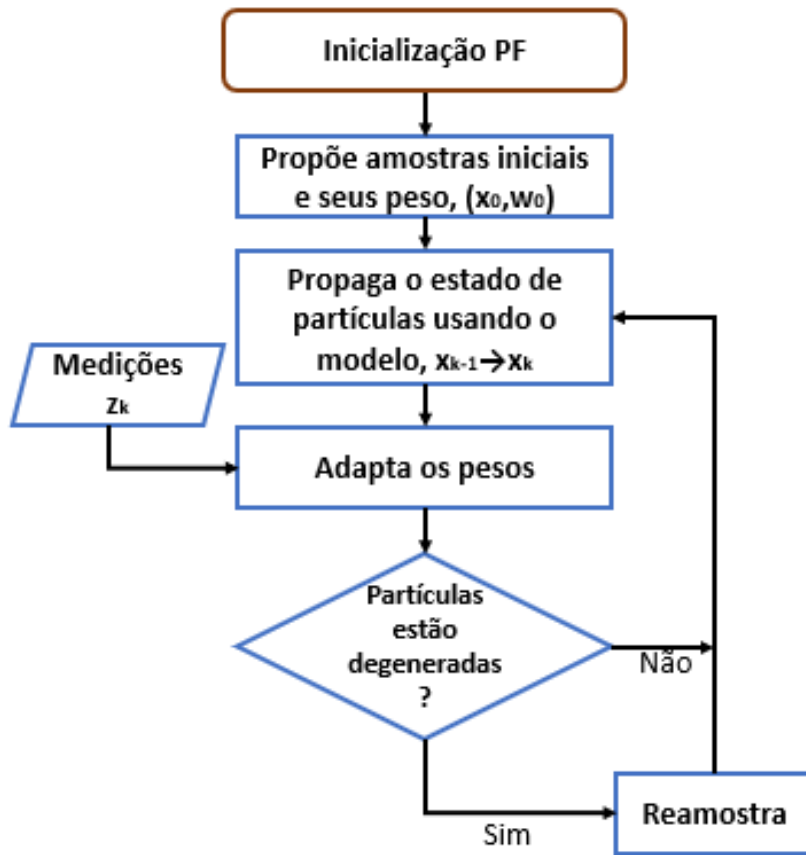
Figura 4.6: Processo de replicação de partículas.



Fonte: Djuric et al. (2003).


As Figuras 4.7 e 4.8 apresentam o fluxograma básico e o processo do filtro de partículas selecionado para este trabalho. Inicialmente, são geradas as (N_s) partículas a partir de uma distribuição $p(x_0|z_0)$, onde todas as partículas apresentam peso uniforme. Segundo Chen (2003), a partir disso, as partículas são **atualizadas** com os pesos $p(x_i|z_{0:i})$ conforme os valores medidos $z_{0:i}$. Na etapa de **reamostragem**, as partículas de menor peso são **desprezadas** e as de maior peso são **selecionadas e replicadas**, pois apresentam maior probabilidade de representar a distribuição *a posteriori*. Na sequência, é feita a **predição** para o próximo passo t_{i+1} . A evolução é realizada até o t_{final} do algoritmo.

Figura 4.7: Fluxograma de filtragem de partículas genérico.



Fonte: Adaptado de Saha et al (2011).

Figura 4.8: Passos de um filtro de Partículas SIR genérico.



Fonte: Adaptado de Chen (2003).

A qualidade do algoritmo depende da escolha da função de **atualização dos pesos** w_i^j . Conforme Arachchige et al (2017), Equação 10 (e suas simplificações, Equações 11 e 12), citando Arulampalam et al (2002), Equação 48 (obtida das suas Equações 43 a 46), temos:

“There are several ways to update the weights:

- Sequential importance sampling: when an importance density function $q()$ is available, the weights can be updated using:

$$w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i) \quad (10)$$

- When the importance density sampling function is chosen so that it reduces the variance of the weights:

$$w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i) \quad (11)$$

- Occasionally, the importance density sampling function is chosen to be the PDF of the state based only on the previous state. The weighted update function is then:

$$w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i) \quad (12)$$

Neste algoritmo, os pesos são atualizados/corrigidos pela 3ª. opção, i.e., por:

$$w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i) \quad (12)$$

$$w_i^j = \frac{w_i^j}{\sum_{j=1}^{N_s} w_i^j} \quad (13)$$

5 ADOÇÃO E EQUACIONAMENTO DOS MODELOS DAS BATERIAS LÍTIO-ÍON

Neste Capítulo, apresentam-se: 1) o modelo clássico de Randles (M1); 2) a reescrita de M1 no modelo empírico descrito por Saha e Goebel (2009) (M2); 3) a flexibilização de M2 por Arachchige et al (2017) (M3); todos para a predição de EOD, EOL e RUL. O M1 modela processos internos como quedas de tensão devidas às resistências internas do eletrólito e aos efeitos de polarização por ativação/carga do eletrodo, polarização por concentração/difusão do reagente da bateria, por um circuito equivalente com resistores e capacitores. O M2 os substitui por curvas de descarga ajustadas sob correntes aproximadamente constantes. O M3 as flexibiliza para correntes variáveis. Apresentam-se um possível repertório de falhas e o equacionamento e as características dos modelos que poderão ser consideradas nos Capítulos 6 e 7. Lá, propõe-se um modelo melhorado e inovado (M4) e compara-se com o M3 sob as mesmas condições deste.

5.1 Repertório de falhas em baterias

Para monitorar as variáveis de interesse, é necessário definir e selecionar o repertório usual de falhas ou falências do sistema. Nas áreas de pesquisa relacionadas ao tratamento ou prognóstico de falhas ou falências, a arquitetura do sistema é geralmente descrita em termos funcionais e/ou físicos. Aqui, são descritas algumas das falhas que poderiam ser utilizadas para modelar o sistema de prognóstico e que o modelo admite.

A bateria de Lítio-Íon contém uma variedade de condições operacionais que podem ser monitoradas por sensores. Dependendo do tipo de aplicação e da disponibilidade dos dados, há muitas abordagens que se concentram na estimativa de: Estado de Carga (SOC), corrente/tensão, capacidade, Estado de Saúde (SOH), Vida Útil Remanescente (RUL), etc. As variáveis de estado comumente usadas para monitorar falhas da bateria e estimar a RUL são: SOC, temperatura, tensão da célula, capacidade de carga e impedância. De

acordo com os modelos utilizados, elas podem variar, salientando que, quanto mais medidas forem colhidas pelos sensores para o monitoramento, maior será a complexidade e a dimensionalidade para os algoritmos e modelos selecionados.

Segundo Stamps et al. (2005), a redução no desempenho da bateria pode se manifestar de duas maneiras: 1) pela redução da capacidade da bateria de armazenar carga; e 2) pelo aumento da impedância específica e da resistência à transferência de carga, que reduzem o potencial da célula.

5.1.1 Redução da capacidade de carga

Segundo Gantenbein (2019), a redução da capacidade de descarga $C(t)$ é causada pela perda do material do eletrodo ativo. Arachchige et al (2017) dizem que esta é uma falha caracterizada pela redução da capacidade de descarga máxima $C(t_0)=Q(t_0)$ que uma bateria é capaz de armazenar. Com o envelhecimento, a capacidade de descarga diminui, o que pode aumentar a impedância interna. Vários fatores podem contribuir para a redução da capacidade de descarga como, por exemplo, o envelhecimento, temperatura do ambiente de armazenamento, o Estado de Carga (SOC) em que a bateria foi armazenada e os ciclos de cargas e descargas sofridos. Ou seja:

$$\frac{dC(t)}{dt} < 0 \quad (5.1)$$

$$\frac{dQ(t)}{dt} < 0 \quad (5.2)$$

Já que $Q(t_0) = C(t_0)V(t_0)$, onde $V(t_0)$ é uma constante externa imposta.

5.1.2 Redução da potência

Redução da potência se refere à incapacidade da bateria de fornecer a energia necessária para utilização. Segundo Arachchige et al (2017), esta falha também tem relação com a impedância interna: um aumento na impedância interna causará uma redução na potência que a bateria pode fornecer. Assim, a impedância interna deve ser monitorada para avaliar a degradação da bateria. A Equação (5.3) mostra esta relação em um curto circuito por uma impedância $Z = \text{impedância externa } Z_{\text{ext}} + \text{impedância interna } Z_{\text{int}}$.

$$P = I V = I^2 Z = \frac{V^2}{Z} \quad (5.3)$$

A Tabela 5.1 mostra um resumo dos modos de falha da bateria e descreve suas principais causas e sintomas. As falhas 1 e 2 ocorrem no nível da célula. A “*thermal runaway*” é uma falha que se origina no nível da célula, mas pode se propagar para as outras células que compõem o sistema. A taxa na qual o calor é produzido no sistema excede a taxa na qual ele pode ser dissipado. O modo de falha 3 ocorre quando os SOCs de diferentes células de uma bateria se desviam uns dos outros.

Tabela 5.1 Repertório de falhas de baterias de Lítio-Ion.

	Falhas	Causas Primárias	Sintomas	Parâmetros para Monitorar
1	<i>Descarga na Prateleira (auto descarga)</i>	Altas temperaturas ambientes, tanto durante o uso quanto no armazenamento	Perda de Capacidade; Aumento da impedância interna da célula.	SOC; Temperatura
2	Avalanche Térmica	Curto-circuito interno ou externo de uma célula; Alta temperatura de operação (<i>overheating</i>); <i>Overcharging</i> .	Aquecimento celular durante o carregamento, especialmente próximo ao final do carregamento; alta queda de tensão durante os períodos de descanso; Capacidade de carga superior à capacidade de descarga.	Temperatura, SOC, tensão
3	Desbalanceamento das Capacidades das Células	Comportamentos diferentes de células dentro do mesmo módulo	Tensões de células diferentes	SOC, tensão
4	Redução da Capacidade de carga	Envelhecimento (tempo e uso); Excesso de descarga celular; Operação a baixa temperatura.	A capacidade diminui com o tempo; Aumento da resistência interna da célula.	SOC; Temperatura e Capacidade
5	Redução da Potência	Envelhecimento (ciclo de envelhecimento)	Alta impedância da bateria	Impedância

Fonte: Adaptado de Arachchige et al (2017).


5.2 Modelagem

Antes de abordar a modelagem para o ciclo de carga e descarga, serão descritos **os três regimes usuais de um ciclo de carga de bateria**: 1) inicialmente, aplica-se uma corrente externa; desta forma, a tensão do “capacitor” interno vai subindo, chegando a um valor que produz bolhas de hidrogênio e de oxigênio internas que elevam a temperatura da bateria e que podem explodi-la; 2) então, inicia-se o segundo regime, o momento que se chaveia para uma tensão constante que seja abaixo da tensão dessa produção de bolhas, um regime que mantém a tensão e abaixa a corrente; 3) o terceiro

regime é quando se aproxima e atinge a carga completa, desligando e chaveando para a **descarga**.

Entre os ciclos de descarga e carga pode haver **um período de descanso**, onde ocorre a auto-recarga; e, na sequência, inicia-se o ciclo de carga, como apresentado na Figura 5.1.

Figura 5.1: Modelo para o processo de descarga e auto recarga.



Fonte: Saha e Goebel (2009).

No processo de carga, existe um intervalo que se inicia em t_0 e vai até t_b , iniciando numa tensão $V(t_0)$ próxima de 0 que se eleva até ao valor $V(t_b)$ da carga. Após, existe um período, um pequeno intervalo de tempo, entre o término da carga e o início da descarga; após esse período, a descarga se inicia com uma tensão que não é a mesma do final da carga. Idealmente seria igual mas, devido às resistências internas em série e paralelo, há uma perda da tensão antes de a descarga se iniciar. Isto admite m modelos, estudados em n publicações, como revisado no Capítulo 2.

De especial importância para esta Tese são as referências Randles (1947), Huggins (2008), Hartman II (2008), Saha e Goebel (2009), Arachchige et al. (2017), Gabrielli (2019), e alguns modelos, a saber: Segundo Gabrielli (2019):

So, to understand electrochemical mechanisms various techniques were proposed. Among all these techniques Electrochemical Impedance Spectroscopy (EIS) is based on

sinewave analysis of stable electrochemical systems [since F. Kohlrausch, in 1869]. This gives a unique “signature” of the investigated processes which has to be compared to a model, not always unique, inspired by the electrochemical theory to interpret the reactional mechanisms evolving at the metal-electrolyte interface.

Dentre eles:

1º. Modelo (M1): é o modelo elétrico/equivalente original (M1a) de Randles (1947); seu rearranjo (M1b), mostrado por Kai e Goebel (2008, 2009); e sua renotação (M1c), mostrada por Arachchige et al (2017). Randles (1947) diz:


There are three factors 1 which may operate in controlling the speed of an electrode reaction, (1) the rate of the electrode process itself, (2) the rates of diffusion of the reactant and product, and (3) the ohmic resistance of the electrolyte.

Hartman II (2008) repete-os com um 4º. fator: a temperatura. Em Randles (1947), ele:

- 1) partindo de um modelo químico de reações iônicas metal-metal de um eletrodo (amálgama de cobre, zinco, cádmio, ou tálio + mercúrio) com o reagente (seus íons);
- 2) partindo de um modelo matemático (Equação da Difusão) da difusão do reagente no eletrólito (solução de cloreto de amônio) (análoga à Equação do Calor, desenvolvida por J. B. J. Fourier (1822) na Teoria da Condução do Calor em Sólidos);
- 3) mantendo a célula em um termostato com temperatura em $25 \pm 0.1^\circ\text{C}$;
- 4) aplicando uma tensão senoidal $v(t) = a \cdot \text{sen}(\omega \cdot t)$, de amplitude a pequena e frequência ω variável entre o eletrodo e um contato de platina imerso no eletrólito, em torno de uma condição de equilíbrio químico e elétrico (E_0) (uma forma do Método da Espectroscopia de Impedância Eletroquímica (ver seção 6.1.1), análogo aos Métodos da Resposta em Frequência e da Linearização, desenvolvidos por H. Nyquist (1922 e 1932), N. Nichols (1934), e H. Bode (1947) na Teoria de

- Controle); aplicando o mesmo a um banco de resistores e capacitores conhecidos, variáveis e em paralelo;
- 5) aplicando a mesma $v(t)$ a um banco de resistores e capacitores conhecidos, variáveis e em paralelo;
 - 6) amplificando as diferenças de potencial em obtidas 4 e 5, e plotando-as nos eixo XX e YY de um tubo de raios catódicos;
 - 7) medindo e comparando as figuras obtidas (análogo ao Método das Figuras de Lissajous);
 - 8) modelou e identificou tal conjunto eletrodo-reagente- eletrólito pelo circuito elétrico equivalente da Figura 3 de Randles (1947), e mostrado na nossa Figura 5.2:

Figura 5.2: Modelo original (M1a) de Randles, a parâmetros concentrados de uma célula.



Fonte: Randles (1947).


Nela, segundo Randles (1947):

The whole electrode system is electrically equivalent to the circuit shown in Fig. 3 (a), where C_r , and R_r , are the capacity and resistance equivalent to the electrode reaction, C_l the

ordinary double layer capacity of the electrode surface and R_c , the electrolyte resistance between the electrode and the platinum gauze.

Rearranjando C_r , and R_r obtém-se M1b da Figura 3 de Goebel et al (2008), copiada na Figura 4 de Saha e Goebel (2009), e mostrada na nossa Figura 5.3:

Figura 5.3: Modelo rearranjado (M1b) de Randles, a parâmetros concentrados de uma célula.



Fonte: Goebel et al (2008) e Saha e Goebel (2009).

Nela, segundo eles:


The parameters of interest are the double layer capacitance C_{DL} , the charge transfer resistance R_{CT} , the Warburg impedance R_W and the electrolyte resistance R_E . The values of these internal parameters change with various aging and fault processes like plate sulfation, passivation and corrosion.

Ou ainda:

The IR drop due to the electrolyte resistance is denoted as R_E . The activation polarization is modeled as a charge transfer resistance R_{CT} and a dual layer capacitance C_{DL} in parallel, while the concentration polarization effect is encapsulated as the Warburg impedance R_W .

Renotando $Z_w=R_w$, obtém-se M1c da Figura 1 de Arachchige et al (2017), e mostrada na nossa Figura 5.4.

Figura 5.4: Modelo renotado (M1c) de Randles, a parâmetros concentrados de uma célula.



Fonte: Arachchige et al (2017).

Nela, segundo eles: “ R_E , R_{CT} and Z_W are the electrolyte resistance, charge transfer resistance, and Warburg impedance, respectively.” Detalhando: há a resistência do eletrólito (*electrolyte resistance*) R_E em série com uma capacitância de dupla camada (*double layer capacitance*) C_{dl} ; e, em paralelo com a capacitância C_{dl} , há a resistência à transferência de carga (*charge transfer resistance*) R_{CT} e a impedância de Warburg (*Warburg impedance*) R_W , redenotada por Z_W .

Desde então, conforme Hartman II (2008) e Gabrielli (2019), muitos autores tentaram estendê-lo para carga e descarga (ver Anexo A), considerando que:

Na carga em $t \in [t_0 ; t_b]$, sendo $V(t)$ a tensão entre os terminais, por causa da corrente que passa em série por R_E , há uma redução de tensão $\Delta V(t)$, chegando $(V(t) - \Delta V(t))$ em C_{dl} . Parte da corrente da carga que passa por R_E se divide, indo uma parte por C_{dl} e outra passa por R_{CT} e $R_W = Z_W$. A parte direcionada a R_{CT} e $R_W = Z_W$ reduz as medições de corrente em C_{dl} , à medida que a bateria se carrega, até que ela se desliga com carga completa. Ao desligar, C_{dl} está com tensão $(V(t_b) - \Delta V(t_b))$ e começa a se descarregar através de R_{CT} e $R_W = Z_W$; ou seja, na carga, quem produz uma redução da tensão é R_E ; e na descarga, quem produz uma redução da corrente são R_{CT} e $R_W = Z_W$.

Na descarga em $t \in [t_k ; t_{k+1}]$, quando o circuito externo ainda não está ligado, não circula corrente pelo resistor em série, mas passa a circular pelos paralelos. O “capacitor” começa a descarregar pelos resistores em paralelo.

Quando o circuito externo é ligado, o “capacitor” já descarregou um pouco e continua, ou seja, quando se inicia o processo de descarga por um circuito externo, há uma segunda queda de tensão por causa dos resistores em paralelo e uma terceira queda por conta do resistor em série, o que produz uma tensão medida menor. Para a descarga, a medida de interesse para a modelagem é a tensão medida, que não é a tensão do “capacitor” interno, mas é a tensão nos extremos= terminais da bateria.

M1 não é usado diretamente por Saha e Goebel (2009), nem por Arachchige et al (2017), e nem por esta Tese.

2°. modelo (M2): é um modelo matemático/empírico apresentado na Figura 5 de Saha e Goebel (2009), copiada como Figura 2 de Arachchige et al (2017), e mostrada na nossa Figura 5.4. Em tais referências, M2 é usado; e aqui será usado e melhorado diretamente.

No modelo de Saha e Goebel (2009), o comportamento de baterias de Lítio-Íon durante os ciclos de descarga e de vida útil é descrito, reescrevendo as 3 quedas de tensão de saída do modelo de Randles. Segundo os autores, embora o modelo tenha sido desenvolvido com as químicas das baterias de Lítio-Íon, ele pode ser aplicado a outras baterias, desde que os efeitos específicos dessas químicas também sejam modelados, como, por exemplo, o efeito de memória nas baterias recarregáveis de Ni-Cd. A base do modelo foi vinculada aos processos internos da bateria e validada usando dados experimentais. Ele será detalhado a seguir.

3°. modelo (M3): repete-se M2 mas: 1) sintetiza-se uma medida \tilde{C}_k da capacidade de descarga máxima $C_k=C(t_k)=Q_k=Q(t_k)$ no ciclo atual $[t_k; t_{k+1}]$, usando o método de contagem de Coulomb na sua Equação 14, aqui mostrada como nossa Equação (5.9) (segundo o código de M3); ou 2) gera-se uma predição $\hat{C}(t_k)$ pelo seu Filtro de Partículas alimentado por \tilde{C}_k (segundo as suas Figuras 4 e 6).

Em tais referências, M1 é citado, mas não usado diretamente, pois supõe equilíbrio e desvios senoidais; e não carga e descarga. Mas foi estendido a estas por vários autores, considerando:

5.2.1 Modelo para o Fim de Descarga (EOD - *End-Of-Discharge*)

Fazer a estimativa do Fim de Descarga (EOD) de uma bateria, segundo Saha e Goebel (2009) é um problema com diferentes processos físicos que afetam a Vida Útil Remanescente (RUL) tanto para o Fim de Descarga (EOD) quanto para o Fim de Vida (EOL). Em relação à descarga, a busca de uma solução exige prever como os parâmetros de impedância se alteram com a queda da carga no ciclo de descarga. Esses parâmetros de impedância são representações de reações eletroquímicas e processos de transporte dentro da bateria, que são afetados pela temperatura interna da bateria, a carga atual e as concentrações iônicas dos reagentes. Conforme o processo de descarga avança, calor é gerado pelas reações que, junto com a corrente, resultam no aumento da temperatura e aumento da mobilidade dos íons, diminuindo a impedância de Warburg ($R_W = Z_W$). Com o decréscimo de Z_W , aumenta a taxa de auto-descarga aumentando a resistência eletrolítica (R_E) da bateria. Com a elevação da temperatura da bateria, o consumo é afetado, fazendo com que a bateria descarregue mais rápido perto do final da descarga, contribuindo para o aumento da resistência à transferência de carga (R_{CT}) e para uma queda acentuada na tensão celular. O processo de descarga é desligado quando a tensão de saída atinge o mínimo da tensão (com limiar (*threshold*) seguro), chegando ao valor de EOD. Então:

No 1º. Modelo (M1): a tensão de saída é expressa pela Equação 1 de Saha e Goebel (2009), copiada na Equação 4 de Arachchige et al (2017), e mostrada na nossa Equação (5.3), como:

$$E = E_0 - I(R_E + R_{CT} + Z_W) \quad (5.3)$$

onde: E_0 é teoricamente a tensão de circuito aberto; I é a corrente; R_E , R_{CT} e $R_W = Z_W$ são as resistências ao eletrólito, resistência à transferência de carga e impedância de Warburg, respectivamente.

A Equação (5.3) adiciona E_0 em série com os R_s e zera a corrente em C_{dl} na Figura 5.3; e não é função do tempo t , pois M1 supõe equilíbrio (E_0) e pequenos desvios senoidais $v(t) = a \cdot \text{sen}(\omega \cdot t)$ em torno dele; e não carga e descarga. M1 não é usado diretamente por Saha e Goebel (2009), nem por Arachchige et al (2017), e nem por esta Tese.

No 2º. Modelo (M2): a tensão de saída pode ser reescrita pelas Equações 2 a 5 de Saha e Goebel (2009), copiada nas Equações 5 a 8 de Arachchige et al (2017), e mostrada nas nossas Equações (5.4) a (5.7), como:

$$E(t) = E_0 - \Delta E_{sd}(t) - \Delta E_{rd}(t) - \Delta E_{mt}(t) \quad (5.4)$$

Onde ΔE_{sd} é a queda de tensão devido à descarga de prateleira (*shelf discharge*); ΔE_{rd} é a queda de tensão causada pelo esgotamento do reagente celular, ΔE_{mt} representa a queda de tensão devido à resistência interna à transferência de massa. Eles podem ser expressos individualmente como:

$$\Delta E_{sd}(t) = \alpha_1 \exp\left(\frac{-\alpha_2}{t}\right) \quad (5.5)$$

$$\Delta E_{rd}(t) = \alpha_3 \exp(\alpha_4 t) \quad (5.6)$$

$$\Delta E_{mt}(t) = \Delta E_{init} - \alpha_5 t \quad (5.7)$$

Onde: ΔE_{init} é a queda da tensão inicial quando a corrente I , passa pela resistência interna R_E no início do ciclo de descarga. Isso é calculado por


$\Delta E_{init} = I R_E$. Os alfas ($\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5$) são os parâmetros (>0) do modelo a serem estimados pelo Filtro de Partículas, por meio da implementação do modelo e dos dados adquiridos. A Figura 5 de Saha e Goebel (2009), copiada como Figura 2 de Arachchige et al (2017), e mostrada na nossa Figura 5.5, mostra o efeito de cada termo e mostra também como os diferentes componentes de queda de tensão definidos nas Equações (5.5) a (5.7) se combinam para dar o perfil de descarga de uma bateria de íons de Lítio de corrente aproximadamente constante típico de todo o modelo de EOD. Pode-se observar que dos três componentes dados nas Equações (5.5) a (5.7), o esgotamento do reagente celular (ΔE_{rd}) é o termo principal na determinação do EOD. Os termos α_3 (pequeno) e α_4 são os parâmetros que mais contribuem para a descarga; portanto, são os que mais afetam a predição de EOD.

O problema é predizer o fim da descarga, o instante t_{eod} em que o estado $E(t_{eod})$ (tensão da célula) atinge o limiar estabelecido E_{eod} . Desta forma, a tensão de saída $E(t)$ é modelada a partir da Equação (5.8), com $t = t_{eod}$, $E(t)=E_{eod}$:

$$E(t) = E_0 - \alpha_1 \exp\left(\frac{-\alpha_2}{t}\right) - \alpha_3 \exp(\alpha_4 t) - I R_E - \alpha_5 t \quad (5.8)$$

Por fim, Saha e Goebel (2009) tornaram as Equações de alfas (α_{1-5}), $E(t)$ recursivas; e com $z(t)$, amostradas e com ruídos, num ciclo de descarga, $[t_k; t_{k+1}]$ onde t_i é um instante de amostragem no intervalo de amostragem $[t_i; t_{i+1}]$ num ciclo de descarga $[t_k; t_{k+1}]$; isto é, $t_i \in [t_i; t_{i+1}] \subset [t_k; t_{k+1}]$ obtendo as Equações (6.1) a (6.7).

Figura 5.5: Decomposição dos perfis de descarga (da bateria) de Lítio-Íon.



Fonte: Saha e Goebel (2009).

No 3º. Modelo (M3): repete-se M2 mas calcula-se α_4 pela variável de estado auxiliar $SOC(t_i) = Q(t_i)/Q(t_k)$, onde C é produzido pelo EOD usando o método de contagem de Coulomb na sua Equação 14, aqui mostrada como nossa Equação (5.9), onde C é a carga $Q(t)$:

$$C = \int Idt \quad (5.9)$$

Este método de contagem de Coulomb é utilizado para estimar o estado de carga da bateria SOC_{i+1} na sua Equação 19, aqui mostrada como nossa Equação (5.10):

$$SOC_{i+1} \approx SOC_i - \frac{I_i T_s}{C} \quad (5.10)$$

O Estado De Carga (SOC) é refletido pela tensão e o perfil de carga é avaliado pela medição da corrente. Cada vez que uma nova medição de corrente está presente, o estado de carga da bateria é atualizado para incluir os efeitos da carga que já foi extraída da bateria.

Quando se quer prever o EOC ou o EOL (pontos * nos gráficos), a última atualização das variáveis α_1 , α_2 , α_3 e α_5 é mantida e o parâmetro α_4 é recalculado, assumindo que o perfil de carga utilizado pela aplicação permanece o mesmo até o final da descarga, a fim de propagar o estado atual da bateria. E a adaptação do novo estado de carga é calculado pela sua Equação 28, aqui mostrada como Equação (5.11).

$$SOC_{i+1} \sim SOC_i - \frac{(1 - SOC_i) T_s}{t_i} \quad (5.11)$$

onde o período de amostragem T_s é usado para atualizar o tempo t_i .

As aproximações e considerações para estas equações que são consideradas inclusive para o cálculo de α_4 não são detalhadas ou explicadas na publicação.

A maior contribuição de Arachchige et al (2017) é na Equação (5.12), que é o cálculo de α_4 :

$$\alpha_{4,i+1} = a \frac{(1 - SOC_i)}{t_i} + v_{4,i} \quad (5.12)$$

onde a é uma constante de ajuste do algoritmo, t_i é o instante de amostragem atual e f_s é a frequência de amostragem. Diz-se que $a = 10.8$ (parece muito alto para um “ajuste”...!) um valor encontrado experimentalmente (não é detalhado como). As demais equações são as mesmas do modelo M2.

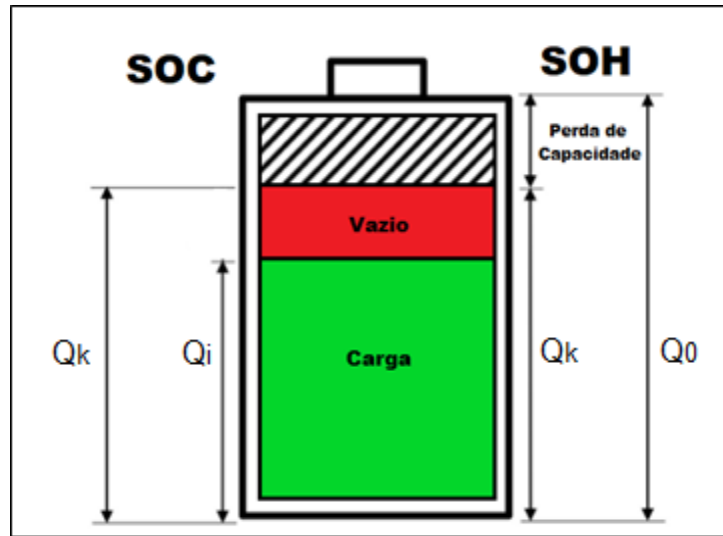
5.2.2 Modelo para o Fim de Vida (EOL - *End-of-life*)

Segundo Saha e Goebel (2009), para determinar efetivamente a EOL de uma bateria de Lítio-Íon, deve-se entender como os diferentes modos operacionais (carga, descarga e repouso) influenciam a capacidade de descarga.

Desta forma, devemos entender como esses conceitos de SOC, SOH e RUL se aplicam ao sistema e ao modelo para que a análise dos resultados seja adequadamente interpretada. O SOH e SOC podem ser confundidos; assim, é importante salientar as diferenças entre eles. O SOC se refere às mudanças a curto prazo na bateria; pode ser medido pela relação $SOC(t_i) = Q_i/Q_k$ entre a capacidade de descarga instantânea no ciclo atual $Q_i = Q(t_i)$ da bateria e a sua capacidade de descarga máxima no ciclo atual $Q_k = Q(t_k)$ num ciclo de descarga, $[t_k; t_{k+1}]$ onde t_i é um instante de amostragem no intervalo de amostragem $[t_i; t_{i+1}]$ num ciclo de descarga $[t_k; t_{k+1}]$; isto é, $t_i \in [t_i; t_{i+1}] \subset [t_k; t_{k+1}]$. Já o SOH se refere às mudanças a longo prazo; pode ser medido pela relação $SOH(t_k) = Q_k/Q_0$ entre a capacidade de descarga máxima no ciclo atual Q_k e a capacidade de descarga máxima no ciclo inicial=capacidade nominal $Q_0 = Q(t_0)$, como mostra a Figura 5.6. Eles e vários autores usam $C_k = C(t_k) = Q_k = Q(t_k)$.


A Figura 5.7 apresenta a relação de SOH ao longo do tempo, que pode ser em horas (t) ou ciclos (k). Conforme o tempo avança, a degradação aumenta até esta atingir os limites aceitáveis de saúde (Q_{eol}). Os valores de SOH (Q_k/Q_0) combinados aos de SOC (Q_i/Q_k) são utilizados para a predição da RUL de uma célula de bateria. A RUL é medida pelo tempo de vida remanescente ($t_{eol} - t_i$) desde o instante atual no ciclo atual $t_i \in [t_k; t_{k+1}]$, até a falência da bateria em algum instante do ciclo final $t_{eol} \in [t_n; t_{n+1}]$. Este é definido quando a capacidade de descarga $Q(t_{eol})$ atinge o seu valor final (Q_{eol}). A bateria atinge simultaneamente seus EOD ($t_i = t_{eol}$) e EOL ($k=n$).

Figura 5.6: Diferença entre SOC e SOH.



Fonte: Adaptado de Okoh, Roy, Mehnert e Redding (2014).


Figura 5.7: SOH ao longo do tempo, EOD, EOL e RUL.



Fonte: Adaptado de Okoh, Roy, Mehnert e Redding (2014).

Huggins (2008) destaca que: 1) com o envelhecimento (t) da bateria, acontece a degradação da capacidade (Q_k) ; 2) ela tem forte relação com o índice (k) do ciclo de carga e descarga [t_k ; t_{k+1}] ; e 3) ela pode ser modelada pelo conceito de Eficiência Coulombiana (η_C) . Esta é definida como a fração $\eta_C = Q_{k+1}/Q_k$ da capacidade de descarga máxima (Q_k) no ciclo atual [t_k ; t_{k+1}] que está disponível como capacidade de descarga máxima (Q_{k+1})no ciclo seguinte [t_{k+1} ; t_{k+2}]. Esse conceito depende de uma série de fatores, como por exemplo, a corrente e a profundidade de descarga em cada ciclo, as temperaturas nas quais as baterias são armazenadas e operadas. Para exemplificar a dependência da degradação da capacidade de descarga com a Eficiência Coulombiana, a Figura 5.8 mostra a influência de η_C sobre a capacidade de descarga durante ciclagem; em particular, como um pequeno fator de ineficiência ($\eta_C=0,995$) pode reduzir a capacidade a aproximadamente 60% dentro de ~100 ciclos.


Figura 5.8: Influência de η_C sobre a capacidade de carga durante as ciclagens.



Fonte: Huggins (2008).

A corrente de saída é um parâmetro importante a ser considerado para a análise de desempenho da bateria, pois esta exerce uma contribuição na determinação das perdas internas. A finalidade de uma bateria é de armazenar carga/energia elétrica/química e liberá-la em determinado tempo de uma maneira controlada. A capacidade de carga é diferente da capacidade de descarga. Ou seja, o ideal seria toda a carga/energia disponível sem deixar que a carga/energia se dissipe. Porém, isso não ocorre devido à perda de carga/energia que acontece dentro da bateria e à queda de tensão que faz com que a bateria alcance mais rapidamente o final da descarga. As correntes de carga e descarga de uma bateria usualmente são medidas em Taxa C (*C-Rate*). A taxa de descarga de uma bateria é expressa como C/r , onde r é o número de horas necessárias para descarregar completamente sua capacidade nominal $C=Q_0$. Portanto, uma bateria de 2 A.h descarregando a uma taxa de $C/10$ ou 0,2 A duraria 10 horas. A tensão entre os terminais da bateria, assim como a carga fornecida, podem variar consideravelmente com as mudanças da *C-Rate*. Além disso, a quantidade de energia fornecida, relacionada à área sob a curva de descarga, também é dependente da *C-Rate*. A Figura 5.9 mostra a influência da corrente no ciclo de descarga, onde cada curva corresponde a um valor de *C-Rate* diferente (quanto menor for r , maior será a corrente) e assume condições de temperatura constantes.

Figura 5.9: Influência da corrente no ciclo de descarga.



Fonte: Huggins (2008)

O método para o prognóstico de EOL e EOD prevê a RUL da bateria através da integração de medidas da corrente (contagem de Coulomb) para sintetizar uma medida da capacidade de descarga máxima $C_k=C(t_k)=Q_k=Q(t_k)$ no ciclo atual $[t_k; t_{k+1}]$, usando o método de contagem de Coulomb na sua Equação 14, aqui mostrada como nossa Equação (5.9). A degradação da bateria é afetada principalmente pela redução de (Q_k) da bateria (*capacity fade*). A carga deve ser avaliada usando parâmetros monitorados por um Sistema de Gerenciamento de Bateria (BMS), pois não há mecanismo para medir a capacidade de descarga de uma célula. Os parâmetros utilizados usualmente são a tensão da célula, corrente de entrada ou saída, e temperatura. (SAHA E GOEBEL, 2009; SAHA et al., 2011; ARACHCHIGE et al, 2017,). Então:

No 1°. modelo (M1): originalmente (RANGLES, 1947) não se tratava EOD nem EOL pois era um modelo de equilíbrio, conforme a Equação (5.3) e seus comentários. Desde então, conforme Hartman II (2008) e Gabrielli (2019), muitos autores tentaram estende-lo para carga e descarga (ver Anexo A). M1 não é usado diretamente por Saha e Goebel (2009), nem por Arachchige et al (2017), e nem por esta Tese.

No 2°. modelo (M2): O modelo para o EOL considera a corrente de saída e a contagem de Coulomb para o EOL. A corrente de saída é utilizada para 1) sintetizar uma medida \tilde{C}_k da capacidade de descarga máxima $C_k=C(t_k)=Q_k=Q(t_k)$ no ciclo atual $[t_k; t_{k+1}]$, usando o método de contagem de Coulomb na sua Equação 14, aqui mostrada como nossa Equação (5.9).

O modelo (M2) de Saha e Goebel (2009) admite corrente aproximadamente constante em $[t_k; t_{k+1}]$. Neste modelo (M2), o efeito combinado dos ciclos de carga e descarga é capturado pelo fator de eficiência Coulombiana (η_c). Ele também considera relevante a auto-recarga durante o eventual descanso como um fator adicional, a saber:

Em qualquer bateria, os produtos de reação se acumulam ao redor dos eletrodos e diminuem a velocidade da reação. Ao deixar a bateria descansar,

os produtos de reação têm uma chance de se dissipar, aumentando assim a carga disponível para o próximo ciclo. Neste modelo (M2), essa auto-recarga é representada como um processo exponencial que, segundo Saha e Goebel (2009) é o que se adequa aos dados. No entanto, não fica claro qual é a periodicidade deste efeito: a análise dos dados sugere que ele pode não ser utilizado a cada ciclo. A equação para o envelhecimento da bateria passa a ser:

$$C_K = \eta_c \cdot C_0 + \beta_{1,k} \exp\left(\frac{-\beta_{2,k}}{\Delta t_k}\right) \quad (5.13)$$

$$\Delta t_k = t_{k+1} - t_k \sim 3600 \text{ s} = 1h;$$

Onde $C_k = Q_k$ é a capacidade de descarga máxima no ciclo atual $[t_k; t_{k+1}]$, Δt_k é o período de descanso entre os ciclos atual $[t_k; t_{k+1}]$ e futuro $[t_{k+1}; t_{k+2}]$, β_1 e β_2 são parâmetros do modelo de auto-recarga a serem estimados pelo Filtro de Partículas. A Figura 5.1 apresenta a modelagem no processo de descarga e auto-recarga para um ciclo real da bateria de Lítio-Íon, e mostra a validade das Equações (5.4) a (5.7) e (5.10).

No 3º. modelo (M3): repete-se M2 mas: 1) sintetiza-se uma medida \tilde{C}_k da capacidade de descarga máxima $C_k=C(t_k)=Q_k=Q(t_k)$ no ciclo atual $[t_k; t_{k+1}]$, usando o método de contagem de Coulomb na sua Equação 14, aqui mostrada como nossa Equação (5.9) (segundo o código de M3); ou 2) gera-se uma predição $C^{\wedge}(t_k)$ pelo seu Filtro de Partículas alimentado por \tilde{C}_k (segundo as suas Figuras 4 e 6).

No Capítulo 7, é apresentada uma análise detalhada destas equações, apontando as aproximações realizadas e os pontos que serão melhorados após essa análise.

6 IMPLEMENTAÇÃO E COMPARAÇÃO DOS MODELOS M2 E M3

Este Capítulo apresenta: 1) as considerações e informações levantadas sobre o banco de dados utilizado para a implementação dos modelos e as condições dos testes para a predição de EOD e EOL; 2) as considerações e informações levantadas sobre os modelos matemáticos/empíricos (M2) apresentados por Saha e Goebel (2009); 3) as considerações e informações levantadas sobre os modelos matemáticos/flexibilizados (M3) por Arachchige et al (2017); 4) as premissas e os resultados de M2 e M3, que serão melhoradas e comparados com os modelos matemáticos/inovados (M4) no Capítulo 7.

6.1 Banco de dados utilizados

Os dados utilizados neste trabalho foram coletados de um repositório de dados (SAHA; GOEBEL, 2007) do Centro de Excelência de Prognósticos Ames da NASA (*NASA Ames Prognostics Center of Excellence - PCoE*). (SAHA; GOEBEL, 2007).


Durante o estudo da literatura para este trabalho, no levantamento de conceitos e estudo das publicações de prognóstico presentes na literatura, encontramos alguns trabalhos do Dr. Kai Goebel com diversas aplicações. Fizemos um contato (Anexo B) buscando dados que pudessemos utilizar neste trabalho, ele nos retornou (Anexo B) com o link deste repositório com dados de alguns equipamentos, incluindo os dados de baterias utilizados neste trabalho.

Segundo Saha e Goebel (2007), este repositório de dados para prognósticos é uma coleção de conjuntos de dados que foram doados por várias universidades, agências ou empresas. Este repositório de dados se concentra exclusivamente em conjuntos de dados de prognóstico, ou seja, conjuntos de dados que podem ser usados para o desenvolvimento de algoritmos de prognóstico. Na maioria das vezes, são séries temporais de dados de algum estado nominal a um estado de falha. A coleta de dados neste repositório é um processo contínuo.

De acordo com Saha e Goebel (2009), estes dados de baterias são testes com células de baterias de Lítio-Íon recarregáveis modelo 18650 disponíveis comercialmente, como mostra a Figura 6.1. A Figura 6.1 mostra uma configuração de envelhecimento no Centro de Excelência de Prognósticos Ames da NASA.

Segundo Saha e Goebel (2007) este banco de dados é composto de seis (6) grupos de dados de baterias que divergem em algumas características. Em geral, são dados de carga e descarga em diferentes temperaturas. Ele registra a impedância como o critério de dano.

Figura 6.1: Testes de prognósticos de bateria no Centro de Excelência de Prognósticos Ames da NASA.



Fonte: Goebel et al (2008).

Estes dados são organizados em arquivos .m, arquivos de estrutura de dados, onde cada arquivo é estruturado conforme as Figuras 6.2 e 6.3. A forma com que os dados foram salvos, motivou a utilização do software Matlab neste trabalho. O software Matlab inicialmente foi concebido para utilização de cálculos matriciais, faz uso das matrizes como estrutura de dados básica. Para este trabalho, foi adquirida uma licença de estudante para a utilização dos dados disponibilizados pela NASA com o software Matlab.

Figura 6.2: Estrutura de dados das baterias de Lítio-Íon.

1x80 struct with 4 fields

Fields	type	ambient_temperature	time	data
1	'impedance'		24 [2009,2,13,1...	1x1 struct
2	'charge'		24 [2009,2,13,1...	1x1 struct
3	'impedance'		24 [2009,2,13,2...	1x1 struct
4	'discharge'		24 [2009,2,13,2...	1x1 struct
5	'charge'		24 [2009,2,14,1...	1x1 struct
6	'discharge'		24 [2009,2,14,4...	1x1 struct
7	'charge'		24 [2009,2,14,5...	1x1 struct
8	'discharge'		24 [2009,2,14,8...	1x1 struct
9	'charge'		24 [2009,2,14,1...	1x1 struct
10	'discharge'		24 [2009,2,14,1...	1x1 struct
11	'charge'		24 [2009,2,14,1...	1x1 struct

Figura 6.3: Estrutura de dados para a) carga e b) descarga das baterias de Lítio-Íon.

Field ▲	Value	Field ▲	Value
Voltage_measured	1x3815 double	Voltage_measured	1x197 double
Current_measured	1x3815 double	Current_measured	1x197 double
Temperature_measured	1x3815 double	Temperature_measured	1x197 double
Current_charge	1x3815 double	Current_load	1x197 double
Voltage_charge	1x3815 double	Voltage_load	1x197 double
Time	1x3815 double	Time	1x197 double
		Capacity	1.8565

6.1.1 Configuração experimental dos dados utilizados

Segundo Saha e Goebel (2007), a configuração experimental consiste principalmente em um conjunto de células de íons de Lítio (que podem residir dentro ou fora de uma câmara ambiental), carregadores, cargas, equipamentos de Espectroscopia de Impedância Eletroquímica (*Electrochemical Impedance Spectroscopy* -EIS) para monitoramento da saúde da bateria, um conjunto de sensores (tensão, corrente e temperatura), alguns circuitos de comutação personalizados, um sistema de aquisição de dados e um computador para controle e análise. As células foram cicladas através de ciclos de carga e

descarga sob diferentes condições de carga e ambiente definidas pela carga eletrônica e pela câmara ambiental, respectivamente.

O experimento seguiu o seguinte processo:

1. O conjunto de quatro baterias de Lítio-Íon (nº 05, 07, 18 e 30) foi executado em três perfis operacionais diferentes (carga, descarga e impedância) à temperatura ambiente (24°C) para as células B0005, B0007 e B0030 e à temperatura ambiente elevada (43 graus C) para a célula B0030;
2. O carregamento foi realizado em um modo de corrente aproximadamente constante (CC) a 1,5 A até que a tensão da bateria atingisse 4,2 V e depois continuasse em um modo de tensão aproximadamente constante (CV) até que a corrente de carga caísse para 20 mA;
3. A descarga foi realizada a um nível de corrente aproximadamente constante (CC) de 2 A até que a tensão da bateria caísse para 2,7 V; 2,2 V; 2,5 V e 2,2 V para as baterias #5, #7, #18 e #30, respectivamente;
4. A medição da impedância foi realizada através de uma varredura de frequência de EIS de 0,1 Hz a 5 kHz.

De acordo com Saha e Goebel (2007), os ciclos repetidos de carga e descarga resultam no envelhecimento acelerado das baterias, enquanto que as medições de impedância fornecem informações sobre os parâmetros internos da bateria que mudam conforme o envelhecimento avança. Os experimentos foram interrompidos quando as baterias atingiram os critérios de Fim De Vida Útil (EOL e EOD), que foi uma redução de 30% na capacidade nominal (de 2 A.h para 1,4 A.h). Este conjunto de dados pode ser usado para a previsão da Carga Útil Restante (*Remaining Useful Charge-RUC*), para um determinado ciclo de descarga) e da Vida Útil Restante (*Remaining Useful Life RUL*).

6.1.2 Organização da estrutura de dados

- **cycle:** matriz de estrutura de nível superior contendo as operações de carga, descarga e impedância:
 - **type:** tipo de operação, pode ser carga, descarga ou impedância;
 - **ambient_temperature:** temperatura ambiente (em graus Celsius);
 - **time:** a data e hora do início do ciclo, no formato vetorial de data MATLAB;
 - **data:** estrutura de dados contendo as medições.

Para a carga, os dados são:

- **Voltage_measured:** Tensão entre os terminais da bateria (Volts);
- **Current_measured:** Corrente de saída da bateria (Ampéres);
- **Temperature_measured:** Temperatura da bateria (graus Celsius);
- **Current_charge:** Corrente medida no carregador (Ampéres);
- **Voltage_charge:** Tensão medida no carregador (Volts);
- **Time:** Vetor de tempo para o ciclo (segundos).

Para a descarga, os dados são:

- **Voltage_measured:** Tensão entre os terminais da bateria (Volts);
- **Current_measured:** Corrente de saída da bateria (Ampéres);
- **Temperature_measured:** Temperatura da bateria (graus Celsius);
- **Current_charge:** Corrente medida na carga (Ampéres);
- **Voltage_charge:** Tensão medida na carga (Volts);
- **Time:** Vetor de tempo para o ciclo (segundos);

- **Capacity:** Capacidade da bateria (A.h) para descarga até 2,7 V; 2,2 V ; 2,5 V e 2,2V ;para as baterias #5, #7, #18 e #30 respectivamente.

Para a impedância, os dados são:

- **Sense_current:** Corrente no ramo do sensor (Ampéres);
- **Battery_current:** Corrente no ramo da bateria (Ampéres);
- **Current_ratio:** Razão das correntes acima;
- **Battery_impedance:** impedância da bateria (Ohms) calculada a partir de dados brutos;
- **Rectified_impedance:** impedância da bateria calibrada e suavizada (Ohms);
- **Re:** Estimativa de resistência eletrolítica (Ohms);
- **Rct:** Estimativa de resistência de transferência de carga (Ohms).

A seguir, destacam-se as células de baterias cujos dados foram utilizados neste trabalho no Capítulo 7:

- B0005.mat Data for Battery #5;
- B0007.mat Data for Battery #7;
- B0018.mat Data for Battery #18;
- B0030.mat Data for Battery #30.

6.2 EOD e EOL segundo Saha e Goebel (2009)

Saha e Goebel (2009) usaram um modelo matemático/empírico (M2) com um Filtro de Partículas para EOD e outro para EOL. Segundo eles isto foi feito:

The main advantage of PFs here is that model parameters can be included as a part of the state vector to be tracked, thus performing model identification in conjunction with state estimation (Saha et al., 2009). After the model has been tuned to reflect the dynamics of the specific system being tracked, it can then be used to propagate the particles till the failure (e.g. EOD or EOL) threshold to give the RUL pdf (SAHA et al., 2009).

- 1) Os autores não apresentam muitas informações a respeito: das estruturas dos filtros de partículas utilizados para EOD e EOL; das específicas baterias, ciclos de descarga e das suas previsões de EOD (Figura 8) e EOL (Figura 10);
- 2) As informações se referem às equações de estado (Equações 6.1 a 6.6) para EOD e (Equações 6.8 a 6.10) para EOL; e às equações de medida (da **tensão**, Equação 6.7) para EOD, e (da **corrente** e da **capacidade de descarga**, Equação (6.11), auxiliada pelas Equações (6.15) e (6.16); ou pela Equação (6.17) para EOL. **Não há interação de EOD com EOL;**
- 3) A Equação (6.6) é obtida aplicando-se a 1ª. Regra de Euler à Equação (5.8), que é uma combinação das Equações (5.4) a (5.7) para dar o perfil de descarga da bateria de íon de Lítio considerando um perfil de corrente aproximadamente constante.
- 4) é uma medida da capacidade de descarga $C_k=C(t_k)=Q_k=Q(t_k)=-\Delta Q+Q_{k+1}$; é sintetizada pela integral da medida da corrente ao longo do tempo de descarga (Equação 6.15), igual à Equação (5.9), até que a tensão da célula alcance o limiar (*threshold*) E_{EOD} em algum instante do ciclo . Como $I(t)=-I=$ constante, então $\Delta Q=-I.\Delta t$, pode-se medir Δt e pré-tabular Q_{k+1} . Isto pode ser feito:
 - 1) *on-line= a priori* = por previsão = *prediction* para prever Q_{k+1} em $[\cdot; \cdot]$; 2) *off-line = a posteriori* = por alisamento = *smoothing*, para atualizar Q_k . Assim, 1), mas não 2), é conveniente para uma aplicação *on-line*, onde os dados são gerados à medida que a bateria é descarregada.

- 5) Os parâmetros dos modelos de transição são incluídos como parte do vetor de estado, para que o PF possa realizar a identificação dos modelos em conjunto com o rastreamento do estado.

6.2.1 Modelo de transição do estado EOD:

$$\alpha_{1,i+1} = \alpha_{1,i} + \omega_{1,i} \quad (6.1)$$

$$\alpha_{2,i+1} = \alpha_{2,i} + \omega_{2,i} \quad (6.2)$$

$$\alpha_{3,i+1} = \alpha_{3,i} + \omega_{3,i} \quad (6.3)$$

$$\alpha_{4,i+1} = \alpha_{4,i} + \omega_{4,i} \quad (6.4)$$

$$\alpha_{5,i+1} = \alpha_{5,i} + \omega_{5,i} \quad (6.5)$$

$$E_{i+1} = E_i - \frac{\frac{\alpha_{1,i}\alpha_{2,i} \exp\left(-\frac{\alpha_{2,i}}{t_i}\right)}{t^2} - \alpha_{3,i}\alpha_{4,i}\exp(\alpha_{4,i}t_i) - \alpha_{5,i}}{f_s} + \omega_i \quad (6.6)$$

6.2.2 Modelo de medição do EOD:

$$z_i = \tilde{E}_i = E_i + v_i \quad (6.7)$$

onde, segundo os autores: i é o índice do intervalo de amostragem $[t_i ; t_{i+1}]$; f_s é a frequência de amostragem $\left(f_s = \frac{1}{T_s}, T_s = t_{i+1} - t_i \right)$; E_i expressa a tensão da célula medida no instante de amostragem t_i ; e ω_{ai} com $a \forall (1, \dots, 5)$ e v_i

são termos de ruídos considerados como gaussianos, independentes, de médias zero e variâncias ajustáveis.

As médias iniciais dos parâmetros do modelo de EOD ($\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5$ e E_i), que foram utilizadas para a implementação não foram mencionadas.

O problema de estimação para EOL é similar ao EOD.

6.2.3 Modelo de transição de estados do EOL:

$$\beta_{1,k+1} = \beta_{j,k} + \varphi_{1,k} \quad (6.8)$$

$$\beta_{2,k+1} = \beta_{j,k} + \varphi_{2,k} \quad (6.9)$$

$$C_{K+1} = \eta_c \cdot C_k + \beta_{1,k} \exp\left(\frac{-\beta_{2,k}}{\Delta t_k}\right) + \varphi_k \quad (6.10)$$

6.2.4 Modelo de medição do EOL:

$$z_i = \tilde{C}_k = C_k + \psi_k \quad (6.11)$$

onde, segundo Saha e Goebel (2009):

k is the cycle index, C_k denotes the charge capacity measured (as the integral of current over discharge time until cell voltage reaches E_{EOD}) at cycle index k , and $\varphi_{1,k}$, $\varphi_{2,k}$, φ_k and ψ_k are independent zero mean Gaussian noise terms. The first term on the right hand side in the second line of equation (9) takes care of the Coulombic efficiency factor while the second term models the capacity gain due to rest.

Note that in both state equations (7) and (9) we have included the model parameter as part of the state vector, so that the PF can perform model identification in conjunction with state tracking.

Isto é, k é o índice do ciclo de descarga [$t_k ; t_{k+1}$] ; \tilde{C}_k é uma medida da capacidade de descarga $C_k=C(t_k)=Q_k=Q(t_k)$; \tilde{C}_k é aproximada pela integral da medida da corrente ao longo do tempo de descarga (Equação 6.15), até que a tensão da célula alcance o limiar (*threshold*) E_{EOD} em algum instante do ciclo k ; e $\varphi_{1,k}$, $\varphi_{2,k}$, φ_k e ψ_k são termos de ruído considerados como gaussianos, independentes, de médias zero e variâncias variáveis. Como já mencionado, na Equação (6.10), $(\eta_c \cdot C_k)$ modela o fator de eficiência coulombiana, enquanto $\left(\beta_{1,k} \exp\left(\frac{-\beta_{2,k}}{\Delta t_k}\right)\right)$ modela o ganho de capacidade devido ao repouso.

Para a predição da RUL em EOL, Saha e Goebel (2009) optaram por utilizar 70% da carga nominal da bateria (ou seja, 1,4 A.h para uma célula de 2 A.h de capacidade nominal) de acordo com os valores de interrupção experimental das baterias do banco de dados. Detalhes dos experimentos foram apresentados na Seção 6.1.

As médias iniciais dos parâmetros do modelo de EOL (β_1 , β_2 e C_k) que foram utilizadas para a implementação não foram mencionadas.

6.3 EOD e EOL segundo Arachchige et al (2017)

Arachchige et al (2017) flexibilizaram o modelo empírico (M2) de Saha e Goebel (2009) num modelo flexibilizado (M3). Segundo aqueles/isto foi feito:

The novelty of this study when compared to the model proposed by Saha and Goebel [2009] is the method of calculating α_4 . Determination of α_4 according to Saha and Goebel's method is shown by Equation 26 (aqui 6.4). **In their model, the values were initialized knowing the loading profile (aqui, $I(t)=\text{constante}$) and capacity (aqui, Q_k) in advance.** The calculation in Equation 23 (aqui 6.21) for α_4 allows the parameters to adapt to different loads. This proposed modification of α_4 also works when the capacity has faded away, causing a reduction in the EOD time.

- 1) Os autores apresentam algumas informações e fluxogramas a respeito: das estruturas dos filtros de partículas utilizados para EOD e EOL; das específicas baterias, ciclos de descarga e das suas predições de EOD (Figuras 13-16) e EOL (Figuras 9-12).

- 2) As informações se referem às equações de estado (Equações 6.18 a 6.23) para EOD e (Equações 6.25 a 6.27) para EOL; e às equações de medida (da tensão, Equação 6.24) para EOD, e (da corrente e da capacidade de carga, Equação (6.28), auxiliada pelas Equações 6.15 e 6.16; ou pela Equação 6.17) para EOL. **Há ação do EOL sobre o EOD, ao passar-lhe a medida ou a predição de Q_k .**
- 3) adotando a variável de estado auxiliar $SOC(t_i)=Q(t_i)/Q(t_k)$ via (Equações 6.16 ou 6.17); e usando-a para corrigir via (Equação 6.21). Suas estimativas são críticas.
- 4) incorporando no EOD do M3: as amostras da corrente $I(t_i)=<0$ variável e seu módulo I_i , via numerador da 2ª. parcela da (Equação 6.16); e a medida \tilde{C}_k ou uma predição \widehat{C}_k (segundo suas Figuras 4 e 6) da capacidade de descarga $C_k=C(t_k)=Q_k=Q(t_k)$ (segundo o código do M3), via denominador da 2ª. parcela da (Equação 6.16).
- 5) Usando a (Equação 6.17) em lugar das (Equações 6.15 e 6.16) após a última atualização i , para prever os tempos de RUC como uma pdf **quando se quer prever o EOC ou o EOL (pontos * nos gráficos).**
- 6) A medida \tilde{C}_k é sintetizada pela integral (Equação 6.15) do módulo I da corrente $I(t)$ ($I=|I(t)|>0$) no intervalo atual $[t_k; t_{k+1}]$, e até o fim das amostras ($I_i=|I(t_i)|>0$), no início $[t_{k+1}; t_{k+1+rest}]$ de um eventual intervalo de descanso, onde nem $V(t)$ nem $Q(t)$ zeram, mas se recuperam parcialmente (segundo o código do M3). Como $I(t)=-I=$ variável, então $\Delta Q=-I_{media}.\Delta t= -\sum I_i .T_s$, pode-se somar $\sum I_i$, e estimar Q_{k+1} como dito acima em $[t_{k+1}; t_{k+1+rest}]$. Isto pode ser feito: 1) *on-line= a priori = por predição = prediction* para prever Q_{k+1} em $[t_{k+1}; t_{k+2}]$; 2) *off-line = a posteriori = por alisamento = smoothing, para atualizar Q_k* . Assim, 1), mas não 2), é conveniente para uma aplicação *on-line*, onde os dados são

gerados à medida que a bateria é descarregada. A predição \hat{C}_k é produzida pelo EOL do M3, alimentado pela medida \tilde{C}_k da capacidade de descarga $C_k=C(t_k)=Q_k=Q(t_k)$ no ciclo k ; isto acopla EOD ao EOL.

- 7) A predição \hat{C}_k é produzida pelo FP do EOL do M3, alimentado pela medida \tilde{C}_k da capacidade de descarga $C_k=C(t_k)=Q_k=Q(t_k)$ no ciclo k , e agindo no EOD.

Apenas a corrente de saída é necessária para estimar a carga da célula, que é calculada usando o método de contagem de Coulomb na sua Equação 14, aqui mostrada como nossa (Equação 6.15), onde $C(t)$ é a carga $Q(t)$:

$$\tilde{C}_k \cong C = \int I dt \quad (6.15)$$

Sobre ela, Arachchige et al (2017), dizem:

Therefore, the cell output current must be integrated during a full discharge cycle. **The important point is that the battery is not always fully charged or discharged.** Therefore, tables with available test data and other estimation algorithms are required to accurately predict the battery's State of Health (SOH).

Este método de contagem de Coulomb é utilizado para estimar o estado de carga da bateria SOC_{i+1} na sua Equação 19, aqui mostrada como nossa (Equação 6.16):

$$SOC_{i+1} \approx SOC_i - \frac{I_i T_s}{C} \quad (6.16)$$

O Estado De Carga (SOC) é refletido pela medida da tensão e a variação de carga é avaliada pela medida da corrente. Cada vez que uma nova medida de

corrente está presente, o estado de carga da bateria é atualizado para incluir os efeitos da carga que já foi extraída da bateria.

Quando se quer prever o EOC ou o EOL (pontos * nos gráficos), a última atualização das variáveis α_1 , α_2 , α_3 e α_5 é mantida e o parâmetro α_4 é recalculado, assumindo que o perfil de carga utilizado pela aplicação permanece o mesmo até o final da descarga, isto é, $I(t) \cong I_{\text{constante}}(t_i; t_{i+1}) \cong I_{\text{média}}(t_k; t_k + t_i) = -I_{\text{média}} = \Delta Q(t_k; t_k + t_i) / \Delta t < 0$, $\Delta t = t - t_k = t_i$, a fim de propagar o estado atual da bateria. E a adaptação do novo estado de carga é calculado pela sua Equação 28, aqui mostrada como Equação (6.17).

$$SOC_{i+1} \sim SOC_i - \frac{(1 - SOC_i) T_s}{t_i} \quad (6.17)$$

onde o período de amostragem T_s é usado para atualizar o tempo t_i .

As aproximações e considerações para estas equações, inclusive para o cálculo de α_4 , não são detalhadas ou explicadas naquele artigo. No Capítulo 7, é apresentada uma análise detalhada destas equações, apontando as aproximações realizadas e os pontos que serão melhorados após essa análise.

6.3.1 Modelo de transição de estado do EOD:

A maior contribuição de Arachchige et al (2017) é o cálculo de α_4 , via Equação (6.21), auxiliada pelas Equações (6.15) e (6.16); ou pela Equação (6.17):

$$\alpha_{1,i+1} = \alpha_{1,i} + v_{1,i} \quad (6.18)$$

$$\alpha_{2,i+1} = \alpha_{2,i} + v_{2,i} \quad (6.19)$$

$$\alpha_{3,i+1} = \alpha_{3,i} + v_{3,i} \quad (6.20)$$

$$\alpha_{4,i+1} = a \frac{(1-SOC_i)}{t_i} + v_{4,i} \quad (6.21)$$

$$\alpha_{5,i+1} = \alpha_{5,i} + v_{5,i} \quad (6.22)$$

$$E_{i+1} = E_i - \frac{\alpha_{1,i}\alpha_{2,i} \exp\left(-\frac{\alpha_{2,i}}{t_i}\right) - \alpha_{3,i}\alpha_{4,i} \exp(\alpha_{4,i}t_i) - \alpha_{5,i}}{f_s} + v_{6,i} \quad (6.23)$$

6.3.2 Modelo de medição do EOD:

$$V(t_i) = z_i = E_i + n_i \quad (6.24)$$

onde, segundo os autores: $v_{1,i}$, $v_{2,i}$, $v_{3,i}$, $v_{4,i}$, $v_{5,i}$, $v_{6,i}$ e n_i são termos dos ruídos gaussianos, independentes, de médias zero e variâncias ajustáveis; e, como já mencionado, **a é uma constante de ajuste** do algoritmo, t_i é o instante de amostragem atual e f_s é a frequência de amostragem. Diz-se que $a = 10.8$ (parece muito alto para um “ajuste”), um valor encontrado experimentalmente (não é detalhado como).

As médias iniciais dos parâmetros do modelo de EOD (α_1 , α_2 , α_3 , α_4 , α_5 e E_i), que foram utilizadas para a implementação foram mencionadas e equivalem a 0.6, 900, 2.2e-5, 3.8e-3, 1e-7 e 4, respectivamente.

6.3.3 Modelo de transição de estado do EOL:

$$\beta_{1,k+1} = \beta_{j,k} + \varphi_{1,k} \quad (6.25)$$

$$\beta_{2,k+1} = \beta_{j,k} + \varphi_{2,k} \quad (6.26)$$

$$C_{K+1} = \eta_c \cdot C_k + \beta_{1,k} \exp\left(\frac{-\beta_{2,k}}{\Delta t_k}\right) + \varphi_k \quad (6.27)$$

6.3.4 Modelo de medição do EOL:

$$z_i = \tilde{C}_k = C_k + \psi_k \quad (6.28)$$

onde, segundo os autores: k é o índice do ciclo de descarga [t_k ; t_{k+1}] ; A medida \tilde{C}_k é aproximada pela integral (Equação 6.15) do módulo I da corrente $I(t)$ ($I=|I(t)|>0$) no intervalo atual [t_k ; t_{k+1}], e até o fim das amostras ($I_i=|I(t_i)|>0$), no início [t_{k+1} ; $t_{k+1+rest}$] de um intervalo de descanso, onde nem $V(t)$ nem $Q(t)$ zeram, mas se recuperam parcialmente, segundo o código do M3; e $\varphi_{1,k}$, $\varphi_{2,k}$, φ_k e ψ_k são termos de ruído considerados como gaussianos, independentes, de médias zero e variâncias variáveis.

O modelo de transição de estados e de medição do EOL utilizado no modelo flexibilizado (M3) de Arachchige et al (2017) é exatamente o mesmo que o apresentado no modelo empírico (M2) de Saha e Goebel (2009).

Para a predição da RUL em EOL, Arachchige et al (2017) optaram por utilizar 80% da carga nominal da bateria (ou seja, 1,6 A.h para uma célula de 2 A.h de capacidade nominal), justificando ser o valor utilizado pela indústria para rejeitar uma bateria com defeito. Este *threshold* para a carga nominal é mantido neste trabalho. E as variáveis de estado e modelo de medições são os mesmos apresentados em Saha e Goebel (2009), seguindo as Equações (6.8) a (6.11).

As médias iniciais dos parâmetros do modelo de EOL (β_1, β_2 e C_k) que foram utilizadas para a implementação foram mencionadas e equivalem a 0.5, 3e5 e 1.8, respectivamente.

6.4 Algoritmo do filtro de partículas com os modelos M2 e M3

Neste trabalho, o Filtro de Partículas foi utilizado para representar o estado do sistema ($x(t_i)$), o Estado de Carga ($SOC(t_i) = Q(t_i)/Q(t_k)$) da bateria, a tensão entre os terminais ($E(t_i) = V(t_i)$) ou mesmo a sua capacidade de descarga ($C(t_k) = Q(t_k)$), por uma função de densidade de probabilidade (pdf). Esta é aproximada por um conjunto de partículas (pontos, $j = 1, 2, \dots, N_s$) representando valores amostrados ($x_i^j = x^j(t_i)$) do espaço de estados desconhecido, e um conjunto de pesos associados $w_i^j = w^j(t_i)$ denotando massas de probabilidade discretas.

O $SOC(t_i)$ poderia ser o fator principal a ser utilizado para prever a Vida Útil Remanescente ($RUL(t_i)$) até o Fim da Descarga (EOD) ou mesmo, até o fim da Vida (EOL); no entanto, o principal indicador é a tensão entre os terminais ($E(t_i) = V(t_i)$), isso se deve ao fato de que, a maioria dos sistemas que são abastecidos por baterias, possuem um limiar (*threshold*, $E_{eod} = V_{eod}$) baseado na tensão entre os terminais ($E(t)=V(t)$) da bateria. Segundo Saha et al (2011), a relação $C_{dl}(t_k) \cong Q(t_k)/V(t_k)$ entre a capacidade de descarga ($Q(t_k)$) e a tensão entre os terminais da bateria após a carga, em circuito aberto, e antes da descarga ($V(t_k) = E(t_k)=E_0$), conforme fornecida pelo fabricante, não se mantém durante toda a vida útil da bateria ou sob condições extremas de carga e temperatura. Existem outras variáveis, como a impedância interna Z_w que também podem indicar o desgaste da bateria; mas, para essas medições, as técnicas são mais caras, como a Espectroscopia de Impedância Eletroquímica (EIS) (citada na Seção 5.2), conforme Goebel et al (2008), o que as torna impraticáveis para uma implementação a bordo e/ou “on-line”. Um dos objetivos deste trabalho é propor inovações que permitam a implementação a bordo e/ou “on-line”.

Algumas informações úteis e necessárias para reproduzir os resultados de Saha e Goebel (2009) (M2) não foram encontradas. Desta forma, reunimos as informações de Arachchige et al (2017) (M3), juntamente com algumas suposições, para compor a implementação, como, por exemplo, que: o estado de saúde do sistema é vetorial, dado por $x_i = x(t_i)$; o modelo de evolução de

estado (Equações 6.15 a 6.23) e o modelo de medição, Equação (6.24), são markovianos de 1ª. ordem, com ruídos estacionários, normais, de média zero e variância ajustável, no estado $v_i = v(t_i)$ em 2017 (ou $\omega_i = \omega(t_i)$ em 2009) e na medida $n_i = n(t_i)$ em 2017 ($v_i = v(t_i)$ em 2009) conhecidos. Estes pressupostos serão mantidos, mas podem não ser adequados para uma abordagem mais geral.

O método de estimação utilizado foi o **Filtro de Partículas, com Amostragem e Reamostragem por tamanho efetivo da amostra (N_{eff})**. O fluxograma do seu algoritmo está na Figura 7.1. Nele, a **Reamostragem** é realizada quando novas medidas (z_i) estão disponíveis e o tamanho efetivo da amostra (N_{eff}) é baixo, para amenizar o inexorável aumento da variância dos pesos de importância (w_i^j), efeito conhecido por **degeneração dos pesos das partículas**, abordado no Capítulo 4.

Uma maneira de avaliar tal degeneração é calcular o **tamanho efetivo da amostra (N_{eff})** pela Equação (6.29), igual à Equação (4.18). Valores de N_{eff} pequenos indicam a ocorrência de degeneração severa. Uma maneira de reduzir esse efeito é escolher um **número de partículas (N_s)** elevado, o que eleva exponencialmente a carga computacional até torná-la impraticável. Por isto, outra maneira de reduzir a degeneração é realizar a reamostragem. O algoritmo avalia se o tamanho efetivo da amostra (N_{eff}) é menor que um certo **limiar da amostra (N_{tres})**; se for ($N_{\text{eff}} < N_{\text{tres}}$), encaminha-se para o procedimento de reamostragem, pois isto é um indicador da ocorrência de degeneração, conforme visto no Capítulo 4. Assim, as **partículas=estados (x_i^j)** com **pesos (w_i^j)** mais baixos são removidas automaticamente após várias etapas; as outras são replicadas (Figuras 4.6-4.8).

A ideia básica da reamostragem é eliminar as amostras que têm um peso muito pequeno, mantendo apenas as amostras que têm um peso grande. Assim, é gerado um novo conjunto $\{x_i^j, j = 1, 2, \dots, N_s\}$ através de uma amostragem (com replicação) realizada a partir da aproximação discreta da $p(x_i / z_1, \dots, z_i)$, repetida N_s vezes. A normalização dos pesos é necessária em cada instante de

tempo discreto t_i para garantir que $\sum_{j=1}^{N_s} w_i^j = 1$; e é realizada pela Equação (6.30), igual à Equação (4.19).

A qualidade do algoritmo depende da escolha da função de atualização dos pesos w_i^j . Conforme Arachchige et al (2017), Equação 10 (e suas simplificações, Equações 11, 12), citando Arulampalam et al (2002), Equação 48 (obtida das suas Equações 43 a 46):

There are several ways to update the weights:

- Sequential importance sampling: when an importance density function $q()$ is available, the weights can be updated using: $w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i)$;
- When the importance density sampling function is chosen so that it reduces the variance of the weights: $w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i)$;
- Occasionally, the importance density sampling function is chosen to be the PDF of the state based only on the previous state. The weighted update function is then: $w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i)$.

Neste algoritmo, os pesos são atualizados/corrigidos pela 3ª. opção, i.e., por:

$$w_i^j = w_j(t_i) = w_{i-1}^j p(z_i|x_i) \quad (6.29)$$

$$w_i^j = \frac{w_i^j}{\sum_{j=1}^{N_s} w_i^j} \quad (6.30)$$

A Figura 6.4 apresenta o fluxograma do algoritmo, adaptado de Arachchige et al (2017). Ele, no passo 1) Inicialização: a) carrega as medidas utilizadas; b) define o modelo de transição de estado usado pelo filtro de partículas para a previsão; c) define o modelo de medição ou observação usado pelo filtro de partículas para o rastreamento; d) cria os ruídos adicionados aos modelos de transição de estado e de rastreamento; e) gera os valores iniciais para as partículas, usados na primeira etapa do filtro de partículas; f) fornece valores aleatórios para todos os parâmetros do vetor de estado; 2) Propõe amostras iniciais e seus pesos; 3) Propaga as partículas usando o modelo de transição

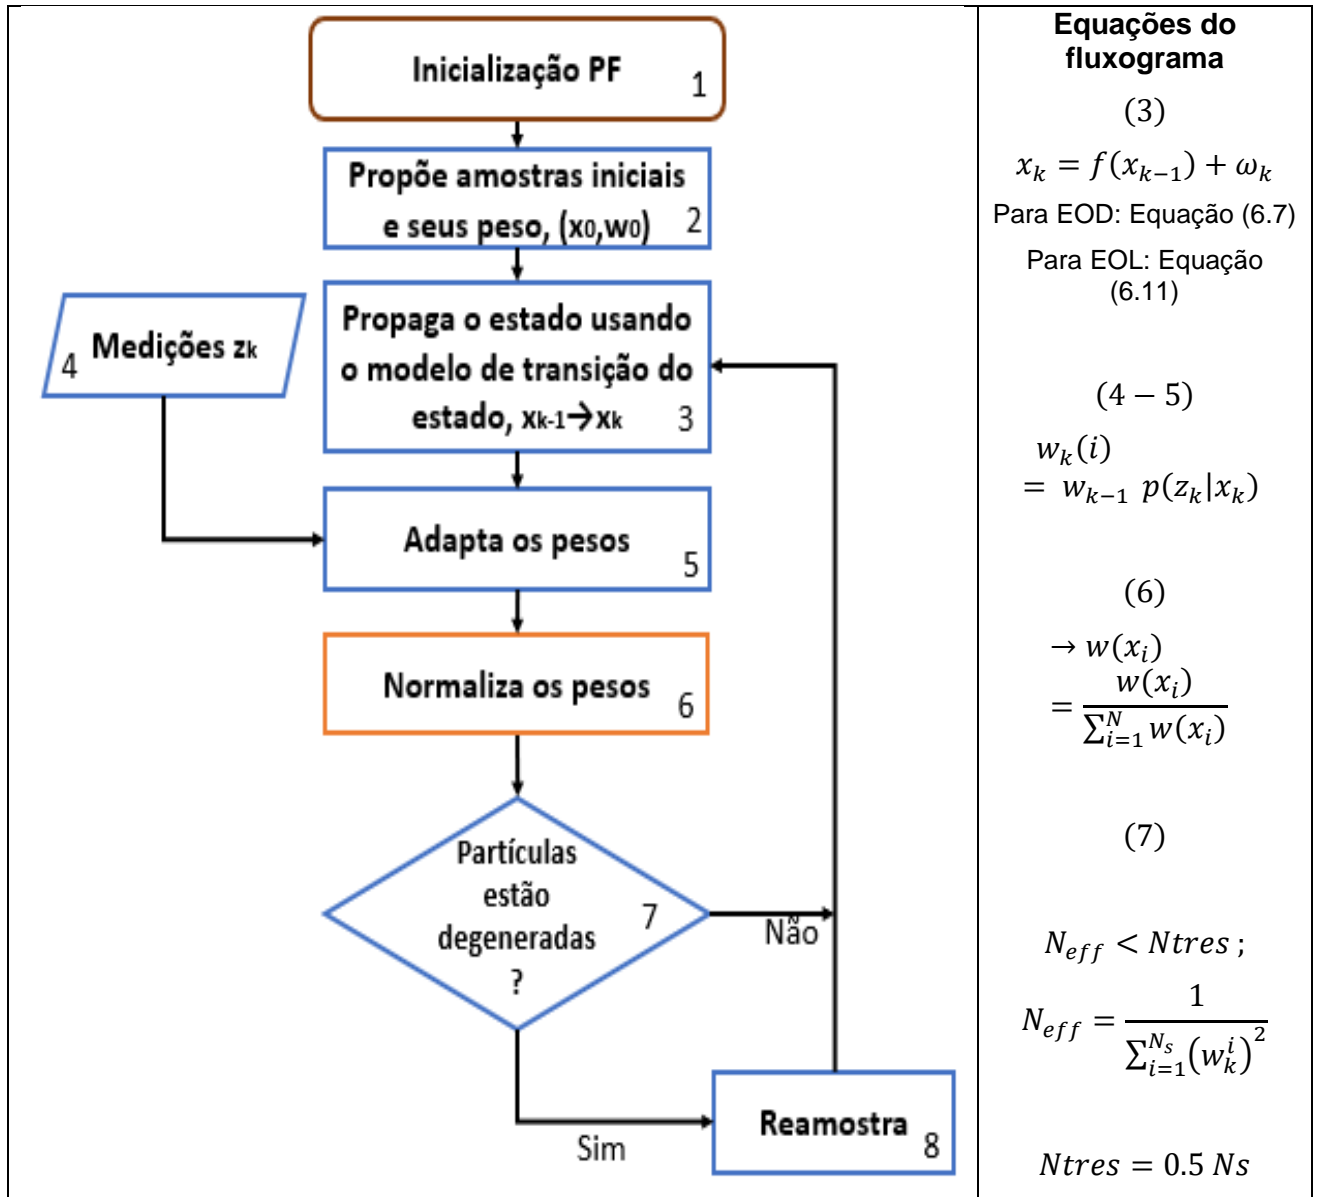
do estado pela Equações (6.15) a (6.23); 4) incorpora as medidas usando o modelo de medição do estado pela Equação (6.24); 5) Adapta os pesos pela Equação (6.29); 6) Normaliza os pesos pela Equação (6.30); 7) Calcula e verifica se houve a degeneração pelas Equações (6.31) e (6.32); e 8) Se sim, realiza a reamostragem como indicado acima. Após isso calcula o estado filtrado e salva os novos pesos e partículas.

$$N_{eff} = \frac{1}{\sum_{i=1}^{N_s} (w_k^i)^2} \quad (6.31)$$

$$N_{eff} < N_{tres} ; N_{tres} = 0.5 N_s \quad (6.32)$$

O fluxograma apresentado na Figura 6.4 se refere a dois modelos: 1) o modelo de transição de estados (caixa 3) e 2) o modelo de medições (caixa 4). As equações desses modelos para EOD e EOL foram apresentadas no Capítulo 6.

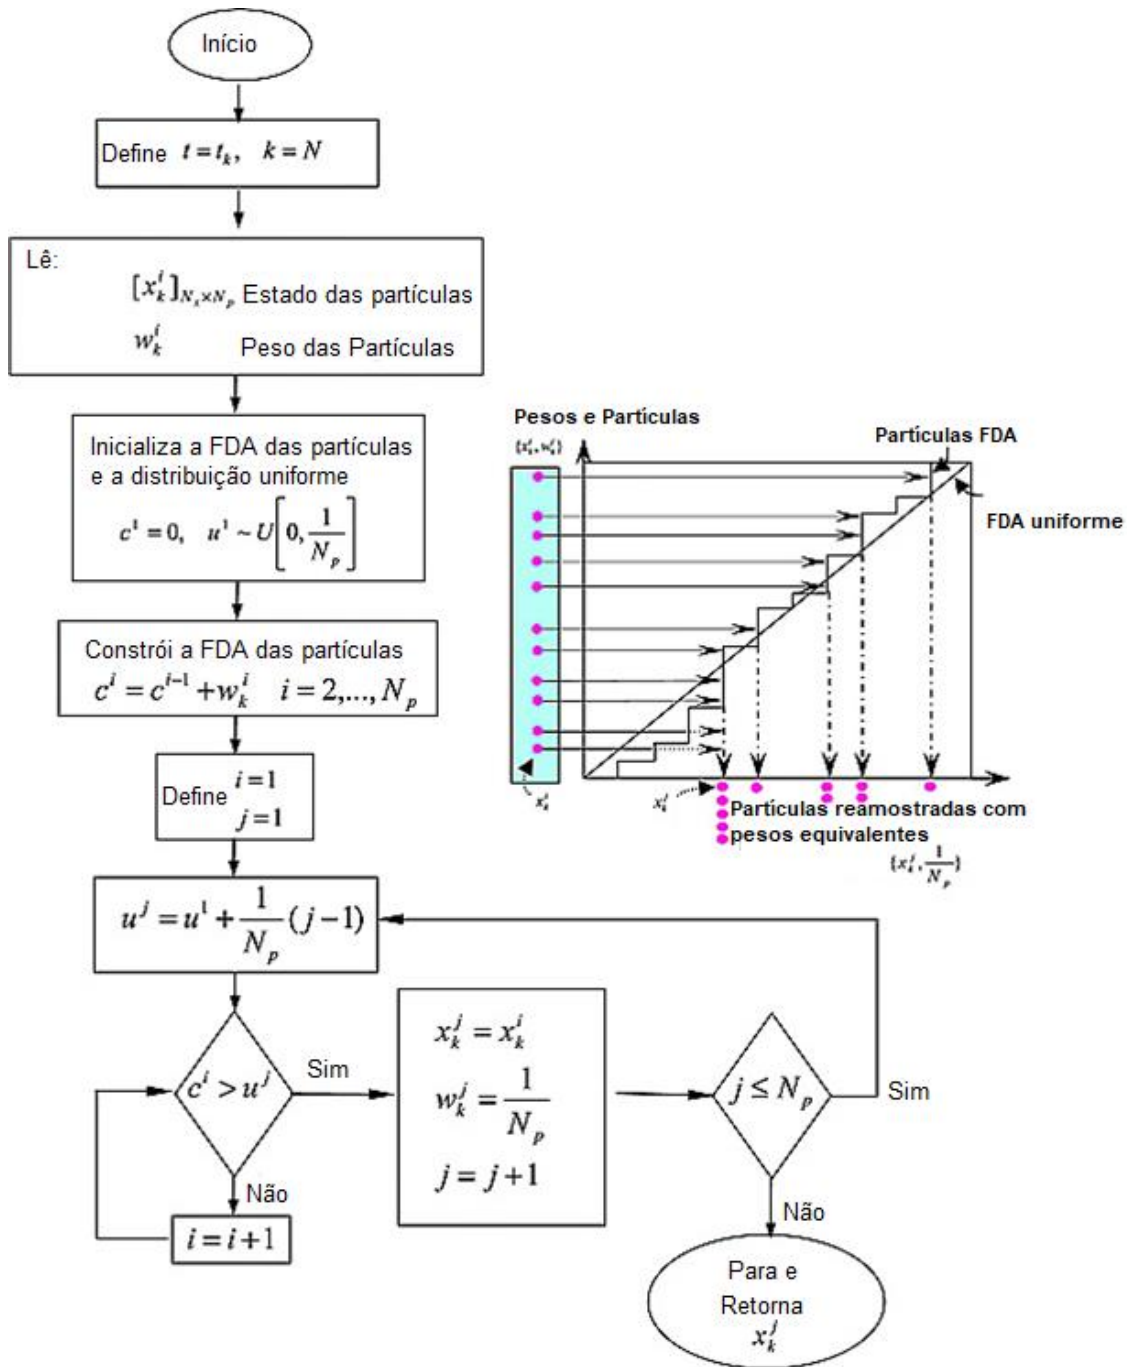
Figura 6.4: Fluxograma do algoritmo do filtro de Partículas adotado.



Fonte: Adaptado de Arachchige et al (2017).

A Figura 6.5 apresenta o fluxograma da reamostragem por tamanho efetivo da amostra com um exemplo, adaptados de Moradkhani et al (2005).

Figura 6.5: Fluxograma da Reamostragem pelo Filtro de Partículas.



Fonte: Adaptado de Moradkhani et al (2005).

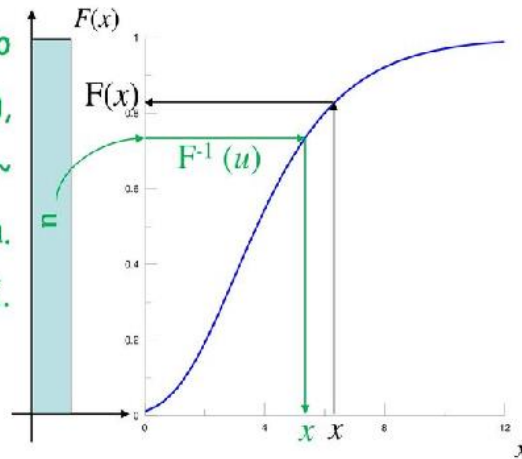
Esta implementa o método da inversão e da aceitação-rejeição, conforme Luna et al (2019), baseados numa versão discreta do Teorema da Função Inversa ou Teorema da Transformação Integral de John Von Neumann em 1951, ilustrado

na Figura 6.6. Este diz que a FDP $z=F_X(x)$ de qualquer fdp $y=f_X(x)$ tem distribuição uniforme em $[0;1]$, isto é, z segue $U[0;1]$ Assim, se gerarmos N_s valores de z_j seguindo $U[0;1]$, então os N_s $x_j = F_X^{-1}(z_j)$ seguirão $f_X(x)$.

Figura 6.6: Teorema da Transformação Integral

Teorema da Transformação Integral da Probabilidade

Se X for uma v.a. com função de distribuição $F_X(x)$, estritamente crescente, e $U \sim U(0,1)$, então $F^{-1}(U)$ é uma v.a. identicamente distribuída a X .



Fonte: Slideplayer (2021).

Nele: uma partícula aleatória x_i^j com peso w_i^j é mapeada em uma nova partícula x_i^{j*} com peso $\frac{1}{N_s}$; somam-se os pesos por $c_j = c_{j-1} + w_i^j$, onde $j = 2, 3, \dots, N_s$ e $c_1 = 0$. Em $j = 1$; gera-se uma distribuição uniforme $U [0, N_s^{-1}]$ para u_j , com $j = 1, 2, \dots, N_s$, utilizando a Equação (6.33); avançam-se os demais passos; faz-se a designação das partículas e pesos; e calcula-se a estimativa do estado atual.

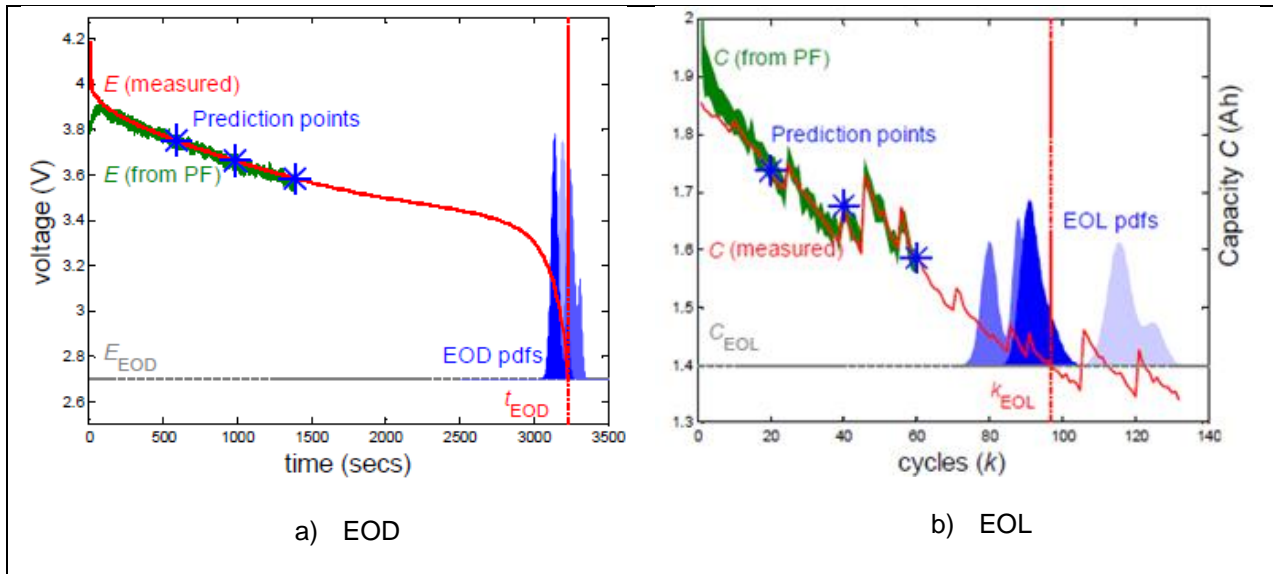
$$u_j = u_i + \frac{1}{N_s}(j - 1) \tag{6.33}$$

6.5 Comparação entre os resultados de Saha e Goebel (2009) (M2) e de Arachchige et al (2017) (M3)

Saha e Goebel (2009) apresentam graficamente um único caso com predições para EOD e para EOL da bateria B0005, e declaram que a acurácia (média) e precisão (desvio padrão) dos pontos de predições mostradas são representativas do desempenho das outras baterias do diretório de teste. Eles não informam qual ciclo de descarga foi utilizado para a predição conforme a Figura 6.7a, mas dizem que este foi selecionado arbitrariamente. Nela, a linha contínua vermelha mostra a tensão medida da célula, enquanto que a linha ruidosa verde mostra a tensão estimada da célula; e as 3 EOD pdfs representam as distribuições dos instantes de EOD preditos nos instantes indicados por * pela propagação das partículas até atingirem o limiar E_{eod} . Na Figura 6.7 b, a carga medida da célula é representada pela linha vermelha e a carga estimada da célula é representada pela linha verde; e as 3 EOL pdfs representam as distribuições dos ciclos de EOD preditos nos ciclos indicados por * pela propagação das partículas até atingirem o limiar C_{eod} . Todas as pdfs estimadas são representadas em azul. Como as 3 pdfs se sobrepõem, elas são diferenciadas por vários tons de azul: a mais antiga se refere ao tom mais claro e as últimas se referem aos tons progressivamente mais escuros. Algumas informações como o número de partículas, médias e medianas não são informadas.

Para Saha e Goebel (2009), devido às diferenças de profundidade de descarga (DOD) e mesmo à duração de período de descanso (que não é mencionado) não haverá células com o mesmo SOL no mesmo índice de ciclo. Mas, o objetivo do algoritmo é ser capaz de gerenciar essas incertezas, que é representativa do uso real e fazer predições confiáveis de RUL nos contextos EOD e EOL.

Figura 6.7: Predições da RUL para EOD e EOL para bateria B0005.

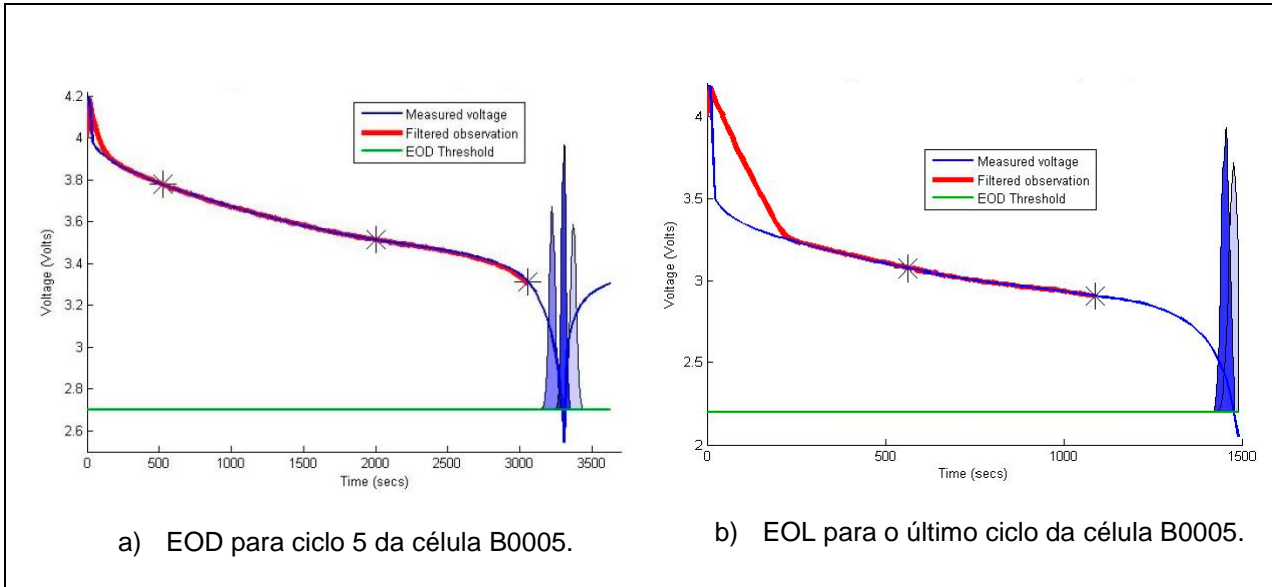


Fonte: Saha e Goebel (2009).

A determinação de α_4 por Saha e Goebel (2009) é feita pela Equação (6.4). A novidade do artigo de Arachchige et al (2017) está na determinação de α_4 pela Equação (6.21), auxiliada pelas Equações (6.15) e (6.16); ou pela Equação (6.17).

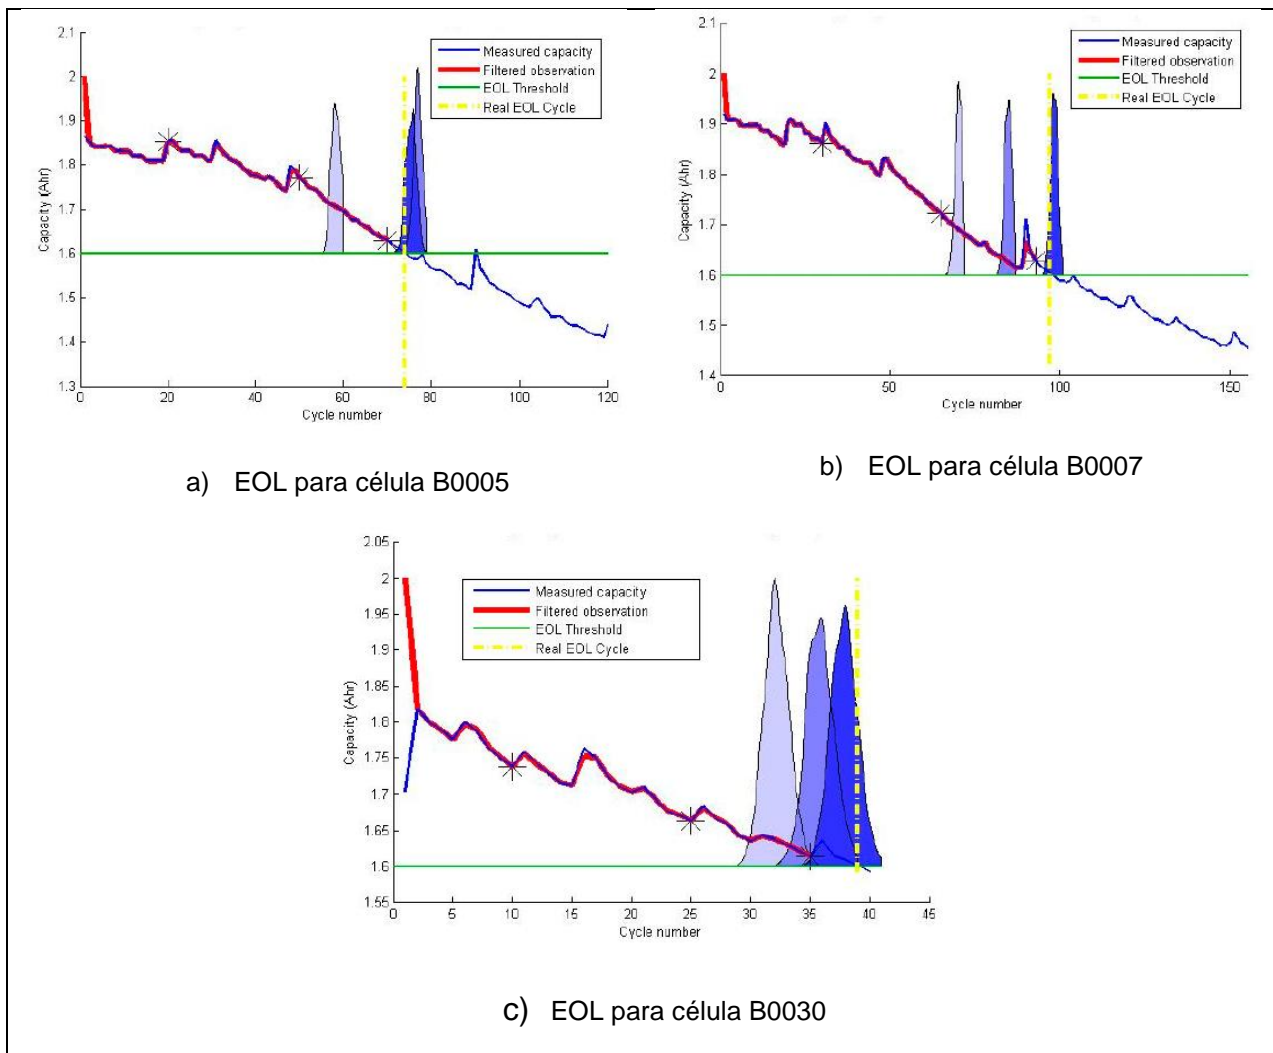
Arachchige et al (2017) apresentam seus resultados para EOD em três pontos de predições para três diferentes ciclos de descarga; a Figura 6.8 apresenta dois destes ciclos para a bateria B0005. Para EOL são apresentados três pontos de predições para três baterias diferentes (B0005, B0007 e B0030) conforme a Figura 6.9. O critério de escolha dos pontos não é mencionado; inferimos que seja aleatório como em Saha e Goebel (2009). Para EOD, a tensão medida da célula é representada pela linha azul e a tensão estimada da célula é representada em vermelho, os pontos de predição são indicados por *, e as EOD pdfs estão em azul, os tons mais escuros se referem às predições mais atuais. Para EOL, é similar, em vermelho a carga estimada da célula, em azul a carga medida da célula, os pontos de predição são indicados por *, e as EOL pdfs estão em azul, com o mesmo critério de cores. O filtro é aplicado a $N_s=400$ partículas.

Figura 6.8: Predições da RUL para EOD.



Fonte: Arachchige et al (2017).

Figura 6.9: Predições da RUL para EOL para as baterias B0005, B0007 e B0030.



Fonte: Arachchige et al (2017).

Baseados em tudo exposto até aqui sobre tais modelos e resultados, gostaríamos de salientar:

A. Algumas Notas/Observações (NOs):

- NO1: No trabalho de Arachchige et al (2017), não foi realizada uma comparação entre os dois modelos (M2 versus M3) ou uma avaliação para indicar o ganho obtido com a flexibilização,
- NO2: O processo de convergência dos algoritmos utilizados por Saha e Goebel (2009) e Arachchige et al (2017) não é discutido nos artigos. As

figuras apresentadas pelos autores mostram variações no número de segundos ou de ciclos até a convergência dos algoritmos. Nas estimativas de EOD vistas na Figura 6.8-a/b, são necessários 250 s aproximadamente para a convergência inicial. Já Nas estimativas de EOL vistas na Figura (6.9-c) são necessários pelo menos 2 ciclos para o algoritmo convergir; n. Isto é bem pior nas Figuras 6.7 a e b. (Ver Cap. 7),

- NO3: Um ponto bem interessante são os picos encontrados nos gráficos de predição de EOL. Os picos são causados devido ao segundo termo do modelo, na Equação (6.10), que se refere à auto-recarga; no entanto, verificamos que isso não ocorre a cada ciclo e parece não ter uma regularidade. Saha e Goebel (2009) não discutem a respeito desses picos, do tempo ou regularidade em que é praticado o repouso das baterias. Este fator de repouso é mencionado nos testes das baterias utilizadas em Goebel et al (2008): eles especificam que o teste de ciclo de vida consistiu em descarga de energia constante e pulsos de regeneração com períodos de descanso intercalados por uma duração total de 72 segundos, e é repetido continuamente enquanto centralizado em torno de 60% SOC,

- NO4: As principais diferenças entre Saha e Goebel (2009) (M2) e Arachchige et al (2017) (M3), são na forma de: 1) calcular o α_4 pelas Equações. (6.4) e (6.21); 2) considerar a corrente na descarga $I(t_i)$; e, com ela, 3) estimar o Q_k ou $\Delta Q = Q_{i+1} - Q_i$ e o SOC. O modelo empírico por Saha e Goebel (2009) considera α_4 aproximadamente constante com um ruído aleatório; a corrente aproximadamente constante, e não usa o SOC nas equações., mas atualiza a medida do Q_k a cada ciclo, pela integral das medidas da corrente; já o modelo flexibilizado por Arachchige et al (2017) i considera o α_4 aproximadamente variável e função do SOC(t_i); a corrente $I(t_i)$ aproximadamente variável, medida nos instantes de amostragem $t_i \in [t_i, t_{i+1}]$, integra-a aproximadamente, estima o decremento na carga $\Delta Q = Q_{i+1} - Q_i = I_i \cdot T_s$ e o SOC(t_i) no

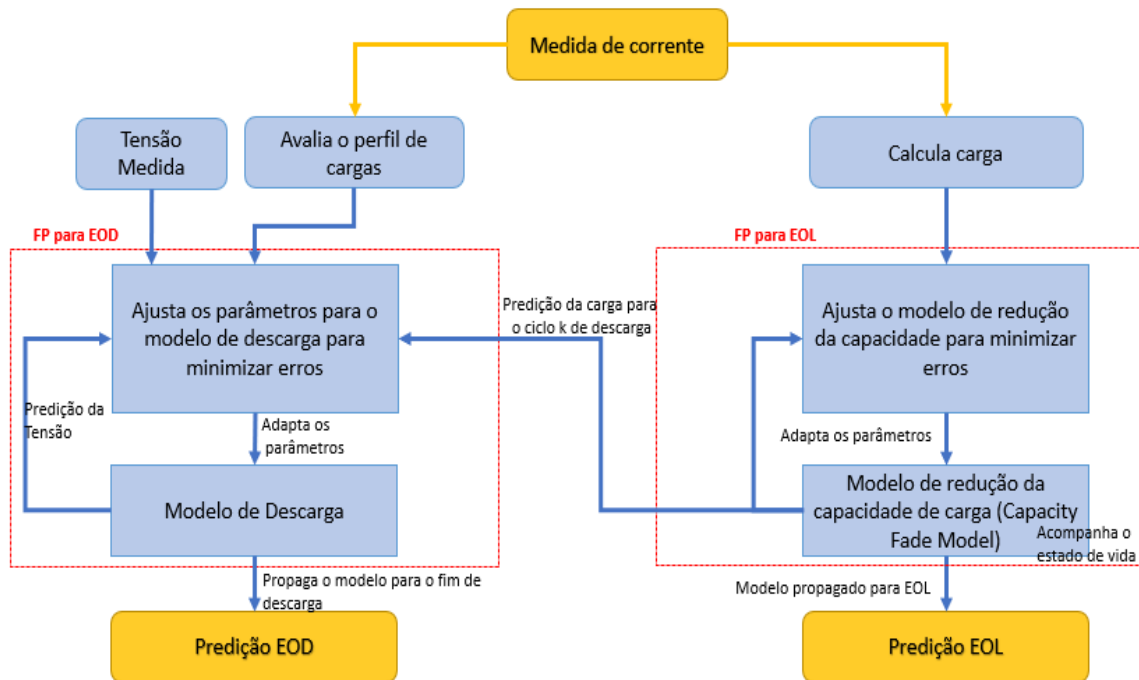
instante t_i no intervalo de amostragem atual $[t_i; t_{i+1}]$, talvez a priori; ou, provavelmente, a posteriori.

B. Algumas Aproximações e Limitações (ALs):

As Aproximações e Limitações (ALs) conjecturadas nos modelos M2 e M3 e seus algoritmos a serem apresentadas no Capítulo 7 deste trabalho em relação a EOD e EOL são:

- O modelo flexibilizado (M3) por Arachchige et al (2017), na tentativa de inserir a variação da corrente, integra aproximadamente as amostras da corrente da bateria ($I(t_i)$) para calcular o decremento ($\Delta Q = Q_{k+1} - Q_k$) na carga em cada ciclo k , e então estimar a EOL e a EOD, como por exemplo as Equações. (6.15) e (6.16) (ver Capítulo 7),
- O modelo flexibilizado (M3) por Arachchige et al (2017), na tentativa de inserir a variação da corrente, utiliza equações com várias aproximações para estimar o SOC, como por exemplo as Equações. (6.16) e (6.17) (ver Capítulo 7),
- O modelo flexibilizado (M3) por Arachchige et al (2017) utiliza a Equação (6.21) para o cálculo do parâmetro α_4 que é proveniente de estimativas de I_i ; e, além disso, é afetado pelas aproximações feitas para o SOC (ver Capítulo 7),
- O modelo flexibilizado (M3) por Arachchige et al (2017) produz uma medida (pelo seu código de M3) e uma previsão (pelas suas Figuras 8 e 10, e nossa Figura 6.10) de $Q(tk)$. Isto pode ser feito: 1) *on-line = a priori*, por filtragem; ou 2) *off line = a posteriori*, por alisamento (ver Capítulo 7),
- O modelo flexibilizado (M3) por Arachchige et al (2017) trabalha com um total de $N_s=400$ partículas, o que, segundo eles, é um número que equilibra carga de trabalho computacional e acurácia. N_s diminuirá se esta aumentar.

Figura 6.10: Diagrama das previsões EOL e EOD.



Fonte: Adaptado de Arachchige et al (2017).

C. Algumas Melhorias e Inovações (MIs):

As Melhorias/Inovações (MIs) adotadas no modelo M4 e implementadas no seu algoritmo a serem apresentadas no Capítulo 7 deste trabalho em relação a EOD e EOL são:

- Eliminar algumas das aproximações utilizadas para integrar a corrente,
- Eliminar algumas das aproximações utilizadas nas equações para estimar a carga Q_k e o SOC,
- Refinar o cálculo do parâmetro α_4 ,
- Operar *on-line = a priori*, utilizando apenas dados até a/da iteração atual para estimar a capacidade de descarga máxima no ciclo atual (Q_k).
- Avaliar uma possível redução no número de partículas sem piorar as previsões a fim de diminuir a carga computacional como resultado do aprimoramento do modelo,
- Trabalhar uma melhoria para a convergência do algoritmo.

7 APROXIMAÇÕES E LIMITAÇÕES DE M2 E M3, MELHORIAS E INOVAÇÕES EM M4

Tanto Saha e Goebel (2009) quanto Arachchige et al (2017) apenas apresentam e usam seus modelos (M2 e M3) mas não os deduzem nem detalham. Assim, tivemos que fazer algumas Conjecturas/Explicações (CEs) em algumas das suas Aproximações e Limitações (ALs), para propor algumas Melhorias e Inovações (MIs), implementá-las no modelo M4, e comparar seus resultados com os dos modelos M2 e M3 em algumas Métricas e Casos (MCs) nas mesmas condições.

Assim, este capítulo apresenta 1) algumas Aproximações e Limitações (ALs) de M2 e M3, com algumas Conjecturas/Explicações (CEs) ; 2) algumas Melhorias e Inovações (MIs) adotadas no modelo M4 e implementadas no seu algoritmo; e 3) algumas Métricas e Casos (MCs) de comparações dos resultados de M4 com os resultados de M2 e M3 nas mesmas condições.

7.1 Aproximações e limitações dos modelos M2 e M3 para EOD

O método mais comum e direto para estimar o SOC(t_i) da bateria e estabelecer sua equação de recorrência é dividir por $Q(t_k)$, a contagem de Coulomb = integral da corrente, dada pelas Equações (5.9) e (6.15),, aqui detalhadas nas Equações (7.1) a (7.5), a saber:

$$Q(t_{i+1}) = Q(t_i) + \int_{t_i}^{t_{i+1}} I(\tau).d\tau = Q(t_i) + \Delta Q(t_i; t_{i+1}) \quad (7.1)$$

$$Q(t_{k+1}) = Q(t_k) + \int_{t_k}^{t_{k+1}} I(\tau).d\tau = Q(t_k) + \Delta Q(t_k; t_{k+1}) \quad (7.2)$$

$$Q(t_k) = \int_{t_k}^{t_{k+1}} -I(\tau).d\tau + Q(t_{k+1}) = \int_{t_k}^{t_{k+1}} |I(\tau)|.d\tau + Q(t_{k+1}) \quad (7.3)$$

$$SOC(t_{i+1}) = \frac{Q(t_{i+1})}{Q(t_k)}, \quad SOC(t_i) = \frac{Q(t_i)}{Q(t_k)} \quad (7.4)$$

$$SOC_{i+1}(t) = SOC_i + \frac{\int_{t_i}^{t_{i+1}} I(\tau). d\tau}{Q(t_k)} \quad (7.5)$$

onde $t_i \in [t_i; t_{i+1}] \subset [t_k; t_{k+1}]$, $t_1 = t_i$, $t_2 = t_{i+1}$, $I(t) < 0$, $Q_k = Q(t_k)$ é a capacidade de descarga máxima no ciclo atual $[t_k; t_{k+1}]$. Tudo isto permite explicar a:

7.1.1 1ª Aproximação/Limitação (AL1): na medida da capacidade de descarga máxima Q_k e no estado de carga SOC_{i+1} , via regras de integração numérica nas Equações (7.6) e (7.7)

A integração de fdps nas nossas Equações (4.3) a (4.13), de correntes nas Equações (14) e (19) de Arachchige et al (2017) e nas nossas Equações (5.9), (6.15), (7.5) e (7.6), (5.10), (6.16), e (7.7), etc., pode ser aproximada numericamente usando as (1ª ou 2ª) Regras de Euler: Avançada (Forward Euler) ou Atrasada (Backward Euler), conforme a Figura 7.1; ou pela regra de Tustin ou Regra do Trapézio, que é a média daquelas, conforme a Figura 7.2. Exemplos são:

No código de M3, a integração numérica da Equação (7.6) usa a regra de Tustin;

A Equação (7.7) usa a 1ª. Regra de Euler no numerador da sua segunda parcela;

No código de M3, a integração numérica da Equação (7.7) usa a Regra de Tustin no denominador da sua segunda parcela.

Figura 7.1: Regras de Euler Avançada e Atrasada.

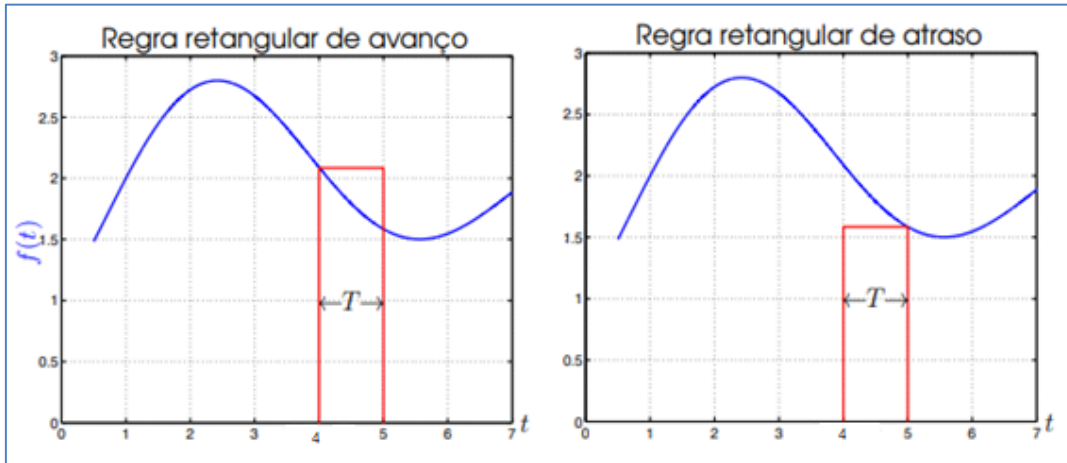
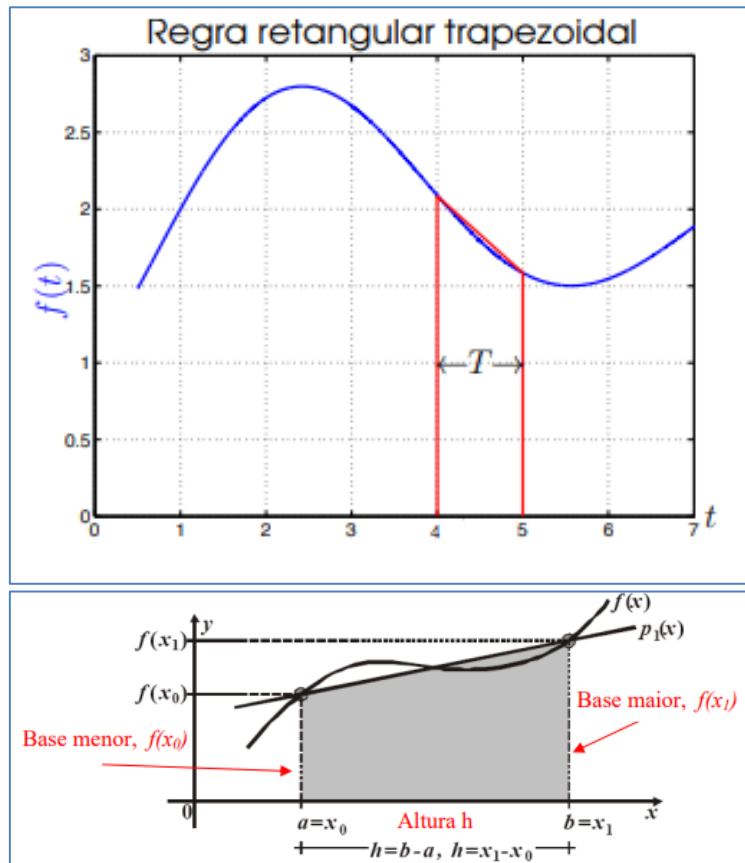


Figura 7.2: Regra do Trapézio.



7.1.2 2ª. Aproximação/Limitação (AL2): na medida da capacidade de descarga máxima Q_k , via intervalo de integração numérica da Equação (7.6)

Considerações para a segunda aproximação no código M3:

- a) A Equação (7.6) aproxima a medida $\tilde{C}_k \cong C_k$ do $Q_k = Q(t_k)$ da Equação (7.3) por $\tilde{C}_{k,k+1+rest}$, aproximando a carga final $Q(t_{k+1})$ da 2ª. parcela da Equação (7.3) pela integral do módulo I da corrente $I(t)$ ($I=|I(t)|>0$) no início de um eventual intervalo de descanso (*rest*) $[t_{k+1}; t_{k+1+rest}]$ até o fim das suas amostras ($I_i=|I(t_i)|>0$), onde nem $V(t)$ nem $Q(t)$ zeram, mas se recuperam parcialmente; a saber:

$$C = \int I dt = \int_{t_k}^{t_{k+1}} |I(\tau)|. d\tau + \int_{t_{k+1}}^{t_{k+1+rest}} |I(\tau)|. d\tau \quad (7.6)$$

- b) Ela aproxima estas integrais por $\sum(I_i+I_{i+1}).Ts/2$ (Regra de Tustin);
- c) Ela usa $I_i=|I(t_i)|$ em todo o ciclo de descarga atual $t_i \in [t_k; t_{k+1}]$ e no início de um eventual intervalo de descanso (*rest*) $[t_{k+1}; t_{k+1+rest}]$. Como $I(t)=-I=$ variável, então $\Delta Q=-I_{media}.\Delta t= -\sum I_i .Ts$, pode-se somar $\sum I_i$, e estimar Q_{k+1} como dito acima em $[t_{k+1}; t_{k+1+rest}]$. Isto pode ser feito: 1) *on-line*= *a priori* = por predição = *prediction* para prever Q_{k+1} em $[t_{k+1}; t_{k+2}]$; 2) *off-line* = *a posteriori* = por alisamento = *smoothing*, para atualizar Q_k . Assim, 1), mas não 2), é conveniente para uma aplicação *on-line*, onde os dados são gerados à medida que a bateria é descarregada.

7.1.3 3ª. Aproximação/Limitação (AL3): no estado de carga SOC_{i+1} , via 2ª parcela da Equação (7.7)

Considerações para a terceira aproximação:

- a) A Equação (7.7) aproxima a integral da corrente $I(t)$ no numerador da 2ª. parcela da Equação (7.5) por $-I_i.T_s$ (1ª. Regra de Euler);
- b) Ela aproxima o $Q(t_k)$ do denominador da segunda parcela da Equação (7.5) pelo C da Equação (7.6), a saber:

$$SOC_{i+1} \approx SOC_i - \frac{I_i T_s}{C} \quad (7.7)$$

7.1.4 4ª. Aproximação/Limitação (AL4): no estado de carga SOC_{i+1} , via 2ª parcela da Equação (7.11)

Arachchige et al (2017) não dizem como eles foram obtidos. Assim, faz-se a:

1ª. Conjectura/Explicação (CE1):

- a) A Equação (7.11) aproxima a integral da corrente $I(t)$ no numerador da segunda parcela da Equação (7.5) por $-I_{\text{constante}}.T_s$, supondo $I(t) \cong -I_{\text{constante}}$ no intervalo $[t_i; t_{i+1}]$, e multiplicando seu módulo $|I(t)| \cong I_{\text{constante}}$ pela duração do intervalo $T_s = t_{i+1} - t_i$ (1ª. Regra de Euler);
- b) Ela aproxima $I_{\text{constante}}$ no intervalo $[t_i; t_{i+1}]$ pela corrente média $I_{\text{médio}}$ no intervalo $[t_k; t_k + t_i]$, isto é, $I(t) \cong I_{\text{constante}}(t_i; t_{i+1}) \cong I_{\text{médio}}(t_k; t_k + t_i) = -I_{\text{médio}} = \Delta Q(t_k; t_k + t_i) / \Delta t < 0$, $\Delta t = t - t_k = t_i$, a saber:

$$I_{\text{médio}}(t_k; t) \cong \frac{Q(t) - Q(t_k)}{t - t_k} \quad (7.8)$$

$$I_{\text{médio}}(t_k; t_k + t_i) \cong \frac{Q(t_i) - Q(t_k)}{t_i} \quad (7.9)$$

$$I_{m\u00e9dia}(t_k; t_k + t_i) = \frac{\frac{Q(t_i) - Q(t_k)}{Q(t_k)}}{\frac{t_i}{Q(t_k)}} = \frac{\frac{Q(t_i)}{Q(t_k)} - \frac{Q(t_k)}{Q(t_k)}}{t_i} Q(t_k)$$

$$I_{m\u00e9dia}(t_k; t_k + t_i) = \frac{(soc_i - 1)}{t_i} Q(t_k)$$

$$I_{m\u00e9dia} = |I_{m\u00e9dia}(t_k; t_k + t_i)| = \frac{(1 - soc_i)}{t_i} Q(t_k) \quad (7.10)$$


$$SOC_{i+1} \sim SOC_i - \frac{(1 - SOC_i)Q(t_k)}{t_i} \cdot \frac{T_s}{Q(t_k)}$$

$$SOC_{i+1} \sim SOC_i - \frac{(1 - SOC_i) T_s}{t_i} \quad (7.11)$$

Isto \u00e9 feito quando se quer prever o EOD ou o EOL (pontos * nos gr\u00e1ficos): a \u00faltima atualiza\u00e7\u00e3o das vari\u00e1veis α_1 , α_2 , α_3 e α_5 \u00e9 mantida e o par\u00e2metro α_4 \u00e9 recalculado, assumindo que o perfil de carga utilizado pela aplica\u00e7\u00e3o permanece o mesmo at\u00e9 o final da descarga, isto \u00e9, $I(t) \cong I_{constante}(t_i; t_{i+1}) \cong I_{m\u00e9dia}(t_k; t_k + t_i) = -I_{m\u00e9dia} = \Delta Q(t_k; t_k + t_i) / \Delta t < 0$, $\Delta t = t - t_k = t_i$, a fim de propagar o estado atual da bateria. E o novo estado de carga \u00e9 calculado pela sua Equa\u00e7\u00e3o 28, aqui mostrada como nossas Equa\u00e7\u00f5es (6.17) e (7.11).

Isso \u00e9 apresentado na Figura 7.3. Nesta, apresenta o instante de amostragem t_i no intervalo de amostragem $[t_i; t_{i+1}]$ de dura\u00e7\u00e3o T_s num ciclo de descarga atual $[t_k; t_{k+1}]$; isto \u00e9, $t_i \in [t_i; t_{i+1}] \subset [t_k; t_{k+1}]$; e o instante inicial t_k do ciclo k , que coincide com o tempo $t_i = 0$, $i = 0$.

Figura 7.3: Aproximação da corrente $I(t)$ pela sua média $I_{m\u00e9dia}(t_k; t_k + t_i)$ no intervalo $[t_k; t_i]$.



7.1.5 5ª. Aproximação/Limitação: No par\u00e2metro, via Equa\u00e7\u00e3o (7.14)

Arachchige et al (2017) n\u00e3o dizem como eles foram obtidos. Assim, faz-se a:

2ª. Conjectura/Explicação (CE2):

- a) A Equa\u00e7\u00e3o (23) de Arachchige et al (2017), nossas Equa\u00e7\u00f5es (5.12), (6.21), e (7.12) para α_4 s\u00e3o:

$$\alpha_4 \cong a \frac{(1 - soc_i)}{t_i} \quad (7.12)$$

- b) nela, antes de **se prever o EOD ou o EOL (pontos * nos gr\u00e1ficos)**, o SOC_i \u00e9 calculado pela Equa\u00e7\u00e3o (19) de Arachchige et al (2017), nossas Equa\u00e7\u00f5es (5.10), (6.16), (7.5), (7.7) e (7.13):

$$SOC_{i+1} \approx SOC_i - \frac{I_i T_s}{\tilde{C}_{k,k+1+rest}} \quad (7.13)$$

então, o SOC_i decresce e $(1-SOC_i)$ cresce linearmente com t_i em degraus constantes de $\frac{I_i T_s}{\tilde{C}_{k,k+1+rest}}$; portanto, α_4 permanece aprox.

constante com t_i ;

- c) nela, **quando se quer prever o EOD ou o EOL (pontos * nos gráficos)**, o SOC_i passa a ser calculado pela Equação (28) de Arachchige et al (2017), nossas Equações (5.11, 6.17, 7.11 e 7.14):

$$SOC_{i+1} \sim SOC_i - \frac{(1 - SOC_i) T_s}{t_i} \quad (7.14)$$

então, o SOC_i decresce e $(1-SOC_i)$ cresce menos que linearmente com t_i em degraus decrescentes de $\frac{T_s}{t_i}$ e tendem para seus limites; portanto, α_4 decresce monotonicamente com t_i ;

- d) nela, introduzindo a aproximação de $I_{m\u00e9dia}$ dada pela Equação (7.10), obt\u00eam-se:

$$\alpha_4 \cong a \cdot \frac{(1 - soc_i) Q(t_k)}{t_i} \cong a \cdot \frac{I_{m\u00e9dia}}{Q(t_k)} \quad (7.15)$$

- e) nela, o fator de ajuste $a = 10.8$ foi introduzido para compensar o decr\u00e9scimo de α_4 detalhado no item c e o uso de $I_{m\u00e9dia}$ detalhado no item d e aparece na Equação (7.16).

$$\alpha_4 \cong \frac{a(1 - SOC_i)}{t_i} \quad (7.16)$$

Nada é dito sobre estas aproximações. Diz-se que $a = 10.8$ (parece muito alto para um “ajuste”), um valor encontrado experimentalmente (não é detalhado como); e α_4 é utilizado como variável de estado após adicionar o ruído.

7.2 Melhorias/Inovações (MIs) adotadas no modelo M4 e implementadas no seu algoritmo

As Melhorias/Inovações (MIs) propostas abaixo foram adotadas no modelo M4 e implementadas no seu algoritmo, a saber:

7.2.1 1ª. Melhoria/Inovação (MI1): na medida da capacidade de descarga máxima Q_k , e no estado de carga SOC_{i+1} , via regras de integração numérica nas Equações (7.6) e (7.7)

Conforme a AL1, a integração de fdps nas nossas Equações (4.3) a (4.13), de correntes nas Equações (14) e (19) de Arachchige et al (2017) e nas nossas Equações (5.9), (6.15), (7.5) e (7.6); (5.10), (6.16), e (7.7), etc., pode ser aproximada numericamente utilizando as (1ª ou 2ª) Regras de Euler: Avançada (*Forward Euler*) ou Atrasada (*Backward Euler*), conforme a Figura 7.1. Nesta, a integral da curva $y=f(t)$ no intervalo $[t_i; t_{i+1}]$ é área sob a curva, aproximada por: pela 1ª. regra; e por pela 2ª. regra. Isto pode ser melhorado pela Regra de Tustin, ou Regra do Trapézio, que é a média daquelas, conforme a Figura 7.2.

A Figura 7.2, mostrada no Tópico 7.1.1 deste capítulo apresenta a ideia básica da regra do trapézio, que é aproximar a função $f(x)$ por um polinômio de ordem 1 (reta). Nesta aproximação, a integral da função $f(x)$ pode ser aproximada pela área de um trapézio. Se utilizarmos a fórmula de Lagrange para expressar o polinômio interpolador de ordem 1, $p_1(x)$, que interpola $f(x)$ nos pontos x_0 e x_1 , tem-se:

$$p_1(x) = f(x_0)L_0(x) + f(x_1)L_1(x) \quad (7.17)$$

Onde, $L_0(x) = \frac{x-x_1}{x_0-x_1}$ e $L_1(x) = \frac{x-x_0}{x-x_0}$. Pode-se considerar $h = \frac{x_1-x_0}{n}$, n é o número de subdivisões do intervalo $[x_0, x_1]$, neste caso $n = 1$. Substituindo os fatores de Lagrange no polinômio podemos reescrevê-lo:

$$p_1(x) = \frac{x-x_1}{-h} f(x_0) + \frac{x-x_0}{h} f(x_1) \quad (7.18)$$

$$\begin{aligned} \int_a^b f(x) dx &\approx \int_{x_0}^{x_1} p_1(x) \\ &= \int_{x_0}^{x_1} \left[\frac{x-x_1}{-h} f(x_0) + \frac{x-x_0}{h} f(x_1) \right] dx \\ &= \frac{h}{2} [f(x_0) + f(x_1)] dx \end{aligned} \quad (7.19)$$

Baseado nisto, **propõe-se usar a regra de Tustin, ou Regra do Trapézio na integração numérica de fdps, correntes, etc., especialmente: nas Equações (7.6) e (7.7), como:**

$$\int_{i-1}^i Idt \approx \frac{T_s}{2} (I_{i-1} + I_i) \quad (7.20)$$

7.2.2 2ª. Melhoria/Inovação (MI2): na medida da capacidade de descarga máxima Q_k listada no banco de dados; e, talvez, via intervalo de integração numérica da Equação (7.6) e sua propagação

Sabe-se que a carga $Q(t)$ num instante $t \in [t_k; t_{k+1}]$. relaciona-se com a tensão $V(t)$ e com a energia $E(t)$ que pode ser drenada da bateria ao longo do tempo. Esta pode ser afetada pela ciclagem e deterioração dos aspectos eletroquímicos da bateria.

Em $t_k=t_0$, $k=0$, a capacidade de descarga máxima do ciclo de descarga inicial $Q_0=Q(t_0)$ é a maior carga possível que pode ser retirada no ciclo inicial $k=0$, sob diversas condições. Esta, segundo Espedal et al (2021), é incapaz de atingir o valor nominal Q_{nom} , ou seja, é menor que a carga especificada pelo fabricante para operação regular, $Q_0 < Q_{nom}$.

Em $t_k > t_0$, $k > 0$, a capacidade de descarga máxima do ciclo de descarga atual $Q_k=Q(t_k)$ pode ser calculada pela Equação (7.3) e propagada pelas Equações (6.8) a (6.11). Esta sempre tem um valor residual $Q_{k+1} = Q(t_{k+1}) > 0$. Como Arachchige et al (2017) dizem:

Therefore, the cell output current must be integrated during a full discharge cycle. **The important point is that the battery is not always fully charged or discharged.** Therefore, tables with available test data and other estimation algorithms are required to accurately predict the battery's State of Health (SOH).

Conforme a AL2, a aproximação da medida $\tilde{C}_k \cong C_k$ do $Q_k = Q(t_k)$ da Equação (7.4) por $\tilde{C}_{k,k+1+\varepsilon}$ da Equação (7.19), depende da regra de integração da sua 1ª. parcela e da aproximação da carga remanescente $Q_{k+1} = Q(t_{k+1})$ da sua 2ª. parcela. Em Arachchige et al (2017), esta é aproximada estendendo a integração ao início de um **eventual intervalo de descanso**, conforme a Equação (7.6). Eles dizem que Kai e Goebel (2009) conhecem a corrente ($I(t_i)=\text{constante}$) e a capacidade de descarga Q_k antecipadamente, i.e.:

The novelty of this study when compared to the model proposed by Saha and Goebel [2009] is the method of calculating α_4 . Determination of α_4 according to Saha and Goebel's method is shown by Equation 26 (aqui 6.4). **In their model, the values were initialized knowing the loading profile (aqui, $I(t)=\text{constante}$) and capacity (aqui, Q_k) in advance.** The calculation in Equation 23 (aqui 6.21) for α_4 allows the parameters to adapt to different loads. This proposed modification of α_4 also works when the capacity has faded away, causing a reduction in the EOD time.

Tais valores são listados no banco de dados; mas, nem Saha e Goebel (2009) nem Arachchige et al (2017) dizem como eles foram obtidos. Assim, faz-se a:

3ª. Conjectura/Explicação (CE3): Os valores de Q_k no banco de dados foram obtidos: 1) estendendo a integração a um **obrigatório intervalo de depleção** $[t_{k+1} ; t_{k+1+\varepsilon}]$, até $Q(t)=Q_\varepsilon >0$ e $V(t)=V_\varepsilon >0$ ficarem ínfimos em $t_{k+1+\varepsilon}$; 2) propagando $Q_k = Q(t_k)$ para $[t_{k+1} ; t_{k+2}]$ pelas Equações (6.8) a (6.11).

Baseado nisto, **propõe-se usar a medida $\tilde{C}_{k,k+1+\varepsilon}$ listada no banco de dados**; e obtida, talvez: 1) estendendo o intervalo de integração das Equações (7.4) e (7.6) muito além de $[t_k ; t_{k+1}]$, até $Q(t)=Q_\varepsilon >0$ e $V(t)=V_\varepsilon >0$ ficarem ínfimos, conforme a Equação (7.19); 2) propagando este valor para $[t_{k+1} ; t_{k+2}]$ pelas Equações (6.8) a (6.11), a saber:

$$\tilde{C}_{k,k+1+\varepsilon} = \int_{t_k}^{t_{k+1}} |I(\tau)|.d\tau + \int_{t_{k+1}}^{t_{k+1+\varepsilon}} |I(\tau)|.d\tau \quad (7.21)$$

7.2.3 3ª. Melhoria/Inovação (MI3): no estado de carga SOC_{i+1} via 2ª. parcela da Equação (7.7)

Conforme a AL3:

a) a Equação (7.7) aproxima a integral da corrente $I(t)$ no numerador da 2ª. parcela da Equação (7.5) por $I_i.T_s$ (1ª. Regra de Euler); isto melhorará com a MI1;

b) ela aproxima o $Q(t_k)$ do denominador da 2ª. parcela da Equação 7.5e pelo $\tilde{C}_{k,k+1+\varepsilon}$ da Equação (7.6); isto melhorará com a MI2;

Baseado nisto, **propõe-se: 1) aproximar a integral da corrente $I(t)$ no numerador da 2ª. parcela da Equações (7.5) e (7.7) por $(I_i + I_{i+1})T_s / 2$ (Equação 7.21); e o $Q(t_k)$ no denominador da 2ª. parcela da Equações (7.5) e (7.7) por $\tilde{C}_{k,k+1+\varepsilon}$ (Equação 7.19), a saber:**

$$SOC_{i+1} \approx SOC_i - \frac{(I_i + I_{i+1})T_s / 2}{\tilde{C}_{k,k+1+\varepsilon}} \quad (7.22)$$

7.2.4 4ª. Melhoria/Inovação (MI4): no estado de carga SOC_{i+1} , via 2ª. parcela da Equação (7.11)

Arachchige et al (2017) nada dizem como a Equação (7.11), foi obtida. Assim, detalhando a 1ª Conjectura/Explicação (CE1):

Conforme a AL4, **quando se quer prever o EOC ou o EOL (pontos * nos gráficos)**: a última atualização das variáveis α_1 , α_2 , α_3 e α_5 é mantida e o parâmetro α_4 é recalculado, assumindo a corrente constante até o final da descarga na sua Equação 19, aqui Equações. (5.10), (6.16) e (7.7); isto é, $I(t) \cong I_{\text{constante}}(t_i; t_{i+1}) \cong I_{\text{média}}(t_k; t_k + t_i) = - I_{\text{média}} = \Delta Q(t_k; t_k + t_i) / \Delta t < 0$, $\Delta t = t - t_k = t_i$, a fim de propagar o estado atual da bateria. E o novo estado de carga é calculado pela sua Equação 28, aqui Equações (5.11), (6.17) e (7.11).

A Equação (7.11) aproxima a integral da corrente $I(t)$ no numerador da 2ª. parcela da Equação (7.5) por $I_{\text{constante}}(t_i; t_{i+1}) \cdot T_s$, e $I_{\text{constante}}(t_i; t_{i+1})$ por $I_{\text{média}}(t_k; t_k + t_i)$, e $I_{\text{média}}(t_k; t_k + t_i)$ pela Equação (7.10).

Tais aproximações reduzem a acurácia da Equação (7.11), sobretudo quando a corrente varia e cai muito. Então, é mais fiel usar os últimos I_i em $[t_k; t_{k+1}]$.

Baseado nisto, **propõe-se usar os últimos I_i em $[t_k; t_{k+1}]$ para a propagar o estado até o EOD, quando se quer prever o EOC ou o EOL (pontos * nos gráficos)**,

a saber pela Equação (7.22): $SOC_{i+1} \approx SOC_i - \frac{(I_{i\text{ult}} + I_{i+1\text{ult}}) \cdot T_s / 2}{\tilde{C}_{k,k+1+\varepsilon}}$

7.2.5 5ª. Melhoria/Inovação (MI5): no parâmetro, via Equação (7.14)

O parâmetro α_4 é a variável de estado mais crítica nos modelos M2 e M3. Mas, nem Saha e Goebel (2009) nem Arachchige et al (2017) dizem como seus modelos, especialmente de α_4 , foram obtidos. Assim, detalhando a 2ª Conjectura/Explicação (CE2):

Conforme a AL5, a Equação (7.17) parece ter sido obtida:

a) introduzindo a aproximação de $I_{média}$ dada pela Equação (7.10) na Equação (7.7) obtendo:

$$\alpha_4 \cong a \cdot \frac{(1 - soc_i) Q(t_k)}{t_i} \cong a \cdot \frac{I_{média}}{Q(t_k)} \quad (7.23)$$

b) introduzindo o fator de ajuste $a=10.8$ para compensar o decréscimo de α_4 após t^* e o uso de $I_{média}$, detalhados nos itens c, d, da AL5;

Nada é mencionado sobre tais aproximações. Diz-se que $a = 10.8$ (parece muito alto para um “ajuste”), um valor encontrado experimentalmente (não é detalhado como); e α_4 é usado como variável de estado após adicionar o ruído. Tais aproximações reduzem a acurácia da Equação (7.13), sobretudo quando a corrente varia e cai muito. Então, é mais fiel usar I_i eliminar a na Equação (7.13).

Baseado nisto, **propõe-se usar o atual I_i em $[t_k ; t_{k+1}]$ para estimar α_4 ; e até propagar o estado até o EOD ou EOL, quando se quer prever o EOC ou o EOL (pontos * nos gráficos), a saber:**

$$\alpha_{4i} = \alpha_4(t_i) = \frac{I(t_i)}{Q(t_k)} \quad (7.24)$$

Outro modo de obter isto é pela:

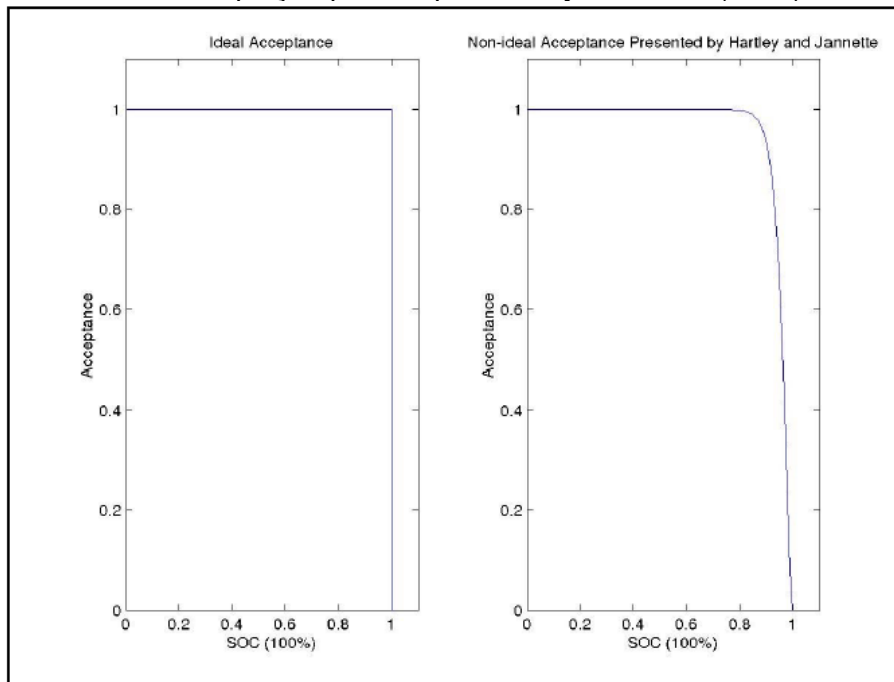
4ª Conjectura/Explicação (CE4): Segundo Hartman II (2008), p. 22-23, especialmente nas suas Equação(2.41) e Figura 2.5, nossas Equação (7.22) e Figura 7.4:

In an ideal world, the battery would transform all the charge applied to the cell into stored charge for later use, as shown in the first plot of Figure 2.5. A more realistic plot of charge acceptance is shown in the second plot of Figure 2.5. This second plot was generated using the equation

$$a(q_s) = \begin{cases} 1 & i(t) > 0 \\ 1 - 5e^{-40\left(1-\frac{q_s(t)}{Q}\right)} + 4e^{-50\left(1-\frac{q_s(t)}{Q}\right)}, & i(t) \leq 0 \end{cases} \quad (7.25)$$

which was presented by Hartley and Jannette (2005). The exponential terms in Equation 2.41 (Indicada aqui como 7.25) provide the upper limit on the total amount of charge that can be stored in the cell, as well as the rounding effects near full SOC.

Figura 7.4: Gráficos mostrando a Aceitação Ideal e a Aceitação Não Ideal realizados usando a equação provida por Hartley & Janette (2005).



Fonte: Hartman II (2008).

onde: $i(t) < 0$ indica a descarga, $q_s(t)$ é a carga armazenada, Q é a capacidade de carga, $q_s(t)/Q$ é o estado de carga SOC(t), e $(1 - q_s(t)/Q)$ é o estado de descarga SOD(t). Quando amostrados, se tornam, na nossa notação: $I_i = I(t_i)$, $Q_i = Q(t_i)$, $Q_k = Q(t_k)$, $SOC(t_i) = SOC_i$, $SOD(t_i) = SOC_i = 1 - SOC(t_i) = 1 - SOC_i$.

Nelas, os termos exponenciais são função de $SOC(t) = q_s(t)/Q$, (Equação 7.26) e têm a mesma forma que $\Delta E_{rd}(t)$ da Equação (5.6) ($\Delta E_{rd}(t) = \alpha_3 \exp(\alpha_4 t)$), a saber:

$$a(q_s) = \begin{cases} 1 & i(t) > 0 \\ 1 - 5e^{-40\left(1-\frac{q_s(t)}{Q}\right)} + 4e^{-50\left(1-\frac{q_s(t)}{Q}\right)}, & i(t) \leq 0 \end{cases} \quad (7.26)$$

Nelas, se $I(t)=I=$ constante, então:

$$q_s(t) = I \cdot t, \alpha_4 = I/Q$$

$$SOC(t) = \frac{q_s(t)}{Q} = I \cdot \frac{t}{Q} = \alpha_4 \cdot t$$

$$a(q_s) = 1 - \alpha_{3\&} \cdot \exp(\alpha_{4\&} \cdot t) + \alpha_{3*} \exp(\alpha_{4*} \cdot t) \quad (7.27)$$

Baseado nisto, **propõe-se usar o atual I_i em $[t_k ; t_{k+1}]$ para estimar α_4 ; e até propagar o estado até o EOD ou EOL, quando se quer prever o EOC ou o EOL (pontos * nos gráficos), a saber:**

$$\alpha_{4i} = \alpha_4(t_i) = \frac{I(t_i)}{Q(t_k)} \quad (7.28)$$

7.3 Avaliação e comparação de resultados dos modelos M2, M3, M4 para EOD

Para os 3 grupos de avaliação e comparação dos resultados obtidos com os modelos M2, M3, M4 nas mesmas condições, utilizaremos, respectivamente:

1) O Erro Relativo (*Relative Error* - RE): usado por Arachchige et al (2017) (suas Equações. 29 e 30, nossas Equação 7.29); **e o Erro Absoluto Médio (*Mean Absolute Deviation* - MAD)** (Equação 7.30), para análise da acurácia (μ) e precisão (σ):

$$RE = \frac{|[Predito - Real]|}{Real} \quad (7.29)$$

onde o Predito é a média das estimativas geradas pelo algoritmo $\sum_1^{Ns} EOD / Ns$.

$$MAD = \frac{1}{N_s} \sum_1^{N_s} |[Predito - Real]| \quad (7.30)$$

onde N_s é o tamanho da amostra; *Predito* é, p. ex., o tempo estimado para atingir o limiar (*threshold*) para o fim de descarga E_{eod} ; e *Real* é, p. ex., o tempo exato em que a célula de bateria atinge o limiar (*threshold*) E_{eod} de, p. ex.: 2,7 V, nos casos escolhidos a seguir por Projeto e a Análise de Experimentos.

2) O Número de Partículas, a Acurácia e Precisão, e a Carga Computacional: O número de partículas será utilizado para avaliar a carga computacional do algoritmo gerado pelas melhorias/ inovações. Tal critério de planejamento da comparação dos resultados obtidos com o aprimoramento do algoritmo *on-line* será avaliado sozinho e em conjunto com as outras melhorias.

3) A Acurácia e Precisão, a Distância Prognóstica e o Tempo de Resposta: conforme a Seção 2.5.3, especialmente as Figuras 2.11 e 2.12, para a avaliação final do algoritmo com todas as melhorias.

7.3.1 1ª. Avaliação e Comparação (AC1): usando o Erro Relativo (Relative Error - RE) e o Erro Absoluto Médio (Mean Absolute Deviation - MAD)

Segundo Montgomery (2017), o método do Projeto e Análise de Experimentos deve ser iniciado pelo Planejamento Fatorial, onde se planeja o menor número de casos para o estudo do efeito conjunto dos fatores = causas sobre determinada variável de resposta = efeito. Nele, são feitos os (b^n) testes com todas as possíveis combinações dos (b) níveis dos (n) fatores. O Anexo C resume o Projeto e Análise de Experimentos e o Planejamento Fatorial. Aqui (b=2, n=5), será utilizado o Planejamento Fatorial Fracionado, onde não se exploram todas as combinações possíveis, realizando apenas um subconjunto ou fração dos experimentos do Planejamento Fatorial Total (neste caso $2^4=16$).

As melhorias/ inovações implementadas serão avaliadas separadamente e comparadas com os equivalentes sem elas (caso 0); depois, serão unificadas para uma avaliação final.

A Tabela 7.1 apresenta os casos que serão avaliados e comparados com o algoritmo sem melhorias. Os casos de 1 a 6 serão comparados com o equivalente da literatura (caso 0). O Erro Relativo (RE) e o Erro Absoluto Médio (MAD) serão avaliados em cada caso para representar a acurácia e a precisão das predições, respectivamente.

Inicialmente, três melhorias/ inovações (MI1, MI4, MI5) serão avaliadas isoladamente (casos 1, 2, 3a) em três tempos de iteração $i=20$ (344,54 s), $i=40$ (708,9 s) e $i=60$ (1075,3s) para o ciclo 5 da célula B0005; e, posteriormente, serão avaliadas conjuntamente (casos 3b, 4, 5) em três tempos de iteração $i=20$ (344,54 s), $i=40$ (708,9 s) e $i=60$ (1075,3s) ou $i = 30$ ($\cong 500$ s), $i = 120$ ($\cong 2000$), $i = 165$ ($\cong 3000$) para o ciclo 5 da célula B0005. A segunda melhoria/ inovação (MI2) será avaliada isoladamente e em conjunto com as anteriores nos casos 6 e 7. Estas serão unificadas para uma nova avaliação em mais de uma célula (B0030; e B0007, B0018,) e mais tempos de iteração, ciclos, e células, nos casos 8 e 9.

Os casos 8 e 9 objetivam aplicar o algoritmo a outras células de baterias para verificar o comportamento do algoritmo. Esses casos não serão comparados com o algoritmo sem melhorias; o interesse é apenas demonstrar o bom funcionamento com dados diferentes. O tempo de convergência será avaliado em um ciclo do início e um ciclo do final de, pelo menos, duas células de bateria, pois a melhoria/ inovação MI5 é uma medida que facilita a aplicação *on-line* e previne os tipos de falhas que podem afetar os primeiros e/ou os últimos ciclos.

Tabela 7.1: Planejamento das comparações.

Caso	Melhoria / Inovação	Célula de Bateria	Ciclos de descarga	Tempo I=
0	Nenhuma	B0005	5	20, 40, 60
1	MI1	B0005	5	20, 40, 60
2	MI2	B0005	5	20, 40, 60
3	MI4	B0005	5	20, 40, 60
4a	MI5	B0005	5	20, 40, 60
4b	MI4 e 5	B0005	5	20, 40, 60
5	MI1, 4 e 5	B0005	5	20, 40, 60
6	MI1, 4 e 5	B0005	5	30, 120, 165
7	MI1, 2,3,4, 5	B0005	5 e último.	Ciclo 5, i = 20, 40 e 60. Último ciclo, i = 20, 80 e 120
8	MI1, 2,3,4, 5	B0030	5 e penúltimo	Ciclo 5, i = 20, 40, 60, 80. Penúltimo ciclo, i = 20, 80,120
9	MI1, 2,3,4, 5	B0007, B0018	B0007 = ciclo 10; B0018 = ciclo 4 e último ciclo	B0007 – ciclo 10, i = 20, 40, 60, 80, 120; B0018 – ciclo 4, i = 20, 40, 60, 200, 300; último ciclo, i = 20, 40, 60.
10	Análise no Início do ciclo	B0005 e B0030	Ciclo 5	I = 4,8 e 12

Para o ciclo 5 da bateria B0005, os tempos de iteração $i=20$ (344,54 s), $i=40$ (708,9 s) e $i=60$ (1.075,3s) são considerados tempos pequenos e médios comparados com o tempo em que a célula atingirá o *threshold* da tensão (2,7 V) que será aproximadamente em $i=178$ (3.307,7 segundos ~ 55 minutos),. Esses tempos foram escolhidos com base na perspectiva de tomadas de decisão, buscando avaliar a acurácia do algoritmo com um horizonte de predição de pelo menos 37 minutos (para $i = 60$).

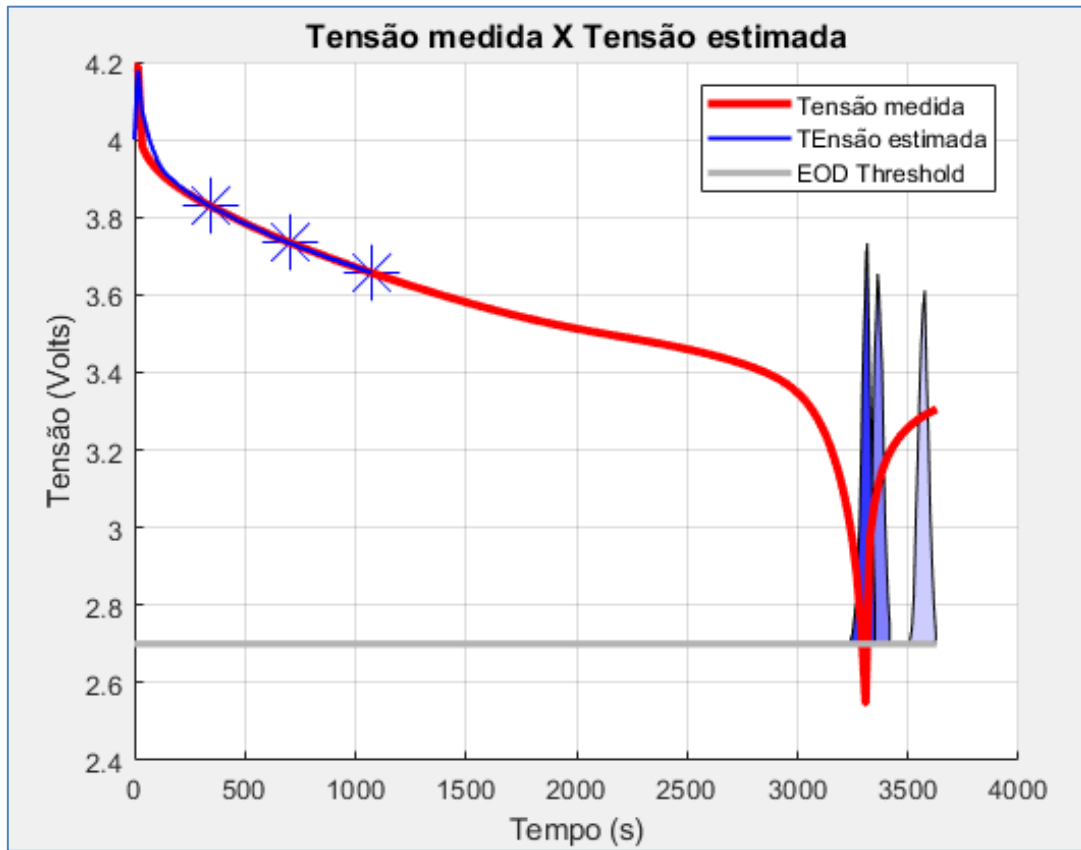
Para comparação do nosso algoritmo final com o algoritmo de Arachchige et al (2017), foram utilizados a sua Figura 13 com os tempos $i = 30$ (~500 s), 121

(~2.000 s) e 167 (~3.100 s). Esses tempos próximos do ponto considerado como falência são utilizados basicamente para a comparação e para mostrar a convergência do algoritmo. O número de partículas utilizadas será avaliado para identificar a carga computacional do algoritmo gerado pelas melhorias.

Para facilitar a comparação e o entendimento, o valor de tensão medido será representado nas figuras pela linha vermelha, os valores estimados pelo filtro pela linha azul, os pontos de predição são representados pelos asteriscos em destaques e a predição usualmente não retorna um ponto de falência, mas uma massa de pontos prováveis; ou seja, uma função densidade de probabilidade calculada para o intervalo de tempo possível quando a carga da célula é estimada para terminar. Essas predições são representadas em azul; as predições mais atuais possuem uma tonalidade mais forte que as anteriores.

Caso 0: O caso 0, ilustrado pela Figura 7.5, é a Figura 13 de Arachchige et al (2017), mas lá com $i = 30$ (~500 s), 121 (~2.000 s) e 167 (~3.100 s), sem melhorias, com 400 partículas, aqui repetida na Figura 6.8a e refeita na Figura 7.6 com $i=20$ (344,54 s), $i=40$ (708,9 s) e $i=60$ (1075,3s) para o ciclo 5 da célula B0005:

Figura 7.5: Ação preditiva sem melhorias (caso 0).



Caso 1: No caso 1, ilustrado pela Figura 7.6, é possível identificar visualmente a melhoria da convergência da predição com a comparação das Figuras 7.5, 7.6 e 7.7. A predição do tempo $i=40$ e $i=60$ são tão próximos que a predição foi dividida na Figura 7.6 e Figura 7.7. A separação ocorreu para identificar visualmente a fdp da predição. Na Tabela 7.2 é possível perceber que o erro relativo de $i=40$ e $i=60$ é menor que 1%. Com essa melhoria, o algoritmo reduziu em aproximadamente 34% o erro absoluto médio, conforme aponta a Tabela 7.2.

Numa predição prognóstica sob a perspectiva de acionar uma decisão, a medida estimada deve ocorrer sempre antes da falência real, para evitar ações muito conservadoras e reduzir o risco de não ter tempo suficiente de implementações das ações necessárias, o que não ocorre para a medida estimada para $i=20$.

Figura 7.6: Resultado após a implementação de melhorias do Caso 1, para $i = 20$ e 40.





Tabela 7.2: Erro relativo, Caso 1.

Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo Predição sem melhoria	MAD Ação Predição sem melhoria	Erro relativo Melhoria 1	MAD Melhoria 1
	$i=20$ (344,54 s)	$i=20$ (344,54 s)	0,07934 7,93%	262,46 s ~4,37min	0,05226 5,22%
	$i=40$ (708,9 s)	$i=40$ (708,9 s)	0,02165 2,16%	71,64 s ~1,19min	0,00889 0,89%
	$i=60$ (1075,3 s)	$i=60$ (1075,3 s)	0,007508 0,75%	24,83 s	0,00246 0,246%

Figura 7.7: Resultado após a implementação de melhorias do Caso 1, para $i = 20, 40$ e 60 .



Caso 2: Como mencionado ao final do Capítulo 6 e enfatizado na análise das equações utilizadas e visualizado na Figura 7.8, Arachchige et al (2017) parece fazer uma aplicação *off-line*, utilizando os valores de corrente de todo o ciclo para ajustar a carga nominal. Como o interesse deste trabalho é um algoritmo a operar em tempo real, a quarta melhoria de aproximar a capacidade de descarga máxima Q_k do ciclo k analisado é uma medida que pode ser aplicada visando a possibilidade de o algoritmo operar em tempo real. Esta é uma medida que possibilita avaliar a EOD considerando uma possível redução de capacidade de carga ("*Capacity Fade Model*") tipo de falha que pode ocorrer ao longo da ciclagem ou ainda a falha de Descarga na Prateleira/Auto-descarga ("*BatteryCellShelfDischarge*") que pode se apresentar nos primeiros ciclos.

A melhoria declarada no caso 2 se refere em só utilizar os dados de corrente até o ciclo analisado para estimativa de Q_k . Esta é uma alteração que permite que o algoritmo possa ser aplicado em situações *on-line*. Acreditava-se que esta melhoria teria um ganho qualitativo, mas talvez não quantitativo; no

entanto, a acurácia melhorou, conforme Tabela 7.3. ou seja, são dois ganhos, uma no valor da acurácia das predições e outro na implementação de predições em tempo real que é o ganho qualitativo e de maior importância.

Figura 7.8: Predições realizadas referente caso 2.




Tabela 7.3: Erro relativo, Caso 2.

Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo	MAD Ação	Erro relativo	MAD
		Predição sem melhoria	Predição sem melhoria		
	i=20 (344,54 s)	0,07934 7,93%	262,46 s ~ 4,37min	0,072010668 7,20%	238,19 s
	i=40 (708,9 s)	0,02165 2,16%	71,64 s ~1,19min	0,011222174 1,12%	37,12 s
i=60 (1075,3 s)	0,007508 0,75%	24,8371	0,00529996 0,529%	17,53 s	

Caso 3: O caso 3 se refere a uma melhoria na estimativa de SOC, evitando aproximações que podem resultar em baixa acurácia e precisão. Essa melhoria afeta a estimativa do parâmetro de estado α_4 . Ao analisar os erros relativos e erro absoluto comparados aos valores anteriores a esta melhoria, é perceptível que não há ganho de acurácia na medida estimada. Em termos de acurácia essa alteração não resulta em benefícios. No entanto, ao avaliar os valores médios estimados para o fim da carga e a Figura 7.9 é possível observar os benefícios, a melhoria na estimação do SOC resulta em uma estimativa preditiva mais conservadora, o que, como já comentado, em termos de tomadas de decisões, é o ideal.

Figura 7.9: Resultado após a implementação de melhorias do Caso 3, para $i = 20, 40$ e 60 .




Tabela 7.4: Erro relativo, Caso 3.

Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo	MAD Ação	Erro relativo	MAD
		Predição sem melhoria	Predição sem melhoria	Melhoria 2	Melhoria 2
	$i=20$ (344,54 s)	0,07934 7,93%	262,46 s ~4,37min	0,08354 8,354 %	276,33 s ~4,6 min
	$i=40$ (708,9 s)	0,02165 2,16%	71,64 s ~1,19min	0,05283 5,283 %	174,76 s ~2,9min
$i=60$ (1075,3 s)	0,007508 0,75%	24,83 s	0,04148 4,148%	137,19 s ~2,28min	

Caso 4: A melhoria mais significativa é em relação ao cálculo da variável de estado α_4 , que se refere ao caso 4. Ao reavaliar as características do sistema de aplicação (bateria) e aprimorar o método de cálculo desse parâmetro, sabendo este é o que mais afeta a tensão do sistema foi possível obter uma menor variância nos pontos gerados, reduzindo a dispersão da pdf gerada, melhorando a precisão do algoritmo ao prever o tempo que atinge o *threshold* da tensão. No entanto, essa melhoria não deveria ser avaliada separadamente, pois depende dos valores do estado de carga que também foi aprimorado. Por esse motivo o caso 4, foi dividido em 4a e 4b, onde 4b é a análise das melhorias em relação ao SOC e do parâmetro α_4 unificadas. Se analisarmos separadamente, conforme Figura 7.10 veremos que os valores preditos voltam a ser após a falência do sistema e não há ganhos em relação a acurácia. Mas se avaliarmos a melhoria no parâmetro α_4 , e no estado de carga esse problema deixa de existir, conforme observado pela Figura 7.11 que representa o caso 4b. É possível observar pela Tabela 7.5 que as melhorias no algoritmo resultam em ganho na acurácia da predição. Os valores preditos ficam quase imperceptíveis pelas cores das fdps, devidos à pouca variabilidade das medidas. Estas podem ser visualizadas melhor com a Figura 7.12. O ponto de $i=60$, conforme Tabela 7.5 e Figura 7.11 e 7.12, perde acurácia; e, após este ponto, o algoritmo volta a convergir para o ponto real diminuindo o erro.

Figura 7.10: Resultado após a implementação de melhorias do Caso 4a, para $i = 20$, 40 e 60.




Figura 7.11: Resultado após a implementação de melhorias do Caso 4b, para $i = 20$, 40 e 60.




Figura 7.12: Detalhe do resultado após a implementação de melhorias do Caso 4b para $i = 20, 40$ e 60 .




Tabela 7.5: Erro relativo, Caso 4b.

Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo	MAD	Erro relativo	MAD
		Predição sem melhoria	Predição sem melhoria	Melhorias 2 e 3	Melhorias 2 e 3
i=20 (344,54 s)		0,07934	262,46 s	0,003387	112,05 s
		7,93%	~ 4,37min	3,3875 %	1,8675 min
i=40 (708,9 s)		0,02165	71,64 s	0,004423	14,63 s
		2,16%	~1,19min	0,4423 %	
i=60 (1075,3 s)		0,007508	24,83 s	0,001959	6,48 s
		0,75%		0,1959 %	

Caso 5: O Caso 5 se refere à junção das melhorias 1, 4 e 5. Essas melhorias, quando unificadas, mantem o ganho em precisão, com baixa dispersão (σ) e aumento na acurácia (μ), podem ser visualizadas na Figura 7.13. Ao avaliar a Tabela 7.6, é possível mensurar os ganhos com acurácia comparados com o algoritmo sem a implementação das melhorias e constatar que houve melhoras. Verificamos que a melhoria de acurácia e precisão é mantida. O resultado das predições é mais conservador, ocorrendo normalmente antes do valor real, favorecendo as tomadas de decisões.

Figura 7.13: Resultado após a implementação de melhorias do Caso 5.




Tabela 7.6: Erro relativo, Caso 5.

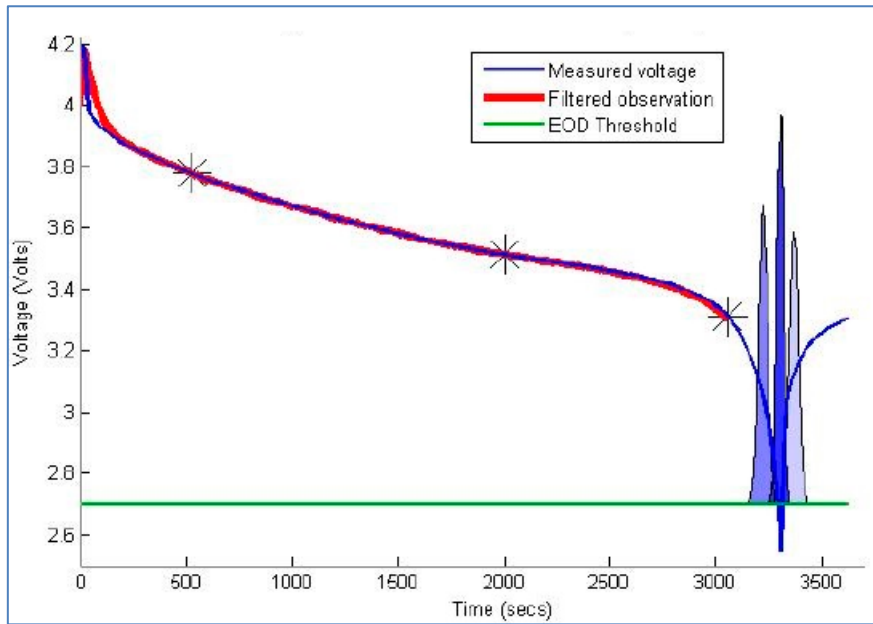
Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo Predição sem melhoria	MAD Ação Predição sem melhoria	Erro relativo Melhoria 1, 2 e 3	MAD Melhoria 1 2 e 3
	i=20 (344,54 s)	0,07934 7,93%	262,46 s ~ 4,37min	0,003387 3,38 %	112,04 s 1,867 min
	i=40 (708,9 s)	0,02165 2,16%	71,64 s ~1,19min	0,00442 0,442 %	14,62 s
	i=60 (1075,3 s)	0,007508 0,75%	24,83 s	0,001958 0,1958 %	6,47 s

Caso 6: A análise do caso 6 se refere aos tempos $i = 30, 120$ e 165 , considerados na Figura 7.15 para comparar com a predição feita na Figura 13 de Arachchige et al (2017) e refeita na Figura 7.14. Os valores da Tabela 7.7 foram estimados para estes tempos i (30, 120 e 165) com e sem melhorias e comparados para verificar a acurácia do algoritmo gerado. A predição gerada pelo algoritmo sem melhorias com sua variabilidade cobre um intervalo maior de possibilidades de ocorrência da falha.

Tabela 7.7: Erro relativo, Caso 6.


Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo Predição sem melhoria	MAD Ação Predição sem melhoria	Erro relativo	MAD
	i=30 (~500s)	0,03245 3,24%	107,32 s	0,020146 2,01%	65,32 s
	i=120 (~2000s)	0,0138815 1,38%	45,92 s	0,004377 0,43%	14,5 s
	i=165 (~3100s)	0,00751 0,751%	24,84 s	0,006655 0,66%	22,16 s

Figura 7.14: Predições da referência sem melhorias para i=30,120 e 165.



Fonte: Arachchige et al (2017).

Figura 7.15: Predições i=30,120 e 165 com melhorias do Caso 6.



Caso 7: O Caso 7 avalia a junção das melhorias de 1 a 5. Ele foi escolhido para verificar a acurácia em um ciclo de descarga do início e do fim do ciclo de vida da célula de bateria. Para o ciclo inicial foi mantido o ciclo 5, já avaliado para as outras melhorias; e, para o ciclo final, foi escolhido o último ciclo de descarga para os tempos $i=20, 80$ e 120 . As Figuras 7.16 e 7.17 ilustram as predições nos tempos indicados e a Tabela 7.8 aponta os Erros Relativo e Absoluto das predições realizadas em comparação ao algoritmo sem melhorias.

As quatro melhorias do algoritmo visam uma melhora na acurácia e precisão de aplicações em tempo real, e mesmo comparado com o algoritmo para operar *off-line* apresentou melhora na acurácia.

Tabela 7.8: Erro relativo, Caso 7 para BAT (B0005).

Ciclo 5 de descarga da Bateria B0005	400 partículas	Erro relativo		MAD Ação Predição sem melhoria	MAD Melhoria 1,2,3 e4
		Predição sem melhoria	Erro relativo Melhoria 1,2,3 e4		
Ciclo 5 de descarga da Bateria B0005	$i=20$ (344,54 s)	0,07934 7,93%	262,46 s ~ 4,37min	0,046313 4,63%	146,41 s
	$i=40$ (708,9 s)	0,02165 2,16%	71,64 s ~1,19min	0,01536 1,53%	50,04 s
	$i=60$ (1075,3 s)	0,007508 0,75%	24,83 s	0,00345 0,34%	11,44 s
Último ciclo de descarga da Bateria B0005	$i=20$ (178,84 s)	0,081565 8,15%	194,45 s	0,044171 4,4171%	100,85 s
	$i=80$ (740,9 s)	0,01848 1,84%	44,05 s	0,00567 0,567%	13,43 s
	$i=120$ (1115,6 s)	0,02995 2,99%	71,41 s	0,002146 0,214%	5,128 s

Figura 7.16: Resultado da análise do Caso 7 para BAT B0005 (ciclo 5).





Figura 7.17: Resultado da análise do Caso 7 no último ciclo de descarga, para BAT B0005.



Caso 8: As Figuras 7.18 e 7.19 apresentam as estimativas de EOD para a célula de bateria B0030, se referem ao caso 8 da Tabela 7.1. A Tabela 7.9 apresenta os Erros Relativos e Absolutos para cada predição. As predições mostradas nas Figuras 7.18 e 7.19, assim como em todas as outras predições, estão na sequência da esquerda para a direita, a primeira pdf se refere ao primeiro ponto assim por diante.

Figura 7.18: Resultado da análise do Caso 8 no quinto ciclo de descarga para BAT B0030.




Figura 7.19: Resultado da análise do Caso 8 no penúltimo ciclo de descarga para BAT B0030.




Tabela 7.9: Erro relativo, Caso 8 para BAT (B0030).

	400 partículas	Erro relativo Predição sem melhoria	MAD Ação Predição sem melhoria	Erro relativo Melhoria 1,2,3 e4	MAD Melhoria 1,2,3 e4
Ciclo 5 de descarga da Bateria B0030	i=20 (182,29s)	0,09106	142,90 s	0,04002 - 4,0%	60,39 s
	i=40 (373,6s)	0,01481	23,23 s	0,00681 0,68%	10,61 s
	i=60 (564,7s)	0,007806	12,25 s	0,00482 - 0,48%	7,53 s
	i=80 (755,87s)	0,017065	26,78 s	0,000727 - 0,072 %	1,14 s
Penúltimo ciclo de descarga da Bateria B0030	i=20 (208,10s)	0,110985	154,73 s	0,0343 - 3,43%	47,33 s
	i=80 (867,20s)	0,006413	8,94 s	0,005687 - 0,56%	8,07 s
	i=120 (1306,3s)	0,021077	29,38 s	0,00533 - 0,53%	7,65 s

Caso 9: O caso 9, assim como o 8, tem o objetivo de mostrar que o algoritmo possui boa acurácia para outras células de bateria. As Figuras 7.20 e 7.21 são aplicações à célula de bateria B0007, para o ciclo de descarga (10) e o último ciclo, respectivamente. As Figuras 7.22 e 7.24 são aplicações do algoritmo para a célula de bateria B0018, para o ciclo inicial (4) e para o último ciclo, respectivamente. As Tabela 7.10 e 7.11 apresentam os Erros Relativos e Absolutos das predições de B0007 e B0018. É possível observar pela Tabela 7.10 que a estimativa da RUL sem melhorias para o ponto $i=60$ do último ciclo da célula B0007 é um pouco melhor que a estimativa do algoritmo inovado.

A análise dos Erros Absolutos e Relativos das predições, assim como alguns dos gráficos como, por exemplo, pode ser visualizada na Tabela 7.11. Quando

o algoritmo faz previsões para pontos muito próximos do valor de falência, os erros tendem a aumentar um pouco. Este é um ponto que também ocorre com o algoritmo sem melhorias e pode ocorrer devido às flutuações e acúmulos de incertezas do filtro.

Figura 7.20: Resultado da análise do Caso 8 para a BAT B0007, no décimo ciclo de descarga.




Figura 7.21: Resultado da análise do Caso 8 para aBAT B0007, no último ciclo de descarga.




Tabela 7.10: Erro relativo, Caso 9 para BAT (B0007).

Ciclo 10 de descarga da Bateria B0007	400 partículas	Erro relativo Predição sem melhoria	MAD Ação Predição sem melhoria	Erro relativo Melhoria 1,2,3 e4	MAD Melhoria 1,2,3 e4
	i=20 (344,42 s)	0,091214	311,0 s	0,044986	146,78 s
	i=40 (727,06 s)	0,030904	105,37 s	0,013814	46,46 s
	i=60 (1075,20 s)	0,011986	40,87 s	0,00711	24,07 s
	i=80 (1444,3 s)	0,003838	13,09 s	0,006313	21,39 s
	i=120 (2191,9 s)	0,00566	19,31 s	0,003901	13,25 s

Figura 7.22: Resultado da análise do Caso 8 para a BAT B0018, no quarto ciclo de descarga.




Figura 7.23: Resultado da análise do Caso 8 para a BAT B0018, no último ciclo de descarga.




Tabela 7.11: Erro relativo, Caso 9 para BAT (B0018).

	400 partículas	Erro relativo Predição sem melhoria	MAD Ação Predição sem melhoria	Erro relativo Melhoria 1,2,3 e4	MAD Melhoria 1,2,3 e4
Ciclo 4 de descarga da Bateria B0018	i=20 (182,75 s)	0,075448	248,68 s	0,045203	142,55 s
	i=40 (384,18 s)	0,009688	31,93 s	0,023754	76,48 s
	i=60 (566,32 s)	0,00559	18,42 s	0,009494	31,00 s
	i=200 (1909,2 s)	0,02021	66,63 s	0,002	6,60 s
	i=300 (2868,7s)	0,00553	18,22 s	0,00374	12,38 s
Último ciclo de descarga da Bateria B0018	i=20 (256,71 s)	0,0619	149,75 s	0,050107	116,67 s
	i=40 (530,10 s)	0,0044	10,65 s	0,014552	35,07 s
	i=60 (806,45 s)	0,0123	29,92 s	0,003546	8,64 s

Caso 10: Este caso salienta que o algoritmo melhorado é capaz de fazer predições nos tempos iniciais como, por exemplo, após 4 iterações de tempo (~1min), o que o algoritmo sem melhorias não faz bem: dependendo da célula, este pode dar erro e não fazer as predições, devido às aproximações que utiliza. As Figuras 7.25 e 7.26, mostram os resultados de predições feitas para $i=4$, 8 e 12 unidades de tempo que equivalem para a bateria B0005 em 28,9 s, 66,3 s e 103,8 s e para a bateria B0030 29,26s, 67,56s e 105,75s. A Tabela 7.12 apresenta valores de erros que se referente da diferença entre o valor real e a média dos valores preditos.

As Figuras 7.25 e 7.26 mostram que a cada ponto ($i=4$, 8, 12) os valores preditos pela pdf se aproximam do valor real, como acontecem em pontos que acumulam mais valores de dados como é demonstrado nos outros casos ($i=20,40, 60$, etc).

Figura 7.24: Resultado do algoritmo original aplicado para BAT B0030 nos tempos iniciais.




Figura 7.25: Resultado do algoritmo inovado aplicado para BAT B0030 nos tempos iniciais.




Tabela 7.12: Erro para o Caso 10 para BAT B0005 e B0018.

Ciclo 5 de descarga da Bateria B0005			Ciclo 5 de descarga da Bateria B0030		
400 partículas	Sem Melhorias	Com melhorias	400 partículas	Sem Melhorias	Com melhorias
Tempo i	Real - Predito	Real - Predito	Tempo i	Valor Real - Predito	Valor Real - Predito
i=4 (53,85 s)	-1323,0326 s ~22min	1203 s ~20min	i=4 (29,26 s)	-900,04 s ~15min	557,979 s ~9min
i= 8 (144,62 s)	-1380,9 s ~23min	459,406 s ~7,6min	i= 8 (67,56 s)	-713,608 s ~11,89min	193,236 s ~3,2min
i=12 (199,28 s)	-611,1562 s ~10min	263,08 s ~4,38min	i=12 (105,75 s)	-327,93 s	109,334 s ~1,822min

7.3.2 2ª. Avaliação e Comparação (AC2): usando o número de partículas, a acurácia e precisão, e a carga computacional

De uma forma geral o número de amostras (partículas) utilizadas nos métodos de filtragem, em especial no Filtro de Partículas está diretamente relacionado com a carga computacional, e com a acurácia e precisão da técnica. Como já mencionado no método SIS, com um maior número de amostras, a representação de Monte Carlo torna-se um modelo aproximado da função densidade de probabilidade *a posteriori* desejada, e o resultado apresentado pelo filtro SIS se aproxima da estimativa Bayesiana ótima. No entanto, com o problema da degeneração, existem outros filtros auxiliares que podem ser utilizados como, por exemplo, o SIR, que foi empregado neste trabalho e o ASIR (*Auxiliary Sampling Importance Resampling*) (ARULAMPALAM, 2002).

Alguns trabalhos que utilizaram o PF (HOFFMANN, 2017; SILVA, 2012; LUCUMI, 2015; CARVALHO, 2018) demonstraram que, à medida que aumenta o número de partículas, o erro diminui, aumentando a acurácia das predições, independentemente do filtro auxiliar utilizado. Este comportamento já era esperado pois a convergência destes métodos é garantida pelo Teorema dos Grandes Números; ou seja, quanto maior for o número de partículas, maior será a probabilidade de convergir.

O número de partículas versus acurácia e precisão é um grande desafio para as ações empregadas, uma vez que se busca o equilíbrio entre acurácia e precisão, e a carga computacional. No entanto, o aprimoramento do modelo de EOD resultou em baixa carga computacional, sendo possível reduzir o número de partículas mantendo a acurácia e precisão, como mostra a Tabela 7.12. Com um menor número de partículas a dispersão da PDF aumenta, como pode ser visualizado nas Figuras 7.26, 7.27 e 7.28.

Em Estatística, à medida que se aumenta o número de amostras ($n=N_s$) a média amostral (m) converge para a média populacional (μ), onde m tem uma dispersão em torno de μ . O desvio padrão amostral (s) converge para o desvio padrão populacional dividido pela raiz de n (Equação 7.31), o que significa que a dispersão (s) da amostra é reduzida com \sqrt{n} (BALESTRASSI, 2007). É mais uma demonstração de que quanto maior o número de amostras ($n=N_s$), maior tende ser a acurácia e menor o desvio ou a dispersão em torno da média. Ou seja, quando reduzimos o número de partículas de 400 para 100, por exemplo, reduzimos as partículas em 4x, mas com isso o desvio padrão é aumentado em apenas 2x:

$$s^2 = \frac{\sigma^2}{n} \quad \text{ou} \quad s = \frac{\sigma}{\sqrt{n}} \quad (7.31)$$

Enfatizamos que as melhorias implementadas no modelo o tornam mais fiel às características da aplicação e o facilita para operar *on-line* e até em tempo real. Em aplicações *on-line*, a baixa carga computacional é um requisito. Desta forma, a redução do número partículas compensando a acurácia e a precisão é um grande ganho, pois quanto maior o número de partículas maior o tempo computacional, uso de memórias etc. Isto é confirmado pelo que se segue:

Figura 7.26: Predição com 100 partículas.




Figura 7.27: Predição com 20 partículas.




Figura 7.28: Predição com 20 partículas no detalhe.




Tabela 7.13: Erro Absoluto para diferentes números de partículas.

Ciclo 5 de descarga da Bateria B0005	partículas	400	100	20
	Tempo i	MAD Melhoria 1,2,3 e4	MAD Melhoria 1,2,3 e4	MAD Melhoria 1,2,3 e4
i=20 (344,54 s)		146,41 s	146,41 s	146,41 s
i=40 (708,9 s)		50,04 s	50,04 s	50,04 s
i=60 (1075,3 s)		11,44 s	11,44 s	11,44 s

Segundo Daum (2003), o principal problema do PF é a grande complexidade (aqui = carga) computacional. Filtros não lineares de qualquer tipo sofrem com a "maldição da dimensionalidade", por exemplo, a complexidade computacional do filtro de Kalman cresce como o cubo de dimensão; mas, para problemas

não lineares gerais, usando filtros que alcançam a precisão ideal, a complexidade computacional aumenta exponencialmente com a dimensão.

Daum (2003) afirma que muitos trabalhos vêm publicando que o FP não sofre com a "maldição da dimensionalidade", o que não é verdade. Mas, em: aplicações com baixa dimensão, filtros bem projetados e modelos fiéis, a aplicação podem alcançar boa acurácia.

Daum (2003) deriva uma fórmula que explica por que um PF cuidadosamente projetado deve mitigar a "maldição da dimensionalidade" para certos problemas de filtragem. Essa estimativa usa a Equação (7.31), considerando que a classe de problemas de estimação de interesse tem uma densidade condicional de x que é vagamente gaussiana, mas não necessariamente gaussiana.

Segundo Daum (2002), isso significa que a maior parte do volume do espaço de estados com probabilidade significativa é limitada por contornos elípticos. Esses contornos elípticos podem ser transformados em contornos esféricos sem perder a generalidade. Agora, supondo que o volume significativo no espaço de estados seja limitado por contornos k esféricos, ou seja, estamos trabalhando com uma esfera d -dimensional com raio $k\sigma$. Para dimensões d grandes, usando a aproximação de Stirling para $n!$ e a fórmula para o volume de uma esfera d -dimensional, Daum descobriu que o número de pontos da amostra de Monte Carlo neste volume esférico é descrito aproximadamente pela Equação (7.32).

$$n = c_1(2k\sigma)^d d^{-(d+1)/2} 2^d \quad (7.32)$$

Após combinar a Equação (7.31) o número de amostras n e a variância amostral s^2 com esta aproximação geométrica (Equação 7.32), o número de pontos da amostra de Monte Carlo é:

$$n = \frac{c_2 d}{Sk^2} \quad (7.33)$$

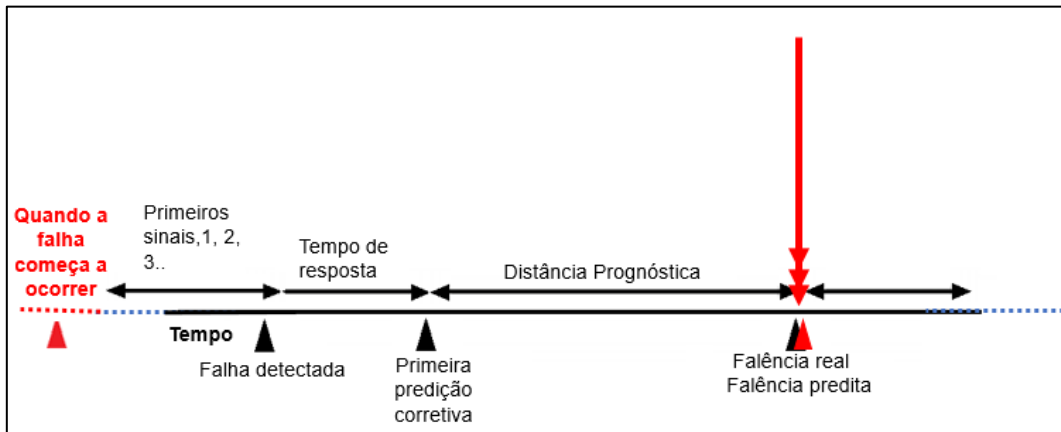
A complexidade computacional dos métodos de PF (que de alguma forma evitam o esgotamento de partículas e que conseguem amostrar com eficiência a densidade condicional) para esta classe de problemas “vagamente gaussianos” com dimensão d deve ser aproximadamente descrita pela Equação (7.34).

$$\frac{c_3 d^{\alpha+1}}{sk^2} \quad (7.34)$$

7.3.3 3ª. Avaliação e Comparação (AC3): usando a acurácia e precisão, a distância prognóstica e o tempo de resposta

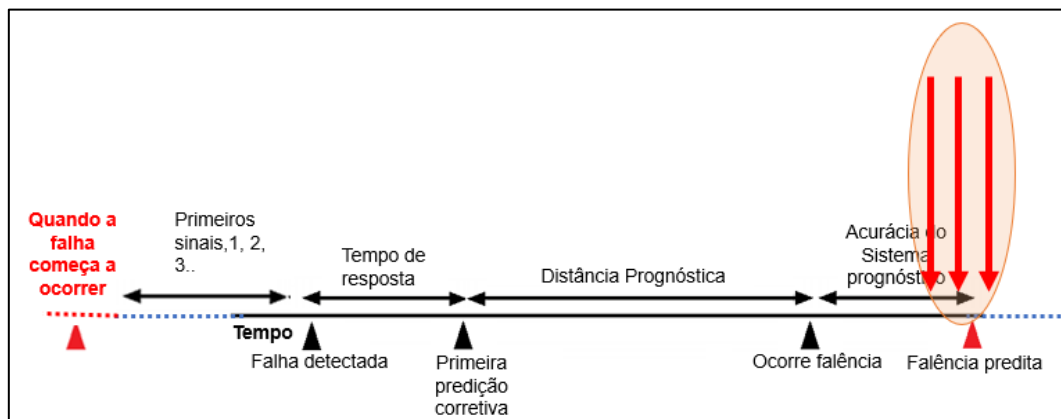
Conforme a Seção 2.5.3, especialmente as Figuras 2.11 e 2.12, as métricas enfatizadas pela IEEE Std 1856 (2017) podem ser resumidas pelas Figuras 7.29 e 7.30. Algumas dessas medidas serão utilizadas para a avaliação do algoritmo deste trabalho. Como o algoritmo não faz o diagnóstico, algumas medidas não se aplicam, como: o tempo em que detecta uma mudança de comportamento podendo ser considerado o ponto de falha detectada e o tempo de resposta, se este se referir ao quão rápido após detectar a falha faz uma predição. As medidas que podem se aplicar são a acurácia e precisão, a distância prognóstica e o tempo de resposta, se este se referir à medida da rapidez com que a função prognóstica produz uma saída. Esses fatores são analisados de uma forma geral, com base nos testes de predições feitos com o algoritmo.

Figura 7.29: Ciclo do prognóstico enfatizando a acurácia.



Fonte: Adaptado de IEEE (2017).

Figura 7.30: Ciclo do prognóstico enfatizando a precisão.



Fonte: Adaptado de IEEE (2017).


Acurácia e precisão: Os Erros Relativos e Absolutos das predições de fim de descarga foram utilizados para avaliar a acurácia e a precisão das predições ao longo do tempo, conforme as Figuras 2.11 e 2.12. Pode-se dizer que: 1) a acurácia melhorou para todos os testes realizados, reduzindo os erros, ou seja, o tempo estimado de EOD se aproximou mais do valor real; 2) a precisão da estimativa de EOD no tempo i melhorou após as implementações resultando em baixa dispersão (σ) da fdp. A acurácia de uma predição é apresentada graficamente na Figura 7.31: o traço amarelo representa a acurácia da primeira predição de EOD no tempo $i = 20$ (~ no tempo de 3min). Como a acurácia e a

precisão das previsões aumentou, foi possível reduzir o número de partículas das aplicações reduzindo o custo computacional.

Horizonte de previsão: O horizonte das previsões (distância prognóstica) indica que houve melhoras, quando observadas nas aplicações do algoritmo, de uma forma geral. Nos tempos iniciais, as previsões passaram a ser mais conservadoras, sendo propagadas para tempos anteriores à falência, mas com maior acurácia. Isso pode auxiliar a implementar uma decisão e resposta acionáveis, como parte da atividade de gerenciamento de saúde do sistema. Isto é apresentado na Figura 7.30, que mostra a distância prognóstica, representada pela base do triângulo em verde, das previsões para os tempos $i= 20$ (~3min) e $i= 40$ (~6 min) para a Bateria B0018 no quarto ciclo de descarga.

Tempo de resposta da previsão: aqui será considerado como o tempo em que as previsões podem levar para retornar um resultado. Para 400 partículas, o tempo é de aproximadamente 1,2 s e para 4000 partículas 15 s. Esses valores podem variar de acordo com o computador utilizado.

Figura 7.31: Distância prognóstica e acurácia.



7.3.4 Evolução dos estados com as melhorias

O parâmetro α_4 é o que mais influi na descarga; conseqüentemente, o que mais afeta a predição de EOD. Com o aprimoramento do cálculo de α_4 , buscamos avaliar a evolução dos parâmetros do modelo de EOD, os alfas ($\alpha_1, \alpha_2, \alpha_3, \alpha_4$ e α_5). Essa evolução é demonstrada nas Figuras 7.32 a 7.37, mostrando a evolução das pdfs dos parâmetros com o tempo antes e após as melhorias. Cada pdf de cada parâmetro do vetor de estado recebe todos os Ns valores respectivos das partículas ao longo do tempo e as figuras mostram como os valores mudam com o tempo.

O parâmetro α_4 era um dos parâmetros que mais se alterava, ao longo das iterações, conforme mostra a Figura 7.35. Após o refinamento do cálculo de SOC e de α_4 , onde o valor real da corrente I_i é considerado, α_4 passou a ser um dos parâmetros que menos possui variação, como mostra a Figura 7.36. A baixa dispersão na estimativa de α_4 ao longo das iterações resulta em melhor acurácia e precisão, i.e., menor média (μ) e desvio padrão (σ) nos erros, o que pode gerar um menor custo computacional, sendo necessário avaliar as estimativas em relação à massa de probabilidade necessária para o PF.

Figura 7.32: Evolução do α_1 a) antes das melhorias e b) após.

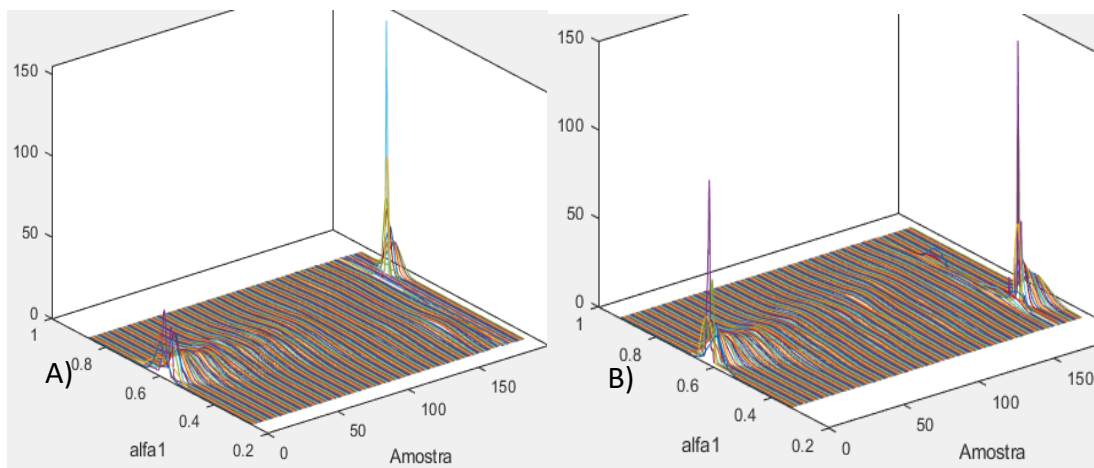


Figura 7.33: Evolução do α_2 a) antes das melhorias e b) após

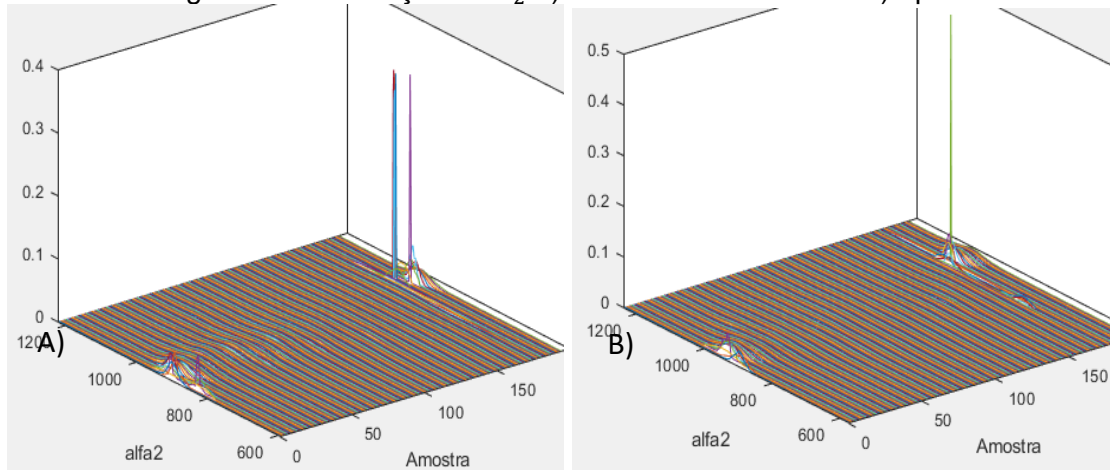


Figura 7.34: Evolução do α_3 a) antes das melhorias e b) após.

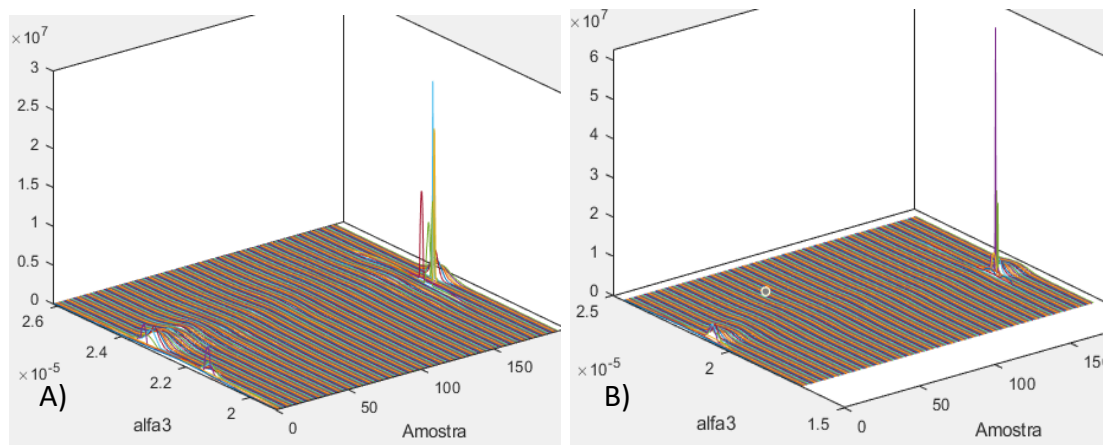


Figura 7.35: Evolução do α_4 antes das melhorias.




Figura 7.36: Evolução do α_4 após as melhorias.





Figura 7.37: Evolução do α_5 a) antes das melhorias e b) após.



7.4 Melhorias e Inovações na convergência e nas previsões de EOL

O processo de convergência dos algoritmos utilizados por Saha e Goebel (2009) e Arachchige et al (2017) não é discutido nos artigos. Supomos que o modelo de evolução de estado f (Equação 4.1) e o modelo de medição h (Equação 4.2) são de natureza estacionária com distribuições de ruído conhecidas w e v , respectivamente; e algumas das variáveis de estado são parâmetros desconhecidos com algumas flutuações. Isto sugere a:

7.4.1 6ª. Aproximação/Explicação (MI6): na capacidade de descarga inicial Q_0 , na convergência inicial e nas predições de EOL

Tal processo é inicialmente afetado por:

1) Se a aproximação inicial de Q_0 estiver longe do valor real e o desvio padrão for pequeno, o filtro pode realizar muitas etapas para então convergir, isso se convergir. O valor do desvio padrão pode ser aumentado visando cobrir um espaço de estados maior, mas isso também pode atrasar a convergência. Melhorando a convergência do algoritmo, a predição da RUL também pode ser afetada, recebendo também um fator de melhoria. Portanto, o processo de convergência é afetado diretamente pela falha nos **valores das condições iniciais**.

2) Sabe-se que a falha conhecida como Descarga na Prateleira ou ainda como Auto Descarga é causada por processos eletroquímicos dentro da célula e é equivalente à aplicação de uma pequena descarga externa, o que faz com que ela perca carga elétrica mesmo estando parada. Isso pode gerar impactos no valor da capacidade de carga nominal Q_{nom} . O que faz com que a bateria inicie com uma carga nominal aproximada mas menor do que a especificada. Portanto, o processo de convergência é afetado diretamente pela falha conhecida como **Descarga na Prateleira**, do Inglês ("*Battery Cell Shelf Discharge*").

Ambas as falhas podem contribuir para a redução da capacidade de carga da bateria. Isto foi analisado e melhorado no modelo EOL, como se segue:

6ª. Melhoria/Inovação (MI6): na capacidade de descarga inicial Q_0 , na convergência inicial e nas predições de EOL

A capacidade de descarga nominal Q_{nom} da bateria utilizada para implementar o algoritmo é um valor conhecido e utilizado como condição inicial no modelo EOL; mas, ao analisar os gráficos resultantes das aplicações, é perceptível que a capacidade de descarga inicial Q_0 medida é sempre inferior ao valor da

capacidade de descarga nominal Q_{nom} . Tal fato é apresentado nas Figuras (7.38) e (7.39), onde os dados da bateria B0005 e B0030 são utilizados para uma estimativa; e são necessários 2 ciclos de descarga completos [t_k ; t_{k+1}] para que haja a convergência.

Figura 7.38: Estimativa de EOL usando o modelo EOL sem modificações (B0005).

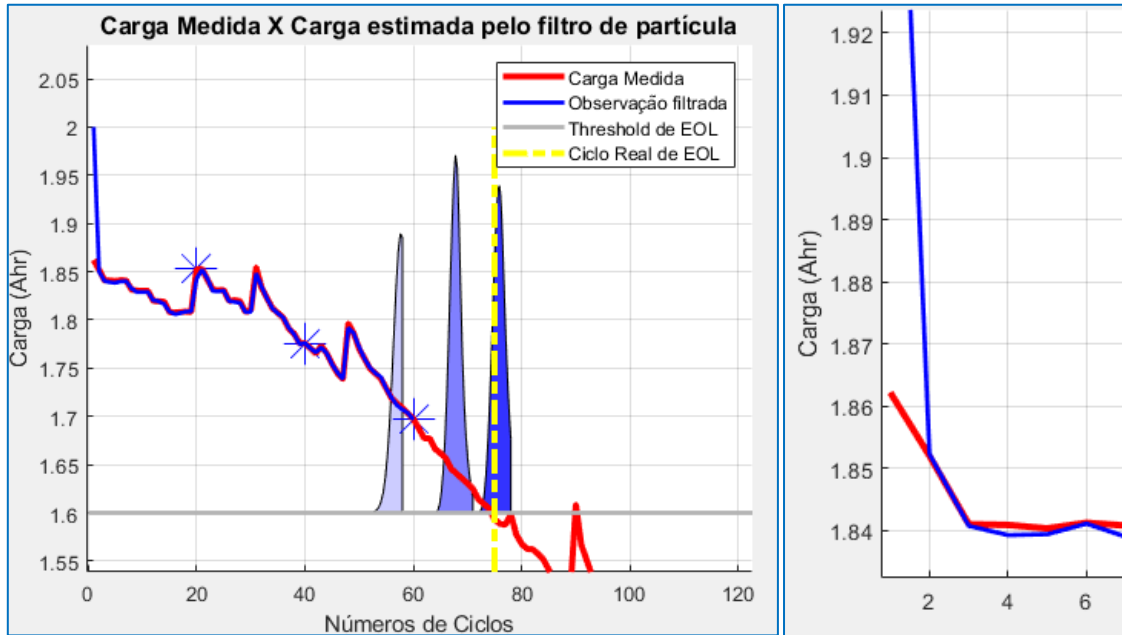
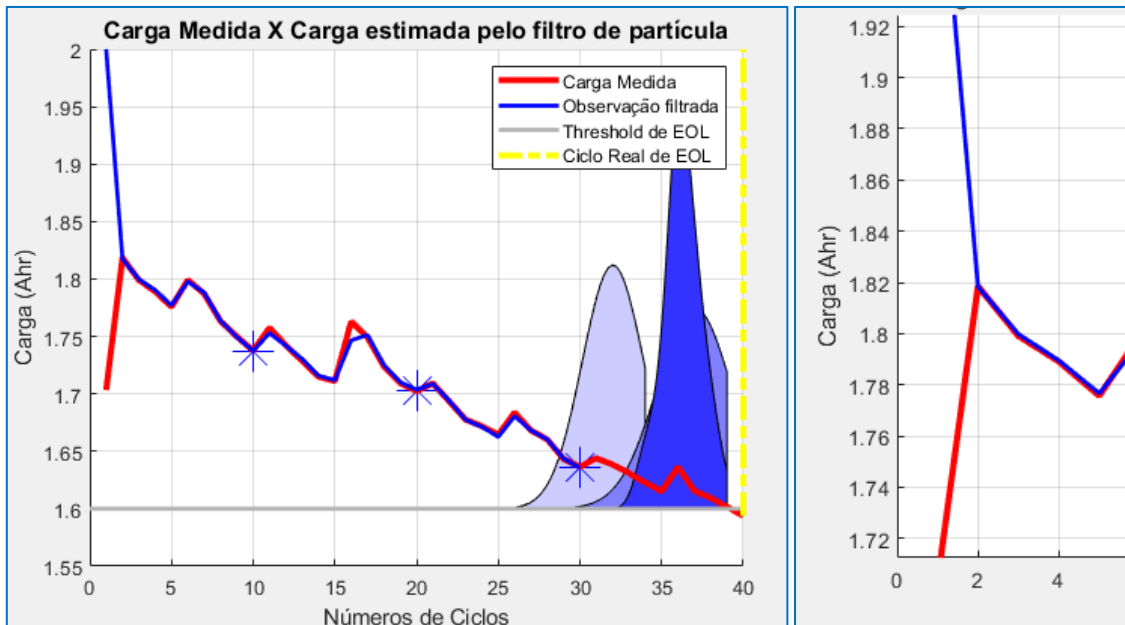


Figura 7.39: Estimativa de EOL usando o modelo EOL sem modificações (B0030).



Considerando a bateria como um capacitor e a lei das malhas de Kirchoff aplicada ao circuito de carga, temos a Equação (7.35). **propõe-se calcular a capacidade de descarga inicial pela soma do valor de carga final Q_1 com o produto do módulo da corrente média I_m pelo tempo médio Δt_m dos valores do primeiro ciclo de descarga [t_0 ; t_1] :**

$$Q(t_1) = \int_{t_0}^{t_1} I(\tau) d\tau + Q(t_0), I(\tau) < 0 \quad (7.35)$$

$$Q_0 \approx I_m \Delta t_m + Q_1$$

Onde I_m é o módulo da corrente média e Δt_m o intervalo de tempo médio, ambos ao longo do primeiro ciclo de descarga. Para o cálculo foi utilizado a regra do trapézio utilizada para o modelo EOD.

A aproximação do valor de Q_n . é suficiente para melhorar o processo de convergência do algoritmo, como mostram as Figuras (7.40) e (7.41) que se referem à convergência antes e após a implementação da correção de Q_n para a célula de bateria B0005. A Figura (7.42) mostra as estimativas de EOL e ilustra essa convergência, se comparada com a Figura (7.38) que mostra as mesmas estimativas antes de aplicar a melhoria. Naquela, é possível perceber que também houve melhoras nas estimativas de EOL.

Figura 7.40: Convergência do algoritmo antes de correção de Q_n .

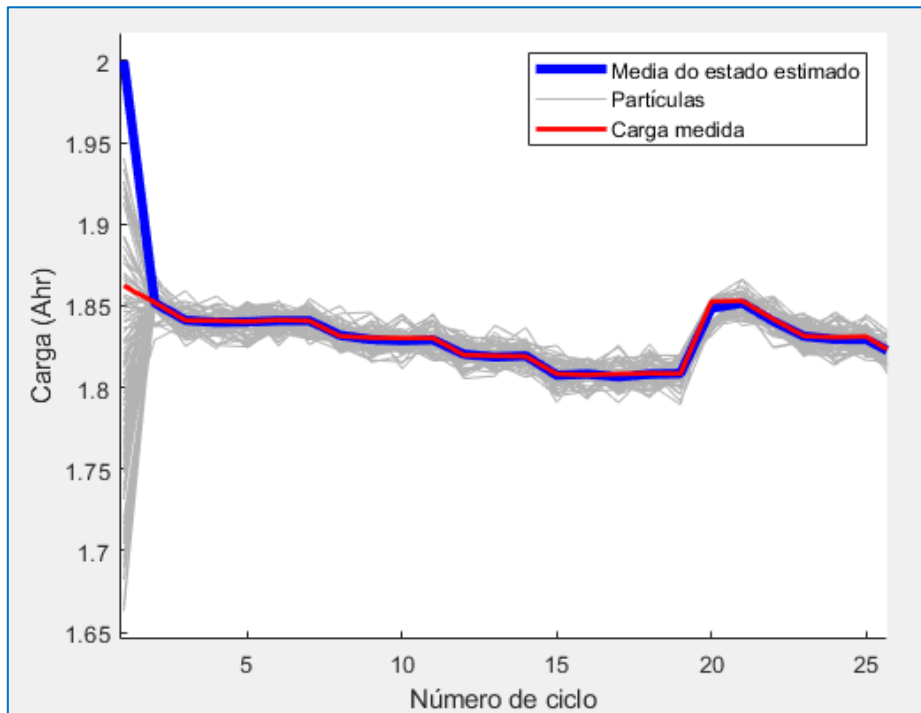


Figura 7.41: Convergência do algoritmo após correção de Q_n .


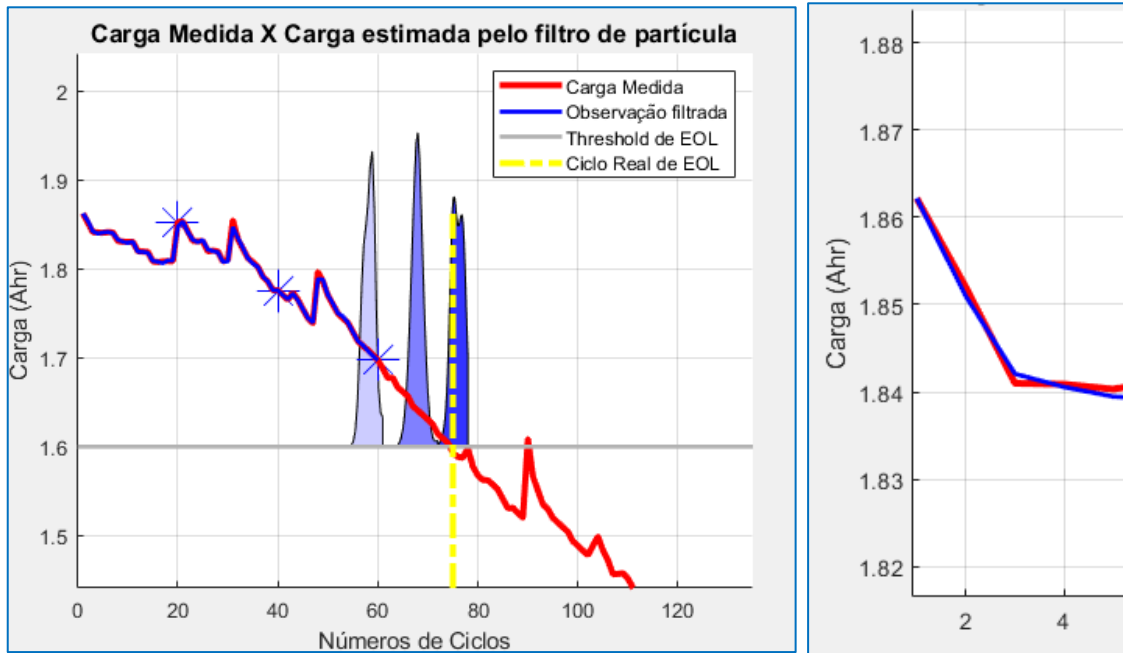


Figura 7.42: Estimativa de EOL usando o modelo EOL com correção de Q_n .



8 CONCLUSÕES

Este trabalho estudou, detalhou e inovou modelos M2 e M3 de carga e descarga e algoritmos por filtro de partículas para a predição de falhas (EOD, EOL, RUL) em baterias de Lítio-Íon usáveis em satélites artificiais. Como um resultado teórico foi obtido: 1) um conjunto revisado da literatura recente sobre as abordagens, métodos e algoritmos voltados ao Prognóstico de Falhas; 2) uma seleção dos métodos, repertório de falhas e caracterização de algumas falhas de baterias; 3) um levantamento dos conjuntos de métricas para avaliação e desempenho de algoritmos de prognóstico.

Como um resultado prático foi obtido o detalhamento dos modelos M2 e M3 de carga e descarga e incorporadas melhorias no modelo M4. O aprimoramento do modelo M4 resultou em melhor acurácia e precisão no modo *off-line*.

Uma das melhorias empregadas facilita a aplicação do algoritmo de M4 no modo *on-line*. A alteração para o modo *on-line* manteve boa acurácia e precisão; e o aprimoramento do modelo permitiu diminuir o número de partículas do método resultando na redução da complexidade, memória e tempo de resposta após acionar a estimativa, ou seja, teve um ganho computacional. Estes e outros ganhos devem ser considerados seriamente, pois sistemas embarcados tem várias restrições, em especial as que envolvem complexidade e custo computacional.

As predições após as melhorias passaram a ser mais conservadoras, o que é um ganho na perspectiva de acionar uma decisão pois, se a medida estimada ocorrer antes da falência real, é possível tomar decisões e ações necessárias para manter a função do sistema. Como o sistema de aplicação é em baterias, cargas podem ser reduzidas a fim de retardar o fim de descarga em situações críticas.

8.1 Principais dificuldades encontradas

No decorrer deste trabalho foram encontradas inúmeras dificuldades. Algumas delas serão destacadas.

O foco deste estudo, a abordagem prognóstica, é um assunto que não está bem fundamentado; seu processo de normalização está em andamento buscando acompanhar a evolução e resultados da literatura. Como reflexo disto, não há padronização nos trabalhos publicados, há termos e simbologias diferentes em diversos estudos e livros, muitas vezes até interpretações e considerações que divergem de um estudo a outro. Este é um ponto que dificulta a compreensão de conceitos, necessitando muito cuidado e pesquisa para reunir e concatenar as informações. Diversos trabalhos vêm sendo publicados; prognóstico é um assunto vasto, como mostra a Figura 3.1.

Sabe-se que bancos de dados são custosos, demandam tempo, dinheiro, mão de obra especializada, etc.; e, devido a esses e outros fatores, dificilmente são disponibilizados. Além disso, o sucesso das aplicações que envolvem dados depende diretamente da confiabilidade dos dados. Por estes motivos, pode-se dizer que a busca por dados confiáveis de vida que progredissem para a falha/falência (de equipamentos/subsistema/sistema) que tivessem aplicações na área espacial foi uma verdadeira “caça ao tesouro”. É importante salientar que o sistema de aplicação do algoritmo de prognóstico influencia na complexidade da abordagem.

Existem vários pontos envolvendo os dados (testes), os modelos, os filtros, etc. que foram fontes de dúvidas, incertezas e pontos de aprofundamento e pesquisa, devido à falta de informação, detalhamento ou por não estar claro o que os trabalhos de referência realmente utilizaram ou adotaram dentro de uma variedade de opções e alternativas. Alguns deles são:

- 1- Alguns pontos do sistema de aplicação, condições na qual os testes foram feitos não são esclarecidos no repositório de dados ou pelos trabalhos que tratam esses dados como, por exemplo, o trabalho de Saha e Goebel (2009) e/ou o repositório não dizem como é tratado o tempo de repouso das baterias que proporciona a auto-recarga que é modelada para EOL e constatada nos gráficos de EOL.

- 2- O processo de convergência que é uma das características mais importantes de qualquer algoritmo não é ponto de discussão nas publicações que se referem à aplicação.
- 3- Na literatura há muitos trabalhos que aplicam o método de filtragem de partículas, como foi mencionado e referenciado nos capítulos anteriores deste trabalho. É evidente que o número de partículas adotado influencia na acurácia, precisão e na carga computacional. Um grande ganho deste trabalho se deve a obter resultados melhores neste sentido. No entanto, é um ponto pouco discutido ou mencionado nos trabalhos de referência.
- 4- O termo RUL (Vida Útil Remanescente) é aplicado tanto para EOL quanto para EOD, para o contexto de EOD o evento: “tempo em que a bateria atinge a tensão limite de descarga definido com o “*threshold*” estabelecido (2,7 V)”, deve ser considerado como o evento de falência, ou seja, o fim de vida do ciclo k de descarga. Este é um fato implícito: a consideração do evento falência deveria ser especificada para a aplicação; ou, neste contexto, sugerimos que poderia ser adaptada para Carga Útil Remanescente (*Remaining Useful Charge* - RUC).

8.2 Direções futuras:

Como mencionado e exemplificado pela Figura 3.1, este trabalho se relaciona com três grandes nichos de estudos: 1) Abordagens de Falhas focando em Prognóstico; 2) Métodos, Técnicas e Algoritmos de Filtros, sobretudo de Partículas; e 3) Modelos e Dados de Baterias, adotando uma abordagem híbrida. Estes nichos estão em ascensão na comunidade científica, seja pela complexidade e/ou alta integração para atender a missões cada vez mais exigentes, seja pela hostilidade dos ambientes de operação; ou ainda, pela propensão a falhas e a necessidade de controlá-las (monitorar, diagnosticar e prever). Estes nichos de estudos são extensos e há muito para pesquisar e estudar. Este trabalho deu margem a uma série de pontos que podem ser mais

explorados, e algumas linhas de pesquisa promissoras para a continuidade do trabalho, a saber:

- 1) Estudar as Equações (5.5) a (5.7), em especial a Equação (5.7) para avaliar os efeitos e possíveis valores de ΔE_{init} que depende da resistência eletrolítica ($\Delta E_{init} = IR_E$) a fim de viabilizar a utilização da equação exata (Equação 5.4 ou 5.8), substituindo a equação derivada (Proposta por Saha e Goebel (2009), Equação 6.6) pela equação da solução. Esta linha pode gerar um grande ganho em exatidão e acurácia ao modelo de EOD. Este seria mais um ponto de melhoria no modelo.
- 2) Ainda há possibilidade de melhorias nos modelos adotados como, por exemplo, incorporar as influências da temperatura. Esta linha necessita de uma investigação teórica e talvez experimental do comportamento da bateria. Quando medidas como as descritas em 1 e 2 são aprimoradas, é possível tirar melhor proveito de técnicas de filtragem avançadas, conforme o resultado este trabalho demonstra.
- 3) Aplicar outros métodos de filtragem ao modelo M4, iniciando com o filtro ASIR e podendo se estender a outros como, por exemplo, o filtro de Daum. Nesta linha, segundo Arulampalam (2002), o filtro ASIR pode ser caracterizado como o algoritmo do filtro SIR com uma reamostragem no instante de tempo anterior, baseada em algumas estimativas μ_k que caracterizam a função $p(x_k|x_{k-1})$; e, se o nível de ruído do processo for pequeno, pode resultar em uma estimativa melhor.
- 4) Estudo, levantamento e detalhamento dos métodos de reamostragem do Filtro de Partículas. Esta linha buscaria o aprimoramento e inovação da reamostragem utilizada neste trabalho.
- 5) Pensar no processo de predição como: 1) amostragem, 2) propagação e 3) estimativa da fdp: Esta linha buscaria estudar possibilidades e técnicas para implementar o método de modelar a fdp prefixando uma forma e ajustando os parâmetros para melhoria da estimativa e propagação. Esta linha melhoraria as estimativas da fdp a partir das

amostras. Para a estimativa da fdp podem ser adotadas n alternativas, inclusive:

- a. Modelar a fdp com uma forma pré-fixada, como por exemplo, a forma Weibull (com parâmetros conhecidos α , β e γ). Ou seja, modelá-la como uma distribuição Weibull e ajustar os parâmetros para a distribuição. Outro exemplo seria utilizar uma função exponencial (só tem um parâmetro conhecido α), supondo que no próximo passo ela continue uma exponencial com parâmetro diferente. Quando se especifica uma forma, é necessário garantir que as três propriedades da fdp sejam cumpridas (Equações 8.1, 8.2 e 8.3). Para isso, é necessário utilizar as propriedades para escolher os parâmetros, sabendo que a fdp deve ter suas propriedades cumpridas ($f_{dp}: \mathbb{R} \rightarrow [0, \infty)$), a saber:

$$f_{dp} \geq 0$$

$$\int_{-\infty}^{\infty} f_{dp}(\tau) d\tau = 1$$

$$P(a < t < b) = \int_a^b f_{dp}(\tau) d\tau$$

- b. Implementar o método de modelar fdp como séries, para a melhoria da estimativa e propagação. Esse caso é mais geral e flexível que o proposto em a). Pode ser utilizado: 1) série de potências, com coeficientes a determinar, opção que pode implicar em alta carga e erros computacionais devido às potências; 2) série de funções básicas, usando uma base de funções ortogonais: Fourier com senos e cossenos, etc.
- c. Implementar o método de modelar fdp como polinômios. Isto minora os problemas computacionais, mas piora a acurácia da estimativa da fdp.

REFERÊNCIAS BIBLIOGRÁFICAS

- AMOR-SEGAN, M.; JONES, R. P. A framework for health monitoring of automotive electrical and electronic control systems. In: IEEE VEHICULAR NETWORKING CONFERENCE (VNC), 2011. **Proceedings...** IEEE, 2011. Doi: 10.1109/VNC.2011.6117140.
- ARACHCHIGE, B.; PERINPANAYAGAM, S.; JARAS, R. Enhanced prognostic model for lithium ion batteries based on particle filter state transition model modification. **Applied Sciences**, v.7, n. 11, e1172, 2017.
- ARULAMPALAM, M. S. et al. A tutorial on particle filters for online nonlinear/non-gaussian bayesian tracking. **IEEE Transactions on Signal Processing**, v. 50, n. 2, 2002.
- ASENEK, V.; SWEETING, M.; WARD, J. **Reliability prediction and improvement of electronic systems on-board modern cost-effective microsatellites**. Disponível em: <http://ysc.sm.bmstu.ru/microsat/e-library/ccdh/radiation/apres.htm>. Acesso em: 11 abr. 2017.
- AVIZIENIS, A. et al. Basic concepts and taxonomy of dependable and secure computing. **IEEE Transactions on Dependable and Secure Computing**, v. 1, n. 1, p.1-23, 2004.
- BALESTRASSI, P. P.; PAIVA, A. P. **Estatística aplicada**. Itajubá: Universidade Federal de Itajubá, 2007. Notas de aula.
- BELMONTE, D.; DALLA VEDOVA, M. D. L.; MAGGIORE, P. New prognostic method based on spectral analysis techniques dealing with motor static eccentricity for aerospace electromechanical actuators. **WSEAS Transactions on Systems**, v.14, p.45-53, 2015.
- BOSH GMBH. **Mid Range Radar sensor (MRR)**. Disponível em: [https://www.bosch-mobility-solutions.com/en/products-and-services/passenger-cars-and-light-commercial-vehicles/driver-assistance-systems/predictive-emergency-braking-system/mid-range-radar-sensor\(mrr\)/](https://www.bosch-mobility-solutions.com/en/products-and-services/passenger-cars-and-light-commercial-vehicles/driver-assistance-systems/predictive-emergency-braking-system/mid-range-radar-sensor(mrr)/). Acesso em: 11 maio 2018.
- BOSH GMBH. **Predictive emergency braking system**. Disponível em: <https://www.bosch-mobility-solutions.com/en/products-and-services/passenger-cars-and-light-commercial-vehicles/driver-assistance-systems/predictive-emergency-braking-system/>. Acesso em: 11 maio 2018b.

BOTTONE, S.; LEE, D.; O'SULLIVAN, M.; SPIVACK, M. Failure prediction and diagnosis for satellite monitoring systems using bayesian networks. 2008. Disponível em: <https://pdfs.semanticscholar.org/1532/61dd7b4d011bc8c295efc42a77265d0c5120.pdf>. Acesso em: 9 nov. 2017.

BRONDANI, M. F. **Modelagem matemática do tempo de vida de baterias de lítio íon polímero utilizando algoritmos genéticos**. 2015. 114p. Dissertação (Mestrado em Modelagem Matemática) - Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Unijuí, 2015.

BUCHMANN, I. **Will Lithium-Ion batteries power the new millennium?** 2001. Disponível em: <http://www.buchmann.ca/Article5-Page1.asp>.

BUI, T. H. **Prognostic algorithm development for plant monitoring and maintenance planning**. 2015. 211 p. Tese (Doutorado em Engenharia Industrial) - Universidade do Tennessee, Knoxville, 2015.

CARDENUTO, N. C. **Aeronaves configuradas por controle do tipo preditivo neural**. 2003. 144 p. Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003. Disponível em: <http://urlib.net/sid.inpe.br/jeferson/2003/05.14.14.55>. Acesso em: 21 nov. 2017.

CARILLO, K. **In-orbit maintenance: the future of the satellite industry**. Toulouse: Toulouse Business School, 2016. 79p.

CARVALHO, R. N. S. **Estimação de parâmetros e estados via filtros bayesianos em um processo de adsorção de SO₄-2 em resinas de troca iônica**. 2018. 86p. Dissertação (Mestrado em Engenharia Química) - Universidade Federal do Espírito Santo, Vitória, .2018.

CHEN, Z. **Bayesian filtering: from Kalman filters to particle filters, and beyond**. 2003. 69p. Disponível em: <http://140.113.144.123/EnD106/Bayesian%20filtering-%20from%20Kalman%20filters%20to%20Particle%20filters%20and%20beyond.pdf>.

CHENG, S.; AZARIAN, M.; PECHT, M. Sensor system selection for prognostics and health monitoring. In: ASME INTERNATIONAL DESIGN ENGINEERING TECHNICAL CONFERENCES AND COMPUTERS AND INFORMATION IN ENGINEERING CONFERENCE, 2008. **Proceedings...** ASME, 2008. p.1383-1389. Doi: 10.1115/DETC2008-49907.

CHENG, S.; TOM, K.; THOMAS, L.; PECHT, M. A wireless sensor system for prognostics and health management. **IEEE Sensors Journal**, v.10, p.856-862, 2010.

CHUNHUA, Z.; HUA, S.; KAI, X. Fault prediction for satellite attitude control system based on fuzzy-parity equation and grey model. In: INTERNATIONAL CONFERENCE ON INSTRUMENTATION AND MEASUREMENT, COMPUTER, COMMUNICATION AND CONTROL, 5., 2015, Qinhuangdao, China. **Proceedings...** IEEE, 2015.

DAIGLE, M. J.; SAHA, B.; GOEBEL, K. A comparison of filter-based approaches for model-based prognostics. In: IEEE AEROSPACE CONFERENCE, 2012. **Proceedings...** IEEE, 2012.

DANHEL, M.; ŠTEPÁNEK, F.; KUBÁTOVÁ, H. The effect of the transient faults in dependability prediction. In: EUROMICRO CONFERENCE ON DIGITAL SYSTEM DESIGN, 2016, Limasso, Cyprus. **Proceedings...** IEEE, 2017.

DANIEL, C.; BESENHARD, J. O. **Handbook of battery materials**. 2.ed. [S.l.]: Wiley, 2013. ISBN: 978-3-527-63719-5.

DAUM, F. E.; HUANG, J. The curse of dimensionality for particle filters. In IEEE CONFERENCE ON AEROSPACE, 2003, Big Sky, MT. **Proceedings...** IEEE, 2003.

DAUM, F. Nonlinear filters: beyond the Kalman filter. **IEEE A&E Systems Magazine**, v. 20, n. 8, 2005.

DICKERSON, A.; RAJAMANI, R.; BOOST, M.; JACKSON, J. Determining remaining useful life for li-ion batteries. In: SAE AERO TECH CONGRESS AND EXHIBITION, 2015. **Proceedings...** 2015.

DJURIC, P.; KOTECHEA, J.; ZHANG, J.; HUANG, Y.; GHIRMAI, T.; BUGALLO, M.; MIGUEZ, J. Particle filter. **IEEE Signal Processing Magazine**, p. 19–38, 2003.

DONG, X. et al. Sensors for prognostic and health management of armored vehicles. In: PROGNOSTICS AND SYSTEM HEALTH MANAGEMENT CONFERENCE (PHM-Paris), 2019. **Proceedings...** 2019.

DUDLEY, G. J. Lithium-ion batteries for space. In: EUROPEAN SPACE POWER CONFERENCE (ESPC), 5., 1998. **Proceedings...** Noordwijk, The Netherlands: ESA Publications, 1998. Disponível em: <http://adsbit.harvard.edu/full/1998ESASP.416...17D/0000024.000.html>. Acesso em: 10 dez. 2018.

EPEC ENGINEERED TECHNOLOGIES. **Battery cell comparison**. 2018. Disponível em: <https://www.epectec.com/batteries/cell-comparison.html>. Acesso em: 20 nov. 2018.

EUROPEAN COOPERATION FOR SPACE STANDARDIZATION – ECSS.
ECSS-Q-ST-30C: space product assurance – dependability. Noordwijk, 2009a.
54p. Doi: 10.4271/2015-01-2584.

EUROPEAN COOPERATION FOR SPACE STANDARDIZATION – ECSS.
ECSS-Q-ST-30-02C: space product assurance - failure modes, effects (and
criticality) analysis (FMEA/FMECA). Noordwijk, 2009b. 74 p.

EUROPEAN COOPERATION FOR SPACE STANDARDIZATION (ECSS).
Standardization training program Q30 discipline: dependability. The
University of Arizona, Tucson, USA, 2016. Disponível em: <http://ecss.nl/wp-content/uploads/2016/09/ECSS-Training-L2-Q302016-06-28.pdf>. Acesso em:
14 dez. 2016.

ESPEDAL, I. A. et al. Current trends for State-of-Charge (SoC) estimation in
lithium-ion battery electric vehicles. **Energies**, v.14, e3284, 2021.

GABRIELLI, C. Once upon a time there was EIS. **Electrochimica Acta**, v. 331,
2020.

GAYARRE PEÑA, L. **Um algoritmo de clusterização de dados para auxílio à
análise de comportamentos de sistemas**. 2015. 185 p. IBI:
8JMKD3MGP3W34P/3JCFC22. Tese (Doutorado em Mecânica Espacial e
Controle) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos
Campos, 2015.

GLINZ, M. A. **Glossary of requirements engineering terminology**. Zurich:
University of Zurich, 2014. 130p. Disponível em: http://www.future-network-cert.at/fileadmin/user_upload/pdf/FN_Cert_2016/ireb_cpre_glossary_16_en.pdf.
Acesso em: 3 fev. 2017.

GOEBEL, K. et al. Prognostics in battery health management. **IEEE
Instrumentation and Measurements Magazine**, v. 11, n. 4, p. 33–40, 2008.

GORDON, N.; SALMOND, D.; SMITH, A. F. M. Novel approach to nonlinear
and non-Gaussian Bayesian state estimation. **Proceedings of the Institution
of Electrical Engineers**, v. 140, p. 107–113, 1993.

GOURIVEAU, R.; MEDJAHAR, K.; ZERHOUNI, N. **From prognostics and
health systems management to predictive maintenance 1**: monitoring and
prognostics. [S.l.]: Wiley, 2016. 173p.

HARTMANN II, R. L. **An aging model for lithium-ion cells**. 263p. Thesis
(PhD) - University of Akron, Akron, 2008.

HASAN, R. SCOTT, J. Extending Randles's battery model to predict impedance, charge–voltage, and runtime characteristics. **IEEE Access**, v.8, 2020.

HOFFMANN, R. X. **Filtro de partículas aceleração-reponderação em um problema referência da engenharia química**. 2017. 79p. Dissertação (Mestrado em Engenharia Química) - Universidade Federal do Espírito Santo, Vitória, 2017. Disponível em: [https://repositorio.ufes.br/bitstream/10/7829/1/tese_9836_Disserta%
%a3o%20Rayani%20Xavier%20Hoffmann.pdf](https://repositorio.ufes.br/bitstream/10/7829/1/tese_9836_Disserta%c3%a7%c3%a3o%20Rayani%20Xavier%20Hoffmann.pdf). Acesso em: 17 maio 2021.

HOLLAND, S. et al. Health ready components: unlocking the potential of IVHM. **SAE International Journal of Materials and Manufacturing**, v.9, n. 2, p. 217-223, 2016. Disponível em: <https://doi.org/10.4271/2016-01-0075>. Acesso em: 17 maio 2021.

HU, X. et al. A comparative study of equivalent circuit models for Li-ion batteries. **Journal of Power Sources**, v.198, p. 359-367, 2012.

HUGGINS, R. **Advanced batteries: materials science aspects**. [S.I.]: Springer, 2008. ISBN: 978-0-387-76423-8.

IEEE RELIABILITY SOCIETY. **IEEE standard framework for prognostics and health management of electronic systems**. [S.I.]: IEEE, 2017. 31p.

ISERMANN, R. **Fault diagnosis systems: an introduction from fault detection to fault tolerance**. Heidelberg: Springer, 2006. ISBN 978-3-642-12767-0.

JOHNSON, S. B.; GORMLEY, T.; KESSLER, S.; MOTT, C.; PATTERSONHINE, A.; REICHARD, K.; SCANDURA JUNIOR, P. **System health management: with aerospace applications**. [S.I.]: John Wiley & Sons, 2011.

JONGERDEN, M.; HAVERKORT, B. R. **Battery modeling**. [S.I.]: Faculty Electrical Engineering, Mathematics and Computer Science, 2008.

JOUIN, M. et al. Particle filter-based prognostics: review, discussion, and perspectives. **Mechanical Systems and Signal Processing**, v.72/73, p. 2–31, 2016.

LAAYOUJ, N.; JAMOULI, H. Prognosis of degradation based on a new dynamic method for remaining useful life prediction. **Journal of Quality in Maintenance Engineering**, v. 23, n. 2, p. 239-255, 2017.

LAFRAIA, J. R. B. **Manual de confiabilidade, manutenibilidade e disponibilidade**. Rio de Janeiro: Qualitymark, 2001. 388p. ISBN 8573032944.

LEITE, A. C. **Detecção e diagnóstico de falhas em sensores e atuadores da plataforma multi-missão**. 374p. Dissertação (Mestrado em Engenharia e Tecnologias Espaciais) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2007.

LEWIS, E. E. **Introduction to reliability engineering**. 2.ed. New York, NY: John Wiley and Sons, 1996. 435 p. ISBN 9780471018339.

LI, D.; HU, X. Redundant and fault-tolerant algorithms for real-time measurement and control systems for weapon equipment. **ISA Transactions**, v. 67, p. 398–406, 2017. Disponível em: https://ac.els-cdn.com/S0019057817300265/1-s2.0-S0019057817300265-main.pdf?_tid=df56c87c-cb07-11e7-a916-00000aab0f01&acdnat=1510862213_7eed025355a355f2e41e3ecbee02ebfb. Acesso em: 14 jul. 2019.

LIU, D. et al. Fragment anomaly detection with prediction and statistical analysis for satellite telemetry. **IEEE Access**, v.5, p.19269-19281, 2017.

LUCUMI, A.A.R. **Comparação dos algoritmos de filtros de partículas SIR e ASIR na detecção de fechamento de válvulas em gasodutos**. 2015. 97p. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2015. Disponível em: https://w1files.solucaoatrio.net.br/atrio/ufrj-pem_upl/THESIS/1482/pemufri2015mscmabelanglicaramoslucumi_20150615114459799.pdf. Acesso em: 10 jan. 2021.

MAGALHÃES, R. O. **Estudo de avalanche térmica em um sistema de carga e descarga de bateria em satélites artificiais**. 2012. 171 p. Tese (Doutorado em Mecânica Espacial e Controle) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.

MATOS, M.R. S. **Estudo e estimação de parâmetros de um modelo eléctrico de bateria**. 2011. 98p. Dissertação (Mestrado em Engenharia Electrotécnica e de Computadores) - Universidade do Porto, Porto, 2011.

MICHELINI, A. **Baterias recarregáveis**: para equipamentos portáteis. Cotia, SP: [s.n.], 2017. 200p.

MILITARY STANDARD. **MIL-STD-1629A**: procedures for performing a failure mode, effects and criticality analysis. Washington, 1983. 80p.

MORADKHANI, H. et al. Uncertainty assessment of hydrologic model states and parameters: sequential data assimilation using the particle filter. **Water Resources Research**, v.41, n.5, 2005.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION – NASA. **Guidelines on lithium-ion battery use in space applications**. Washington: NASA, 2009. Disponível em: <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/20090023862.pdf>. Acesso em: 10 dez. 2018.

OKOH, C.; ROY, R.; MEHNEN, J.; REDDING, L. Overview of remaining useful life prediction techniques in through-life engineering services. In: CIRP CONFERENCE ON INDUSTRIAL PRODUCT-SERVICE SYSTEMS, 6., 2014. **Proceedings...** 2014. 6p.

ORLANDE, H.; COLAÇO, M.; DULIKRAVICH, G.; VIANNA, F.; SILVA, W.; FONSECA, H.; FUDYM, O. State estimation problems in heat transfer. **International Journal for Uncertainty Quantification**, v. 2, n. 3, 2012.

PECHT, M.G. **Prognostic and health management of electronics**. [S.l.]: John Wiley & Sons, 2008. 336p. ISBN 978-0-470-27802-4.

PORCIUNCULA, C. M. D. **Aplicação de modelos elétricos de bateria na predição do tempo de vida de dispositivos móveis**. 2012. 84p. Dissertação (Mestrado em Modelagem Matemática) - Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Unijuí, RS, 2012.

PORTO, R. C. F. **Dependabilidade em sistemas espaciais e análise de falhas reais em satélites**. São José dos Campos: INPE, 2018. 71 p. Qualificação (Doutorado). IBI: 8JMKD3MGP3W34P/3QGKDJP. Disponível em: <<http://urlib.net/rep/8JMKD3MGP3W34P/3QGKDJP>>.

PRISACARU, A. et al. Prognostics and health monitoring of electronic systems: a review. In: INTERNATIONAL CONFERENCE ON THERMAL, MECHANICAL AND MULTI-PHYSICS SIMULATION AND EXPERIMENTS IN MICROELECTRONICS AND MICROSYSTEMS, 18., 2018. **Proceedings...** 2018. Doi: 10.1109/EuroSimE.2017.7926248.

QI, H.; GANESAN, S.; PECHT, M. No-fault-found and intermittent failures in electronic products. **Microelectronics Reliability**, v. 48, p. 663-674, 2008. Disponível em: http://www.prognostics.umd.edu/calcepapers/08_Qi_No_Fault_Found_Intermittent_Failure.pdf. Acesso em: 5 abr. 2017.

QIN, L.; ZHANG, Q. New algorithm for multiple satellite faults detection and exclusion based on time series prediction. In: FORUM ON COOPERATIVE POSITIONING AND SERVICE, 2017, Harbin, China. **Proceedings...** IEEE, 2017.

RABELLO, A. P. S. S. **Um novo processo para melhorar a dependabilidade de sistemas espaciais entre as fases de planejamento e projeto detalhado incluindo extensões do Diagrama de Markov (DMEP) e da FMECA (FMEP) a projetos.** 2017. 344 p. IBI: 8JMKD3MGP3W34P/3MP6RNL. Tese (Doutorado em Engenharia e Gerenciamento de Sistemas Espaciais) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2016.

RELIASOFT CORPORATION. **Reliability hot wire the magazine for the reliability professional:** conceitos de confiabilidade. 2010. Disponível em: <http://www.reliasoft.com.br/hotwire/edicao58/conceito58.htm>. Acesso: 23 jan. 2016.

RELIAWIKI. **Systems analysis (RBDs and Fault Trees):** repairable systems analysis through simulation. Disponível em: http://www.reliawiki.org/index.php/Repairable_Systems_Analysis_Through_Simulation. Acesso: 12 jun. 2017.

RIBEIRO, R. O., **Filtragem de partículas na estimação dos parâmetros de canais rádio móvel.** 2012. 88p. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual de Londrina, Londrina, 2012. Disponível em: <http://www.uel.br/pos/meel/disserta/2012_Rafael%20de%20Oliveira%20Ribeiro_2010-1.pdf>. Acesso em: 15 abr. 2017.

ROBERTSON B.; STONEKING, E. Satellite GN&C anomaly trends. In: ANNUAL AAS GUIDANCE AND CONTROL CONFERENCE, 26., 2003. **Proceeding...** AAS, 2003.

ROEMER, M. J.; NWADIOGBU, E. O.; BLOOR, G. Development of diagnostic and prognostic technologies for aerospace health management applications. In: IEEE AEROSPACE CONFERENCE, 2001. **Proceedings...** IEEE, 2001. Doi: 10.1109/AERO.2001.931331.

SAHA B., GOEBEL, K. **Battery data set.** NASA Ames Prognostics Data Repository, 2007. Disponível em: <http://ti.arc.nasa.gov/project/prognostic-data-repository>.

SAHA, B. et al., Battery health management system for electric UAVs. In: AEROSPACE CONFERENCE, 2011, Big Sky, MT, USA. **Proceedings...** 2011. p.1-9.

SAHA, B.; GOEBEL, K. Modeling li-ion battery capacity depletion in a particle filtering framework. In: ANNUAL CONFERENCE OF THE PROGNOSTICS AND HEALTH MANAGEMENT SOCIETY, 2009. **Proceedings...** 2009.

SAHA, B.; GOEBEL, K.; CHRISTOPHERSEN, J. Comparison of prognostic algorithms for estimating remaining useful life of batteries. **Transactions of the Institute of Measurement & Control**, v. 31, n. 3/4, p. 293-308. 2009.

SAHA, B.; GOEBEL, K.; POLL, S.; CHRISTOPHERSEN, J. An integrated approach to battery health monitoring using bayesian regression and state estimation. In: IEEE AUTOTESTCON, 2007, Baltimore, MD, USA. **Proceedings...** IEEE, 2007. p. 646-653.

SAHA, B.; GOEBEL, K.; POLL, S.; CHRISTOPHERSEN, J. Prognostics methods for battery health monitoring using a bayesian framework. In: **IEEE Transactions on Instrumentation and Measurement**, v. 58, n. 2, 2009.

SANKAVARAM, C. et al. Model-based and data-driven prognosis of automotive and electronic systems. In: ANNUAL IEEE CONFERENCE ON AUTOMATION SCIENCE AND ENGINEERING. 5., 2009. **Proceeding...** IEEE, 2009.

Disponível em:

http://www.prognostics.umd.edu/calcepapers/09_Sankavaram_Model_Based_Data_Driven.pdf. Acesso em: 6 dez. 2017.

SAXENA, A.; CELAYA, J.; BALABAN, E.; GOEBEL, K.; SAHA, B.; SAHA, S.; SCHWABACHER, M. Metrics for evaluating performance of prognostic techniques. In: INTERNATIONAL CONFERENCE ON PROGNOSTICS AND HEALTH MANAGEMENT, 2008. **Proceedings...** 2008. Disponível em: <http://dx.doi.org/10.1109/PHM.2008.4711436>.

SAXENA, A.; CELAYA, J.; SAH, B.; SAHA, S.; GOEBEL, K. Metrics for offline evaluation of prognostic performance. **International Journal of Prognostics and Health Management**, v. 1, n. 1, p. 20, 2010.

SAXENA, A.; SANKARARAMAN, S.; GOEBEL, K. Performance evaluation for fleet and unit-based prediction methods. In: EUROPEAN CONFERENCE OF THE PROGNOSTICS AND HEALTH MANAGEMENT SOCIETY, 2., 2014, Nantes, France. **Proceedings...** 2014.

SCHWABACHER, M. A. A survey of data driven prognostics. In: SAE WORLD AEROSPACE CONGRESS, 2005, Dallas, TX. **Proceedings...** 2005. Doi: 10.2514/6.2005-7002.

SGOBBA, T. **Treinamento em tópicos da garantia da qualidade em programas espaciais**. São José dos Campos: INPE, 2016. Notas de aula da disciplina garantia do produto.

SHUAN, L. H. et al. Network equipment failure prediction with big data analytics. **International Journal of Advances in Soft Computing and its Applications**, v. 8, n. 3, 2016.

SILVA JUNIOR, D. P.; PAES, A.; OLIVEIRA, D. **Predição de falhas em workflows científicos em nuvens baseada em aprendizado de máquina**. Niterói: Universidade Federal Fluminense (UFF), 2017. 8p.

SILVA, B. F.; SAUSEN, A.; SAUSEN, P. S.; REIMBOLD, M. Método da procura em rede melhorado: uma proposta para a estimação dos parâmetros do modelo de Rakhmatov e Vrudhula. **Tendências em Matemática Aplicada e Computacional**, v.14, n. 3, p. 463-482, 2013. Doi: 10.5540/tema.2013.014.03.0463.

SILVA, D. R. C. **Sistema de detecção e isolamento de falhas em sistemas dinâmicos baseado em identificação paramétrica**. 2008. 114p. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Norte (UFRN), Natal, 2008.

SILVA, S.; DIAS JUNIOR, M.; LOPES JUNIOR, V. Detecção de falhas estruturais utilizando controle estatístico de processos. In: CONGRESSO TEMÁTICO DE DINÂMICA, CONTROLE E APLICAÇÕES, 4., 2005, Bauru, SP. **Anais...** 2005.

SILVA, W. B. **Aplicação de filtros de partículas para assimilação de dados em problemas de fronteira móvel**. 2012. 181p. Tese (Doutorado em Energétique et Transferts) - Institut National Polytechnique de Toulouse, Toulouse, 2012. Disponível em: <https://oatao.univ-toulouse.fr/11752/1/betencurte.pdf>. Acesso em: 10 jan. 2021.

SILVA, F. C. A. **Métodos sequencias de Monte Carlo bayesianos: aspectos computacionais, inferenciais e aplicações**. 2016. 198p. Tese (Doutorado em Estatística e Probabilidade) – Universidade Federal de Minas Gerais, Belo Horizonte, 2016.

SIMEÓN, E. J. A. **Prognóstico de falhas baseado em redes neurais com estados de ECO**. 2015. 145 p. Tese (Doutorado em Sistemas Mecatrônicos Departamento de Engenharia Mecânica) - Universidade de Brasília, Brasília, 2015.

- SORENSEN, H. W. **Kalman filtering: theory and applications**. New York: IEEE, 1985.
- SOUZA, A. J. **Aplicação de multisensores no prognóstico da vida útil da ferramenta de corte em torneamento**. 2004. 226p. Tese (Doutorado em Engenharia Mecânica) - Universidade Federal de Santa Catarina, Florianópolis, 2004.
- SOUZA, M. L. O.; CARVALHO, T. R. The fault avoidance and the fault tolerance approaches for increasing the reliability of aerospace and automotive systems. In: SAE BRASIL, 2005, São Paulo. **Anais...** 2005.
- SOUZA, M. L. O.; PORTO, R. C. F. The fault correction and the fault prediction approaches for increasing the reliability of aerospace and automotive systems. In: SAE BRASIL, 2016, São Paulo. **Anais...** 2016.
- STAMPS, A. T. et al. Analysis of capacity fade in a lithium ion battery. **Journal of Power Sources**, v.150, p.229–239, 2005.
- STANDEX ELECTRONICS. **Smart automotive Market applications and transportation industry**. Disponível em: <https://standelectronic.com/automotive-market-applications-transportation-industry/>. Acesso em: 22 maio 2019.
- STRATONOVICH, R. L. Conditional Markov processes. In: FINE, T. L. (Ed.). **Theories of probability**. USA: Elsevier, 1960. p. 156–178.
- SUTHARSSAN, T. et al. A review on prognostics and health monitoring of proton exchange membrane fuel cell. **Renewable and Sustainable Energy Reviews**, v. 75, p. 440-450, 2017.
- SUWATTHIKUL, J. **A framework and methods for on-board network level fault diagnostics in automobiles**. 2008. 207p. Tese (Doutorado em Engenharia) - Universidade de Warwick, Coventry, 2008.
- TAHAN, M. et al Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines: a review. **Applied Energy**, v. 198, p.122–144. 2017
- TEIXEIRA, A. J. **Detecção identificação e reconfiguração de falhas múltiplas em sensores de sistemas lineares invariantes no tempo**. 2005. 312 p. IBI: 6qtX3pFwXQZGivnJSY/KaHQU. Tese (Doutorado em Mecânica Espacial e Controle) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005. Disponível em: <http://urlib.net/6qtX3pFwXQZGivnJSY/KaHQU>. Acesso em: 12 abr. 2017

THORAT, S.; THORVE, S.; UPASE, J.; DHUPAR, A. S. Design and implementation of automatic emergency braking system. **International Journal of Current Engineering and Technology**, p.337-342, 2016. Doi: 10.14741/ijcet/22774106/spl.4.2016.67.

TONELLI NETO, M. S. **Desenvolvimento de um sistema inteligente para o diagnóstico e prognóstico de falhas em sistemas de distribuição de energia elétrica**. 2015. 111p. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual Paulista, Ilha Solteira, 2015. Disponível em <https://repositorio.unesp.br/bitstream/handle/11449/126378/000844126.pdf?sequence=1>. Acesso em: 20 nov. 2017.

TORCHIO, M. **Model predictive control strategies for advanced battery management systems**. 2017. 213p. Tese (Doutorado em Eletrônica, Computação e Engenharia Biomédica) - Universidade de Pavia, Pávia, 2017.

TORRES JÚNIOR, R. G.; MACHADO, M. A. S.; SOUZA, R. C. Previsão de séries temporais de falhas em manutenção industrial usando redes neurais. **Egevista**, v. 7, n. 2, p. 4-18, 2005.

VACHTSEVANOS, G.; LEWIS, F. ROEMER, M.; HESS, A.; WU, B. **Intelligent fault diagnosis and prognosis for engineering systems**. New Jersey: John Wiley and Sons, 2006.

VALSERA-NARANJO, E. et al. Electrical vehicles: state of art and issues for their connection to the network. In: INTERNATIONAL CONFERENCE ELECTRICAL POWER QUALITY AND UTILISATION, 10., 2009. **Proceeding...** 2009.

VILLEMEUR, A. **Reliability, availability, maintainability and safety assessment: methods and techniques**. New York: Wiley, 1992. 398 p. ISBN 978-0-471-93048-8.

VIANNA, L. M. S. **Aplicações do filtro de partículas para observação de estados e estimação de parâmetros em sistemas dinâmicos não lineares multivariáveis**. 2020. 76p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 2020.

VOGL, G. W.; WEISS, B. A.; DONMEZ, M.A. Standards for Prognostics and Health Management (PHM). In: ANNUAL CONFERENCE OF THE PROGNOSTICS AND HEALTH MANAGEMENT SOCIETY, 2014. **Proceedings...** National Institute of Standards and Technology, 2014. 13p.

WALD, R. et al. A review of prognostics and health monitoring techniques for autonomous ocean systems. In: INTERNATIONAL ISSAT ON RELIABILITY AND QUALITY DESIGN, 16., 2010. **Proceedings...** 2010. 6p.

WALKER, E.; RAYMAN, S.; WHITE, E.R. Comparison of a particle filter and other state estimation methods for prognostics of lithium-ion batteries. **Journal of Power Sources**, v. 287, p.1-12, 2015.

WAN, E. A.; MERWE, R. V. D. **The unscented Kalman filter for nonlinear estimation**. 2000. Disponível em:
<https://www.seas.harvard.edu/courses/cs281/papers/unscented.pdf>.

WANG, Z. et al Combination forecasting method for storage reliability parameters of aerospace relays based on grey-artificial neural networks. **Journal International Journal of Innovative Computing, Information and Control**, v. 9, n. 9, 2013.

WOJCIECH J. **Monte Carlo integration.**, 2008. Disponível em:
<<https://cs.dartmouth.edu/~wjarosz/publications/dissertation/appendixA.pdf>>.
Acesso em: 20 mar 2021.

YAIRI, T. et al A data-driven health monitoring method for satellite housekeeping data based on probabilistic clustering and dimensionality reduction. **IEEE Transactions on Aerospace and Electronic Systems**, v. 53, n. 3, 2017.

ZHANG, J.; LEE, J. A review on prognostics and health monitoring of Li-ion battery. **Journal of Power Sources**, v. 196, n. 15, 2011.

ZHU, Q. et al. Study and application of fault prediction methods with improved reservoir neural networks. **Chinese Journal of Chemical Engineering**, v. 22 p. 812–819, 2014.

ZOU, Y et al. Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan electric vehicles. **Journal of Power Sources**, v. 273, p. 793-803, 2015.

GLOSSÁRIO

Acurácia do Sistema Prognóstico (*Prognostic System Accuracy*): Uma medida quantitativa do erro entre o EOL previsto e o EOL observado do componente ou sistema monitorado (IEEE, 2017).

Capacidade Nominal da Bateria (*Rated Capacity*): O número de Ampères-horas que uma bateria pode fornecer em condições específicas (MICHELINI, 2017).

Ciclo da Bateria (*Battery Cycle*): A descarga e a carga subsequente ou anterior de uma bateria secundária, tal como quando é restaurada nas suas condições originais (MICHELINI, 2017).

Ciclo de Vida da Bateria (*Battery Life Cycle*): O número de ciclos em condições especificadas que estão disponíveis a partir de uma bateria secundária antes que ela não atenda aos critérios especificados quanto ao desempenho (MICHELINI, 2017).

Descarga da Bateria (*Battery Discharge*): A conversão da energia química de uma célula ou bateria em energia elétrica que é retirada da bateria e transferida a uma carga (MICHELINI, 2017).

Descarga na Prateleira ou Auto-Descarga da Bateria (*Battery Self-Discharge*): A perda de capacidade útil de uma célula ou bateria devida a reações químicas internas quando a bateria está armazenada fora de uso (MICHELINI, 2017).

Distância Prognóstica (*Prognostic Distance*): O intervalo de tempo entre a primeira instância em que uma predição atinge o desempenho desejado (acurácia, precisão e/ou confiança) e o tempo estimado de falha do sistema (SAXENA et al, 2008).

Falência (*Failure*): Uma falência é uma interrupção permanente da capacidade de um sistema de executar uma função necessária sob condições operacionais especificadas e pode ser classificada em:

Falência Catastrófica (*Catastrophic Failure*): Qualquer falência que possa causar a perda da missão ou do sistema; perda de vida, lesão com risco de vida ou incapacidade permanente ou doença ocupacional. Perda de um sistema de voo tripulado de interface. Graves efeitos ambientais prejudiciais. Perda de instalações do local de lançamento (LEITE, 2007; VILLEMEUR, 1992; ECSS, 2009a; 2009b).

Falha Crítica (*Critical Failure*): Qualquer falência que possa causar perda incapacitante temporária, mas não lesão com risco de vida, doença ocupacional temporária; ou efeitos ambientais prejudiciais importantes. Qualquer falência que possa causar grandes danos às propriedades públicas ou privadas ou grandes danos aos sistemas de voo de interface. Danos graves às instalações terrestres (LEITE, 2007; VILLEMEUR, 1992; ECSS, 2009a; 2009b).

Falência Maior (*Significant/Major Failure*): Qualquer falência que possa causar grande degradação no sistema ou nas funções de desempenho da missão, com qualquer dano considerável à vida ou membro do sistema (LEITE, 2007; VILLEMEUR, 1992; ECSS, 2009a; 2009b).

Falência Menor ou Insignificante (*Insignificant/Minor Failure*): Qualquer falência que possa causar uma pequena degradação no sistema ou nas funções de desempenho da missão sem causar danos significativos à vida ou aos membros do sistema (LEITE, 2007; VILLEMEUR, 1992; ECSS, 2009a; 2009b).

Falha (*Fault*): Uma falha é um desvio não permitido de pelo menos uma propriedade, característica ou recurso do sistema da condição padrão aceitável e usual (ISERMANN, 2006).

Fim de Vida (*End-Of-Life - EOL*): O momento a partir do qual um componente ou sistema não executa sua função pretendida dentro das especificações desejadas (SAXENA et al, 2008; SAXENA, 2010). EOL equivale a Fim de Vida Útil (IEEE, 2017).

Monitoração de Saúde (*Health Monitoring*): A função de estimar o estado de saúde de um sistema, incluindo a medição de variáveis de estado e identificar se os estados dessas variáveis indicam uma condição fora da nominal (IEEE, 2017).

Perda de Capacidade de Carga da Bateria (*Capacity Fade*). Perda gradual de capacidade de uma bateria secundária com ciclos de carga e descarga. (MICHELINI, 2017).

Prognóstico (*Prognostics*): O processo de prever a RUL de um sistema objeto ao prever a progressão de uma falha dado o grau atual de degradação, o histórico de carga e as condições operacionais e ambientais futuras previstas para estimar o tempo em que o sistema objeto não executará mais sua função pretendida dentro das especificações desejadas (IEEE, 2017).

Recarga da Bateria (*Battery Recharge*). Um método que retorna a capacidade total de uma bateria recarregável (MICHELINI, 2017).

Saúde (*Health*): Informações resumidas sobre a capacidade atual de um sistema ou subsistema de executar sua função pretendida. (O estado de saúde de um produto nem sempre é observado diretamente e, portanto, é estimado) (IEEE, 2017).

Tempo de resposta (*Response Time*): Uma medida de quão rapidamente uma resposta é executada, desde o momento em que a resposta é solicitada até a conclusão da resposta (IEEE, 2017).

Tempo Prognóstico (*Prognostic Time*): A medida de quão cedo, antes de um evento de falha real, um sistema prognóstico produz uma predição com

acurácia (conforme definido em uma métrica de acurácia) de EOL (IEEE, 2017).

Vida Útil Remanescente ou Restante (*Remaining Useful Life* - RUL): O período desde o tempo presente até o tempo estimado em que se espera que o sistema (ou produto) não execute mais a função pretendida dentro das especificações desejadas. Ou seja, a quantidade de tempo restante antes que a integridade do sistema caia abaixo de um limite de falência definido (IEEE, 2017; SAXENA, 2008).

Histerese é a tendência de um sistema de conservar suas propriedades na ausência de um estímulo que as gerou, ou ainda, é a capacidade de preservar uma deformação efetuada por um estímulo.

ANEXO A – SEÇÃO 2.3.1 DA TESE DE HARTMAN II (2008)

A.1 Introdução

Este Anexo reproduz o início da Seção 2.3 e a Seção 2.3.1 da tese de Hartman II (2008): “An Aging Model for Lithium-Ion Cells”.

2.3 Electrochemical cell: dynamic models

Due to transient effects, measurements from sensors are not sufficient to determine the SOC within a cell. Therefore, many types of dynamic models have been developed to estimate the SOC of a cell. Feedback from sensors is normally used to minimize errors from the model. As discussed earlier, one method of determining SOC is to create a pre-defined look-up table that maps E_{oc} (the open circuit voltage) to SOC for various currents. Another method is to calculate SOC by integrating the current passing through the cell. More advanced methods create state observers using a derived model (Plett, 2004). This section discusses some common modeling methods based on the physical properties of the electrochemical cell presented in the previous sections.

2.3.1 Electric circuit models

An accurate model is typically required to create a controller. Often, a constant DC voltage source is used to model a battery. This section will build upon this simple model by incorporating the dynamics of the electrochemical cell discussed in the previous sections. The simplest addition to the constant voltage source model is a resistor in series with the constant voltage source as shown in Figure 2.10. This simple model accounts for the instantaneous voltage drop across the cell when a current is applied to the cell, but it does not address the other dynamics of the cell.

One of the key dynamics of a cell that should be addressed is diffusion. In Section 2.2.4, the diffusion in a cell was discussed, and an approximate solution

to the change in the diffusing charge was given in Equation 2.65. This differential equation has the same form as the voltage across the parallel RC circuit shown in Figure 2.11. Rewriting Equation 2.65 in terms of the circuit elements R_d and C_d yields:

$$\frac{dv_d(t)}{dt} = \frac{1}{C_d}i(t) - \frac{1}{R_d C_d}v_d(t) \quad (2.66)$$

where the voltage, $v_d(t)$, dropped across the capacitor C_d is proportional to the diffused charge, $v_d(t) = k_d q_d(t)$. As illustrated in Figure 2.12, the values for the circuit elements R_d and C_d can be determined experimentally by applying a step change in current to the circuit in Figure 2.11.

Eveready Battery Company (2001) provides an equivalent linear electric circuit model that combines Figure 2.10 and Figure 2.11 together as shown in Figure 2.13.

Figure 2.10: Simple resistive cell model.

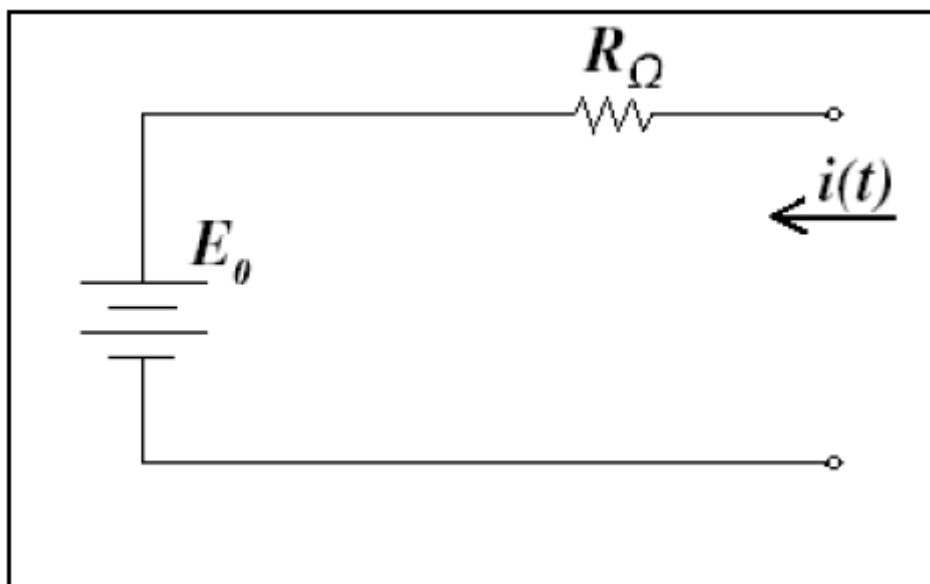


Figure 2.11: RC circuit representing diffusion within a cell.





Figure 2.12: Voltage across parallel RC circuit due to a step change in current (Hartley & Lorenzo, 2002).



This model is for a NiMH cell. In the circuit, E_0 is defined as the effective open circuit cell voltage which is in series with the resistor R_Ω , the effective instantaneous resistance, and the resistor R_d , which is in parallel with the capacitor C_d . Eveready defines R_d as the delayed resistance and C_d as the effective parallel capacitance.

Another key cell dynamic, which is not included in the Eveready model, is the effect of the state of charge on the terminal voltage of the cell. Figure 2.1, which is repeated in Figure 2.14 for convenience, shows how the terminal voltage of an electrochemical cell decreases as the cell is discharged. Figure 2.14 also indicates the areas of the discharge cycle that are approximately linear with respect to state of charge and those that are nonlinear.

Often the terminal voltage of the electrochemical cell is assumed to be constant within the middle of the operating range. However, as seen in Figure 2.14, the terminal voltage of the cell near the middle of the graph is approximately linear, but gradually decreases as the cell is discharged. This approximately linear decrease in voltage can be modeled by inserting a capacitor in series with the voltage source as shown in Figure 2.15. The voltage across the capacitor C_s is proportional to the stored charge in the cell; that is, $v_s(t) = k_s q_s(t)$. As the state of charge in the cell increases or decreases, the voltage $v_s(t)$ across this capacitor will increase or decrease accordingly.

None of the models introduced in this section so far has addressed the loss of charge while the circuit is at rest. To account for this loss of charge, a resistor can be placed in parallel with the storage capacitor. Figure 2.16 shows a full circuit model that includes a resistive term, R_{sd} , representing the self-discharge of the cell.

In Section 2.2.4, a model of the diffusion process was presented. This model of the diffusion process resulted in Equation 2.54, which contains the Warburg impedance.

Figure 2.13: Linear circuit model for NiMH cell as described by Eveready Company (2001).

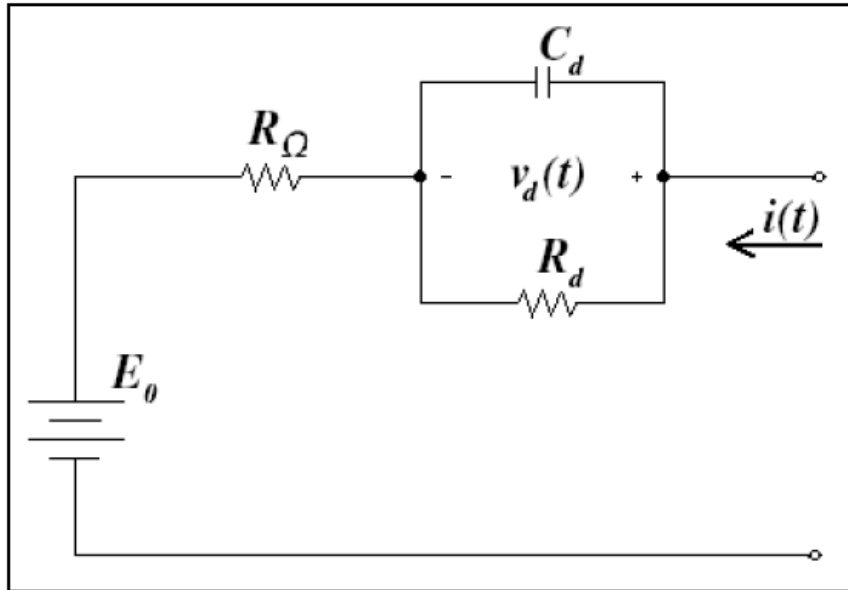



Figure 2.14: Voltage discharge curve for a (9.5) NiMH cell indicating linear and nonlinear regions.



In the electrical circuit models presented above, the entire diffusion process is approximated by the parallel circuit branch containing the elements C_d and R_d . A more complete model is shown in Figure 2.17 with the Warburg impedance

added in series with the resistor R_d . In Figure 2.18, the Warburg impedance is replaced with a constant phase element. The next section presents a model that incorporates the nonlinear aspects of the electrochemical cell voltage.

Figure 2.15: Circuit model including a capacitor representing capacity of the cell.

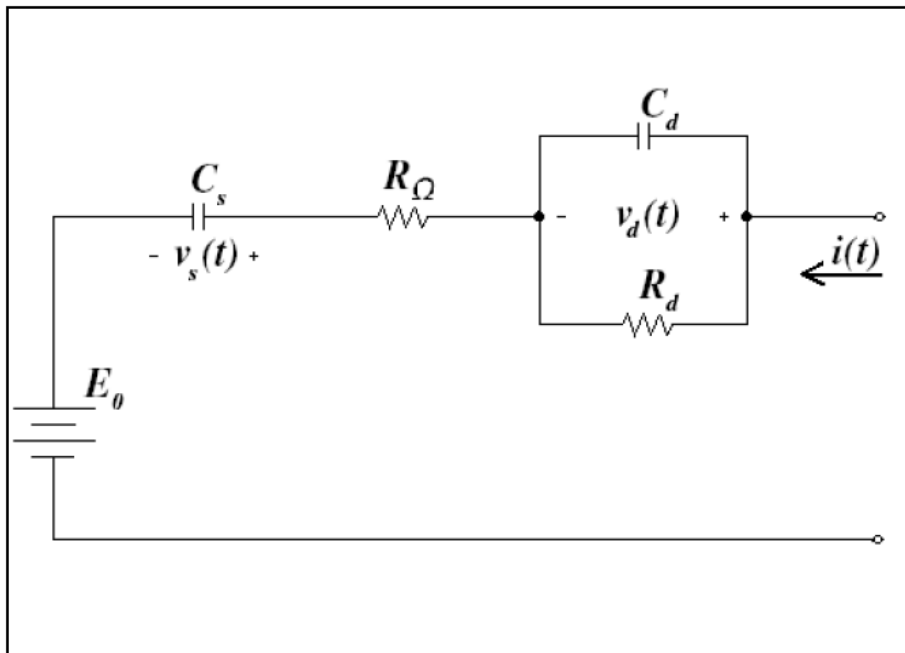


Figure 2.16: Circuit model including self-discharge resistor.

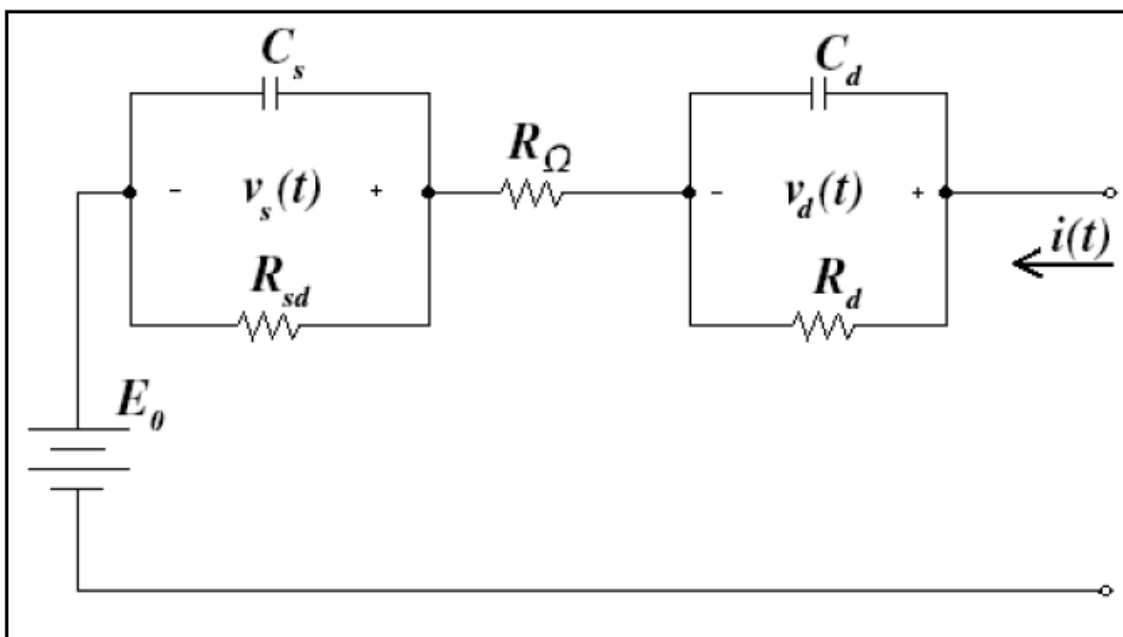


Figure 2.17: Circuit model including Warburg impedance.

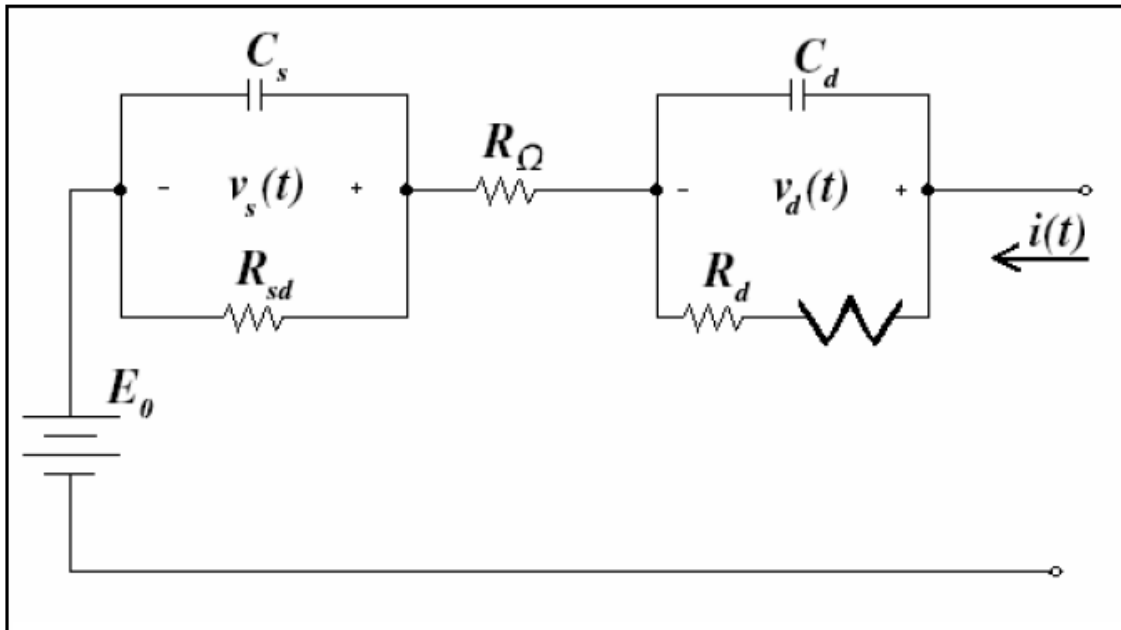
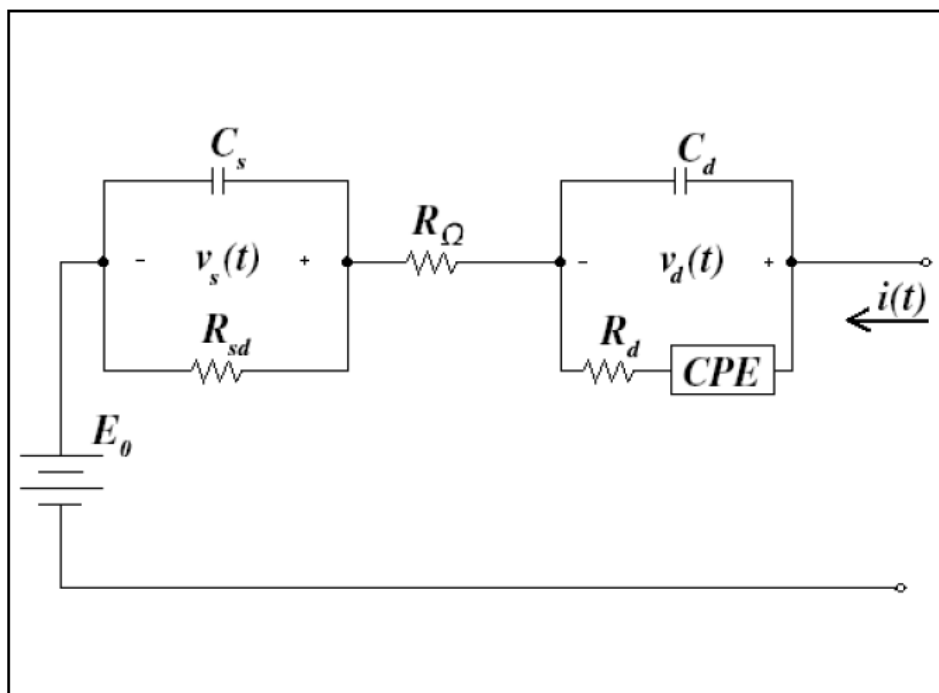


Figure 2.18: Circuit model including constant phase element.



ANEXO B -CONTATO COM O DR. KAI GOEBEL PARA DADOS DE PROGNÓSTICO

Durante o estudo da literatura para este trabalho, no levantamento de conceitos e estudo das publicações de prognóstico presentes na literatura, foram encontrados alguns trabalhos do Dr. Kai Goebel com diversas aplicações. Fizemos um contato (Figura B1) buscando dados que pudéssemos utilizar neste trabalho, ele nos retornou (Figura B2) com o link deste repositório com dados de alguns equipamentos, incluindo os dados de baterias utilizados neste trabalho.

Figura B.1: Contato feito com Dr. Kai Goebel.

Roberta Porto <roberta.cfporto@gmail.com> qua., 11 de abr. de 2018 17:03 ☆ ↶ ⋮
para kai.goebel, kai.goebel, Marcelo ▾

Dear Dr. Goebel
My name is Roberta Porto, I am a DSc. Student at National Institute of Space Research (INPE) in Brazil. I am advised by Marcelo L. O. Souza, Ph.D. I am starting a failure prediction/prognostic research on devices of small civilian satellites. The intention is to make an algorithm for the failures prognosis of a system device. The biggest hindrance is getting life data that has progressed to failure to fit the model.

I had opportunity to see your works about failure prognostics and I would be grateful if you could provide me some data to help with my work.

Thank you for your help.

Yours faithfully

MSc. Roberta Porto

Figura B.2: Resposta ao contato realizado com o link aos dados.

Kai Goebel <kai.goebel@nasa.gov> qua., 11 de abr. de 2018 18:44 ☆ ↶ ⋮
para mim, kai.goebel, Marcelo ▾

🌐 inglês ▾ > português ▾ Traduzir mensagem Desativar para: inglês x

Dear Roberta Porto,

Please check the data sets in our repository here: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>

Regards,

Kai Goebel

ANEXO C - PROJETO E ANÁLISE DE EXPERIMENTOS

C.1 Introdução

Este Anexo reproduz o início da Seção B.6 e as Seções B6.1 e B6.2 da Dissertação “Estudo e Otimização do Processo de Soldagem de Interconectores às Células de Painéis Solares Empregados em Satélites Artificiais Aplicando Projeto e Análise de Experimentos” defendida por Graziela Fernanda de Souza Maia e aprovada pela Banca no Curso ETE/CSE do INPE em 11/Maio/2021, a saber:

B.6 Técnicas de projeto e análise de experimentos

Nesta seção são resumidas algumas técnicas para o Projeto e Análise de Experimentos, tais como: planejamento fatorial, planejamento fatorial fracionado, análise de variância, metodologia de superfície de resposta, metodologia de Taguchi. Este trabalho não pretende abordar todas as técnicas de Projeto e Análise de Experimentos presentes na literatura.

No setor industrial se faz necessário a realização de experimentos, a fim de assegurar que as informações do processo sejam confiáveis e que os recursos, sejam eles materiais, humanos, equipamentos ou informações tenham uma boa utilização. Para isto, pode-se usar o:

B.6.1 Planejamento fatorial

Planejamento Fatorial (Total/Completo) é empregado com frequência em experimentos que envolvem diversos fatores, onde se faz necessário o estudo do efeito conjunto dos fatores sobre determinada variável de resposta (MONTGOMERY, 2017).

Ainda segundo Montgomery (2017), nesta etapa são feitos os testes com todas as possíveis combinações dos níveis (alto e baixo) de fatores pré-estabelecidos a serem investigados.

Existem vários casos especiais no Planejamento Fatorial (Total/Completo), devido ao fato de serem amplamente empregados em diversos trabalhos de pesquisas, além de formarem a base para outros planejamentos de valor prático considerável. O mais importante desses casos é aquele de k fatores, cada um com apenas dois níveis. Os níveis por sua vez podem ser qualitativos (por exemplo: temperatura, pressão, tempo) ou quantitativos (duas ferramentas, duas pessoas); aqui serão os níveis “alto” e “baixo”.

Esta técnica é indicada nas fases iniciais do planejamento experimental, quando existe a necessidade de se definir os fatores mais importantes a serem investigados e estudar seus efeitos sobre a variável de resposta selecionada.

O modelo estatístico de um experimento fatorial 2^2 é representado pela Equação (C.1) o (MONTGOMERY, 2017).

$$y = k + k_1x_1 + k_2x_2 + k_3x_1x_2 \quad (\text{B.1})$$

Em que:

k é a constante;

k_1 é o coeficiente do fator de controle x_1 ;

x_1 é o primeiro fator de controle;

k_2 é o coeficiente do fator de controle x_2 ;

x_2 é o segundo fator de controle;

k_3 é o coeficiente da interação entre os fatores x_1x_2 ;

x_1x_2 é a interação entre o primeiro e o segundo fator de controle.

A forma como os fatores e as respostas de um experimento são organizados é chamada de **matriz experimental**. A fim de ilustrar uma matriz, na Tabela B.1 é apresentado um experimento com três fatores (A, B e C), ou seja, $2^3 = 8$

experimentos, cada fator com dois níveis alto (+) e baixo (-). Todas as combinações entre os fatores e níveis são representadas.


Tabela B.1 – Matriz experimental de um delineamento fatorial 2^3 .

Nº do teste	A	B	C
1	-	-	-
2	+	-	-
3	-	+	-
4	+	+	-
5	-	-	+
6	+	-	+
7	-	+	+
8	+	+	+

Fonte: Adaptada de Montgomery (2017).

A representação geométrica dos fatores, seus níveis e interações são apresentados na Figura B.2.

Figura B.2: Representação geométrica de 3 fatores.



Fonte: Adaptada de Montgomery (2017).

B.6.2 Planejamento fatorial fracionado

O Planejamento Fatorial Fracionado é caracterizado como um planejamento em que se realiza apenas um subconjunto ou fração dos experimentos do Planejamento Fatorial Total.

Segundo Brito (2014), este tipo de planejamento é aplicado quando os recursos são moderados; ou então, quando a quantidade de fatores no projeto é grande, comparado com as poucas observações e com os planejamentos fatoriais totais/completos.


Esse tipo de experimento acaba sendo muito utilizado por indústrias já que possibilita diminuir o número de tratamentos e, desta forma, diminuir o custo para realizar tais experimentos.

De acordo com Montgomery (2017), o número de observações ou experimentos necessários para executar um planejamento fatorial de 2 níveis é 2^k onde k representa o número de fatores. Enquanto o número de fatores k num planejamento 2^k aumenta, a quantidade de experimentos necessários para realizar um planejamento fatorial completo aumenta exponencialmente. Um exemplo de planejamento fatorial completo com 5 fatores, requer 32 experimentos (pois $2^5 = 32$), já um planejamento com 8 fatores requer 256 experimentos (pois $2^8 = 256$); porém, quando se aplica um planejamento fatorial fracionado pela metade, seriam necessárias apenas a metade desses experimentos.

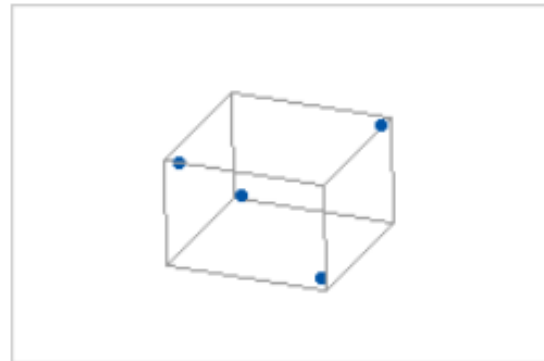
Os diagramas da Figura B.3, mostram a comparação de um experimento fatorial completo *versus* um experimento fatorial de $\frac{1}{2}$ fração. Na Figura C.2, é possível verificar que o experimento fatorial completo contém o dobro de pontos de experimentos que o experimento fatorial fracionado pela metade; assim, a resposta é medida em quatro dos oito pontos de extremidade possíveis. Porém, neste tipo de experimento, os efeitos principais são confundidos com as interações de 2 fatores.

Figura B.3: Comparação experimento fatorial completo e experimento fatorial fracionado pela metade.

Experimento fatorial completo



Experimento fatorial de 1/2 fração



Fonte: MINITAB 17®.