



**UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS DE SOBRAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO**

ERICK FROTA DA COSTA

**PREDIÇÃO DA DESCARGA E CAPACIDADE DE BATERIAS LI-ION UTILIZADAS
EM VANTS**

SOBRAL

2019

ERICK FROTA DA COSTA

**PREDIÇÃO DA DESCARGA E CAPACIDADE DE BATERIAS LI-ION UTILIZADAS
EM VANTS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e da Computação da Universidade Federal do Ceará, como requisito à obtenção do título de mestre em Engenharia Elétrica e da Computação. Área de concentração: Sistemas de Energia Elétrica e subárea: Eletrônica de Potência.

Orientador: Prof. Dr. Vandilberto Pereira Pinto.

SOBRAL

2019

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- C871p Costa, Erick Frota da.
Predição da descarga e capacidade de baterias li-ion utilizadas em vants / Erick Frota da Costa. – 2019.
94 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Campus de Sobral, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Sobral, 2019.
Orientação: Prof. Dr. Vandilberto Pereira Pinto.
1. Baterias Li-Ion. 2. VANTs. 3. PHM. 4. Filtro de Partículas. 5. Filtro de Kalman Unscentend. I. Título.
CDD 621.3
-

ERICK FROTA DA COSTA

**PREDIÇÃO DA DESCARGA E CAPACIDADE DE BATERIAS LI-ION UTILIZADAS
EM VANTS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e da Computação da Universidade Federal do Ceará, como requisito à obtenção do título de mestre em Engenharia Elétrica e da Computação. Área de concentração: Sistemas de Energia Elétrica e subárea: Eletrônica de Potência.

Aprovada em: ___/___/_____.

BANCA EXAMINADORA

Dr. Vandilberto Pereira Pinto (Orientador)
Programa de Pós-Graduação em Engenharia Elétrica e de Computação (PPGEEC),
Universidade Federal do Ceará (UFC)

Dr. João Paulo Pordeus Gomes (Externo ao Programa)
Departamento de Computação, Universidade Federal do Ceará (UFC)

Dr. Leonardo Ramos Rodrigues (Externo a Instituição)
Departamento de Ciência e Tecnologia Aeroespacial (DCTA), Instituto de Aeronáutica e
Espaço (IAE)

A Deus.

A minha família.

AGRADECIMENTOS

A Deus, que propiciou esta e todas as realizações em minha vida.

A minha mãe, Eliene, e meu pai, Heraldo, que diante de todas as dificuldades sempre se esforçaram para me dar tudo que foi preciso.

Aos demais membros da minha família, que sempre me apoiaram em especial a minha avó Gerarda e minha tia Wellingta, que sempre prezaram pela minha educação e foram imagens de motivação nos momentos difíceis.

Aos amigos que sempre torceram por mim. Aos colegas da turma de graduação e mestrado, pelas reflexões, críticas e sugestões recebidas.

Aos docentes e funcionários do Programa de Pós-Graduação em Engenharia Elétrica e de Computação.

Ao Prof. Dr. Vandilberto pela excelente orientação e grandes ensinamentos desde a época de graduação.

Aos membros da banca examinadora pelo tempo, pelas valiosas colaborações e sugestões.

“Nosso mundo, nossa vida, nosso destino, são dominados pela incerteza. Esta é talvez a única declaração que podemos afirmar sem incerteza.” De Finetti

RESUMO

Esta pesquisa busca realizar um estudo de predição da capacidade e descarga de baterias de íons de lítio (Li-Ion) de um conjunto de base de dados da NASA. Essas baterias são comumente usadas em VANTS (Veículos Aéreos não Tripulados) por apresentar certas características, como: leveza, alta densidade energética, grande quantidade de ciclos de descarga, entre outras. Os métodos de predição são usados na forma de aprendizagem supervisionada, na qual os algoritmos são informados das entradas e saídas de uma parte da base de dados da NASA. Os métodos usados para este estudo foram: Mínimos quadrados não recursivos, Filtro de Kalman Discreto, Rede Neural Artificial com o treinamento ELM (Máquina de Aprendizagem Extremo), Filtro de Partículas e Filtro de Kalman Unscented. Para se fazer uma análise comparativa destes, foram usados o RMSE (raiz do erro quadrático médio), R^2 (coeficiente de correlação) e o custo computacional. Além disso, foram utilizadas técnicas de PHM (Prognostics and Health Management ou Prognóstico e Gerenciamento de Saúde) junto às técnicas citadas, com uma metodologia de falha baseada em threshold e barreiras de predição para a capacidade com intervalos de confiança de 95%.

Palavras-chave: Baterias Li-Ion. VANTs. PHM. RNA ELM. Filtro de Partículas. Filtro de Kalman Unscented. Mínimos Quadrados Não Recursivos.

ABSTRACT

This research aims to perform a prediction study of the capacity and discharge of lithium ion batteries (Li-Ion) from a set of a NASA database. These batteries are commonly used in UAVs (Unmanned Aerial Vehicles) because it presents characteristics such as lightness, high energy density, large number of discharge cycles, among others. The prediction methods are used in the form of supervised learning, in which algorithms are fed part of the NASA database's inputs and outputs. The methods used in this study were: Non-recursive least squares, Discrete Kalman Filter, Artificial Neural Network with ELM (Extreme Learning Machine) training, Particle Filter and Unscented Kalman Filter. In order to make a comparative analysis of these, RMSE (Root-Mean-Square Error), R^2 (correlation coefficient) and computational cost were used. In addition, PHM (Prognostics and Health Management) techniques were used alongside the aforementioned ones, utilizing a threshold-based failure methodology as well as prediction barriers for the capacity with 95% confidence intervals.

Keywords: Batteries Li-Ion. UAVs. PHM. ELM ANN. Particles Filter. Unscented Kalman Filter.

LISTA DE FIGURAS

Figura 1 - Fluxograma OSA-CBM.	19
Figura 2 - Hierarquia das Abordagens de Prognóstico de Falhas.	19
Figura 3 - Exemplo de Prognóstico de Falha com Séries Temporais.	20
Figura 4 - Esquema de uma Célula Eletroquímica.	24
Figura 5 - Operação de uma Bateria.	25
Figura 6 - Curva de Descarga de Bateria com Diferentes Correntes.	26
Figura 7 - Janela de Operação de Baterias de Íon-Lítio.	28
Figura 8 - Modelamento de Saúde de Baterias – ARC.	30
Figura 9 - Ciclo de Baixa Corrente de Descarga.	31
Figura 10 - Tensão na Bateria Após Vários Ciclos de Descarga.	31
Figura 11 - Degradação da Capacidade Após Vários Ciclos de Descarga.	32
Figura 12 - Fluxograma da metodologia para a estimativa da capacidade.	33
Figura 13 - Algoritmo ELM.	35
Figura 14 - Arquitetura da RNA ELM.	36
Figura 15 - Algoritmo do Filtro de Kalman.	40
Figura 16 - Algoritmo do Filtro de Partículas.	43
Figura 17 - Algoritmo da Reamostragem.	44
Figura 18 - Algoritmo do Filtro de Partículas com Reamostragem.	44
Figura 19 - Fluxograma do Filtro de Kalman <i>Unscented</i> .	46
Figura 20 - Degradação da capacidade por ciclos usando RNA ELM-RW9.	48
Figura 21 - Estimativa do último ciclo de descarga usando RNA ELM da bateria RW9.	49
Figura 22 - Degradação da capacidade por ciclos usando RNA ELM-RW10.	49
Figura 23 - Estimativa do último ciclo de descarga usando RNA ELM da bateria RW10.	50
Figura 24 - Validação do modelo da capacidade da bateria RW9 com ELM.	51
Figura 25 - Validação do modelo da capacidade da bateria RW10 com ELM	51
Figura 26 - Degradação da capacidade por ciclos usando LMS-RW9.	52
Figura 27 - Estimativa do último ciclo de descarga usando LSM-RW9.	53
Figura 28 - Degradação da capacidade por ciclos usando LMS-RW10.	53
Figura 29 - Estimativa do último ciclo de descarga usando LSM-RW10.	54
Figura 30 - Validação do modelo da capacidade da bateria RW9 com LSM	55
Figura 31 - Validação do modelo da capacidade da bateria RW10 com LSM	55
Figura 32 - Degradação da capacidade por ciclos usando KF-RW9.	56

Figura 33 - Estimativa do último ciclo de descarga usando KF-RW9.	57
Figura 34 - Degradação da capacidade por ciclos usando KF-RW10.	58
Figura 35 - Estimativa do último ciclo de descarga usando KF-RW10.	58
Figura 36 - Validação do modelo da capacidade da bateria RW9 com KF.	59
Figura 37 - Validação do modelo da capacidade da bateria RW10 com KF	60
Figura 38 - Degradação da capacidade por ciclos usando PF-RW9.	61
Figura 39 - Estimativa do último ciclo de descarga usando KF-RW9.	62
Figura 40 - Degradação da capacidade por ciclos usando PF-RW10.	62
Figura 41 - Estimativa do último ciclo de descarga usando PF-RW10.	63
Figura 42 - Validação do modelo da capacidade da bateria RW9 com PF.	64
Figura 43 - Validação do modelo da capacidade da bateria RW10 com PF	64
Figura 44 - Degradação da capacidade por ciclos usando UKF-RW9.	65
Figura 45 - Estimativa do último ciclo de descarga usando IKF-RW9.	66
Figura 46 - Degradação da capacidade por ciclos usando UKF-RW10.	66
Figura 47 - Estimativa do último ciclo de descarga usando UKF-RW10.	67
Figura 48 - Validação do modelo da capacidade da bateria RW9 com UKF	68
Figura 49 - Validação do modelo da capacidade da bateria RW10 com UKF.	68

LISTA DE TABELAS

Tabela 1 - Comparativo entre Tipos Baterias – Características Técnicas.	27
Tabela 2 - Comparativo entre Tipos Baterias – Características de Mercado.	27
Tabela 3 - Comparação dos Resultados do R^2 da bateria RW9.	69
Tabela 4 - Comparação dos Resultados do R^2 da bateria RW10.	70
Tabela 5 - Comparação dos Resultados do RMSE da bateria RW9.	70
Tabela 6 - Comparação dos Resultados do RMSE da bateria RW10.	71
Tabela 7 - Resultados do R^2 das curvas de descarga da bateria RW9.	71
Tabela 8 - Resultados do R^2 das curvas de descarga da bateria RW10.	71
Tabela 9 - Resultados do RMSE das curvas de descarga da bateria RW9.	71
Tabela 10 - Resultados do RMSE das curvas de descarga da bateria RW10.	72
Tabela 11 - Comparação dos Resultados do R^2 da bateria RW9.	72
Tabela 12 - Comparação dos Resultados do R^2 da bateria RW10	72
Tabela 13 - Comparação dos Resultados do RMSE da bateria RW9	73
Tabela 14 - Comparação dos Resultados do RMSE da bateria RW10.	73

LISTA DE ABREVIATURAS E SIGLAS

SISO	Única Entrada e Única Saída (<i>Single Input Single Output</i>)
ELM	Máquina de Aprendizagem Extremo (<i>Extreme Learning Machine</i>)
RNAs	Redes Neurais Artificiais
LSM	<i>Least Square Method</i>
UFK	Filtro de Kalman Unscented (<i>Unscented Kalman Filter</i>)
UT	Transformação Unscented (<i>Unscented Transformation</i>)
KF	Filtro de Kalman (<i>Kalman Filter</i>)
PF	Filtro de Partículas (<i>Partcles Filter</i>)
SVM	Máquina de Vetor de Suporte (<i>Support vector Machine</i>)
PCA	Análise de Componente Principal (<i>Principal Component Analysis</i>)
RMSE	Raiz do Erro quadrático médio (<i>Root Mean Square Error</i>)
R ²	Coefficiente de Correlação Múltipla
RUL	<i>Remaining Useful Life</i>
PHM	<i>Prognostics and Health Management</i>
CBM	<i>Condition Based Maintenance</i>
RCM	<i>Reability Centered Maintenance</i>
NASA	<i>National Aeronautics and Space Administration</i>
UAV	<i>Unmanned Aerial Vehicle</i>
VTOL	<i>Vertical Take-Off Landing</i>
Li-Ion	Íons de Lítio
Li-Po	Polímero de Lítio
NiCd	Níquel Cádmio
SIS	<i>Sequential Importance Sampling</i>
EoD	<i>End of Discharge</i>
SoV	<i>State of Voltage</i>
SoH	State of Health
SoL	<i>State of Life</i>
BHM	<i>Battery Health Modeling</i>
ARC	<i>Ames Research Center</i>

LISTA DE SÍMBOLOS

<i>Cd</i>	Cádmio
<i>Co</i>	Cobalto
<i>Fe</i>	Ferro
<i>C</i>	Capacidade
<i>I</i>	Corrente Elétrica
<i>t</i>	Tempo
<i>V</i>	Tensão Elétrica
<i>C_{final}</i>	Capacidade Final
<i>V_{final}</i>	Tensão Elétrica final
<i>W</i>	Pesos Sinápticos da RNA
<i>b</i>	Bias da RNA
<i>H</i>	Saída da camada oculta da RNA
<i>nc</i>	Número de ciclos
<i>b</i>	Paramento do modelo da capacidade
<i>a</i>	Paramento do modelo de capacidade
<i>t</i>	Tempo ou ciclos
λ	Performance interna da bateria
<i>a</i>	Coefficiente do LMS
<i>x</i>	Valor previsto do LMS (variável independente)
<i>F</i>	Modelo de transição do KF
<i>B</i>	Modelo de transição de estados
<i>w</i>	Ruído do processo
<i>v</i>	Ruído de observação
<i>z</i>	Estado real
<i>x</i>	Sigma
<i>W</i>	Pesos das partículas
<i>P</i>	Covariância

SUMÁRIO

1 INTRODUÇÃO	16
1.1 Prognóstico e Gestão de Saúde.....	16
1.2 Veículos Aéreos Não Tripulados (VANTs)	21
1.3 Objetivos.....	22
1.3.1 <i>Objetivo Geral</i>	22
1.3.2 <i>Objetivos Específicos</i>	22
1.4 Produções Científicas	23
1.5 Organização do Trabalho.....	23
2 BATERIAS DE ÍONS DE LÍTIO.....	24
2.1 Modos de Falha	27
2.2 RUL em Baterias	29
2.3 Base de Dados da NASA.....	30
3 MÉTODOS E TÉCNICAS.....	33
3.1 Preparação para a Estimativa da Degradação da Capacidade nas Baterias Li-Ion.....	33
3.2 Preparação para a Estimativa das Curvas de Descarga nas Baterias Li-Ion.....	34
3.3 Redes Neurais Artificiais <i>Extreme Learning Machine</i>	34
3.4 Método dos Mínimos Quadrados	36
3.5 Filtro de Kalman.....	39
3.6 Filtro de Partículas.....	41
3.7 Filtro de Kalman <i>Unscented</i> (UKF)	44
4.1 Resultados da RNA ELM	47
4.1.1 <i>Resultados da RNA ELM com validação das estimativas</i>	50
4.2 Resultados dos Mínimos Quadrados	52
4.2.1 <i>Resultados dos Mínimos Quadrados com validação das estimativas</i>	54
4.3 Resultados do Filtro de Kalman	56
4.3.1 <i>Resultados do Filtro de Kalman com validação das estimativas</i>	59
4.4 Resultado do Filtro de Partículas.....	60
4.4.1 <i>Resultados do Filtro de Partículas com validação das estimativas</i>	63
4.5 Resultados do Filtro de Kalman <i>Unscented</i>	65
4.5.1 <i>Resultados do Filtro de Kalman Unscented com validação das estimativas</i>	67
4.6 Análise Geral dos Resultados	69
4.6.1 Análise Geral dos Resultados dos modelos de validação	72
5 CONSIDERAÇÕES FINAIS.....	74
5.1 Propostas para Trabalhos Futuros.....	75
REFERÊNCIAS	76
ANEXO A – IMAGENS DO ÚLTIMO CICLO DE DESCARGA DE TENSÃO COM	

BAIXA CORRENTE PARA O CICLO DE DESCARGA DA BATERIA RW9	83
ANEXO B – IMAGENS DO PERFIL DE TENSÃO DE DESCARGA E DA DEGRADAÇÃO DA CAPACIDADE DA BATERIA RW9	84
ANEXO C – IMAGENS DA REFERÊNCIA DE DESCARGA COM PERÍODO APÓS DESCARGA DE TENSÃO E PULSOS DE DESCARGA DE TENSÃO DA BATERIA RW9	85
ANEXO D – IMAGENS DOS 50 PRIMEIROS PONTOS DE TENSÃO, DA CORRENTE E TEMPERATURA DA BATERIA RW9	86
ANEXO E – IMAGENS DOS ÚLTIMOS 50 PONTOS DE TENSÃO, DE CORRENTE E DE TEMPERATURA DA BATERIA RW9	87
ANEXO F – IMAGENS DO ÚLTIMO CICLO DE DESCARGA DE TENSÃO COM BAIXA CORRENTE PARA O CICLO DE DESCARGA DA BATERIA RW10	88
ANEXO G – IMAGENS DO PERFIL DE TENSÃO DE DESCARGA E DA DEGRADAÇÃO DA CAPACIDADE DA BATERIA RW10	89
ANEXO H – IMAGENS DA REFERÊNCIA DE DESCARGA COM PERÍODO APÓS DESCARGA DE TENSÃO E PULSOS DE DESCARGA DE TENSÃO DA BATERIA RW10	91
ANEXO I – IMAGENS DOS 50 PRIMEIROS PONTOS DE TENSÃO, DA CORRENTE E TEMPERATURA DA BATERIA RW10.....	92
ANEXO J – IMAGENS DOS ÚLTIMOS 50 PONTOS DE TENSÃO, DE CORRENTE E DE TEMPERATURA DA BATERIA RW10	93
ANEXO L –VALORES DE PREDIÇÃO DOS DADOS DE CAPACIDADE E ESTIMAÇÃO DO MODELO COM TODOS OS MÉTODOS	94

1 INTRODUÇÃO

1.1 Prognóstico e Gestão de Saúde

Após a Revolução Industrial e o aumento de produção em larga escala, a indústria precisou evoluir em vários aspectos. Nesta evolução, as máquinas e ferramentas se tornaram cada vez mais complexas e essenciais, necessitando de cuidados cada vez mais específicos para manter sua disponibilidade.

A princípio, empregava-se apenas a manutenção corretiva, que ocorria quando o equipamento apresentava falha. Esta gera altos custos devido à indisponibilidade dos ativos, que impacta diretamente na produção, na entrega de determinado serviço ou na segurança. Com o tempo, viu-se a necessidade de realizar manutenções preventivas, que buscavam agir antes do problema, prevenindo as falhas. Estas, porém, também são caras, visto que devem ser realizadas periodicamente, muitas vezes sem necessidade, gerando custos de mão-de-obra e material. Posteriormente, implantou-se a manutenção preditiva, que utiliza equipamentos para coleta de dados e análises a fim de compreender melhor a condição atual do equipamento, sendo possível diagnosticar o mesmo e programar a troca de componentes que apresentem um alto grau de degradação antes da falha (TORRES; MACHADO; SOUZA, 2005).

O ramo industrial tende a se tornar cada vez mais competitivo, o que leva a uma busca constante por redução de custos. Esta necessidade de reduzir custos fez com que os estudos de engenharia buscassem alternativas aos meios convencionais de manutenção (BIZARRIA, 2009; OOIDJEVAAR et al., 2019). Uma destas alternativas é a busca pela operação prolongada do sistema produtivo a plena carga sem perder a eficácia do mesmo e, para isso, torna-se necessário conhecer e controlar todas as variáveis que possam acarretar em falha e parada de produção. Sendo assim, a aquisição, tratamento e análise de dados é de extrema importância para detectar a real necessidade de manutenção, bem como planejar o período ótimo em que deve ocorrer a parada dos equipamentos para reparo (OOIDJEVAAR et al., 2019; TORRES; MACHADO; SOUZA, 2005).

Os meios para manutenção continuam em constante evolução e estudos são feitos para desenvolver novos métodos mais eficientes e com menores custos que garantam a operação dos equipamentos. Os modelos convencionais de supervisão de processos e variáveis vêm sendo substituídos por métodos mais elaborados que utilizam técnicas de engenharia e inteligência computacional (SILVA, 2008).

Com o uso destas técnicas é possível evoluir do diagnóstico para o prognóstico de falhas. A capacidade de monitorar, prever falhas e se antecipar a elas é financeiramente interessante, visto que a manutenção pode ser melhor planejada e programada, bem como ser feito um melhor e mais assertivo gerenciamento de estoque. Estas vantagens têm dado ao um grande enfoque à pesquisa de prognóstico de falhas (LEÃO, 2011).

Para um sistema de prognóstico de falhas, precisa-se de um indicador que quantifique a degradação ou saúde de um componente específico. Com o monitoramento deste indicador, é possível detectar falhas incipientes e estimar quando o mesmo irá atingir um limiar de falha, provocando a falha funcional do sistema. A falha incipiente é uma condição de falha que não inviabiliza o funcionamento da máquina. A falha funcional, por sua vez, impacta diretamente no funcionamento da máquina, tornando-a indisponível para a sua função (GOMES; GALVÃO; YONEYAMA, 2012).

A estimação do instante provável de falha ou da vida útil remanescente (*Remaining Useful Life* – RUL) é uma das principais técnicas no estudo de prognóstico e gestão de saúde (*Prognostics and Health Management* – PHM). Este conceito é parte do que se chama de Manutenção Baseada em Condição (*Condition Based Maintenance* – CBM), que se vê como uma alternativa à Manutenção Centrada em Confiabilidade (*Reability Centered Maintenance* – RCM) (LEÃO, 2011; SOUALHI et al., 2018). A filosofia da CBM utiliza a aquisição e análise de dados para determinar as condições do sistema e seus modos de falha a fim de detectar a necessidade de manutenção antes de uma falha funcional (BIZARRIA, 2009). Dessa forma, é possível reduzir o número de manutenções sistemáticas exigidas no conceito da RCM, bem como nas falhas que estas manutenções, quando mal executadas, podem vir a causar (LEÃO, 2011).

Os estudos de PHM tiveram início na década de 70, quando o Ministério de Defesa dos Estados Unidos passou a monitorar a vibração em rotores de helicópteros militares, buscando segurança e redução de custos com manutenção em aeronaves civis e militares (PENNA, 2011).

O PHM mescla o estudo de mecanismos e modos de falha com a gestão de ciclo de vida. O estudo de prognóstico de falhas estrutura-se em quatro fundamentos (UCKUN; GOEBEL; LUCAS, 2008):

- As condições ambientais, o tempo e o uso levam ao desgaste natural de sistemas eletromecânicos;
- O envelhecimento é um processo monotônico que leva à degradação física e/ou química;

- É possível detectar sinais de envelhecimento antes da falha funcional;
- Há uma correlação entre o envelhecimento de um componente e um modelo de degradação.

A estrutura de um sistema PHM pode ser definida de acordo com um padrão de seis camadas OSA-CBM (*Open System Architecture for Condition Based Maintenance*). Estas seis camadas são definidas na linguagem ULM (*Unified Modeling Language*) de acordo com tendências técnicas, industriais, militares e comerciais (ALVES, 2010).

O fluxograma das seis camadas OSA-CBM é ilustrado pela Figura 1 e estas são descritas como (DISCENZO et al., 2001; ALVES, 2010):

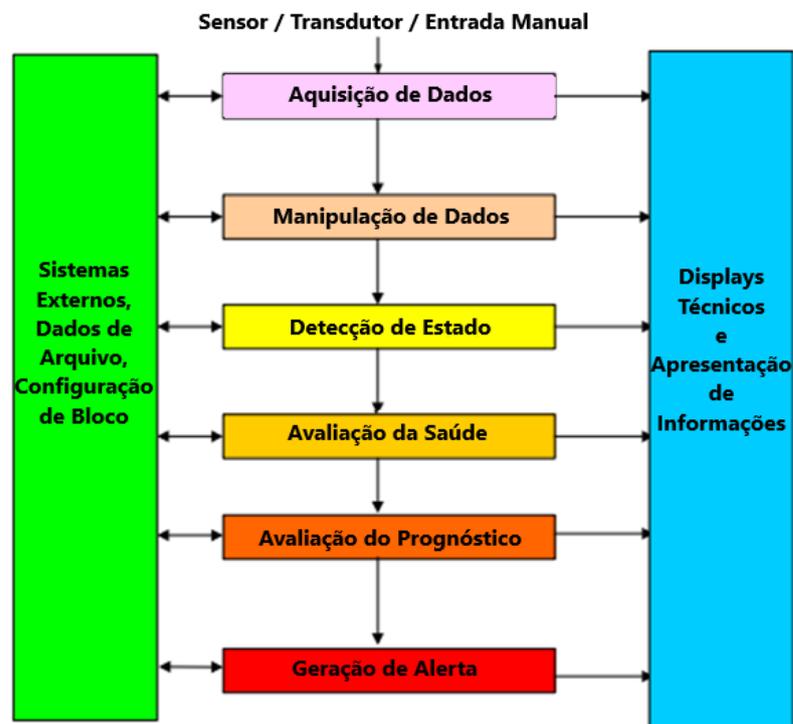
- Aquisição de Dados (*Data Acquisition – DA*): leitura de parâmetros analógicos através de transdutores, conversão destes em sinais digitais e armazenamento;
- Manipulação de Dados (*Data Manipulation – DM*): processamento digital dos sinais adquiridos na etapa anterior;
- Detecção de Estado (*State Detection – SD*): comparação entre os dados obtidos pelo processamento digital e características pré-definidas;
- Avaliação de Saúde (*Health Assessment – HA*): análise de dados históricos e dados adquiridos na etapa de detecção de estado para determinar as condições atuais de saúde do sistema estudado;
- Avaliação Prognóstica (*Prognostic Assessment – PA*): previsão de estado de saúde futuro, com uma incerteza associada, com base no estado de saúde atual definido na etapa anterior;
- Geração de Alertas (*Advisory Generation – AG*): interface para mostrar ao usuário final o estado de saúde do sistema, bem como alertas quando este estado não é satisfatório.

As metodologias empregadas para prognósticos de falhas podem ser divididas em três classes principais: baseadas em dados estatísticos, baseadas em séries temporais, baseadas em modelos analíticos. (BIZARRA, 2009). A Figura 2 ilustra a hierarquia destas três classificações com base na complexidade e na aplicabilidade das mesmas. Ainda é possível encontrar híbridos entre estas três classes mencionadas (ALOZIE et al., 2019).

Na base da pirâmide está a metodologia que utiliza dados históricos de falhas para, a partir de modelos estatísticos, ajustar a curvas de distribuição de probabilidade para calcular as probabilidades de falha de um componente e assim prever a vida remanescente do mesmo. Este é o método mais simples e com aplicabilidade mais abrangente.

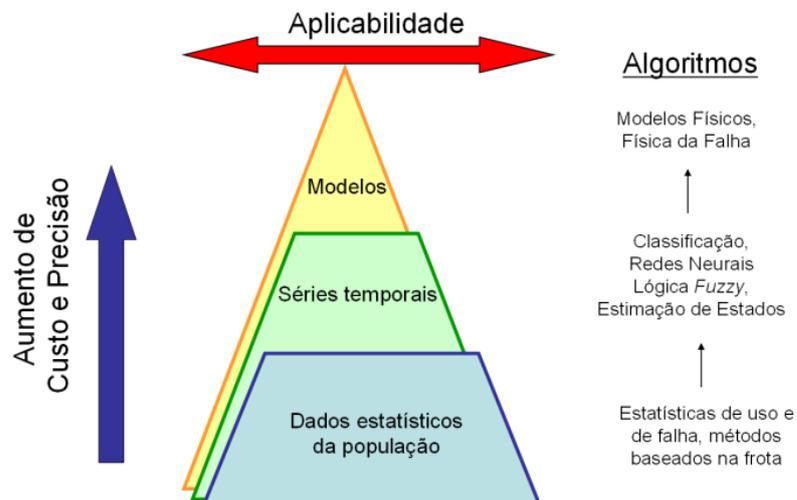
No meio da pirâmide estão os métodos baseados em séries temporais ou em análise de tendências. Estes necessitam de sensores que fazem leituras de parâmetros do componente estudado. Com base nos padrões de falhas conhecidos e no estado atual da máquina, utilizam-se técnicas de classificação, inteligência computacional ou de estimação de estados para determinar a degradação e o tempo de falha desta, conforme ilustra a Figura 3.

Figura 1 - Fluxograma OSA-CBM.



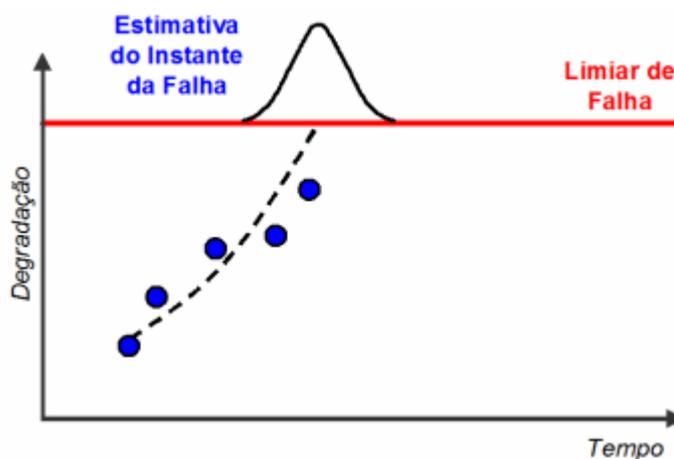
Fonte: Adaptado de ALVES (2010).

Figura 2 – Hierarquia das Abordagens de Prognóstico de Falhas.



Fonte: BIZARRIA (2009).

Figura 3 - Exemplo de Prognóstico de Falha com Séries Temporais.



Fonte: RODRIGUES (2013).

No topo da pirâmide estão os métodos baseados em modelos analíticos. Estes são os mais complexos, pois é necessário, além da presença de sensores, o conhecimento de todo o equacionamento matemático relativo ao componente ou máquina estudada. As condições operacionais são simuladas de acordo com o modelo físico do sistema e comparadas com os dados adquiridos em campo (RODRIGUES, 2013; EKER et al., 2019).

A aplicação do PHM pode trazer uma série de benefícios, como o aumento da disponibilidade e redução de paradas não-programadas, um melhor planejamento das ações de manutenção, auxílio no isolamento das falhas, otimização na escolha das máquinas que serão utilizadas, melhoria no gerenciamento de estoques, aumento na segurança, maximização da vida útil dos componentes que possuem período fixo de troca e redução significativa de custos (ALVES, 2010; RODRIGUES, 2013; EKER et al., 2019; SOUALHI et al., 2018).

O trabalho de (SOUALHI et al., 2018) faz um estudo de diferentes técnicas de processamento de sinais para uso como estratégia de PHM em componentes industriais, aplicados a monitoramento de rolamentos e caixas de engrenagens. Uma estrutura de prognóstico baseada em modelo foi desenvolvida para aplicação em turbinas a gás de aeronaves em (ALOZIE et al., 2019).

Um modelo híbrido baseado em dados e em modelo para previsão de estado foi proposto por (EKER et al., 2019), onde é utilizado Filtro de Partículas para previsão de quebra e entupimento de filtro. Em (ATAMURADOV et al., 2017) é discutida a implementação e algumas ferramentas de PHM voltadas para profissionais de manutenção, com exemplos aplicados na indústria ferroviária. Na pesquisa de (BÖHM, 2017), este fez a

previsão da RUL em mecanismos de comutação ferroviária através de técnicas de classificação utilizando redes neurais artificiais e máquina de vetor de suporte (SVM).

1.2 Veículos Aéreos Não Tripulados (VANTs)

Nos últimos anos, desenvolveu-se na indústria aeronáutica os Veículos Aéreos Não Tripulados (VANTs) ou, do inglês, *Unmanned Aerial Vehicle* (UAV), aeronaves que não necessitam de pilotos embarcados, podendo ser controladas remotamente ou voando de forma autônoma, descartáveis ou recuperáveis, com carga letal ou não-letal (ABDULHAMID, 2016; CÂNDIDO, 2015; FISCHER, 2017).

Os VANTs se encontram nas mais variadas configurações e tamanhos, sendo classificados em asas-fixas (aeronaves convencionais), asas rotativas (helicópteros e multicópteros) e uma combinação de ambos (conhecida como *Vertical Take-Off Landing* – VTOL). Cada um dos diferentes modelos possui características que determinam suas muitas aplicações, como capacidade de carga, velocidade, flexibilidade de manobra e autonomia (ABDULHAMID, 2016; CÂNDIDO, 2015; FISCHER, 2017).

O crescente uso destes veículos é devido principalmente à redução de riscos à vida humana e à sua menor exposição a radares. Além disso, graças a seu dinamismo, estes receberam uma ampla gama de utilização, como aplicações militares, comerciais e civis (CÂNDIDO, 2015; BORGES, 2017). Na área comercial são feitas inspeções em dutos, telhados, manutenção em linhas de transmissão de alta tensão e topografia, por exemplo. Na área militar se utiliza para supervisionar e monitorar áreas de difícil acesso, lançamentos de mísseis, buscas, resgates e vigilância (SANTOS; LÓPEZ; MORATA, 2010; CÂNDIDO, 2015; ABDULHAMID, 2016).

Existem diversos desafios para controle destes equipamentos, pois as condições de voo dependem de fatores externos e os modelos destas aeronaves são não-lineares (ABDULHAMID, 2016). A exposição às mais diversas condições ambientais propiciam desgastes mecânicos e elétricos, que podem acarretar em falhas. Entretanto, um dos principais desafios é o gerenciamento energético dos VANTs. Segundo (CÂNDIDO, 2015), estes veículos são instáveis em malha aberta, necessitam de sistemas embarcados complexos, além de precisar contornar situações climáticas, como ventos e chuvas, e por isso consomem grande quantidade de energia (MELO, 2016). Para contornar este problema, usualmente são instaladas baterias superdimensionadas para que a missão não seja comprometida.

Em muitos casos, os VANTs são de pequeno porte e a instalação de grandes baterias torna-se inviável devido ao seu peso, que pode chegar a 50% do peso total do equipamento (KUMAR, V.; MICHAEL, N, 2012).

Em (MELO, 2016), foram realizados estudos onde a autonomia da bateria estava em torno de 15 a 18 minutos, porém, por questões de segurança, apenas 65% da carga era utilizada para fins de monitoramento e os outros 35% para garantir o retorno seguro da aeronave.

O trabalho de (OSSAI, 2018) utiliza modelamento não linear considerando incertezas no estado da carga de baterias de íons de lítio a fim de determinar o estado de saúde das mesmas. Em (PÉREZ et al., 2018) são discutidos os principais aspectos da impedância interna de baterias de íons de lítio para uso em algoritmos de degradação.

A estimação do estado de saúde de baterias de íons de lítio com base em modelos de decaimento da capacidade e aumento da resistência interna foi feita por (GUHA, 2018) utilizando Filtro de Partículas. Os conceitos de PHM têm obtido grande destaque na indústria aeronáutica, visto a possibilidade de impactos positivos na área de manutenção (GOMES et al., 2013). Algoritmos para prognóstico foram utilizados para prever o tempo de voo restante em um VANT alimentado por uma bateria de íons de lítio em (HOGGE et al., 2018).

Sendo assim, é de grande importância o estudo do gerenciamento energético destes para que se garanta a finalização das missões com segurança, redução de custos com manutenção e otimização no tamanho da bateria.

1.3 Objetivos

1.3.1 Objetivo Geral

Propor estratégia de PHM para o gerenciamento baterias de íons de lítio aplicadas em veículos aéreos não tripulados.

1.3.2 Objetivos Específicos

- Tratar e analisar dados de descarga de baterias de íon-lítio;
- Implementar técnicas para estimação de parâmetros;
- Prever a descarga e a RUL da bateria através de técnicas para estimação de parâmetros do SoV e da capacidade, respectivamente;
- Realizar uma análise comparativa entre as técnicas implementadas.

1.4 Produções Científicas

Durante o desenvolvimento da pesquisa foram originados os seguintes artigos científicos:

- COSTA, E. F.; SOUZA, D. A.; ARAÚJO, M. S.; PINTO, V. P.; PEIXOTO, A. M.; JUNIOR, E. P. C. **Estimate of Discharge of Lithium-Ion Batteries.** 7th World Conference on Information Systems and Technologies, 2019.
- COSTA, E. F.; SOUZA, D. A.; PINTO, V. P.; ARAÚJO, M. S.; PEIXOTO, A. M.; JUNIOR, E. P. C. **Prediction of Lithium-Ion Battery Capacity in UAVs.** 6th International Conference on Control, Decision and Information Technologies. 2019. (Aceito para publicação).

1.5 Organização do Trabalho

No Capítulo 1 será mostrado uma revisão sobre prognóstico e gestão da vida útil de equipamentos e componentes, bem como o conceito de veículos aéreos não tripulados, algumas aplicações e desafios. Apresentou-se também os objetivos deste trabalho e as produções científicas provenientes do mesmo.

No Capítulo 2 será discutido o funcionamento das baterias de íons de lítio e parâmetros para medição de sua saúde. Foi explanada brevemente a base de dados de descarga de baterias da NASA utilizada nas simulações.

No Capítulo 3 apresentará as discussões dos métodos de Mínimos Quadrados, rede neural *Extreme Learning Machine*, Filtro de Kalman, Filtro de Partículas e Filtro de Kalman *Unscented*, utilizados para predição de descarga e degradação das baterias.

No Capítulo 4 serão mostrados e discutidos os resultados das predições e avaliados pelo coeficiente de correlação múltipla (R^2), pelo custo computacional e pela Raiz do Erro Quadrático Médio (RMSE). No Capítulo 5 são comentadas as considerações finais do trabalho e sugeridas propostas para estudos futuros.

2 BATERIAS DE ÍONS DE LÍTIO

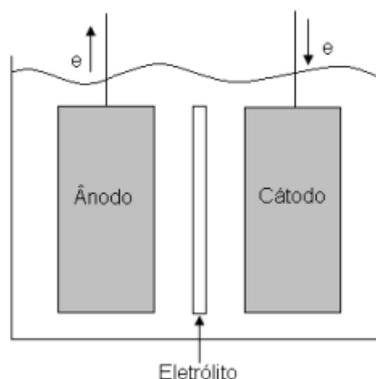
As baterias estão cada vez mais sendo utilizadas em VANTS, substituindo os propulsores a combustão. O uso de baterias reduz o peso do equipamento e proporciona um melhor controle de potência (SOUZA, 2016; HUGGINS, 2009).

As baterias possuem células, conectadas em série ou paralelo, que armazenam e fornecem energia elétrica a um equipamento através de reações eletroquímicas. Para isso são necessários dois eletrodos, um ânodo (polaridade negativa) e um cátodo (polaridade positiva), e uma substância eletrolítica, ou eletrólito, que separa os eletrodos e é o meio responsável pelo transporte de cargas através de íons (SCHINEIDER, 2011). A Figura 4 ilustra o esquema de uma célula.

No processo eletroquímico, o ânodo “doa” elétrons ao cátodo. A capacidade de “doar” e “receber” elétrons é definida como potencial de eletrodo padrão do material. A tensão elétrica na célula é definida pela diferença entre o potencial do cátodo e do ânodo (SOUZA, 2016).

A descarga da bateria ocorre de maneira não-linear devido a sua operação. A Figura 6 exemplifica o estado de operação de uma bateria e como se concentram os elétrons eletrodos na vizinhança de um eletrodo (SAUSEN, 2008).

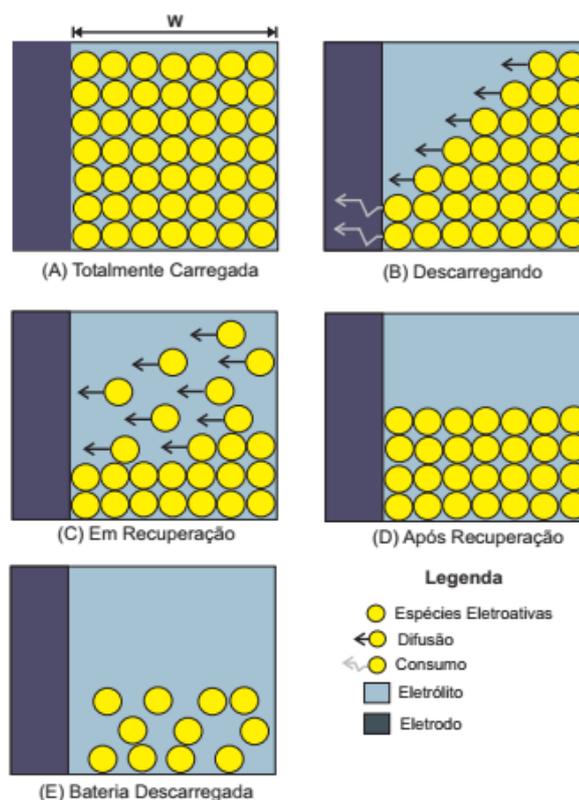
Figura 4 – Esquema de uma Célula Eletroquímica.



Fonte: SCHINEIDER (2011).

Na Figura 5 (A), a bateria completamente carregada possui a concentração máxima de elétrons na superfície do eletrodo com distribuição uniforme de comprimento w . Quando conectada a uma carga, o processo de descarga da bateria se inicia e a quantidade de elétrons próximas ao eletrodo diminui, encadeando a difusão dos elétrons que buscam reequilibrar a concentração, como mostra a Figura 5 (B) (SAUSEN, 2008).

Figura 5 – Operação de uma Bateria.



Fonte: SAUSEN (2008).

Durante a operação, caso haja uma redução no valor da corrente consumida, a bateria assume o chamado efeito de recuperação, onde os elétrons se redistribuem uniformemente na superfície do eletrodo pela difusão, como mostra a Figura 5 (D). A Figura 5 (D) mostra os elétrons uniformemente distribuídos após a recuperação, porém com uma capacidade menor (SAUSEN, 2008).

Quando a tensão da bateria atinge um limite menor que o da tensão de corte, impossibilita a continuação das reações eletroquímicas e se torna indisponível, conforme ilustra a Figura 5 (E) (SAUSEN, 2008).

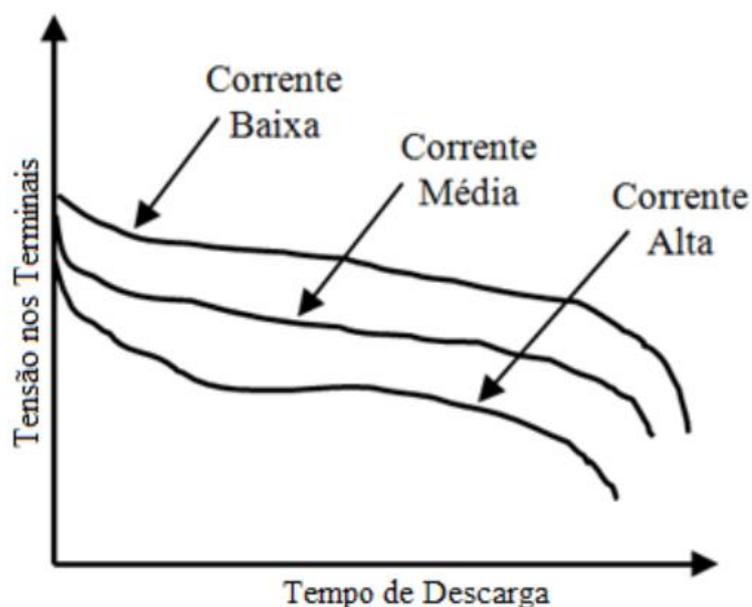
As características da bateria, como capacidade e tensão, dependem do material utilizado nos eletrodos e eletrólito. Nas baterias de íons de lítio o cátodo é formado por grãos de óxidos de metais de transição litados, sendo mais comum o uso do LiCoO_2 por sua estabilidade e grande densidade energética. Para o ânodo se utiliza grafite, metal de lítio ou compostos de liga de lítio. O eletrólito pode ser sólido (politetrafluoretileno, óxido de polietileno, por exemplo) ou líquido (etileno, carbonato, por exemplo) (HARDING ENERGY INC, 2008).

Nos casos onde ocorrem descarga excessiva, óxido de lítio é produzido em uma reação irreversível. No caso de sobrecarga, é produzido óxido de cobalto em uma reação também irreversível (PENNA, 2011).

As baterias são especificadas não só pela tensão, mas pela sua capacidade em Ah. Uma bateria com 1Ah, por exemplo, é capaz de fornecer uma corrente de 1 A durante uma hora a determinada carga.

Entretanto, a corrente consumida em uma bateria não costuma ser constante, ocasionando variações na tensão da bateria. Como se pode ver na Figura 6, correntes diferentes acarretam em diferentes curvas de descarga. Quanto maior a corrente de descarga, menor a autonomia da bateria.

Figura 6 – Curva de Descarga de Bateria com Diferentes Correntes.



Fonte: SOUZA (2016).

Além das baterias de íon-lítio, existem outras opções presentes no mercado, como as de chumbo-ácido, Li-Po, NiCd, entre outras. A bateria de Li-Íon apresenta como vantagem frente às outras uma grande capacidade inicial e conservação da mesma, baixa taxa de autodescarga, elevado número de ciclos de carga/descarga, suporta temperaturas mais frias e são facilmente fabricadas.

Como principal desvantagem, está a alta reatividade do lítio, que é um material inflamável. Portanto, faz-se necessário um circuito especial que controle as cargas e descargas

da mesma a fim de evitar danos à bateria e ao equipamento (SOUZA, 2016). As Tabelas 1 e 2 mostram um comparativo entre diversos tipos de baterias.

Tabela 1 – Comparativo entre Tipos Baterias – Características Técnicas.

	Peso Relativo	Temperatura (°C)	Tensão por Célula	Autodescarga
Chumbo-ácido	Muito pesado	-20 a 50	2	5%
Níquel-cadmio	Pesado	-40 a 60	1,2	20%
Níquel-metal	Moderado	-20 a 60	1,2	30%
Lítio-íon	Leve	-20 a 60	3,7	10%
Lítio-polímero	Leve	0 a 60	3,7	10%

Fonte: Adaptado de HARDING ENERGY INC (2008).

Tabela 2 – Comparativo entre Tipos Baterias – Características de Mercado.

	Ciclo de Vida	Vida em Estoque	Custo Relativo	Manutenção Requerida	Comercialização Desde
Chumbo-ácido	200-300	6 meses	X	3 a 6 meses	1970
Níquel-cadmio	500-1500	6 meses	2X	30 a 60 dias	1950
Níquel-metal	300-500	12 meses	2,5X	60 a 90 dias	1990
Lítio-íon	500-1000	12 meses	4X	não requerida	1991
Lítio-polímero	300-500	12 meses	5X	não requerida	1999

Fonte: PENNA (2011).

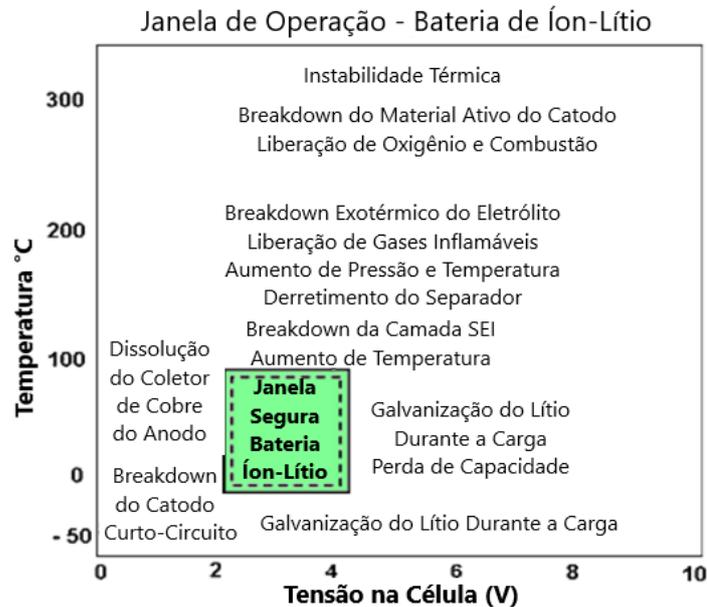
Ponderando todas as características técnicas e de mercado, escolheu-se para estudo em VANTs neste trabalho o uso de baterias de íons de lítio.

2.1 Modos de Falha

As baterias operam de acordo com suas faixas de tensão e temperatura determinadas, como mostrado anteriormente na Tabela 1. O uso de baterias fora do limite de operação pode acarretar em falhas severas, com danos irreversíveis, e até mesmo em explosão, devido à volatilidade de alguns tipos.

A Figura 7 mostra um gráfico Temperatura x Tensão indicando a janela de segurança onde a bateria de íon-lítio pode operar e alguns dos problemas sofridos quando a bateria é submetida a condições fora da sua janela de segurança.

Figura 7 – Janela de Operação de Baterias de Íon-Lítio.



Fonte: Adaptado de ELECTROPAEDIA (2005).

Os principais modos de falha das baterias de íon de lítio são a sobretensão, subtensão, temperatura e fadiga mecânica, descritos por (PENNA, 2011).

Nos casos de sobretensão, em que a tensão ultrapassa o limite de 4,2 V, a corrente se eleva podendo ocasionar em sobreaquecimento e na galvanização do lítio, que por sua vez acarreta em redução irreversível da capacidade da bateria e curto-circuito.

Quando a bateria descarrega excessivamente (abaixo de 2 V), observa-se o caso de subtensão, onde há degradação dos eletrodos, ocasionando perda permanente de capacidade, aumento da taxa de autodescarga e curto-circuito.

Quando opera em baixas temperaturas, as reações químicas são prejudicadas, reduzindo o transporte de cargas. Em altas temperaturas, a corrente se eleva ocasionando instabilidade térmica, que por sua vez, incorre em liberação de gases inflamáveis que podem encadear uma combustão.

Durante o ciclo de operação de uma bateria os eletrodos expandem e retraem com o armazenamento de íons, que podem acarretar em rachaduras, envelhecimento da célula e aumento da impedância.

2.2 RUL em Baterias

O número de ciclos de carga/descarga antes que a bateria perca significativamente sua capacidade define a vida útil remanescente de uma bateria (SOUZA, 2016). Normalmente se especifica como limiar 30% da capacidade nominal.

Faz parte do ciclo natural da bateria a perda de capacidade. Pode-se observar facilmente que as baterias possuem uma maior autonomia no início de sua vida útil. Com o passar do tempo, o tempo para descarga da bateria reduz consideravelmente.

Para o estudo da RUL de uma bateria podem ser analisados alguns parâmetros, como a capacidade, o estado da carga (SoC – *State of Charge*) e o estado de saúde (SoH – *State of Health*). A capacidade, em Ah, pode ser calculada pela Equação 3 (PENNA, 2011).

$$C = \int_0^{t^{final}} I(t)dt \quad (3)$$

Segundo (SAXENA et al., 2012), o SoC quantifica a carga restante no ciclo de descarga. O mesmo pode ser calculado pela Equação (4) e assume valores entre 0 e 1 (PENNA, 2011).

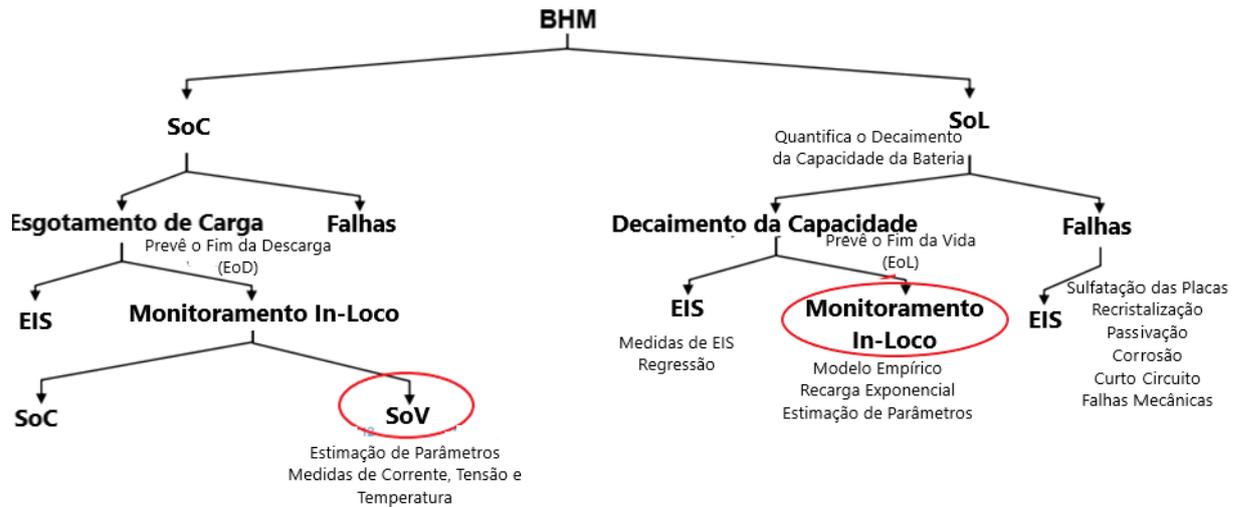
$$SoC(t) = SoC(t - 1) - \frac{1}{C} \int_{t-1}^t I(t)dt \quad (4)$$

Também é possível prever o fim da descarga (EoD – *End of Discharge*) através do monitoramento do estado da tensão (SoV – *State of Voltage*).

O estado de saúde (SoH – *State of Health*) ou estado de vida (SoL – *State of Life*) representa o estado de saúde da bateria e varia entre 0 e 1. Este reduz progressivamente com o passar dos ciclos de carga e descarga da bateria. O SoH é uma medida subjetiva e depende de diversos parâmetros mensuráveis da bateria, como corrente e temperatura (SOUZA, 2016; SAXENA et al., 2012). Sendo assim, não há uma equação definida que o represente.

A Figura 8 mostra uma visão geral do modelamento de saúde de bateria (BHM – *Battery Health Modeling*) sugerido pelo Centro de Pesquisa Ames (ARC – *Ames Research Center*) da NASA. Neste trabalho será vista a predição de descarga e da vida útil através da tensão e degradação da capacidade, respectivamente, como circulado na Figura 8.

Figura 8 – Modelamento de Saúde de Baterias – ARC.



Fonte: Adaptado de SAXENA (2012).

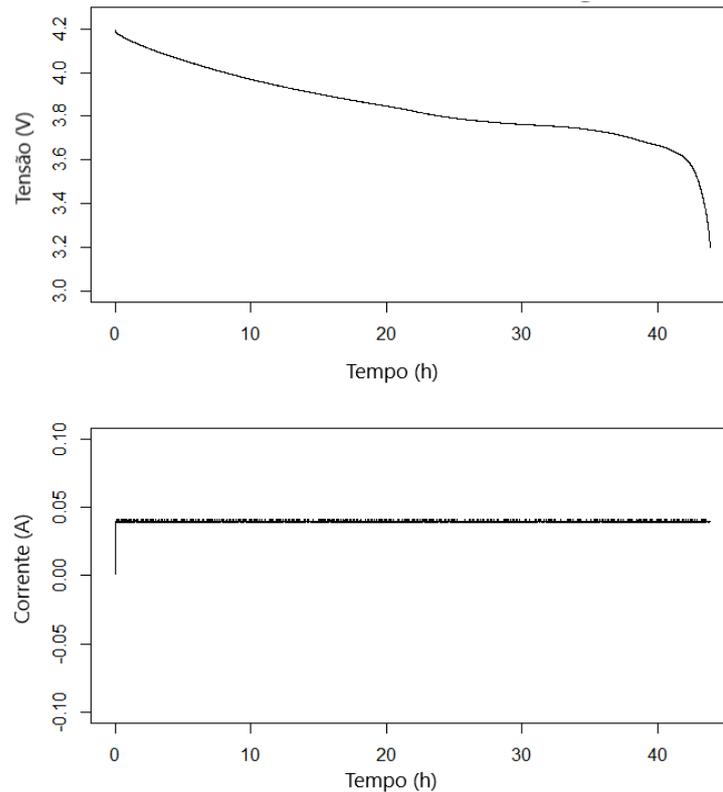
2.3 Base de Dados da NASA

A base de dados utilizada foi coletada no experimento de (BOLE; KULKARNI; DAIGLE, 2014). A mesma possui dados de carga e descarga de quatro baterias de íons de lítio identificadas como RW9, RW10, RW11 e RW12, das quais foram abordadas apenas as duas primeiras neste trabalho. As operações de carga e descarga foram feitas com passeio randômico utilizando correntes de $-4,5A$ a $4,5A$. Cada período de carregamento durou cerca de 5 minutos. Após cinco dias, foram realizadas uma série de ciclos de carga e descarga.

O passeio randômico na carga e descarga da bateria é feito selecionando randomicamente uma corrente do conjunto $\{-4,5A, -3,75A, -3A, -2,25A, -1,5A, -0,75A, 0,75A, 1,5A, 2,25A, 3A, 3,75A, 4,5A\}$, onde as correntes negativas são relacionadas à carga e as positivas à descarga. A corrente é aplicada até que a tensão saia da faixa entre $3,2V$ e $4,2V$ ou passe de 5 minutos.

Também é aplicada uma baixa corrente de descarga ($0,04A$) a fim de observar a tensão de circuito aberto. Na Figura 9, pode-se observar a curva de tensão nos terminais da bateria e baixa corrente de descarga aplicada na mesma. Observa-se que com esta corrente a bateria leva mais de 40 horas para descarregar.

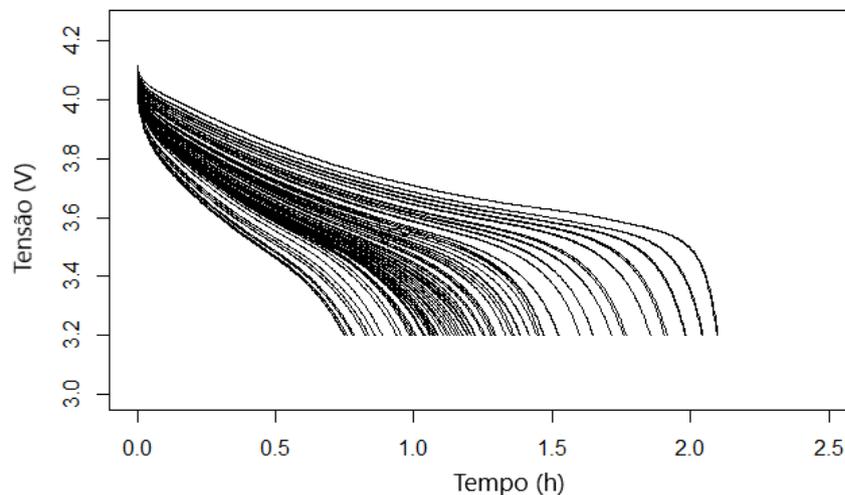
Figura 9 – Ciclo de Baixa Corrente de Descarga.



Fonte: Adaptado de BOLE; KULKARNI; DAIGLE (2014).

Na Figura 10 é possível observar as curvas de Tensão x Tempo de uma bateria após sucessivas descargas. Na primeira descarga, a mesma apresenta uma autonomia de mais de 2 horas, já na última, menos de 1 hora. Este é um comportamento comum, visto que a bateria tem sua saúde degradada no decorrer do experimento.

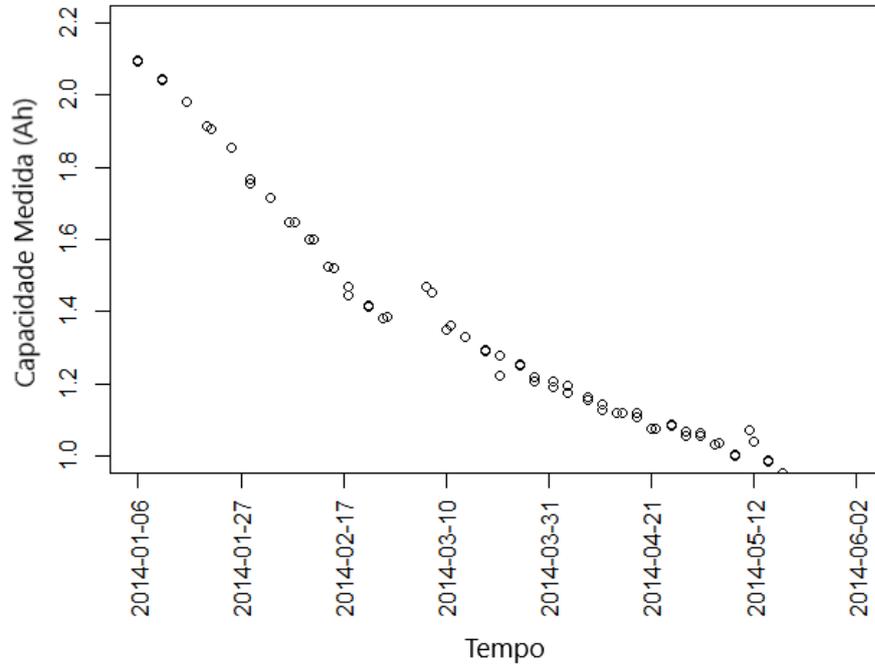
Figura 10 – Tensão na Bateria Após Vários Ciclos de Descarga.



Fonte: Adaptado de BOLE; KULKARNI; DAIGLE (2014).

Conforme a bateria envelhece, a resistência interna cresce e a capacidade de armazenamento de carga decresce, conforme ilustra a Figura 11.

Figura 11 – Degradação da Capacidade Após Vários Ciclos de Descarga.



Fonte: Adaptado de BOLE; KULKARNI; DAIGLE (2014).

3 MÉTODOS E TÉCNICAS

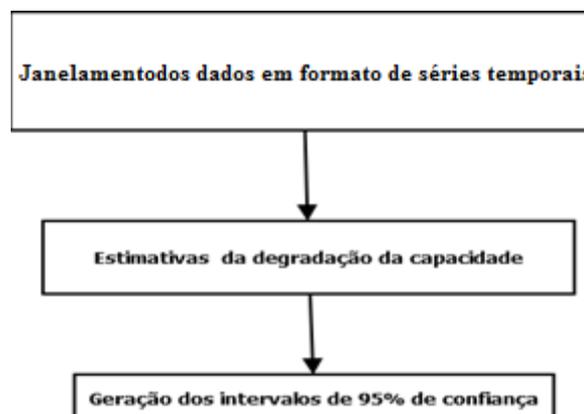
3.1 Preparação para a Estimativa da Degradação da Capacidade nas Baterias Li-Ion

A base de dados de baterias da NASA é usada no trabalho e é sugerido um algoritmo para o cálculo da degradação da capacidade para cada bateria, no qual informa o tempo por mês para a degradação até o fim da capacidade. O preparo dos dados para a estimativa nos algoritmos foi baseado em métodos de séries temporais, que é uma série de pontos de dados indexados (ou listados ou representados graficamente) por ordem de tempo (LIN, JESSICA *et al.*, 2003). Esse conceito se encaixa bem com os dados de tensão e da degradação da capacidade. A bateria de íons de lítio degrada ao longo de ciclos em uso, e o limiar de falha é definido quando a capacidade chega a 30% de seu valor nominal. Segundo o trabalho de (DAWN AN *et al.*, 2003) e (GOEBEL K *et al.*, 2008), uma forma simples do modelo de degradação empírica é expressa por um modelo de crescimento exponencial como segue a equação (5). Essa função é usada para os algoritmos de Filtro de Partículas e o Filtro de Kalman *Unscented*.

$$\lambda = \alpha \cdot \exp(-bt) \quad (5)$$

Antes de estimar a degradação da capacidade das baterias, ocorreu uma organização dos dados em forma de janelamento em séries temporais. Em seguida foi feita a estimativa da degradação da capacidade, e por fim foram calculados os intervalos de confiança com 95%, conforme mostra o fluxograma na Figura 12.

Figura 12 – Fluxograma da metodologia para a estimativa da capacidade.



Fonte: Autoria própria.

3.2 Preparação para a Estimativa das Curvas de Descarga nas Baterias Li-Ion

Do mesmo modo que se estima a degradação, as curvas de descargas também são baseadas no fluxograma da Figura 12, porém os dados estimados são as tensões nos terminais de descarga da bateria. Para o presente trabalho foram usados o último e o antepenúltimo ciclo de descarga em ambas as baterias.

3.3 Redes Neurais Artificiais *Extreme Learning Machine*

As máquinas de aprendizado extremo são redes neurais *feedforward* para classificação, regressão, *clusterização*, aproximação esparsa, compactação e aprendizado de recursos com uma única camada de neurônios. Nesta, os parâmetros de neurônios ocultos (não apenas os pesos que conectam entradas a nós ocultos) não necessitam ser afinados. Esses nós ocultos podem ser designados aleatoriamente e nunca atualizados (isto é, são projeções aleatórias, mas com transformações não-lineares) ou podem ser herdados de seus ancestrais sem serem alterados. Na maioria dos casos, os pesos de saída dos nós ocultos são aprendidos em uma única etapa, o que basicamente equivale a aprender um modelo linear. O nome "*Extreme Learning Machine*" (ELM) foi dado a esses modelos por seu principal inventor, Guang-Bin Huang.

De acordo com seus criadores, esses modelos são capazes de produzir um bom desempenho de generalização e aprendem milhares de vezes mais rápido do que redes treinadas usando *backpropation* (HUANG, GUANG-BIN *et al*, 2006). Na literatura, também é mostrado que esses modelos podem superar as Máquinas de Vetores de Suporte (SVM), fornecem soluções sub-ótimas em aplicações de classificação e regressão (HUANG,, GUANG-BIN *et al*, 2012), (HUANG, GUANG-BIN, 2015) e (HUANG, GUANG-BIN, 2014).

No intervalo entre os anos de 2001 e 2010, os trabalhos com ELM se concentraram principalmente na estrutura de aprendizagem unificada para redes neurais *feedforward* de camada única (SLFNs) "generalizadas", incluindo, mas não limitado, a redes *sigmóides*, redes RBF, redes de limiar (HUANG, GUANG-BIN; QIN-YU ZHU *et al*, 2006), redes trigonométricas, *fuzzy* sistemas de inferência, séries de Fourier (HUANG, GUANG-BIN, LEI CHEN *et al*, 2006) e (RAHIMI, ALI, and BENJAMIN RECHT, 2008), transformada Laplaciana, redes *wavelet* (CAO, JIUWEN *et al*, 2009), entre outras. Uma conquista significativa feita nesses anos foi provar com sucesso as capacidades universais de

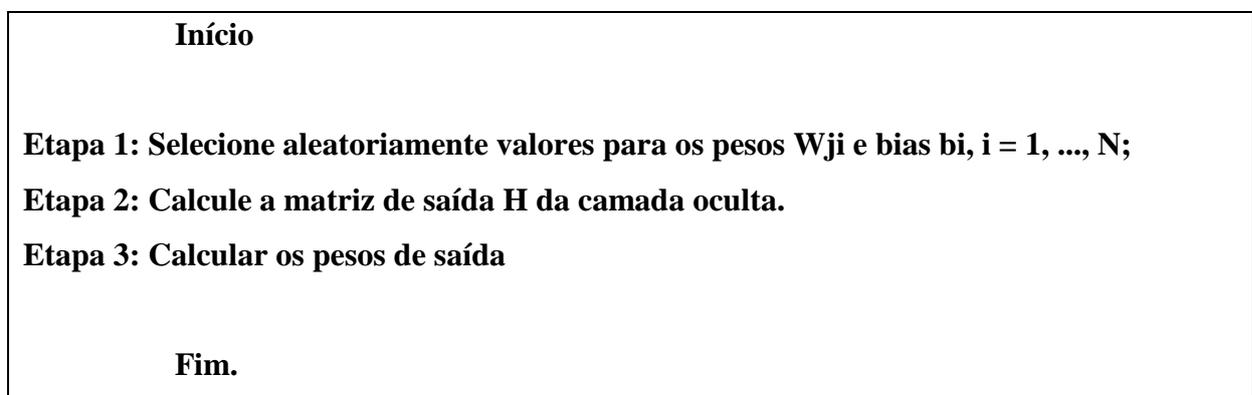
aproximação e classificação da ELM em teoria (HUANG, GUANG-BIN, LEI CHEN *et al*, 2006), (HUANG, GUANG-BIN, LEI CHEN, 2007) e (HUANG, GUANG-BIN, e LEI CHEN, 2008).

De 2010 a 2015, a pesquisa do ELM se estendeu à estrutura de aprendizado unificado para aprendizado de kernel, SVM e alguns métodos típicos de aprendizado de recursos, como Análise de Componentes Principais (PCA) e Fatoração de Matriz Não-Negativa (NMF). É mostrado que o SVM realmente fornece soluções abaixo do ideal em comparação com o ELM, e o ELM pode fornecer o mapeamento de kernel *whitebox*, que é implementado pelo mapeamento de recursos aleatórios do ELM, em vez do kernel do *blackbox* usado no SVM. PCA e NMF podem ser considerados casos especiais em que nós lineares ocultos são usados no ELM (HE, QING, XIN JIN *et al*, 2014) e (KASUN, L. L. C. *et al*, 2016).

A partir de 2015, foi dado um maior enfoque às implementações hierárquicas (HUANG, GUANG-BIN, ZUO BAI *et al*, 2015) e (TANG J. C. D. e GUANG-BIN H, 2016) da ELM. Além disso, desde 2011, foram feitos estudos biológicos significativos que suportam certas teorias de ELM (BARAK O *et al*, 2013), (RIGOTTI, MATTIA *et al*, 2013) e (Fusi, Stefano *et al*, 2015).

A rede ELM tem várias vantagens sobre as outras como: os pesos de entrada e a polarização da camada oculta são escolhidos aleatoriamente, outra vantagem é que os pesos da camada de saída são determinados analiticamente (HUANG, GUANG-BIN *et al*, 2006). A Figura 13 descreve brevemente o algoritmo da rede.

Figura 13 – Algoritmo ELM.



Fonte: Autoria própria.

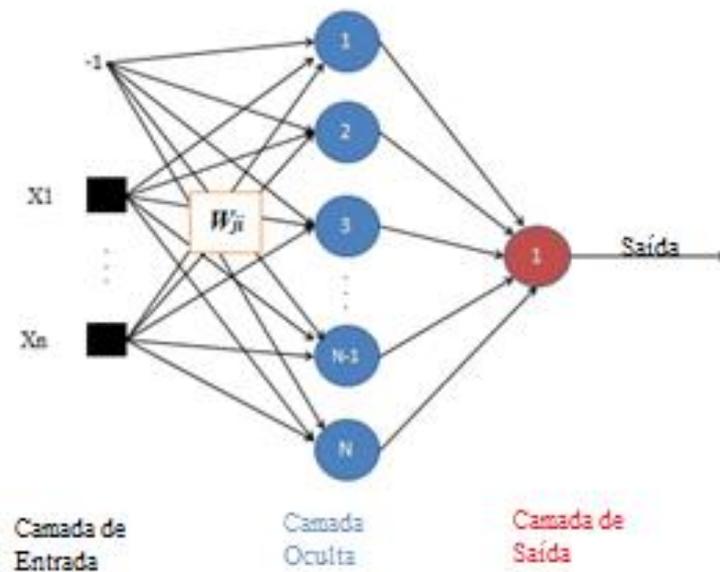
W_{ji} : São os pesos sinápticos

b_i : São os bias

H : Saída da camada oculta

A Figura 14 apresenta a arquitetura da RNA usada para o presente problema. Foram testadas diferentes arquiteturas, conforme alguns parâmetros variados, até se conseguir os resultados esperados.

Figura 14– Arquitetura da RNA ELM.



Fonte: Autoria própria.

A RNA ELM foi o único algoritmo que se utilizou de 2 entradas de dados, além do bias. Os dados de entrada foram indexados em forma de janelamento de 2 pontos de capacidade. Nesse caso as entradas $X1$: capacidade(i), sendo $i=1$ até o total da (capacidade-2), já o $X2$: capacidade($j+1$) até o total da (capacidade - 1), e a saída Y : inicia capacidade($K+2$) até o total da capacidade.

3.4 Método dos Mínimos Quadrados

O método dos mínimos quadrados é uma abordagem padrão na análise de regressão para aproximar a solução de sistemas sobredeterminados, isto é, conjuntos de equações nas quais existem mais equações do que incógnitas. "Mínimos Quadrados" significa que a solução global minimiza a soma dos quadrados dos resíduos nos resultados de cada equação.

A aplicação mais importante está no ajuste de dados. O melhor ajuste no sentido de mínimos quadrados minimiza a soma dos resíduos quadrados (sendo um resíduo a

diferença entre um valor observado e o valor ajustado fornecido por um modelo). Quando o problema tem incertezas substanciais na variável independente (a variável x), então os métodos de regressão simples e de mínimos quadrados têm problemas. Nestes casos, a metodologia necessária para ajustar modelos de erros em variáveis pode ser considerada, em vez daquela para mínimos quadrados.

Problemas dos mínimos quadrados se dividem em duas categorias: lineares (mínimos quadrados ordinários) e mínimos quadrados não-lineares. O problema linear dos mínimos quadrados ocorre na análise estatística de regressão, que tem uma solução de forma fechada. O problema não-linear é geralmente resolvido pelo refinamento iterativo que, em cada iteração o sistema é aproximado por um sistema linear.

Os mínimos quadrados polinomiais descrevem a variância de uma predição da variável dependente como uma função da variável independente e os desvios da curva ajustada. Quando as observações vêm de uma família exponencial e condições suaves são satisfeitas, estimativas de mínimos quadrados e estimativas de máxima verossimilhança são idênticas (CHARNES, A. *et al*, 1976). O método dos mínimos quadrados também pode ser derivado como um método de estimador de momentos.

A técnica de mínimos quadrados se encaixa na Regressão Linear Múltipla Geral. O método dos mínimos quadrados modela a relação entre duas variáveis ajustando uma equação aos dados observados. A equação (6) apresenta a função de ajuste.

$$y = a_0 + a_1x + a_2x^2 + \dots + a_mx^m + \epsilon \quad (6)$$

Onde $a_0 \dots a_m$ são coeficientes polinomiais; $x \dots x^m$: valor previsto da variável independente; ϵ : variável que inclui todos os fatores residuais mais possíveis erros de medição.

Na equação (7) equação é a equação do estimador, onde tem os parâmetros a estimar. Os parâmetros a ser estimados tem formato $na+nb+1$, as variáveis a_i, b_j , é preciso usar as entradas e saídas da planta a ser predita. O $e(k)$ representa o erro de modelagem, erro de medição ou ruído na saída.

$$y(k) = -a_1y(k-1) - a_2y(k-2) - \dots - a_nay(k-na) + \dots \quad (7)$$

$$\dots + b_0u(k-d) + b_1u(k-d-1) + \dots + b_nbu(k-d-nb) + e(k)$$

É possível obter uma nova equação (8) a partir de (9), definindo-se dois vetores:

um de medida, $\varphi(k)$, e outro de parâmetros, $\theta(k)$.

$$y(k) = \varphi^T(k)\theta(k) + e(k) \quad (8)$$

Onde:

$$\varphi^T(k) = [-y(k-1) - y(k-2) \cdots - y(k-na) \quad u(k-d) \cdots u(k-d-nb)] \quad (9)$$

$$\theta^T(k) = [a_1 \quad a_2 \quad a_3 \cdots a_{na} \quad b_0 \quad b_1 \cdots b_{nb}] \quad (10)$$

Por serem executadas N amostras, as quais são usadas para obter a_i e b_j , com isso pode se resultar na equação (11):

$$Y = \phi\theta + E \quad (11)$$

A saída dada por:

$$Y^T = [y(0) \quad y(1) \quad y(2) \cdots y(N-1)] \quad (12)$$

A predição de $\hat{\theta}$, é obtida pelo método dos mínimos quadrados, onde a precisão mais próxima do real é dada por

$$\hat{Y} = \phi \hat{\theta} \quad (13)$$

Para minimizar os critérios da equação (10), é usado o estimador Markov, que também é chamado de mínimos quadrados ponderados.

$$J = \min_{\hat{\theta}} \left\| Y - \phi \hat{\theta} \right\|_w^2 \quad (14)$$

$$J = \left[Y - \phi \hat{\theta} \right]^T W \left[Y - \phi \hat{\theta} \right] \quad (15)$$

As matrizes de ponderações em cada componente de erro são os W, W(i). Aplicando uma derivada em (11) e igualando a “0”, obtém-se a equação (12).

$$\frac{\partial J}{\partial \hat{\theta}} = -2(Y^T W \phi)^T + 2\phi^T W \phi \hat{\theta} = 0 \quad (16)$$

Logo, calculando o estimador dos mínimos quadráticos não-recursivo tem:

$$\hat{\theta} = [\phi^T W \phi]^{-1} \phi^T W Y \quad (17)$$

O estimador é resultante, ao aceita que:

$$\hat{\theta} = \left[\frac{1}{\sigma^2} \right] [\phi^T \phi]^{-1} \phi^T [\sigma^2] Y \quad (18)$$

$$\hat{\theta} = [\phi^T \phi]^{-1} \phi^T Y$$

3.5 Filtro de Kalman

Na Estatística e em Teoria de Controle, a filtragem de Kalman, também conhecida como estimador quadrático linear (LQE), é um algoritmo que utiliza uma série de medidas observadas ao longo do tempo, contendo ruído estatístico e outras imprecisões, e produz estimativas de variáveis desconhecidas que tendem a ser mais precisas do que aqueles baseados em uma única medida, estimando uma distribuição de probabilidade conjunta sobre as variáveis para cada período de tempo.

O filtro de Kalman tem inúmeras aplicações em tecnologia. Uma aplicação comum é para orientação, navegação e controle de veículos, especialmente aeronaves e espaçonaves (PAUL Z. *et al*, 2000). Além disso, o filtro de Kalman é um conceito amplamente aplicado na análise de séries temporais usada em campos como processamento de sinais e econometria. Os filtros de Kalman também são um dos principais tópicos no campo do planejamento e controle de movimento robótico, e por vezes são incluídos na otimização de trajetória. Devido ao atraso de tempo entre a emissão de comandos do motor e o recebimento de feedback sensorial, o uso do filtro de Kalman suporta um modelo realista para fazer estimativas do estado atual do sistema do motor e emitir comandos atualizados (WOLPERT, D *et al*, 2000).

O algoritmo funciona em um processo de duas etapas. Na etapa de previsão, o filtro de Kalman produz estimativas das variáveis de estado atuais, junto com suas incertezas. Uma vez que o resultado da próxima medição (necessariamente corrompido com alguma quantidade de erro, incluindo ruído aleatório) é observado, essas estimativas são atualizadas usando uma média ponderada, com mais peso sendo dado às estimativas com maior certeza. O algoritmo recursivo pode ser executado em tempo real, utilizando apenas as medições de entrada atuais, o estado calculado anteriormente e sua matriz de incerteza; nenhuma

informação passada adicional é necessária. Usando um filtro de Kalman não se assume que os erros são gaussianos (KALMAN, R. E., 1960), no entanto, o filtro produz a estimativa de probabilidade condicional exata no caso especial de que todos os erros são gaussianos. O modelo para o filtro de Kalman assume que o estado real no tempo k é obtido através do estado no tempo $(k - 1)$ de acordo com a equação (19).

$$x_k = F_k x_{k-1} + B_k u_k + w_k \quad (19)$$

e:

F_k : É o modelo de transição de estado, aplicado no estado anterior;

B_k : É o modelo de entradas de controle, aplicado ao vetor de controle de entrada;

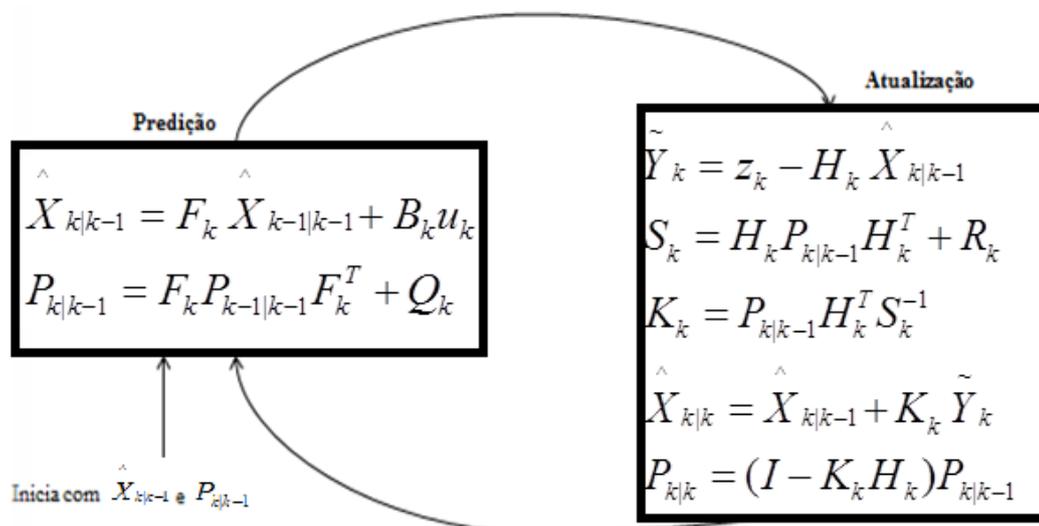
w_k : É o ruído do processo, assumido para ser amostrado a partir de uma distribuição de média zero multivariada normal e covariância.

No momento k , uma observação (ou medição) z_k do estado real x_k é feita de acordo com a equação (20).

$$z_k = H_k x_k + v_k \quad (20)$$

Onde H_k é o modelo de observação, que mapeia o espaço de estado real no espaço de estados observado, e v_k é o ruído de observação, assumido como sendo um ruído branco gaussiano de média zero e covariância R_k . A Figura 15 apresenta os passos do Filtro Kalman.

Figura 15 - Algoritmo do Filtro de Kalman.



Onde:

Y : Resíduo da medição;

S : Resíduo da covariância;

K : Ganho Kalman

P : matriz de covariância do erro;

3.6 Filtro de Partículas

Filtro de Partículas ou Método de Monte Carlo Sequencial (SMC) é um conjunto de algoritmos de Monte Carlo usados para resolver problemas de filtragem que surgem no processamento de sinal e inferência estatística Bayesiana. O problema de filtragem consiste em estimar os estados internos em sistemas dinâmicos quando observações parciais são feitas, e perturbações aleatórias estão presentes nos sensores, bem como no sistema dinâmico. O objetivo é calcular as distribuições posteriores dos estados de alguns processos de Markov, considerando algumas observações ruidosas e parciais. O termo "filtros de partículas" foi apresentado pela primeira vez em 1996 por Del Moral (DEL M. P, 1996) em referência aos métodos de partículas de interação de campo significados usados na mecânica de fluidos desde o começo da década de 1960. A terminologia "Monte Carlo Sequencial" foi proposta por Liu e Chen em 1998.

A filtragem de partículas utiliza um conjunto de partículas (também chamadas de amostras) para representar a distribuição posterior de algum processo estocástico, com observações ruidosas e/ou parciais. O modelo de espaço de estados pode ser não-linear e as distribuições iniciais de estado e ruído podem assumir qualquer forma necessária. As técnicas de Filtro de Partículas fornecem uma metodologia bem estabelecida (DEL M. P, 1996), (DEL M. P, 1998) e (DEL M. P, 2004) para gerar amostras da distribuição necessária, sem exigir suposições sobre o modelo de espaço de estados ou as distribuições de estado. No entanto, esses métodos não funcionam bem quando aplicados a sistemas de altíssima dimensão.

Os filtros de partículas implementam as atualizações de previsão de maneira aproximada. As amostras da distribuição são representadas por um conjunto de partículas; cada partícula tem um peso de probabilidade atribuído a ela que representa a probabilidade de que essa partícula seja amostrada a partir da função de densidade de probabilidade. A disparidade de peso que leva ao colapso de peso é um problema comum encontrado nesses algoritmos de filtragem; no entanto, pode ser mitigado incluindo uma etapa de reamostragem antes que os pesos se tornem muito irregulares. Vários critérios adaptativos de reamostragem podem ser usados, incluindo a variância dos pesos e a entropia relativa em relação à

distribuição uniforme (DEL M. P, *et al*, 2012). Na etapa de reamostragem, as partículas com pesos desprezíveis são substituídas por novas partículas na proximidade das partículas com pesos mais altos.

Do ponto de vista estatístico e probabilístico, o Filtro de Partículas pode ser interpretado como médias das partículas de campo das medidas de probabilidade de *Feynman-Kac*, (DEL M. P, 2004), (DEL M. P, *et al*, 2000), (DEL M. P, *et al*, 2000)*, (DEL M. P, *et al*, 2013) e (DEL M. P, *et al*, 2014). Os métodos de partículas que interagem com *Feynman-Kac* também estão fortemente relacionados aos algoritmos genéticos de seleção de mutações usados atualmente na computação evolucionária para resolver problemas complexos de otimização.

O Filtro de Partículas e as metodologias de partículas de *Feynman-Kac* encontram aplicação em processamento de sinais e imagens, inferência bayesiana, aprendizado de máquina, análise de risco e amostragem rara de eventos, engenharia e robótica, inteligência artificial, bioinformática, filogenética, ciência computacional, economia e matemática, química molecular, física computacional, farmacocinética e outros campos.

O objetivo de um Filtro de Partículas é estimar a densidade posterior das variáveis de estado dadas as variáveis de observação. O Filtro de Partículas é projetado para um modelo de *Markov* oculto, onde o sistema consiste em variáveis ocultas e observáveis. As variáveis observáveis (processo de observação) estão relacionadas às variáveis ocultas (estado-processo) por alguma forma funcional que é conhecida. Da mesma forma, o sistema dinâmico que descreve a evolução das variáveis de estado também é conhecido probabilisticamente.

O algoritmo usado para o presente trabalho em conjunto com o Filtro de Partículas é chamado algoritmo *Sequential Importance Sampling* (SIS), onde possui uma etapa de reamostragem a cada iteração. O SIS no PF usa uma densidade de importância, que é uma proposta para representar outra densidade que não pode ser calculada com precisão. Logo, as amostras são retiradas da densidade de importância.

Onde: $\{X_{0:k}^i, i=0, \dots, N\}$ seja as partículas com pesos associados $\{w_k^i, i=0, \dots, N\}$ e $X_{0:k} = \{X_j, j = 0, \dots, N\}$ ser o conjunto de todos os estados até t_k pode ser discretamente aproximada por:

$$\pi(x_{0:k} | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_{0:k} - x_{0:k}^i) \quad (21)$$

A densidade posterior (21) pode ser escrita como:

$$\pi(x_k | z_{1:k}) \approx \sum_{i=1}^N w_k^i \delta(x_k - x_k^i) \quad (22)$$

Um problema comum com o Filtro de Partículas SIS é o fenômeno de degeneração, onde após alguns estados, alguma partícula terá peso insignificante. Essa degeneração implica que um grande esforço computacional é dedicado à atualização de partículas cuja contribuição para a aproximação da função de densidade posterior é quase zero. O uso da técnica de reamostragem é recomendado para evitar a degeneração das partículas.

A reamostragem envolve um mapeamento da medida aleatória $\{x_k^i, w_k^i\}$ em uma medida aleatória $\{x_k^{i*}, N^{-1}\}$ com pesos uniformes. Pode ser realizado se o número de partículas efetivas com pesos grandes estiver abaixo de um certo número limite. Alternativamente, a reamostragem também pode ser aplicada indistintamente a cada instante t_k . Esse algoritmo pode ser resumido nas etapas a seguir, aplicadas à evolução do sistema de t_{k-1} a t_k , conforme ilustra a Figura 16. O algoritmo da reamostragem é apresentado na Figura 17. Na Figura 18, os passos do algoritmo do Filtro de Partículas são explanados ilustrativamente de forma gráfica.

Figura 16 - Algoritmo do Filtro de Partículas.

Início

Passo 1. Para $i = 1, \dots, N$ retire as novas partículas x_k^i da densidade apriori $\pi(x_k | z_{k-1}^i)$ e em seguida, use a densidade de probabilidade para calcular os pesos correspondentes $w_k^i \pi(x_k | z_{k-1}^i)$.

Passo 2. Calcule o peso total $T_w = \sum_{i=1}^N w_k^i$ e depois normalizar os pesos das partículas, isto é, para $i=1, \dots, N$ tem $w_k^i = T_w^{-1} w_k^i$;

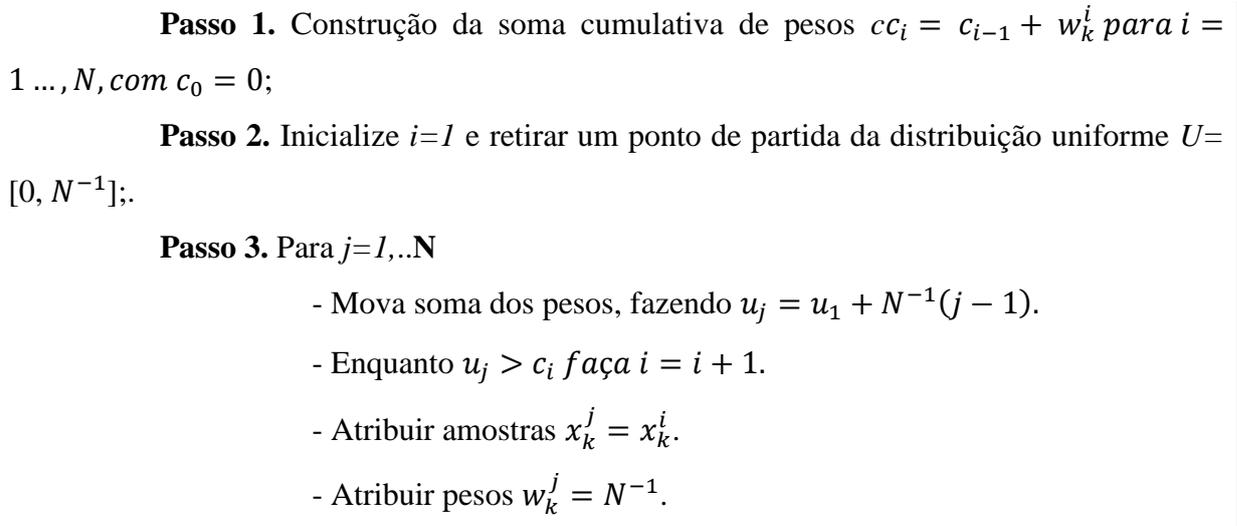
Passo 3. Ocorre a reamostragem das partículas;

Passo 4. Evolução dos estados no tempo;

Fim.

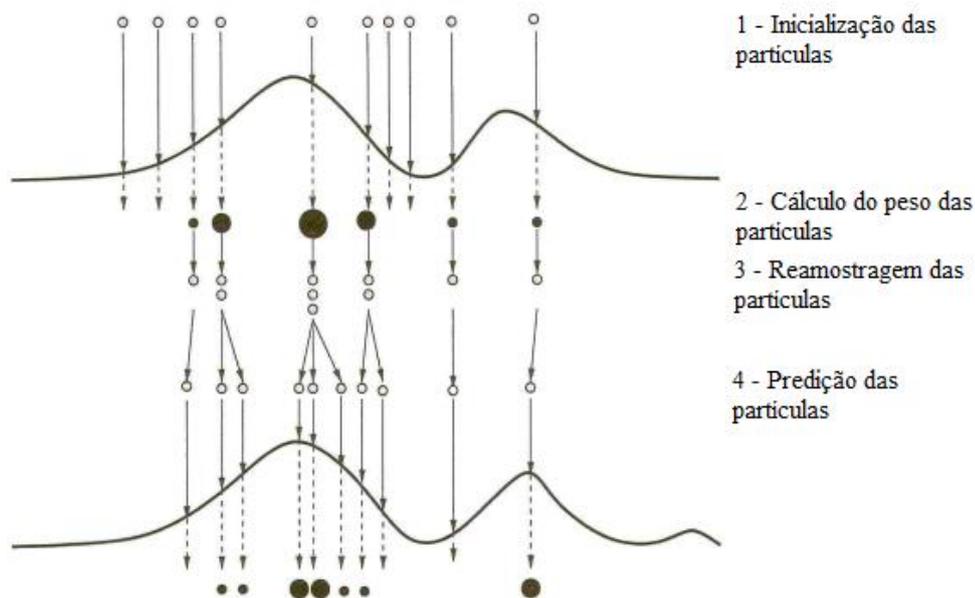
Fonte: Autoria própria.

Figura 17 - Algoritmo da Reamostragem.



Fonte: Autoria própria.

Figura 18 – Algoritmo do Filtro de Partículas com Reamostragem.



Fonte: Adaptado de PINTO (2007).

3.7 Filtro de Kalman *Unscented* (UKF)

O Filtro de Kalman *Unscented* pertence a uma classe maior de filtros chamados *Sigma-Point Kalman Filters* ou *Linear Regression Kalman Filters*, que estão usando a técnica de linearização estatística (ARTHUR G., 1974) e (TINE L. *et al*, 2002). Esta técnica é usada para linearizar uma função não-linear de uma variável aleatória através de uma regressão entre n pontos extraídos da distribuição prévia da variável aleatória. Desde que se considere a

propagação da variável aleatória, a técnica tende a ser mais precisa do que a linearização de séries de Taylor (R. VAN DER MERWE, 2003).

A UKF é fundada na intuição de que é mais fácil aproximar uma distribuição de probabilidade que é aproximar uma função ou transformação não linear arbitrária (SJ JULIER e JK UHLMANN, 2004). Os pontos sigma são escolhidos de modo que sua média e covariância sejam exatamente x_{ak-1} e P_{k-1} . Cada ponto sigma é então propagado através da não linearidade produzindo no final uma nuvem de pontos transformados. A nova média estimada e covariância são então calculadas com base em suas estatísticas. Este processo é chamado de transformação sem cheiro (*unscented transform* - UT). A UT é um método para calcular as estatísticas de uma variável aleatória que sofre uma transformação não linear (E. Wan and R. van der Merwe, 2001; S. J. JULIER e J. K. UHLMANN, 1997).

Considere a propagação de uma variável aleatória x (dimensão L) através de uma função não linear, $y = g(x)$. Suponha que x tenha a média \hat{x} e a covariância P_x . Para calcular a estatística de y , forma-se uma matriz χ de vetores $2L + 1$ sigma χ_i (com pesos correspondentes W_i), de acordo com:

$$\begin{aligned} \chi_0 &= \hat{x} \\ \chi_i &= \hat{x} + (\sqrt{(L + \lambda)P_x})_i \quad i = 1, \dots, L \\ \chi_i &= \hat{x} - (\sqrt{(L + \lambda)P_x})_{i-L} \quad i = L+1, \dots, 2L \\ W_0^{(m)} &= \lambda / (L + \lambda) \\ W_0^{(c)} &= \lambda / (L + \lambda) + (1 - \alpha^2 + \beta) \\ W_i^{(m)} &= W_i^{(c)} = 1 / \{2(L + \lambda)\} \quad i=1, \dots, 2L \end{aligned} \quad (23)$$

Os vetores sigma são propagados através da função não linear:

$$Y_i = g(\chi_i) \quad i = 0, \dots, 2L, \quad (24)$$

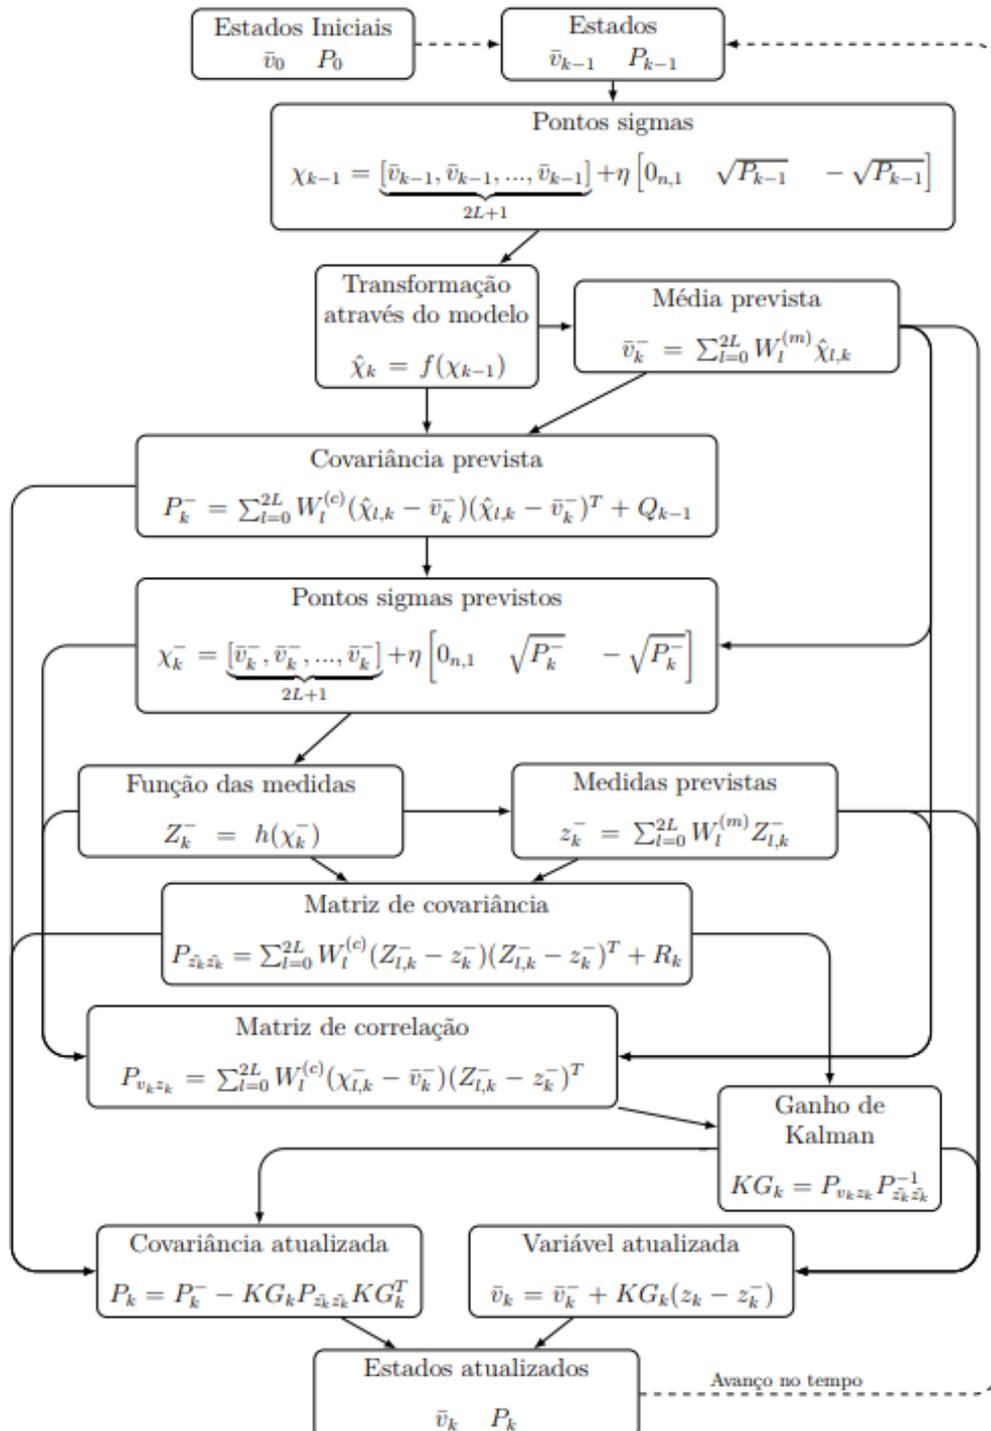
A média e covariância para y são aproximados usando uma média ponderada da amostra e covariância do posterior pontos sigma:

$$\hat{y} \approx \sum_{i=0}^{2L} W_i^{(m)} y_i \quad (25)$$

$$P_y \approx \sum_{i=0}^{2L} W_i^{(c)} \{y_i - \hat{y}\}^T \quad (26)$$

A Figura 19 apresenta uma visão geral do algoritmo do Filtro de Kalman *Unscented*, onde $n = \sqrt{L + \lambda}$, W são os pesos citados anteriormente, a variável Q é o ruído do processo, R são os erros de medições e k é número de iteração do algoritmo, onde $k=i$.

Figura 19 – Fluxograma do Filtro de Kalman *Unscented*.



4 RESULTADOS E DISCUSSÕES

Para a predição de descarga e degradação de saúde de baterias Li-Ion foram utilizados 5 métodos: RNA ELM, Mínimos Quadrados, Filtro de Kalman, Filtro de Partículas e Filtro de Kalman *Unscented*, conforme apresentados na seção anterior. Neste capítulo são explanados os resultados com os dados das baterias identificadas por RW9 e RW10.

4.1 Resultados da RNA ELM

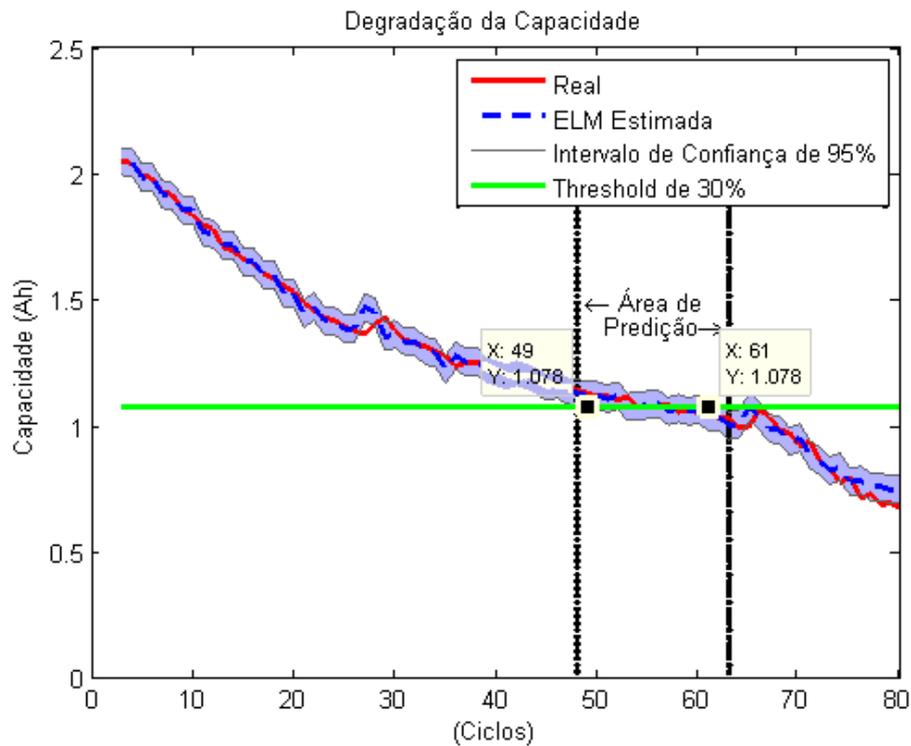
As RNAs são preditores indispensáveis para trabalhos com uma análise comparativa. Foi utilizada uma RNA com o treinamento ELM com a seguinte configuração: 5 neurônios na camada escondida; passo de aprendizagem igual 0.5. Os pesos W finais da camada escondida indicados abaixo, com intervalo entre -0.002 e 2.0.

$$W = \begin{bmatrix} -0.0319 & 0.9022 & 0.2970 \\ 0.3057 & -0.3616 & -1.0930 \\ 0.0547 & 0.2633 & -0.6635 \\ 0.9070 & -0.1301 & -0.7205 \\ 0.1560 & 0.3001 & 0.2009 \end{bmatrix}$$

A Figura 20 apresenta o resultado da RNA com o treinamento ELM para estimar a degradação da capacidade por ciclos da bateria RW9. Além de medir o momento da falha, escolhido em 30% da capacidade nominal, também se avaliou a qualidade da estimativa com o coeficiente de correlação múltipla (R^2). Para este caso, o R^2 obteve valor de **0.99190569**, significando uma boa qualidade da estimativa. É importante lembrar que para o processo de treinamento da RNA é necessária apenas uma execução pela sua facilidade de convergência, porém foi obtido um melhor resultado após uma sequência de 10 execuções.

Ainda na Figura 20, a linha em verde é o *threshold*, ou limiar de falha, que indica o ponto em que a capacidade da bateria é de 30% da nominal, onde se considera o fim da vida útil da bateria. As linhas verticais de cor preta delimitam a área de predição. Nesta área de predição as estimativas devem tocar o *threshold*. As regiões em azul claro são os intervalos de confiança de 95%, que devem tocar no *threshold* dentro da área de predição, e quanto menor esses intervalos, melhor será a predição. A linha em azul com tracejado representa as predições com uso dos métodos. A linha vermelha representa os dados reais da capacidade da bateria.

Figura 20 – Degradação da capacidade por ciclos usando RNA ELM – RW9.



Fonte: Autoria própria.

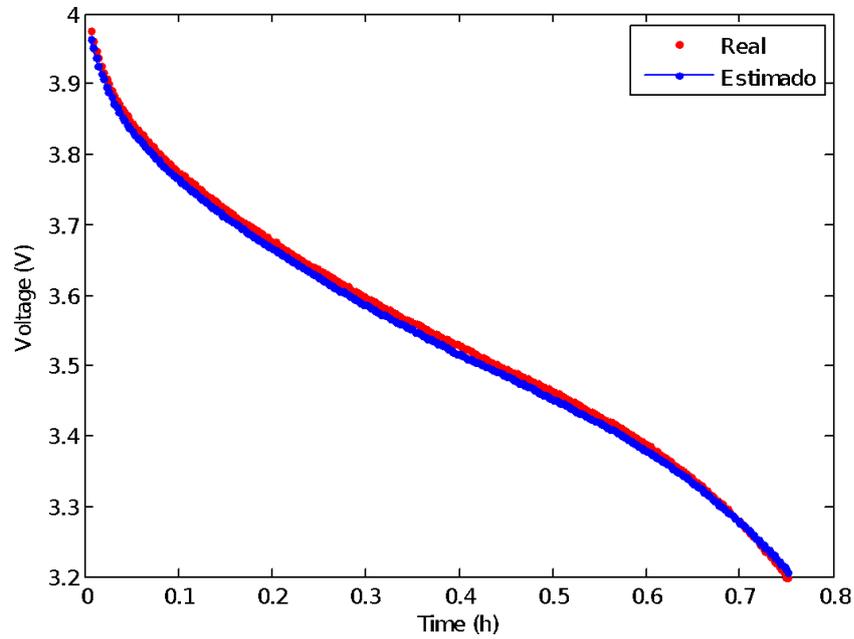
Ao analisar a Figura 20, pode-se perceber que os intervalos de confiança tocam o threshold dentro da área de predição (limites tocam em **49** e **61** ciclos), assim validando estimativa em possível momento de falha. É importante ressaltar que todas as outras predições têm essas informações.

Na Figura 21 é apresentado resultado referente à estimativa da curva de descarga do último perfil de descarga da bateria RW9. A arquitetura da RNA ELM projetada foi: número de pesos na camada oculta de 4, passo de aprendizagem de 0.7, e o intervalo de pesos de -0.2 a 2.0. Abaixo estão os melhores conjuntos de pesos para ambas as estimativas.

$$W = \begin{bmatrix} -0.1961 & 0.4854 & -0.6943 \\ 0.5386 & -0.8913 & 0.1411 \\ -0.6695 & -0.4615 & 0.1994 \\ 0.3620 & -1.9652 & -0.0145 \end{bmatrix}$$

A Figura 21 também foi avaliada pelo R^2 e pelo RMSE. O resultado das estimativas foram bons e serão discutidos mais a frente.

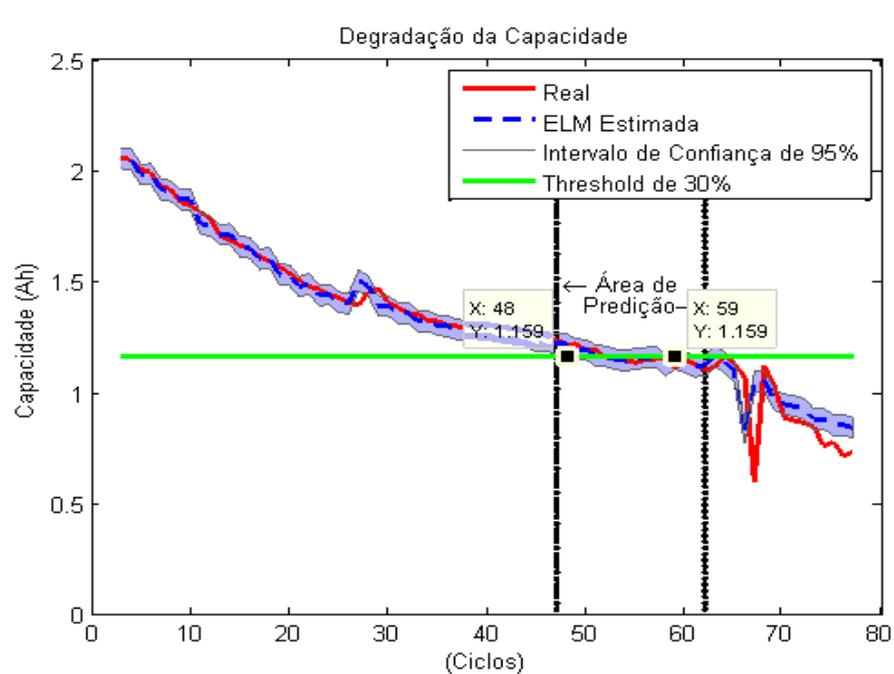
Figura 21 – Estimativa do último ciclo de descarga usando RNA ELM da bateria RW9.



Fonte: Autoria própria.

A Figura 22 apresenta a estimativa da degradação da capacidade com as baterias RW10 usando uma RNA ELM.

Figura 22 – Degradação da capacidade por ciclos usando RNA ELM – RW10.

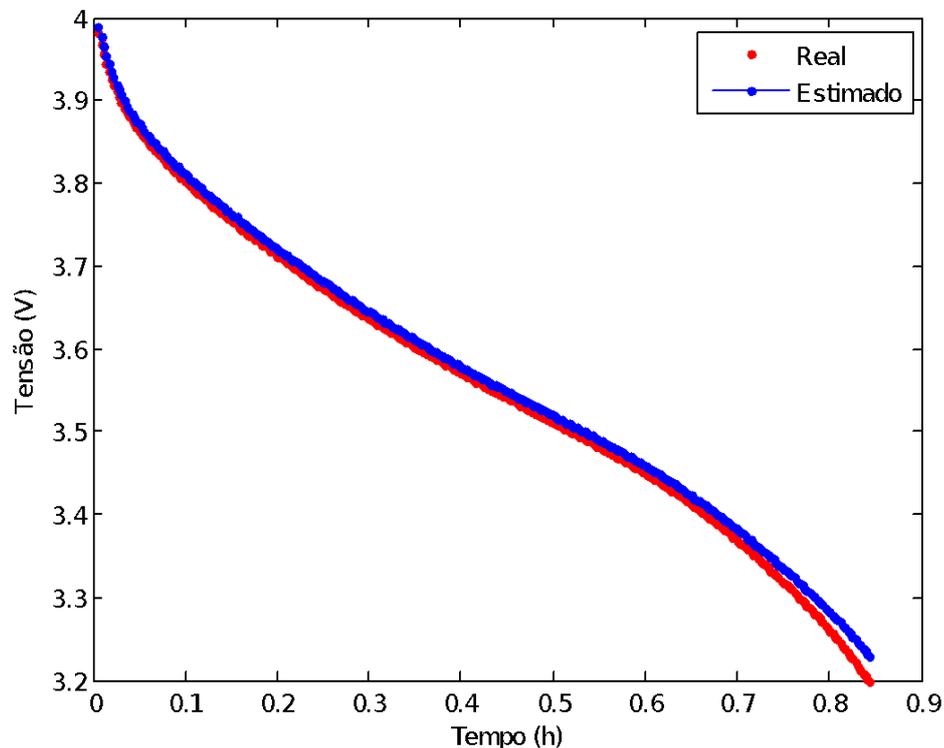


Fonte: Autoria própria.

A Figura 22 apresenta uma estimativa um pouco mais dificultosa, pois o comportamento dos dados da bateria RW10 é um pouco mais complexo. A RNA ELM, contudo, conseguiu tocar com dificuldade o limiar com os intervalos de confiança.

A Figura 23 apresenta a estimativa da curva do último ciclo de descarga da bateria RW10 usando uma rede neural ELM. Os resultados do RMSE e R^2 tiveram bons resultados atingindo acima do esperado. Esses resultados serão discutidos nas tabelas mais a frente.

Figura 23 – Estimativa do último ciclo de descarga usando RNA ELM da bateria RW10.

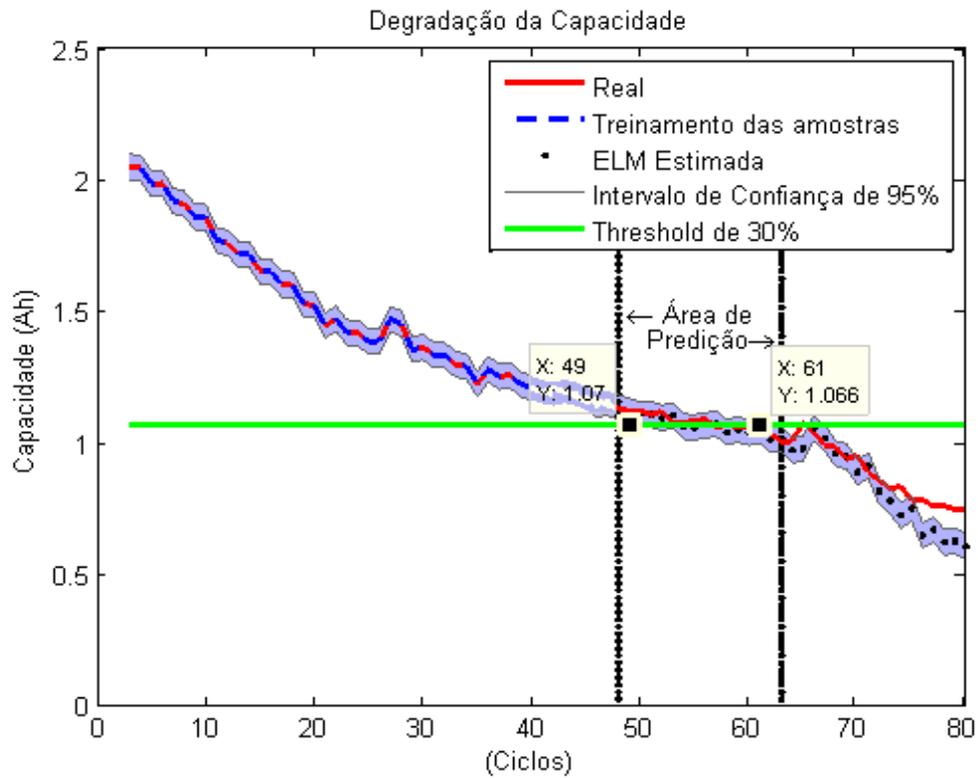


Fonte: Autoria própria.

4.1.1 Resultados da RNA ELM com validação das estimativas

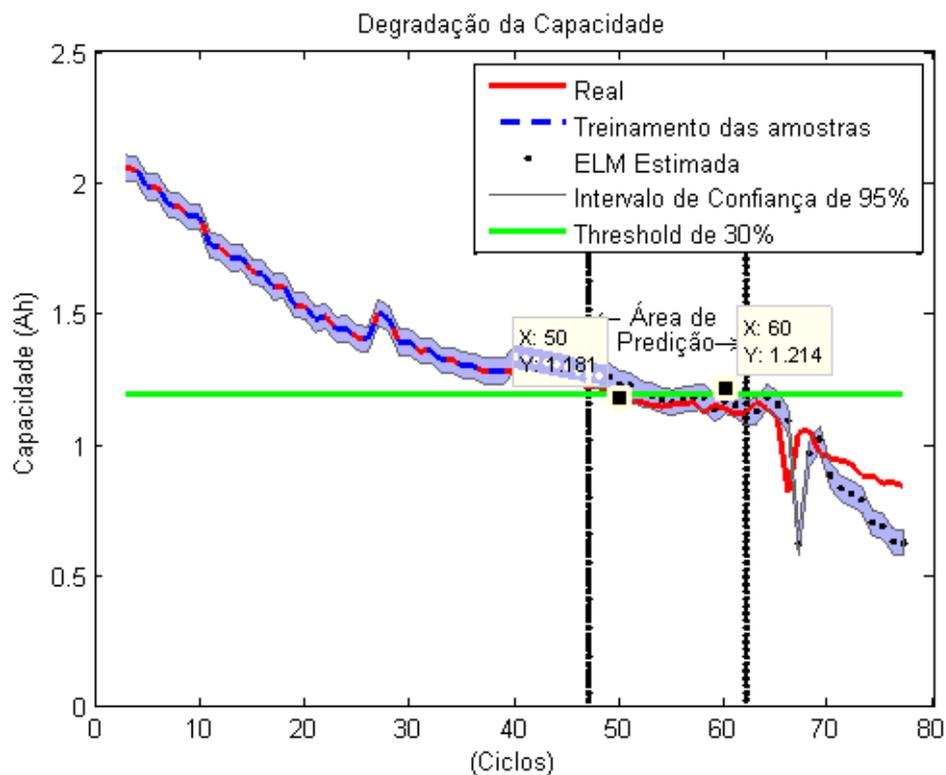
Além desses resultados em forma de regressão, foi desenvolvido um modelo baseado em validações de modelos. Logo o janelamento da rede neural ELM se dá a partir de uma quantidade de 2 pontos de amostragem da série temporal de capacidade do conjunto de dados. Isso é feito somente na etapa de treinamento da rede. Assim, na etapa de validação/teste é usado o modelo mapeado para validar a estimativa resultante do treinamento. A Figura 24 apresenta a estimativa da capacidade da bateria RW9. Já a Figura 25 apresenta a estimativa da capacidade da bateria RW10. Em todas as estimativas com validações de modelos, as previsões dos modelos iniciam sempre com **50%** dos dados de capacidade.

Figura 24 – Validação do modelo da capacidade da bateria RW9 com ELM



Fonte: Autoria própria.

Figura 25 – Validação do modelo da capacidade da bateria RW10 com ELM



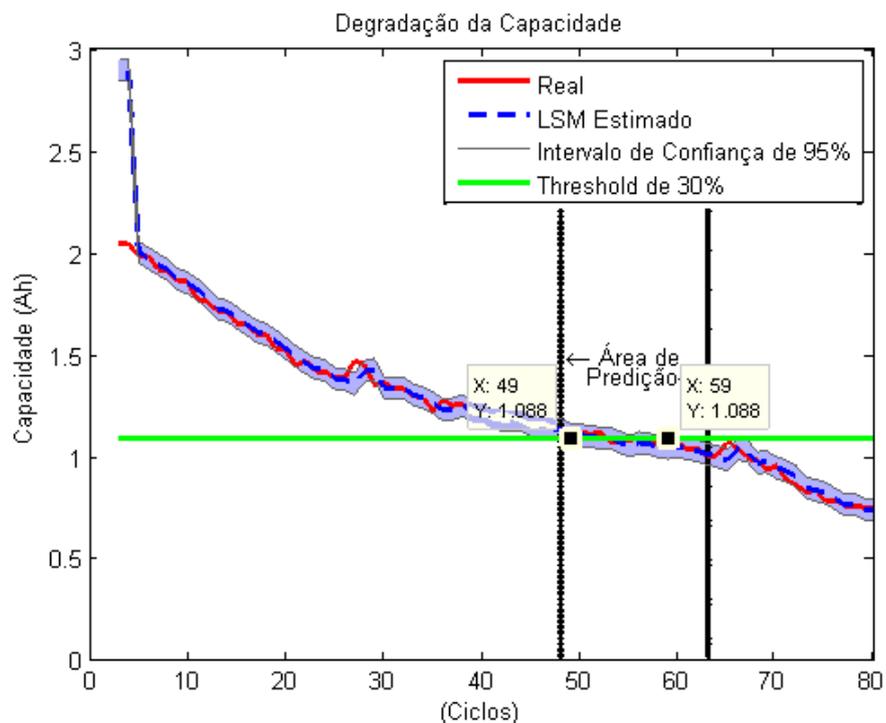
Fonte: Autoria própria.

4.2 Resultados dos Mínimos Quadrados

O método dos mínimos quadrados é uma técnica mais comumente usada em aplicações de regressões. Neste trabalho propõe-se uma análise por esse método, que é bastante importante na literatura quando se trata de predição. Abaixo está a Figura 26, que representa as estimativas da degradação da capacidade pelo método dos mínimos quadrados não recursivo na bateria RW9.

Da mesma forma que a RNA ELM, foi definido um *threshold* de 30% da capacidade e avaliado pelo R^2 . A Figura 26 apresenta a estimativa da degradação da capacidade durante os ciclos de descarga, onde existem duas barreiras no qual a estimativa deve estar alinhada ao dado real até tocar a limiar de falha. Os intervalos de confiança são de 95%.

Figura 26 – Degradação da capacidade por ciclos usando LMS – RW9.



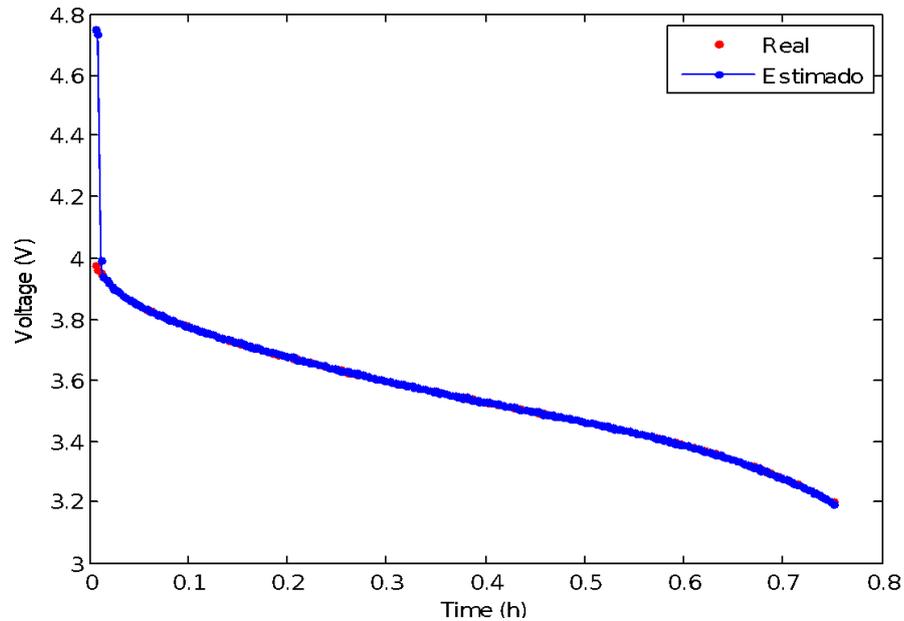
Fonte: Autoria própria.

Apesar dos mínimos quadrados serem uma técnica comumente muito poderosa, teve bastante dificuldade para tocar no limiar com os intervalos dentro da área de predição.

A Figura 27 mostra as estimativas da curva de descarga utilizando o método dos mínimos quadrados do último ciclo da bateria RW9.

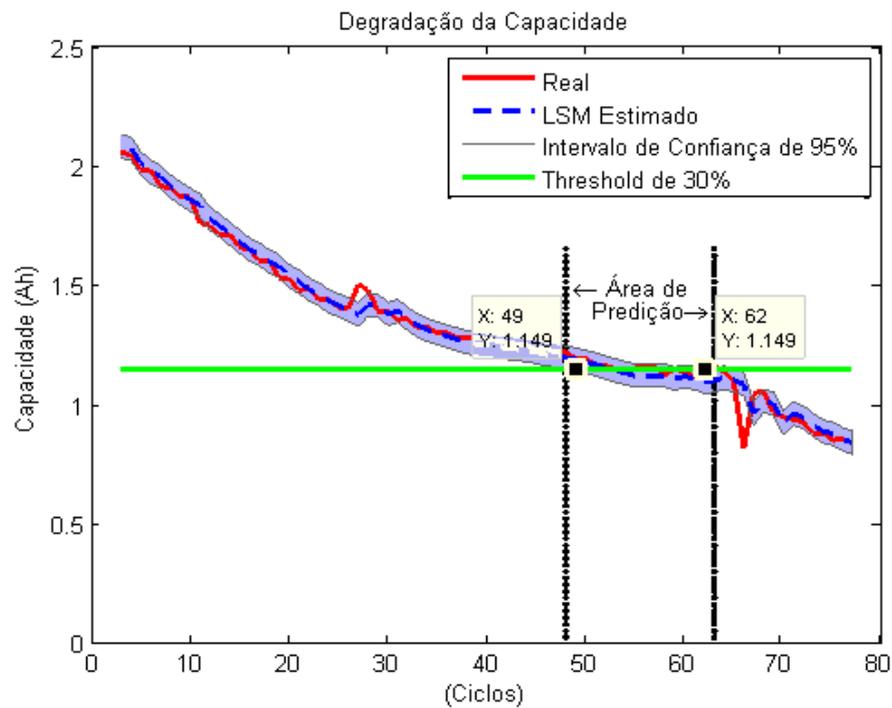
A Figura 28 apresenta a estimativa da degradação da capacidade com LSM da bateria RW10. O método dos Mínimos quadrados não recursivos conseguiu um desempenho aceitável com resultados de estimativas tocando no limiar de falha dentro da área de predição.

Figura 27 – Estimativa do último ciclo de descarga usando LSM – RW9.



Fonte: Autoria própria.

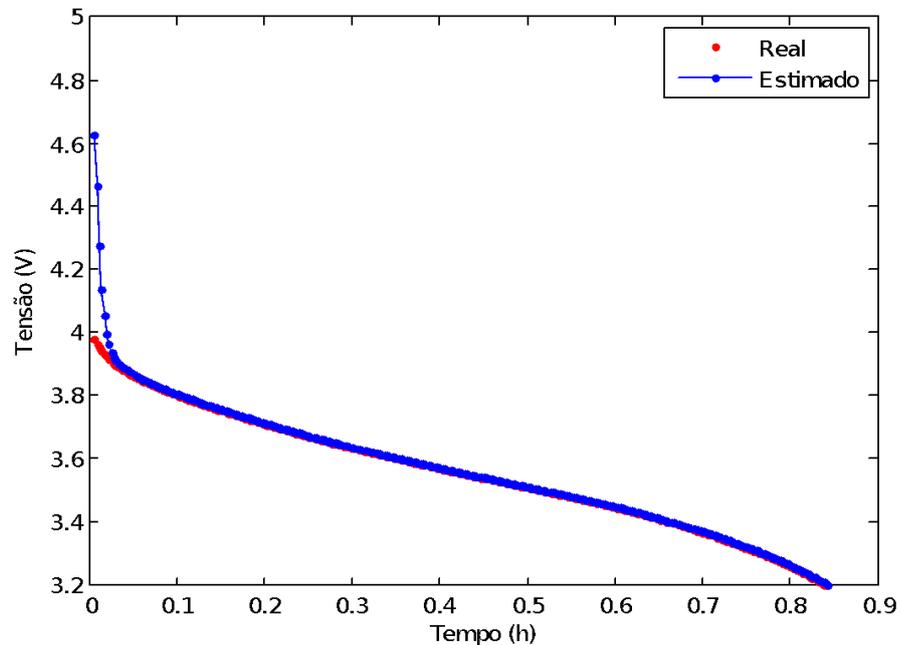
Figura 28 – Degradação da capacidade por ciclos usando LSM – RW10.



Fonte: Autoria própria.

A Figura 29 apresenta a estimativa com LMS da curva da última descarga da bateria RW10.

Figura 29 – Estimativa do último ciclo de descarga usando LSM – RW10.

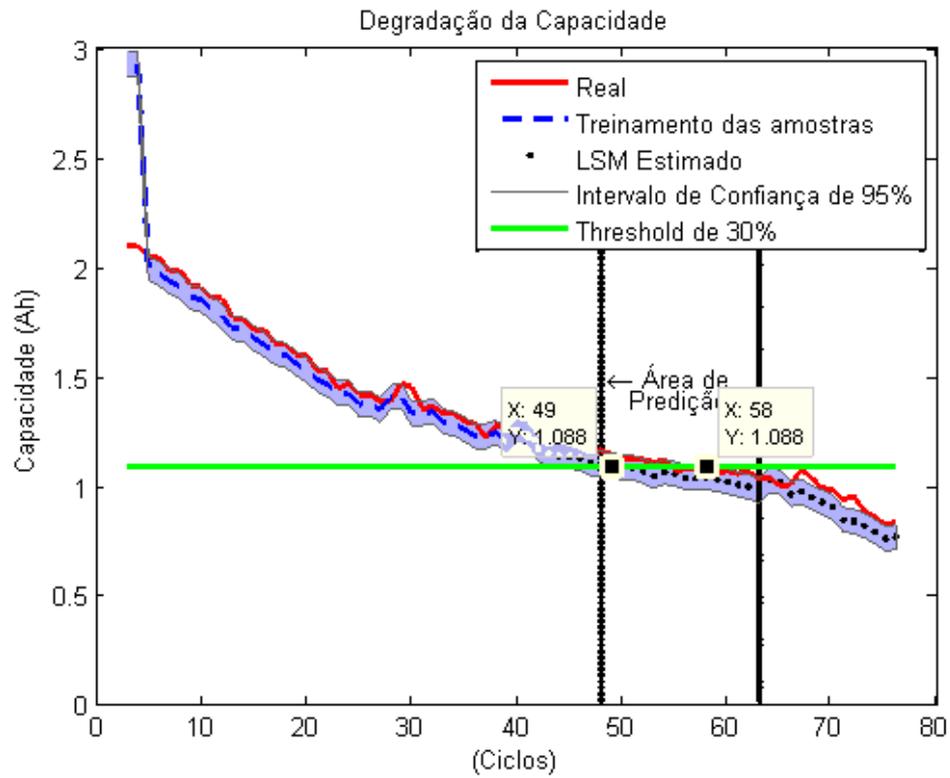


Fonte: Autoria própria.

4.2.1 Resultados dos Mínimos Quadrados com validação das estimativas

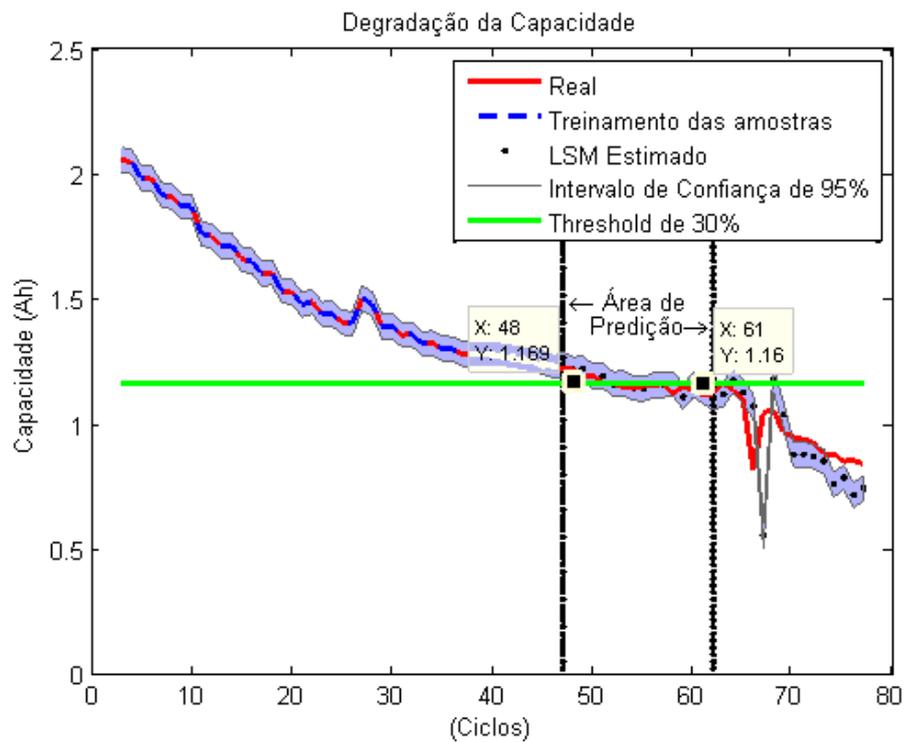
Para formar as entradas dos mínimos quadrados também foi feito um janelamento conforme a ELM, com 2 entradas de janelas moveis, a diferença é que esse método não possui bias. As Figuras 30 e 31 apresentam as estimativas da capacidade das baterias RW9 e RW10 com mínimos quadrados no modo de treinamento e validação.

Figura 30 – Validação do modelo da capacidade da bateria RW9 com LSM



Fonte: Autoria própria.

Figura 31 – Validação do modelo da capacidade da bateria RW10 com LSM



Fonte: Autoria própria.

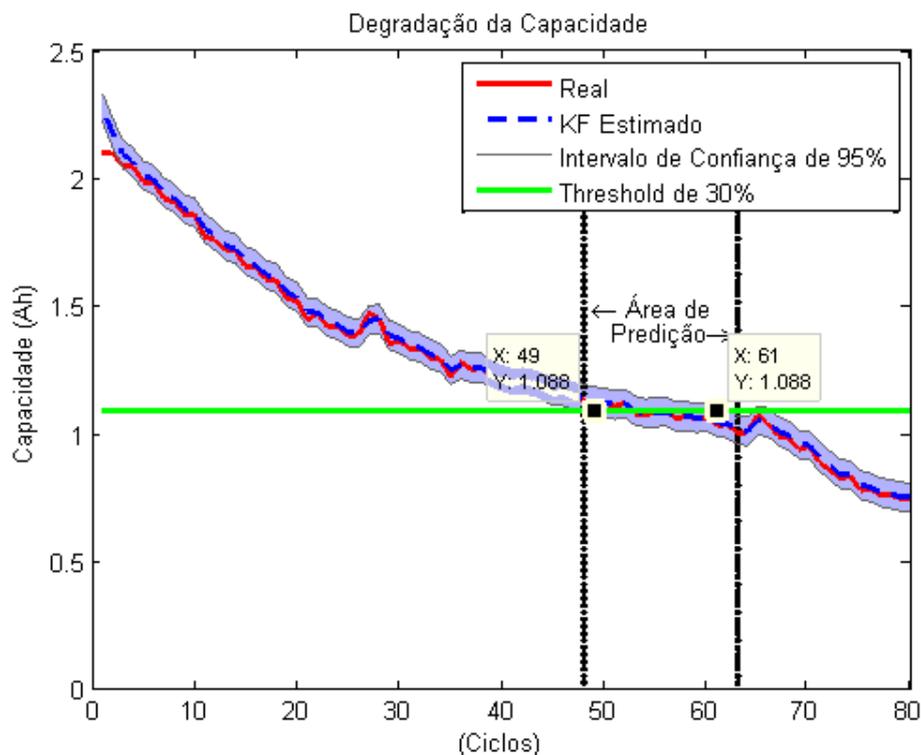
4.3 Resultados do Filtro de Kalman

O Filtro de Kalman tem características de problemas lineares. Assim como os demais métodos, também foi proposto a mesma avaliação R^2 e *threshold*. Na Figura 28 é mostrada a estimativa da degradação da capacidade da bateria Li-Ion RW9 e RW10 no decorrer dos ciclos. Na bateria RW9 o R^2 para a degradação da capacidade foi de **0.99159075**, resultado bom mesmo para um método que é mais recomendado para comportamentos lineares.

É importante ressaltar que na Figura 32 as estimativas conseguiram seguir os dados reais até mesmo na hora que ocorre um toque no limiar (linha verde), podendo comprovar o poder de um filtro de Kalman comum.

As estimativas da Figura 32 apresentaram bons resultados, apesar da simplicidade do método.

Figura 32 - Degradação da capacidade por ciclos usando KF – RW9.



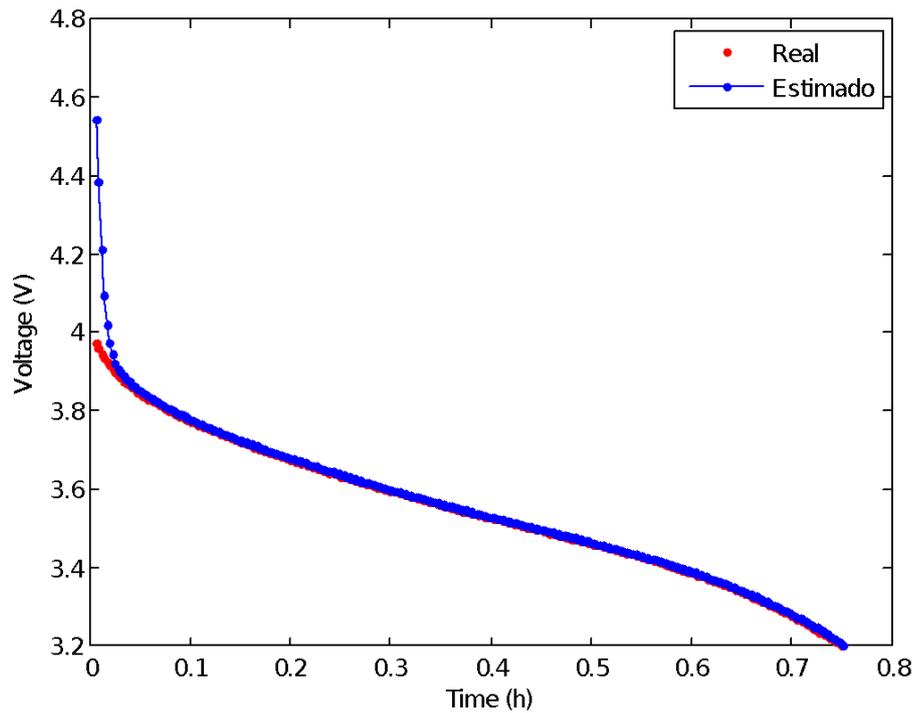
Fonte: Autoria própria.

A Figura 33 mostra a estimativa da curva de descarga do último ciclo da bateria RW9. O R^2 também foi o meio que de avaliação dessas estimativas, que foram bastante

satisfatórias.

Na avaliação do R^2 , a estimativa do último ciclo de descarga foi de **0.96978478**. Assim o Filtro de Kalman comum conseguiu bons resultados nas baterias com o perfil RW9 de Li-Ion da NASA, conforme pode ser visto na figura citada.

Figura 33 - Estimativa do último ciclo de descarga usando Filtro de Kalman – RW9.

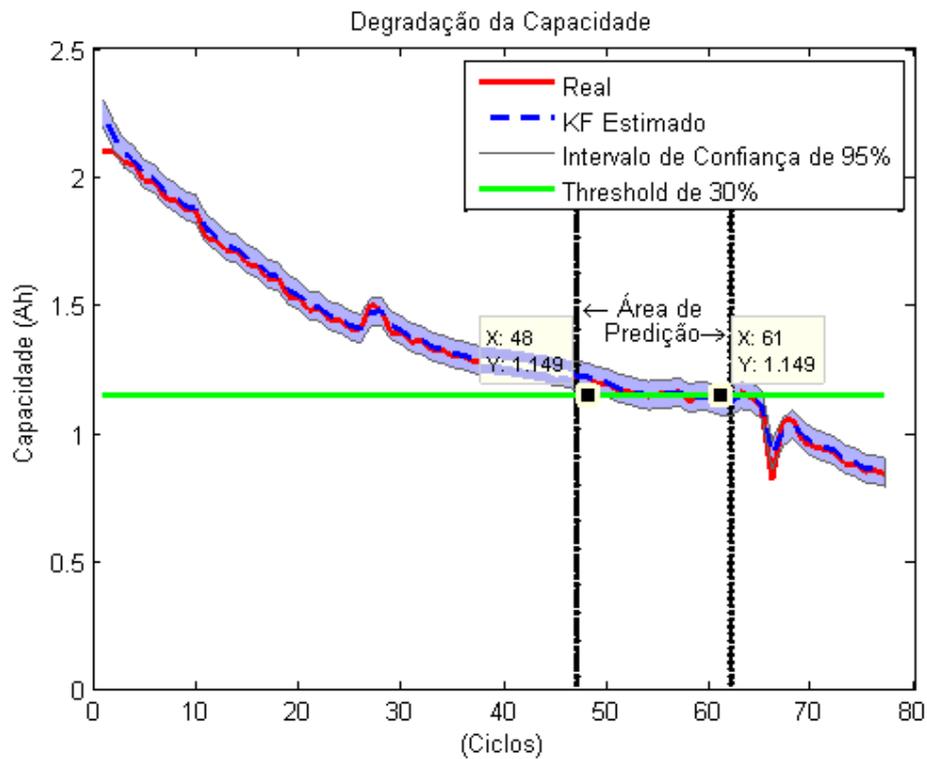


Fonte: Autoria própria.

A Figura 34 apresenta a estimativa da degradação da capacidade com o Filtro de Kalman na bateria RW10. Os resultados conseguiram atingir o objetivo, onde os intervalos de confiança tocam no limiar de falha dentro das barreiras de previsão.

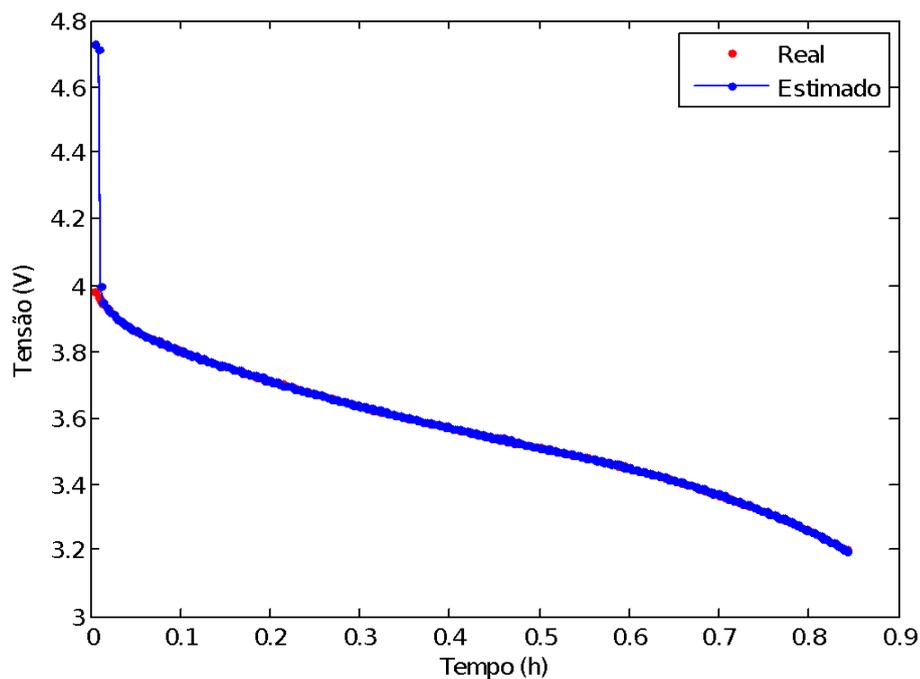
A Figura 35 mostra a previsão de descarga da mesma no último ciclo de descarga aplicada a bateria RW10.

Figura 34 - Degradação da capacidade por ciclos da bateria RW10 usando KF.



Fonte: Autoria própria.

Figura 35 - Estimativa do último ciclo de descarga da bateria RW10 usando Filtro de Kalman.

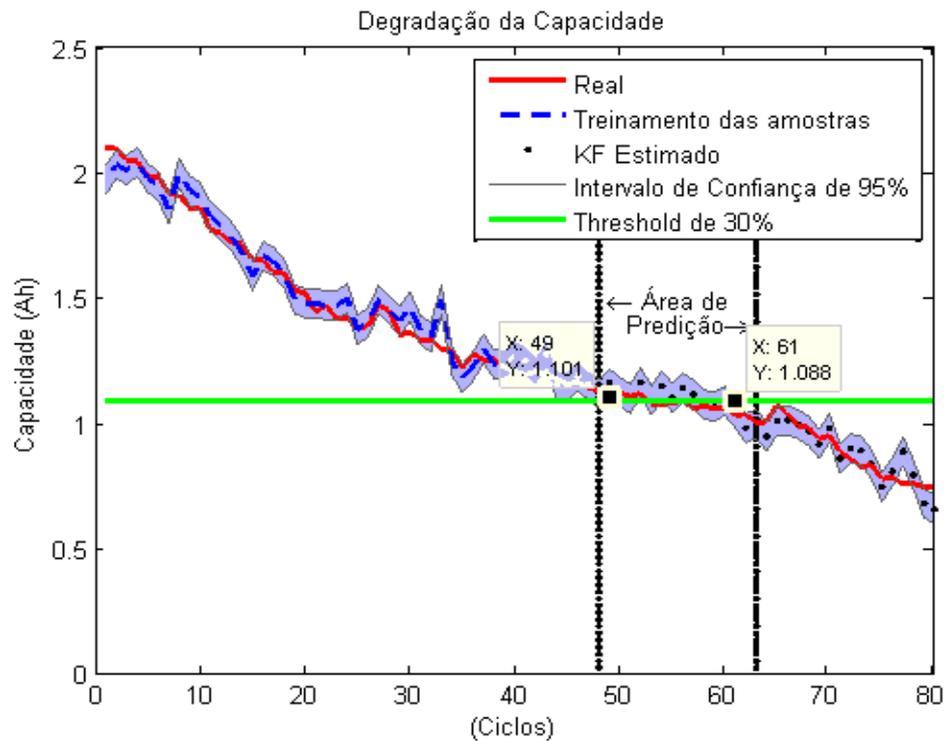


Fonte: Autoria própria.

4.3.1 Resultados do Filtro de Kalman com validação das estimativas

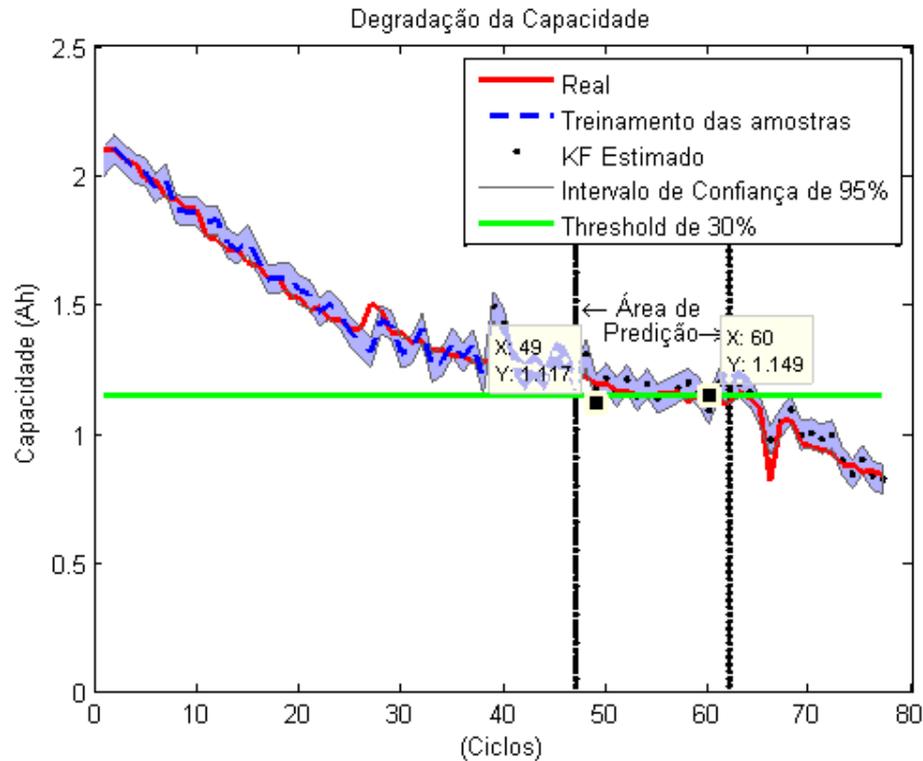
O Filtro de Kalman teve uma janela similar a dos mínimos quadrados também com 2 pontos de capacidade formando uma janela móvel, isso somente na parte de treinamento, a parte de validação foi usado o modelo gerado. Os resultados dessa estimativa estão nas Figuras 36 e 37.

Figura 36 – Validação do modelo da capacidade da bateria RW9 com KF



Fonte: Autoria própria.

Figura 37 – Validação do modelo da capacidade da bateria RW10 com KF



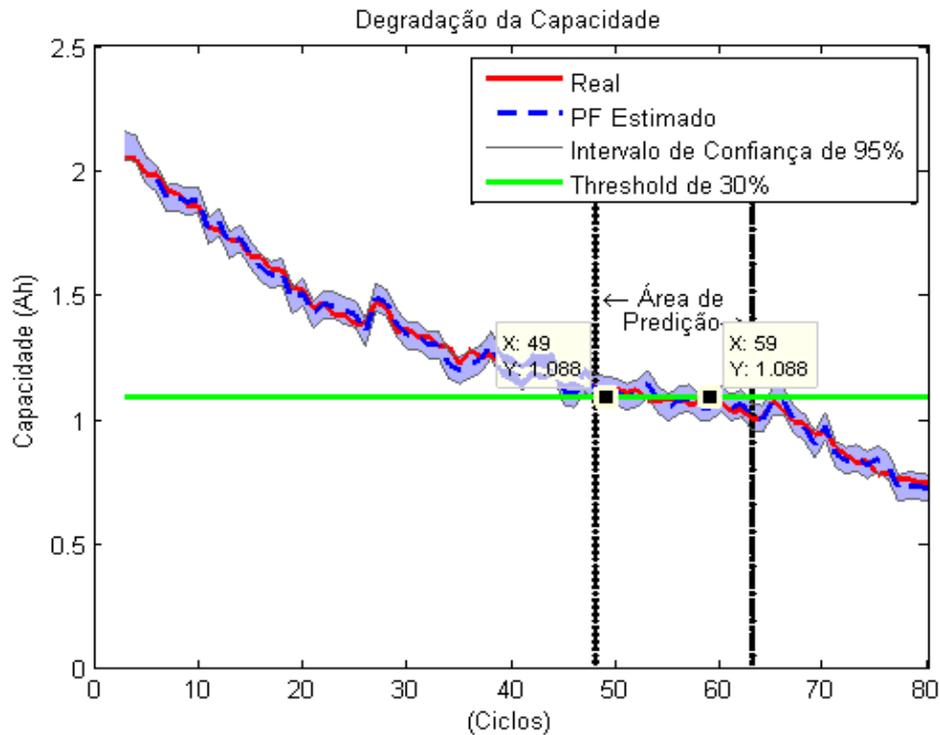
Fonte: Autoria própria.

4.4 Resultado do Filtro de Partículas

O algoritmo do Filtro de Partículas teve sua implementação explanada no capítulo anterior e possui uma característica importante, que é a de trabalhar bem com sistemas não-lineares. Ele é muito comum em aplicação para trajetórias de objetos com grandes variações a todo instante.

A Figura 38 apresenta a estimativa da degradação da capacidade das baterias RW9. A mesma também apresenta *threshold* de 30% e são avaliadas pelo R^2 , que foi de **0.99279405**. O Filtro de Partículas conseguiu superar a RNA ELM, que apresentou a melhor estimativa da capacidade até a presente análise. Apesar de o resultado ser bom, ele tem uma demora ligeiramente maior no seu tempo de execução.

Figura 38 – Degradação da capacidade por ciclos usando PF – RW9.



Fonte: Autoria própria.

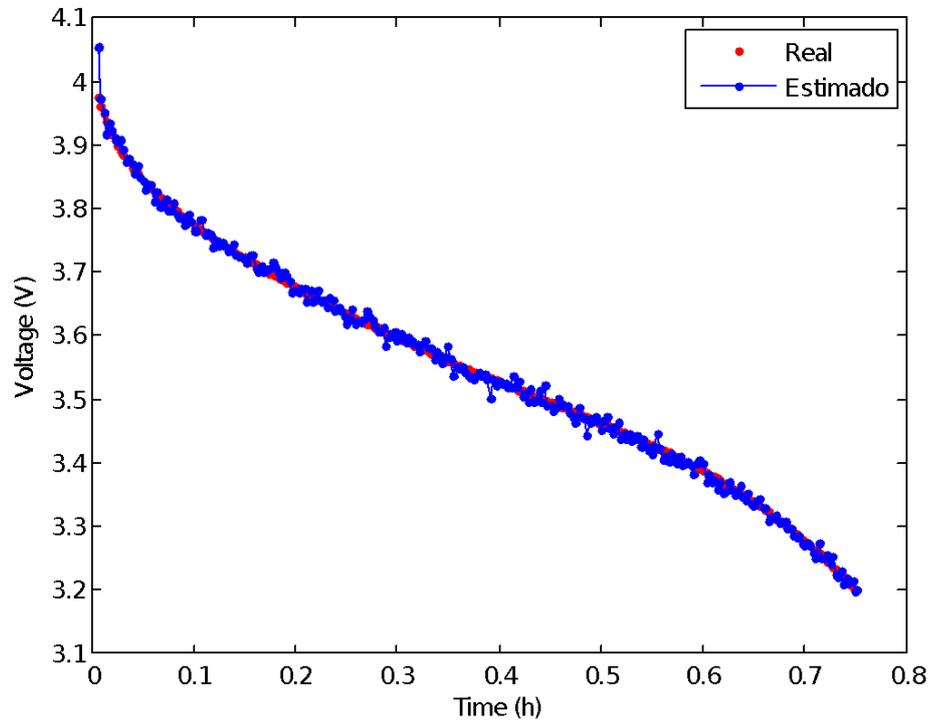
Ao observar a Figura 38, o Filtro de partículas conseguiu prever o momento da falha em ambos os intervalos dentro da área de predição com uma boa margem.

A estimativa da curva de descarga da bateria RW9 com Filtro de Partículas é apresentada na Figura 39, sendo avaliada pelo coeficiente de correlação Múltipla (R^2). Na estimativa da última curva de descarga, o R^2 foi de **0.99703360**.

O método de Filtro de Partículas mostrou resultados excelentes em comparação com os demais métodos apresentados até o momento, justificando seu amplo uso na literatura.

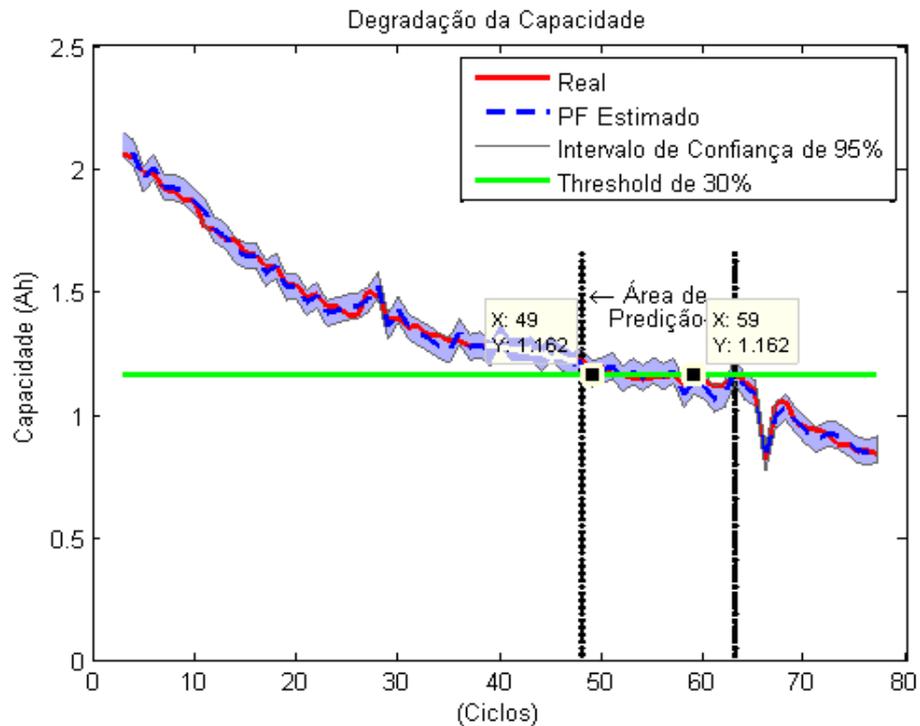
A Figura 40 apresenta a estimativa da capacidade do Filtro de partículas aplicado a bateria RW10, o mesmo conseguiu também resultados dentro da área de predição.

Figura 39 – Estimativa do último ciclo de descarga usando PF – RW9.



Fonte: Autoria própria.

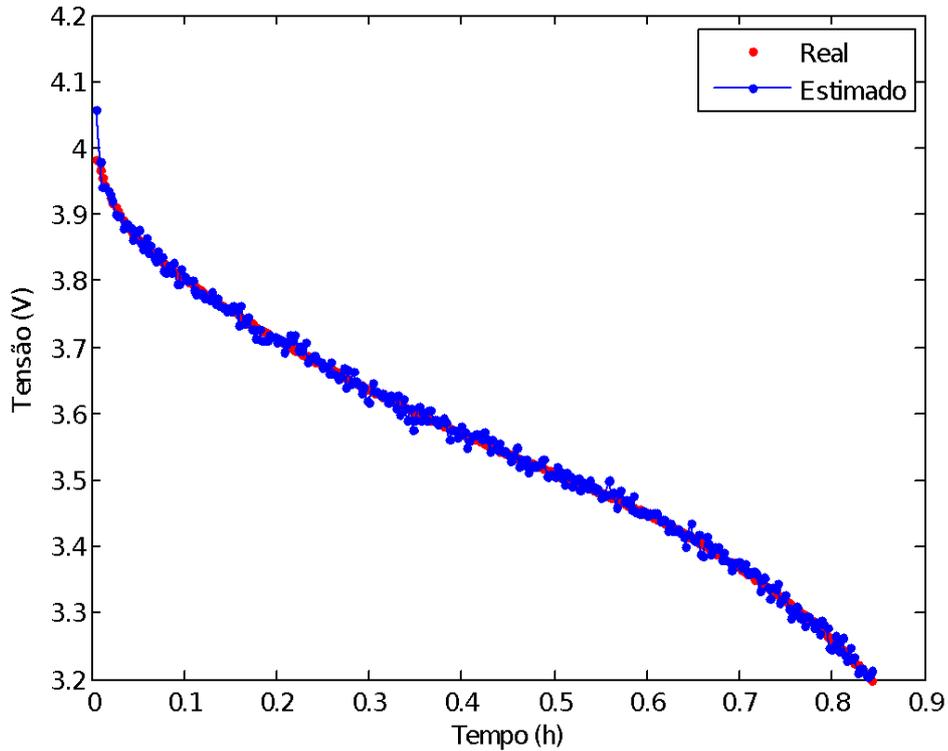
Figura 40 – Degradação da capacidade por ciclos usando PF – RW10.



Fonte: Autoria própria.

A Figura 41 mostra a estimativa do último ciclo de descarga usando o Filtro de Partículas aplicado a bateria RW10.

Figura 41 – Estimativa do último ciclo de descarga da bateria RW10 usando PF.



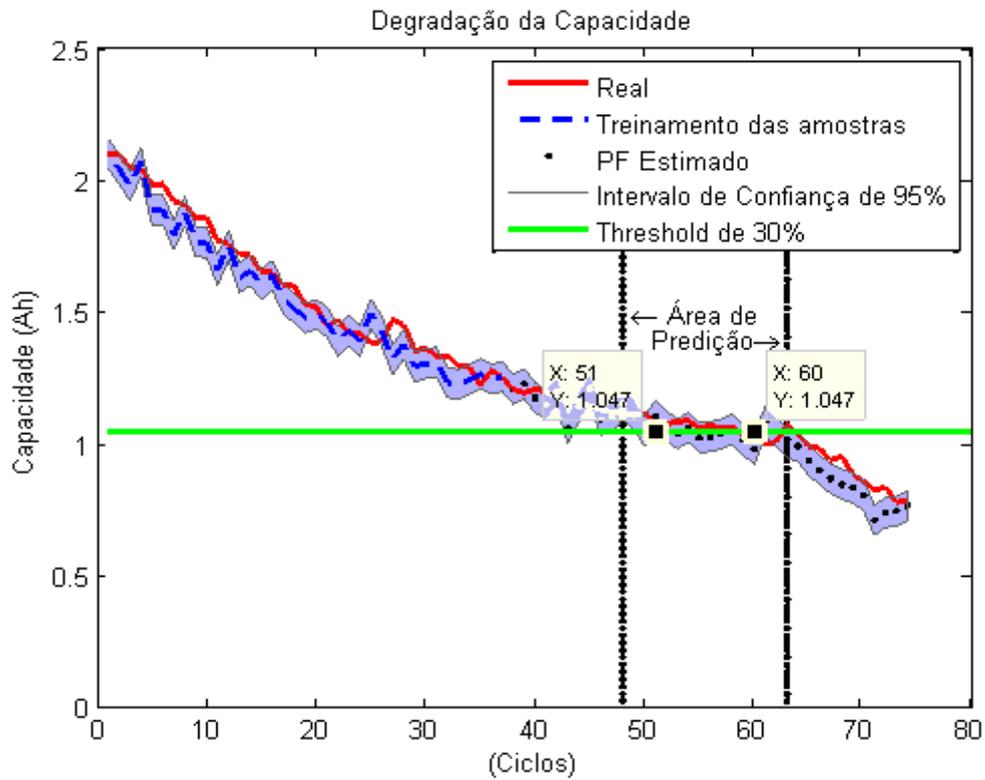
Fonte: Autoria própria.

Ao observar a Figura 41 está explícito que a estimativa do PF para a curva de descarga está melhor que os outros métodos apresentados anteriormente.

4.4.1 Resultados do Filtro de Partículas com validação das estimativas

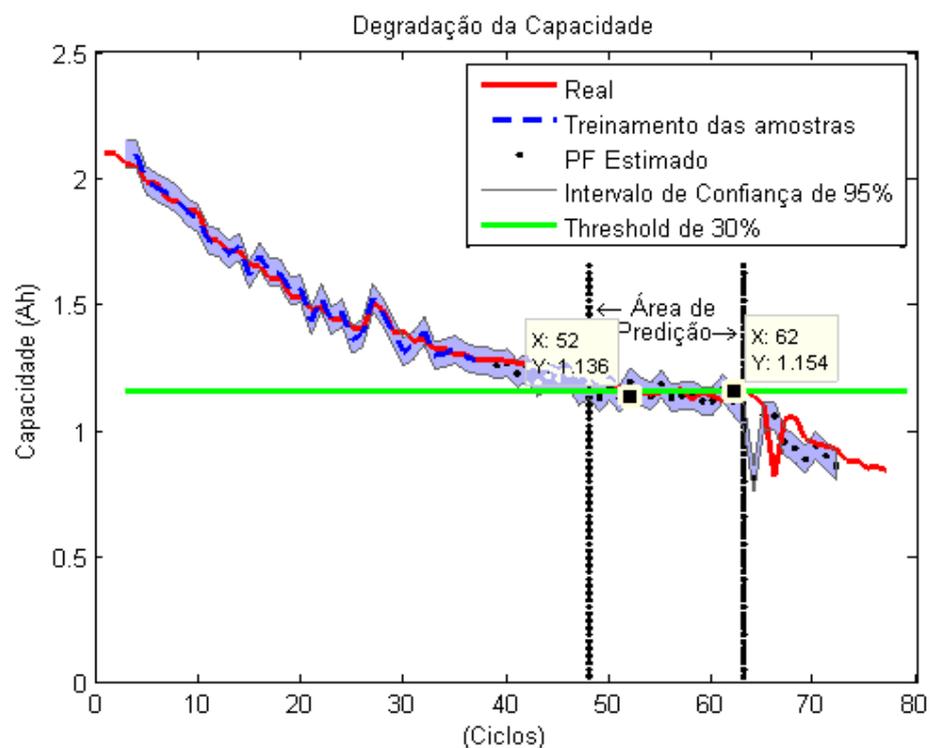
O Filtro de Partículas teve sua janela móvel organizada com 2 pontos de capacidade, também usada no momento do treinamento das amostras. Os resultados dos treinamentos e testes para predição são apresentados nas Figuras 42 e 43.

Figura 42 – Validação do modelo da capacidade da bateria RW9 com PF



Fonte: Autoria própria.

Figura 43 – Validação do modelo da capacidade da bateria RW10 com PF



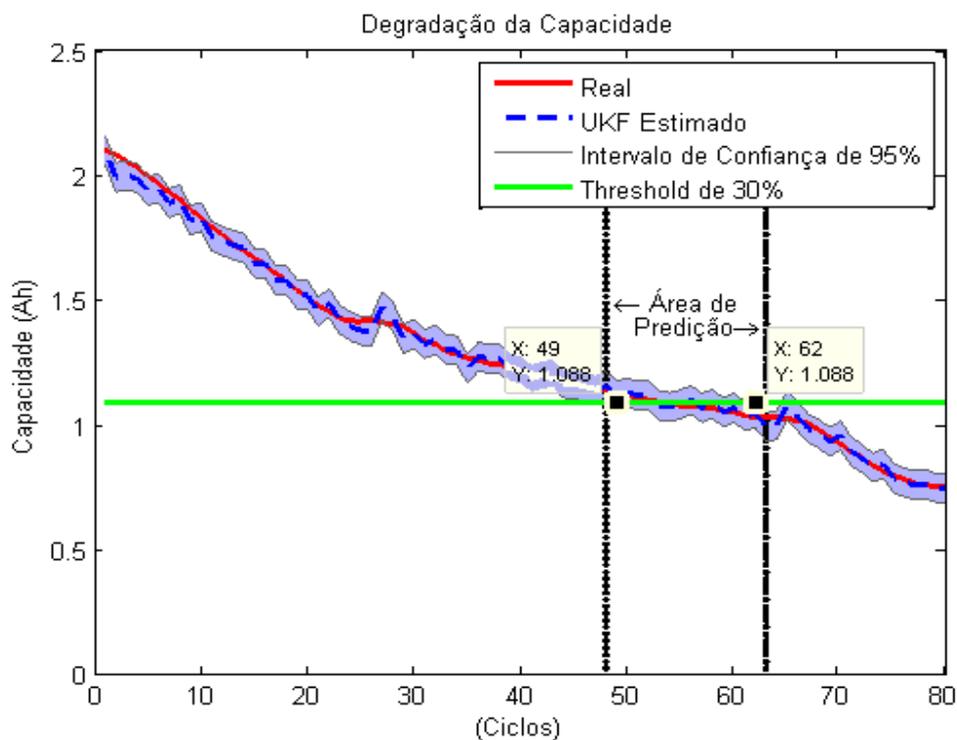
Fonte: Autoria própria.

4.5 Resultados do Filtro de Kalman *Unscented*

O Filtro de Kalman *Unscented* (UFK) vem ganhando bastante espaço em sistemas não lineares, onde o Filtro de Kalman comum ou o estendido conseguiram atingir os resultados esperados.

A Figura 44 mostra a previsão de degradação da capacidade com intervalo de confiança de 95%. O R^2 do método proposto obteve um valor de **0.99728249** para a degradação da capacidade da bateria RW9, estimativas bem próximas do real, assim superando todos os métodos experimentados, mas com uma disputa bem competitiva com o Filtro de Partículas.

Figura 44 - Degradação da capacidade por ciclos usando UKF – RW9.



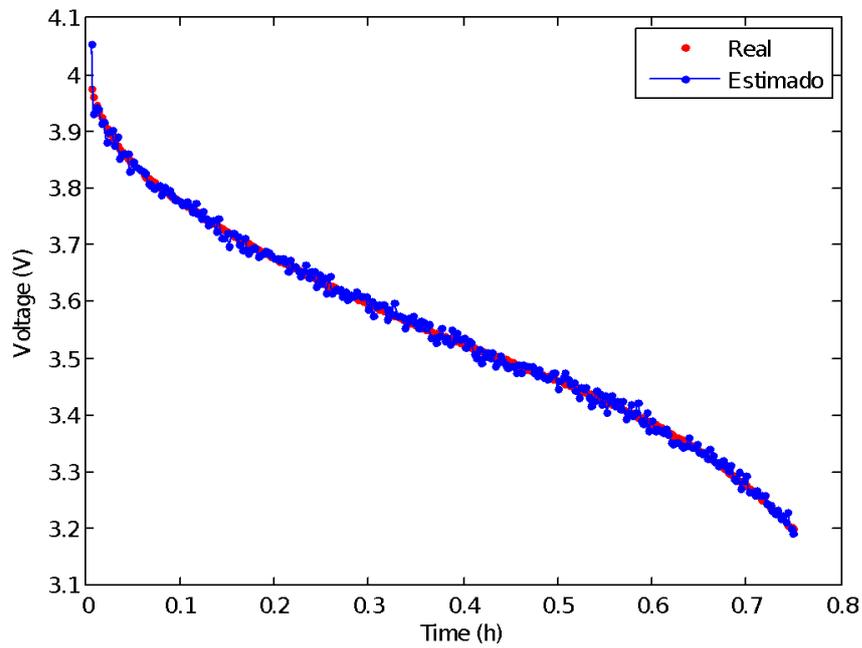
Fonte: Autoria própria.

A Figura 45 apresenta o resultado do último ciclo de descarga estimado pelo UKF na bateria RW9. O R^2 e o RMSE da estimativa tiveram bons resultados.

A Figura 46 apresenta a estimativa da degradação da capacidade com Filtro de Kalman *Unscented* da bateria RW10. O UKF conseguiu prever a falha da bateria RW10 dentro da área de predição com limites máximos e mínimos não tão discrepantes. Os resultados mostraram um bom desempenho. A Figura 47 apresenta a estimativa da última

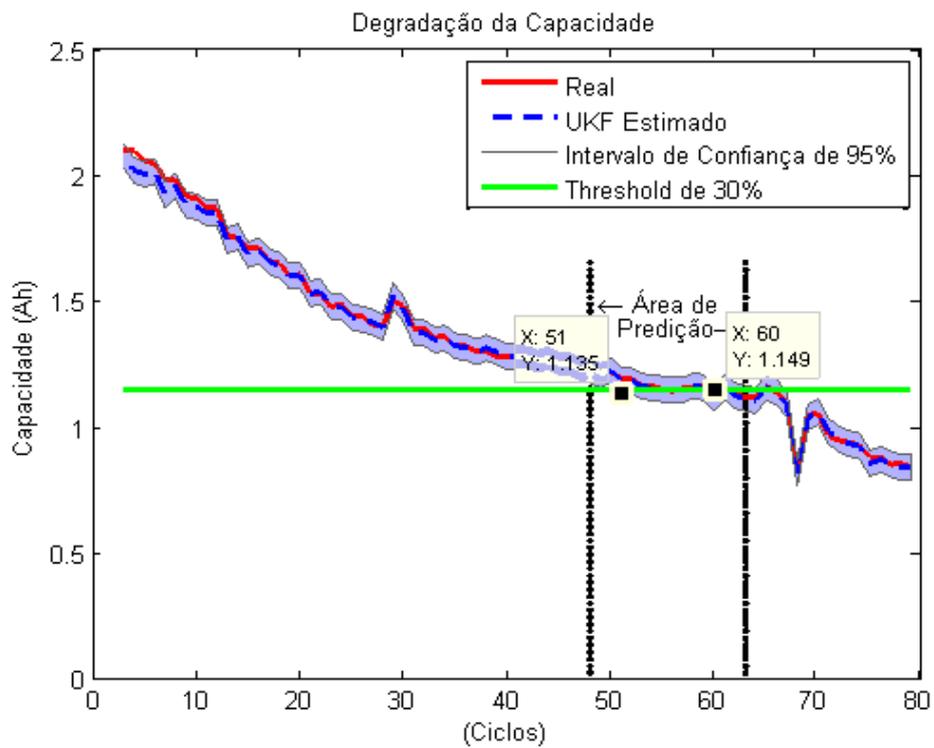
curva de descarga da bateria RW10 utilizando o UKF.

Figura 45 – Estimativa do último ciclo de descarga da bateria RW9 usando UKF.



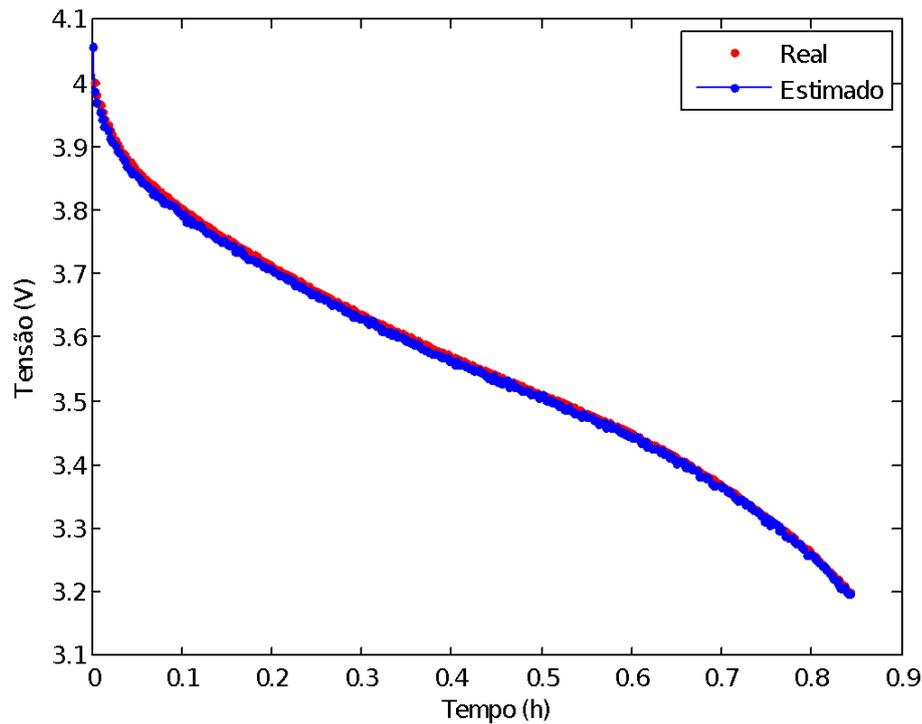
Fonte: Autoria própria.

Figura 46 - Degradação da capacidade por ciclos da bateria RW10 usando UKF.



Fonte: Autoria própria.

Figura 47 - Estimativa do último ciclo de descarga usando UKF – RW10.



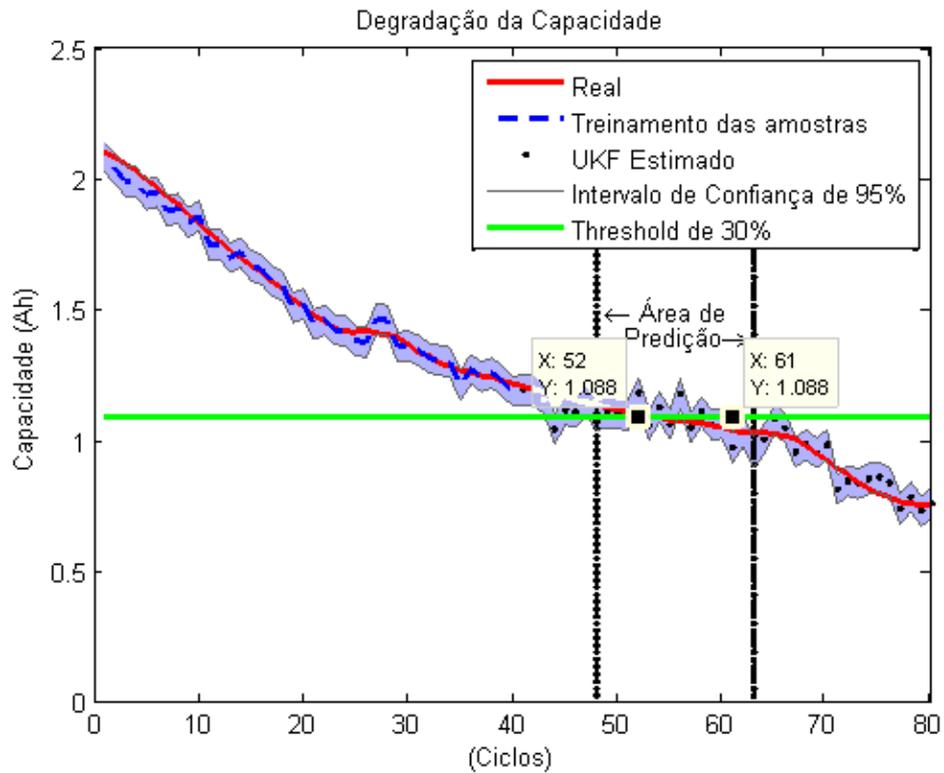
Fonte: Autoria própria.

A estimativa da curva de descarga da bateria RW10 com UKF conseguiu superar os métodos mostrados nas seções anteriores.

4.5.1 Resultados do Filtro de Kalman Unscented com validação das estimativas

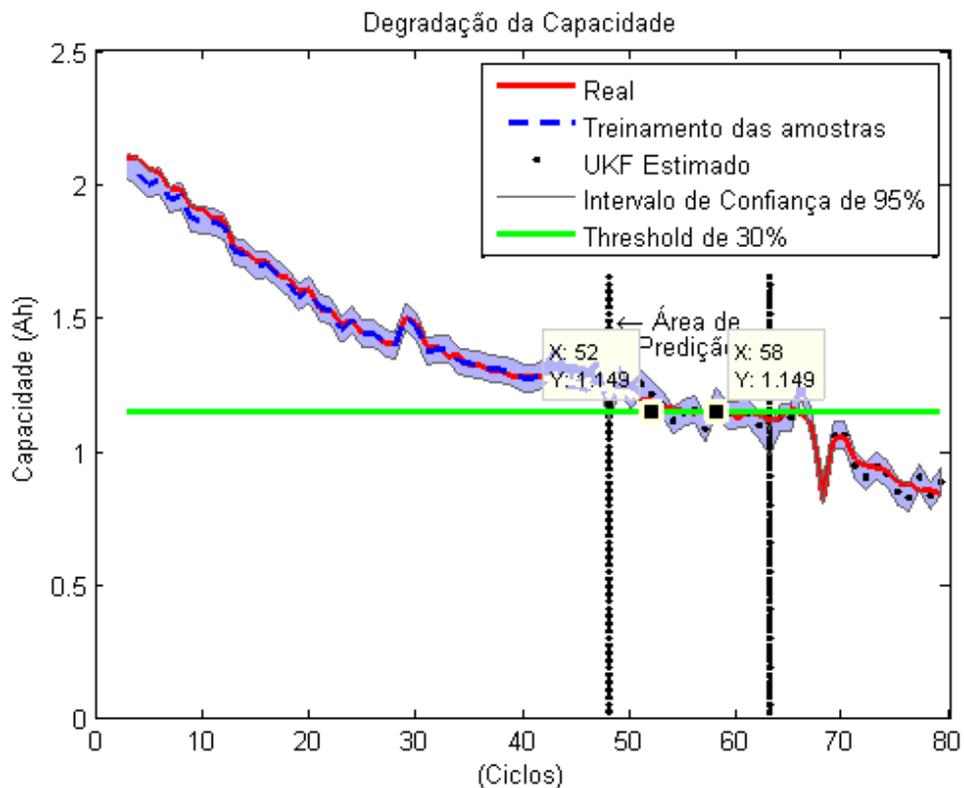
O UKF foi testado com várias formas de janelamento, porém a que o algoritmo mais se adequou foi a com 3 janelas moveis durante o treinamento. Os resultados da validação das predições da degradação da capacidade das baterias RW9 e RW10 são apresentadas nas Figuras 48 e 49.

Figura 48 – Validação do modelo da capacidade da bateria RW9 com UKF



Fonte: Autoria própria.

Figura 49 – Validação do modelo da capacidade da bateria RW10 com UKF



Fonte: Autoria própria.

4.6 Análise Geral dos Resultados

Ao fazer uma análise geral, incluindo os intervalos de confiança, pode-se observar que as estimativas dos intervalos de confiança da bateria RW9 ficaram melhores que a do RW10. Isso pode ocorrer pelo fato da bateria RW9 ter mais dados e ter um comportamento mais suave.

De acordo com as Tabelas 3 e 4, são apresentados todos os resultados oriundos das estimativas da degradação da capacidade, avaliados pelo R^2 (Coeficiente de Correlação), dado pela Equação 27, e pelo custo computacional das baterias identificadas como RW9 e RW10, respectivamente.

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2}, \quad (27)$$

Onde:

y_i : dados observados;

\bar{y} : é a média dos dados observados;

\hat{y}_i : dados estimados pelo modelo.

Conforme mostram as Tabelas 3 e 4, o Filtro de Kalman *Unscented* (UKF) conseguiu superar todos os métodos tratando de R^2 , porém perde no custo computacional por um segundo.

Tabela 3. Comparação dos Resultados do R^2 da bateria RW9.

RESULTADOS OBTIDOS PELA CAPACIDADE		
Métodos	R^2	Custo Computacional
RNA ELM	0.99190569	2 s
Filtro de Kalman	0.99159075	2 s
Mínimos Quadrados	0.97449002	3 s
Filtro de Partículas	0.99279405	4 s
UKF	0.99728249	3 s

Fonte: Autoria própria.

Tabela 4. Comparação dos Resultados do R² da bateria RW10.

RESULTADOS OBTIDOS PELA CAPACIDADE		
Métodos	R²	Custo Computacional
RNA ELM	0.95299792	3 s
Filtro de Kalman	0.92839859	3 s
Mínimos Quadrados	0.92515913	3 s
Filtro de Partículas	0.99152810	5 s
UKF	0.99650783	4 s

Fonte: Autoria própria.

Os métodos foram avaliados também pela raiz do erro quadrático médio (RMSE), onde a Equação 28 apresenta a fórmula usada para o cálculo. As Tabelas 5 e 6 mostram os resultados da RMSE.

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (\hat{y}_t - y_t)^2}{T}} \quad (28)$$

Onde \hat{y} é a predição, y é a variável observada e T é a quantidade de iterações. O RMSE é uma medida de precisão que serve para comparar erros de previsão de diferentes modelos para um conjunto de dados específico e não entre conjuntos de dados, pois é dependente da escala. Quanto menor o valor do mesmo, melhor o resultado.

Ao comparar os resultados com RMSE o UKF também conseguiu atingir melhores resultados, com RMSE de **0.0124**.

Tabela 5. Comparação dos Resultados do RMSE da bateria RW9.

RESULTADOS OBTIDOS PELA CAPACIDADE	
Métodos	RMSE
RNA ELM	0.0219
Filtro de Kalman	0.0279
Mínimos Quadrados	0.1044
Filtro de Partículas	0.0218
UKF	0.0124

Fonte: Autoria própria.

Também foi calculado o R² e o RMSE nas curvas de descarga das baterias RW9 e RW10, os resultados de cada método podem ser observados nas Tabelas 7 a 10.

Tabela 6. Comparação dos Resultados do RMSE da bateria RW10.

RESULTADOS OBTIDOS PELA CAPACIDADE	
Métodos	RMSE
RNA ELM	0.0502
Filtro de Kalman	0.0713
Mínimos Quadrados	0.1050
Filtro de Partículas	0.0201
UKF	0.0133

Fonte: Autoria própria.

Tabela 7. Resultados do R^2 das curvas de descarga da bateria RW9.

RESULTADOS OBTIDOS PELAS CURVAS DE DESCARGA		
Métodos	R^2	Custo Computacional
RNA ELM	0.97741972	3 s
Filtro de Kalman	0.93877950	3 s
Mínimos Quadrados	0.86399332	3 s
Filtro de Partículas	0.99706300	5 s
UKF	0.99882455	4 s

Fonte: Autoria própria.

Tabela 8. Resultados do R^2 das curvas de descarga da bateria RW10.

RESULTADOS OBTIDOS PELAS CURVAS DE DESCARGA		
Métodos	R^2	Custo Computacional
RNA ELM	0.99586031	3 s
Filtro de Kalman	0.99266577	2 s
Mínimos Quadrados	0.98936934	2 s
Filtro de Partículas	0.99722189	4 s
UKF	0.99877978	3 s

Fonte: Autoria própria.

Tabela 9. Resultados do RMSE das curvas de descarga da bateria RW9.

RESULTADOS OBTIDOS PELAS CURVAS DE DESCARGA	
Métodos	RMSE
RNA ELM	0.0190
Filtro de Kalman	0.0395
Mínimos Quadrados	0.0406
Filtro de Partículas	0.0072
UKF	0.0045

Fonte: Autoria própria.

Tabela 10. Resultados do RMSE das curvas de descarga da bateria RW10.

RESULTADOS OBTIDOS PELAS CURVAS DE DESCARGA	
Métodos	RMSE
RNA ELM	0.0083
Filtro de Kalman	0.0207
Mínimos Quadrados	0.0273
Filtro de Partículas	0.0069
UKF	0.0046

Fonte: Autoria própria.

4.6.1 Análise Geral dos Resultados dos modelos de validação

Conforme apresentado nas tabelas 1, 2, 3 e 4 são mostrados os resultados da validação da predição da degradação das baterias RW9 e RW10, assim o UKF conseguiu ainda superar os demais métodos nas métricas R^2 e RMSE.

Tabela 11. Comparação dos Resultados do R^2 da bateria RW9.

RESULTADOS OBTIDOS PELA CAPACIDADE		
Métodos	R^2	Custo Computacional
RNA ELM	0.830981	2 s
Filtro de Kalman	0.797610	2 s
Mínimos Quadrados	0.765620	3 s
Filtro de Partículas	0.887811	4 s
UKF	0.893298	3 s

Fonte: Autoria própria.

Tabela 12. Comparação dos Resultados do R^2 da bateria RW10.

RESULTADOS OBTIDOS PELA CAPACIDADE		
Métodos	R^2	Custo Computacional
RNA ELM	0.821123	3 s
Filtro de Kalman	0.790121	3 s
Mínimos Quadrados	0.763123	3 s
Filtro de Partículas	0.879891	5 s
UKF	0.892109	4 s

Fonte: Autoria própria.

Tabela 13. Comparação dos Resultados do RMSE da bateria RW9.

RESULTADOS OBTIDOS PELA CAPACIDADE	
Métodos	RMSE
RNA ELM	0.0471
Filtro de Kalman	0.0499
Mínimos Quadrados	0.1274
Filtro de Partículas	0.0301
UKF	0.0289

Fonte: Autoria própria.

Tabela 14. Comparação dos Resultados do RMSE da bateria RW10.

RESULTADOS OBTIDOS PELA CAPACIDADE	
Métodos	RMSE
RNA ELM	0.0489
Filtro de Kalman	0.0510
Mínimos Quadrados	0.1281
Filtro de Partículas	0.0312
UKF	0.0293

Fonte: Autoria própria.

5 CONSIDERAÇÕES FINAIS

Na literatura atual de PHM, os conceitos básicos de manutenção vêm sendo reformulados ao longo dos anos visando redução de custos, aumento de disponibilidade e maior segurança. Dessa forma, estudos sobre previsibilidade de falhas e vida útil de equipamentos vêm ganhando cada vez mais espaço. Novas técnicas para aquisição e tratamento de dados, bem como algoritmos e metodologias são foco de pesquisas recentes a fim de otimizar o prognóstico e gestão de saúde de equipamentos e componentes de sistemas críticos ou de grande valor agregado. Em paralelo a isso, os VANTs também vêm ganhando seu espaço nos mais diversos campos de aplicação, como aviação militar e comercial, logística, manutenção, agropecuária e até mesmo com drones de uso doméstico, utilizados como brinquedo, aerodelismo e para fotografia. O fato destes equipamentos serem discretos, ágeis, conseguirem acessar locais de difícil acesso e inseguros e não necessitarem de pessoas a bordo correndo algum risco de vida possibilita uma vasta gama de utilização.

O uso de VANTs também implica em algumas dificuldades, como operação e controle. Os primeiros modelos possuíam propulsão à combustão e estes vêm sendo substituídos por propulsão elétrica com alimentação de baterias, o que traz o desafio do gerenciamento de energia destes equipamentos. O estudo da vida útil remanescente e do tempo de descarga destas baterias pode ser feitos através de técnicas de PHM.

Neste trabalho foi feita uma revisão sobre os conceitos de prognóstico e gestão de saúde de equipamentos, sobre VANTs e baterias de íons de lítio. Foi apresentada uma solução para os problemas de predição da capacidade de baterias Li-Ion e previsão de descarga das mesmas, assuntos ainda muito discutidos no campo de gerenciamento de sistemas. Foram apresentados 5 métodos: rede neural ELM, Mínimos Quadrados Não Recursivos, Filtro de Kalman discreto, Filtro de Partículas e Filtro de Kalman *Unscented*.

Cada um destes métodos foi aplicado com a finalidade de prever de degradação de capacidade e descarga de duas baterias do repositório da NASA, identificadas como RW9 e RW10. Todos os métodos foram avaliados pelo RMSE, R^2 , custo computacional e pelo tamanho de intervalos de confiança no momento da falha em uma área delimitada. Para isso foi definido um limiar de falha para a capacidade em 30% da capacidade nominal da bateria e intervalos de confiança de 95% nas predições. Os intervalos conseguiram obter resultados aceitáveis no momento de falha, porém alguns muito próximos das barreiras de predição. As baterias utilizadas possuem uma mudança de corrente em um dado intervalo de tempo,

simulando um comportamento de bateria sendo usada pelo um drone no momento do voo, pois essas mudanças de correntes podem ser perturbações oriundas do vento ou manobras.

Todos os métodos apresentados mostraram bons resultados de predição quando avaliados pelo coeficiente correlação e pela raiz do erro quadrático médio. Os custos computacionais em todos os casos foram próximos e muito baixos. Em termos práticos, para a situação de degradação de baterias, que ocorre após vários ciclos de carga e descarga, e para a descarga, que ocorre em minutos, os poucos segundos do custo computacional pouco influenciam.

O Filtro de Kalman *Unscented* foi o método que obteve a melhor avaliação dentre todos os outros. O Filtro de Kalman Discreto, mesmo indicado para sistemas lineares, apresentou resultados aceitáveis neste sistema não linear. Observou-se também que, na maioria dos casos, a bateria RW9 possui um padrão de descarga e degradação mais comportada e mais fácil de prever que a bateria RW10. Mesmo com essa variação, todos os métodos aplicados são capazes de realizar as previsões de degradação de capacidade e descarga de ambas as baterias.

5.1 Propostas para Trabalhos Futuros

Neste trabalho foi estudado o prognóstico apenas em um componente do VANT. Em trabalhos futuros podem-se aplicar os métodos apresentados em outros, como motores, hélices, processador, sensores, entre outros.

Em relação às baterias, pode-se estudar a influência da temperatura da bateria na redução da capacidade da mesma, além do prognóstico de outros modos de falha desta. É possível utilizar a predição da descarga para gerenciar rotas, utilizando pesos de importância em cada ponto de pouso e assim replanejar o trajeto de voo. O levantamento de dados também pode ser feito experimentalmente em bancada com bateria e um drone.

Em relação aos algoritmos, é possível buscar melhorias no custo computacional através de algoritmos de busca (heurística, metaheurística ou matheurística), que se possa melhorar o tempo de resposta através de uma função custo, além da redução da área delimitada pelos intervalos de confiança.

Outra proposta é a de aliar a predição de falha com controle preditivo, onde no momento da falha de um dos motores do VANT, o controle possa compensar o esforço dos mesmos em funcionamento, fazendo com que o VANT reorganize sua rota ou faça um pouso emergencial sem danos e acidentes.

REFERÊNCIAS

- ABDULHAMID, Rauhe. **Desenvolvimento de Algoritmo de Controle Robusto para Veículos Aéreos Não Tripulados de Asa Fixa de Pequeno Porte**. 2016. 194f. Dissertação de Mestrado – Instituto Tecnológico de Aeronáutica, São José dos Campos, 2016.
- ALOZIE, Ogechukwu; LI, Yi-Guang; WU, Xin; SHONG, Xingchao; REN, Wencheng. **An Adaptive Model-Based Framework for Prognosis of Gas Path Faults in Aircraft Gas Turbine Engines**. International Journal of Prognostics and Health Management: Vol 10 013, pages: 12, 2019.
- ALVES, Milena Regina Jaloretto. **Determinação da Distribuição de Probabilidade no Tempo para Ocorrência de Falha Empregando Análise de Tendência**. 2010. 110 f. Dissertação (Mestrado em Engenharia Aeronáutica e Mecânica) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2010.
- ARTHUR GELB. **Applied Optimal Estimation**. MIT Press, 1974.
- ASSARAF, ROLAND; CAFFAREL, MICHEL; KHELIF, ANATOLE. **Diffusion Monte Carlo Methods with a fixed number of walkers**. Phys. Rev, 2000.
- ATAMURADOV, Vepa; MEDJAHAR, Kamal; DERSIN, Pierre; LAMOUREUX, Benjamin; ZERHOUNI, Noureddine. **Prognostics and Health Management for Maintenance Practitioners - Review, Implementation and Tools Evaluation**. International Journal of Prognostics and Health Management: Vol 8 (Special Issue on Railways & Mass Transportation) 060, pages: 31, 2017.
- BARAK, OMRI; RIGOTTI, MATTIA; AND FUSI, STEFANO. **The Sparseness of Mixed Selectivity Neurons Controls the Generalization-Discrimination Trade-off**. Journal of Neuroscience, 2013.
- BIZARRIA, Cíntia de Oliveira. **Prognóstico de Falhas no Atuador do Leme da Aeronave EMBRAER-190**. 2009. 98 f. Dissertação (Mestrado em Engenharia Aeronáutica e Mecânica) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2009.
- BOILE, Brian; KULKARNI, Chetan; DAIGLE, Matthew. **Adaptation of an Electrochemistry-based Li-Ion Battery Model to Account for Deterioration Observed Under Randomized Use**. Annual Conference of the Prognostics and Health Management Society, 2014.
- BORGES, Nicolas Pereira. **Improving Stealth in Collaborative UAV Networks**. 2017. 82 f. Dissertação (Mestrado em Engenharia Eletrônica e Computação) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2017.
- CAFFAREL, MICHEL; CEPERLEY, DAVID; KALOS, MALVIN. **Comment on Feynman-Kac Path-Integral Calculation of the Ground-State Energies of Atoms**. Phys. Rev, 1993.
- CÂNDIDO, Adilson de Souza. **Sistema de Gerenciamento do Voo de Quadrirotores Tolerante a Falhas**. 2015. 209 f. Tese (Doutorado em Engenharia Eletrônica e Computação) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2015.

CAO, JIUWEN, ZHIPING LIN, GUANG-BIN HUANG. **Composite Function Wavelet Neural Networks with Extreme Learning Machine**. Neurocomputing, 2009.

CHARNES, A.; FROME, E. L.; YU, P. L. **The Equivalence of Generalized Least Squares and Maximum Likelihood Estimates in the Exponential Family**. Journal of the American Statistical Association. 1976.

DAWN AN. JOO-HO CHOI; NAM H. KIM. **Prognostics 101: A tutorial for particle filter-based prognostics algorithm using Matlab**. Reliability Engineerin, 2013. DOI: 10.1016/j.res.2013.02.019.

DEL MORAL, PIERRE. **Non Linear Filtering: Interacting Particle Solution**. Markov Processes and Related Fields. 1996.

DEL MORAL, PIERRE (1998). **Measure Valued Processes and Interacting Particle Systems. Application to Non Linear Filtering Problems**. Annals of Applied Probability, 1998.

DEL MORAL, PIERRE; MICLO, LAURENT. **Branching and Interacting Particle Systems Approximations of Feynman-Kac Formulae with Applications to Non-Linear Filtering** (PDF). Lecture Notes in Mathematics, 2000.

DEL MORAL, PIERRE; MICLO, LAURENT. **A Moran particle system approximation of Feynman-Kac formulae**. Stochastic Processes and Their Applications, 2000.

DEL MORAL, PIERRE. **Particle approximations of Lyapunov exponents connected to Schrödinger operators and Feynman-Kac semigroups**. ESAIM Probability & Statistics, 2003.

DEL MORAL, PIERRE (2004). **Feynman-Kac formulae. Genealogical and interacting particle approximations**. Springer. Series: Probability and Applications, 2004.

DEL MORAL, PIERRE. **Feynman-Kac formulae. Genealogical and interacting particle approximations**. Probability and its Applications. Springer, 2004.

DEL MORAL, PIERRE; DOUCET, ARNAUD; JASRA, AJAY (2012). **On Adaptive Resampling Procedures for Sequential Monte Carlo Methods**. Bernoulli, 2012.

DEL MORAL, PIERRE. **Mean field simulation for Monte Carlo integration**. Chapman & Hall/CRC. Monographs on Statistics & Applied Probability, 2013.

DISCENZO, F. et al. **Open Systems Architecture Enables Health Management for Next Generation System Monitoring and Maintenance**. Rockwell Automation, Cleveland, OH, the OSA-CBM Development Group. White Paper, 2001.

E. WAN AND R. VAN DER MERWE. **The Unscented Kalman Filter**. Wiley Publishing, 2001.

ELECTROPAEDIA. **Lithium Battery Failures**. 2005. Woodbank Communications Ltd. Disponível em: <[http://www.mpoweruk.com/lithium failures.htm](http://www.mpoweruk.com/lithium%20failures.htm)>. Acesso em: 14 nov. 2018.

EKER, Omer F.; CAMCI, Fatih; Jennions, Ian K. **A New Hybrid Prognostic Methodology**. International Journal of Prognostics and Health Management: Vol 10 009, pages: 13, 2019

FISCHER, Clécio. **Identificação do modelo látero-direcional de um veículo aéreo não tripulado, VECTOR-P**. 2017. 99 f. Dissertação (Mestrado em Engenharia Aeronáutica e Mecânica) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2017.

FUSI, STEFANO, EARL K MILLER AND MATTIA RIGOTTI (2015). **Why Neurons Mix: High Dimensionality for Higher Cognition**. Current Opinion in Neurobiology. 2015.

GOEBEL K, SAHA B, SAXENA A, CELAYA JR, CHRISTOPHERSEN J. **Prognostics in battery health management**. IEEE Instrumentation and Measurement Magazine 2008.

GOMES, João P. P.; GALVÃO, Roberto K. H.; YONEYAMA, Takashi. Prognóstico de Falhas em uma Válvula Pneumática Utilizando Filtro de Kalman. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 2012, Campina Grande. **Anais do XIX Congresso Brasileiro de Automática, CBA 2012**. Campina Grande, 2012. p. 2395 – 2401.

GOMES, João P. P.; RODRIGUES, Leonardo R.; GALVÃO, Roberto K.; YONEYAMA, Takashi. Detecção de Anomalias em uma Válvula Pneumática Usando Modelos de Mistura de Gaussianas. In: XI Simpósio Brasileiro de Automação Inteligente, 2013, Fortaleza. **Anais do XI Simpósio Brasileiro de Automática, CBA 2013**. Fortaleza, 2013.

HE, QING, XIN JIN, CHANGYING DU, FUZHEN ZHUANG, ZHONGZHI SHI (2014). **Clustering in Extreme Learning Machine Feature Space**. Neurocomputing, 2014.

HETHERINGTON, JACK, H. **Observations on the statistical iteration of matrices"**. Phys. Rev, 1984.

HOGGE, Edward F.; BOLE, Brian M.; VAZQUEZ, Sixto I.; KULKARNI, Chetan S.; STROM, Thomas H.; HILL, Boyd I.; SMALLING, Kyle M.; QUACH, Cuong C. **Verification of Prognostic Algorithms to Predict Remaining Flying Time for Electric Unmanned Vehicles**. International Journal of Prognostics and Health Management: Vol 9 (1) 021, pages: 15, 2018.

HUANG,, GUANG-BIN; HONGMING ZHOU; XIAOJIAN DING; AND RUI ZHANG. **Extreme Learning Machine for Regression and Multiclass Classification**. IEEE Transactions on Systems, 2012.

HUANG, GUANG-BIN, LEI CHEN. **Convex Incremental Extreme Learning Machine**. Neurocomputing, 2007.

HUANG, GUANG-BIN, LEI CHEN. **Enhanced Random Search Based Incremental Extreme Learning Machine**. Neurocomputing, 2008.

HUANG, GUANG-BIN, LEI CHEN, AND CHEE-KHEONG SIEW (2006). **Universal**

Approximation Using Incremental Constructive Feedforward Networks with Random Hidden Nodes. IEEE Transactions on Neural Networks, 2006.

HUANG, GUANG-BIN, QIN-YU ZHU, K. Z. MAO, CHEE-KHEONG SIEW, P. SARATCHANDRAN, AND N. SUNDARARAJAN. **Can Threshold Networks Be Trained Directly?.** IEEE Transactions on Circuits and Systems, 2006.

HUANG, GUANG-BIN; ZHU, QIN-YU; SIEW, CHEE-KHEONG. **Extreme learning machine: theory and applications.** Neurocomputing, 2006.

HUANG, GUANG-BIN. **An Insight into Extreme Learning Machines: Random Neurons, Random Features and Kernels.** Cognitive Computation, 2014.

HUANG, GUANG-BIN. **What are Extreme Learning Machines? Filling the Gap Between Frank Rosenblatt's Dream and John von Neumann's Puzzle.** Cognitive Computing, 2015.

HUANG, GUANG-BIN, ZUO BAI, AND LIYANAARACHCHI LEKAMALAGE CHAMARA KASUN, AND CHI MAN VONG. **Local Receptive Fields Based Extreme Learning Machine.** IEEE Computational Intelligence Magazine, 2015.

HARDING ENERGY, INC. Harding Battery Handbook For Quest R Rechargeable Cells and Battery Pack. One Energy Centre, Norton Shores, MI 49441, December 2008. Disponível em: <http://nic.vajn.icu/PDF/battery/Rechargeable_Batteries.pdf>. Acesso em: 12 fev. 2019.

HUGGINS, Robert. **Advanced Batteries: Materials Science Aspects.** Stanford: Springer, 2009.

HYNDMAN, ROB J; KOEHLER, ANNE B. **Outra olhada nas medidas de precisão das previsões.** Jornal Internacional de Previsão, 2006.

KALMAN, R. E. **A New Approach to Linear Filtering and Prediction Problems.** Journal of Basic Engineering, 1960.

KASUN, LIYANAARACHCHI LEKAMALAGE CHAMARA, YAN YANG, GUANG-BIN HUANG, AND ZHENGYOU ZHANG. **Dimension Reduction With Extreme Learning Machine.** IEEE Transactions on Image Processing, 2016.

KUMAR, V.; MICHAEL, N. Opportunities and Challenges with Autonomous Micro Aerial Vehicles. **The International Journal of Robotics Research**, v. 31, n. 11, p. 1279-1291. Set. 2012.

LEÃO, Bruno Paes. **Failure Prognosis Methods and Offline Performance Evaluation.** 2011. 138 f. Tese (Doutorado em Engenharia Eletrônica e Ciências da Computação) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2011.

LIN, JESSICA; KEOGH, EAMONN; LONARDI, STEFANO; CHIU, BILL. **A symbolic representation of time series, with implications for streaming algorithms. Proceedings of the 8th ACM SIGMOD workshop on Research issues in data mining and knowledge discovery.** New York, 2003.

MELO, Roseneia Rodrigues Santos de. **Diretrizes para Inspeção de Segurança em Canteiros de Obra por Meio de Imageamento com Veículo Aéreo Não Tripulado (VANT)**. 2016. 160 f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal da Bahia, Salvador, 2016.

MORAL, PIERE DEL; DOUCET, ARNAUD. **Particle methods: An introduction with applications**. ESAIM, 2014.

NAZRI, Gholam-Abbas; PISTOIA, Gianfranco. **Lithium Batteries - Science and Technology**. Springer Science+Business Media LLC, New York (USA), 2003

OOJEVAAR, Ted; PICHLER, Kurt; DI, Yuan; HESCH, Clemens. **A Comparison of Vibration Based Bearing Fault Diagnostic Methods**. International Journal of Prognostics and Health Management: Vol 10 008, pages: 17, 2019.

OSSAI, Chinedu. **Prognostics Health Estimation of Lithium-ion Batteries in Charge-Decay Estimation Uncertainties – A Comparative Analysis**. International Journal of Prognostics and Health Management: Vol 9 (2) 024, pages: 8, 2018.

PAUL ZARCHAN; HOWARD MUSOFF. **Fundamentals of Kalman Filtering: A Practical Approach**. American Institute of Aeronautics and Astronautics, Incorporated, 2000.

PENNA, José Affonso Moreira. **Monitoramento da Saúde e Estimação da Vida Útil de Baterias Aeronáuticas de Lítio-Íon**. 2011. 101 f. Dissertação (Mestrado Profissional em Engenharia Aeronáutica e Mecânica) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2011.

PÉREZ, Aramis; BENAVIDES, Matías; ROZAS, Heraldo; SERIA, Sebastián; ORCHARD, Marcos. **Guidelines for the Characterization of the Internal Impedance of Lithium-Ion Batteries in PHM Algorithms**. International Journal of Prognostics and Health Management: Vol 9 (Special Issue from PHMAP17 Highlights) 015, pages: 10, 2018.

PINTO, Ana Flávia Cupertino. **Filtro de Partículas: O Algoritmo Resample-Move**. 2007. 67 f. Dissertação (Mestrado em Estatística) – Universidade Federal de Minas Gerais – UFMG, Belo Horizonte, 2007.

RAHIMI, ALI, AND BENJAMIN RECHT. **Weighted Sums of Random Kitchen Sinks: Replacing Minimization with Randomization in Learning**. Advances in Neural Information Processing Systems, 2008.

RIGOTTI, MATTIA; BARAK, OMRI; WARDEN, MELISSA R.; WANG, XIAO-JING; DAW, NATHANIEL D.; MILLER, EARL K.; AND FUSI, STEFANO. **The Importance of Mixed Selectivity in Complex Cognitive Tasks**. Nature, 2013.

RODRIGUES, Leonardo Ramos. **Gerenciamento de Estoques Auxiliado por um Sistema de Prognóstico e Monitoramento da Saúde de Sistemas Aeronáuticos**. 2013. 100 f. Tese (Doutorado em Engenharia Aeronáutica e Mecânica) – Instituto de Tecnologia Aeronáutica, São José dos Campos, 2013.

ROSENBLUTH, MARSHALL, N.; ROSENBLUTH, ARIANNA, W. **Monte-Carlo calculations of the average extension of macromolecular chains.** J. Chem. Phys, 1955.

R. VAN DER MERWE. **Sigma-Point Kalman Filters for Probabilistic Inference in Dynamic State-Space Models.** Technical report, 2003.

SANTOS, M.; LÓPEZ, V.; MORATA, F. **Intelligent Fuzzy Controller of a Quadrirotor.** 2010 IEEE International Conference on Intelligent Systems And Knowledge Engineering, Hangzhou, 2010.

SAUSEN, Paulo Sérgio. **Gerenciamento Integrado de Energia e Controle de Topologia em Redes de Sensores Sem Fio.** 111 f. Tese (Doutorado em Ciências no Domínio da Engenharia Elétrica) – Universidade Federal de Campina Grande, Campina Grande, 2008.

SAXENA, Abhinav et al. **Prognostics for Batteries: Aging Experiments and Modeling.** 2012 NASA Battery Workshop – NASA Ames Research Center – Prognostics Center Excellence. Huntsville, 2012.

SCHNEIDER, Keila Kleveston. **Modelos Analíticos na Predição do Tempo de Vida Útil de Baterias Utilizadas em Dispositivos Móveis.** 2011. 62 f. Dissertação (Mestrado em Modelagem Matemática) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Unijuí, 2011.

SILVA, Diego Rodrigo Cabral. **Sistema de Detecção e Isolamento de Falhas em Sistemas Dinâmicos Baseado em Identificação Paramétrica.** 2008. 115 f. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal do Rio Grande do Norte, Natal, 2008.

SOUALHI, Abdenour; HAWWARI, Yasmine; MEDJAHHER, Kamal; CLERC, Guy; HUBERT, Razik; GUILLET, François. **PHM Survey: Implementation of Signal Processing Methods for Monitoring Bearings and Gearboxes.** International Journal of Prognostics and Health Management: Vol 9 (2) 028, pages: 14, 2018.

SOUZA, Darielson Araújo de. **Predição e Monitoramento da Vida Útil Remanescente de Baterias Aeronáuticas.** 2016. 78 f. Dissertação (Mestrado em Engenharia Elétrica e de Computação) – Universidade Federal do Ceará, Sobral, 2016.

S. J. JULIER AND J. K. UHLMANN. **A New Extension of the Kalman Filter to Nonlinear Systems.** In Proc. of AeroSense: The 11th Int. Symp. On Aerospace/Defence Sensing, Simulation and Controls., 1997.

S. J. JULIER AND JK UHLMANN. **Unscented Filtering and Nonlinear Estimation.** Proceedings of the IEEE, 92(3):401–422, 2004.

TANG, JIEXIONG, CHENWEI DENG, AND GUANG-BIN HUANG. **Extreme Learning Machine for Multilayer Perceptron.** IEEE Transactions on Neural Networks and Learning Systems, 2016.

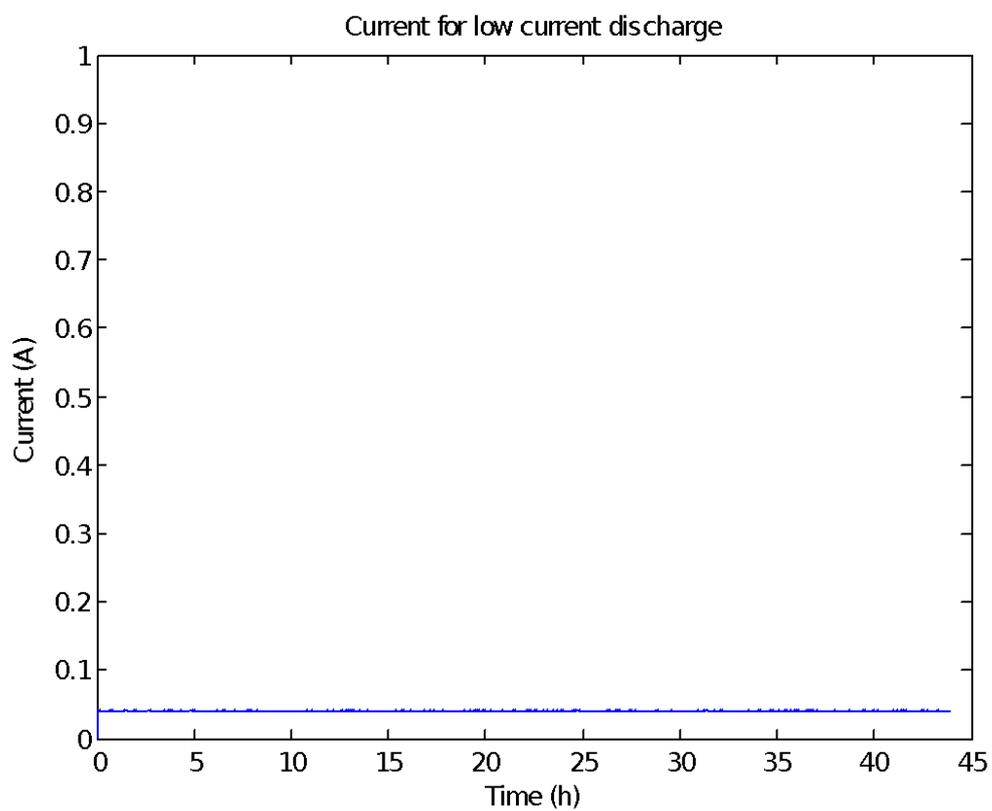
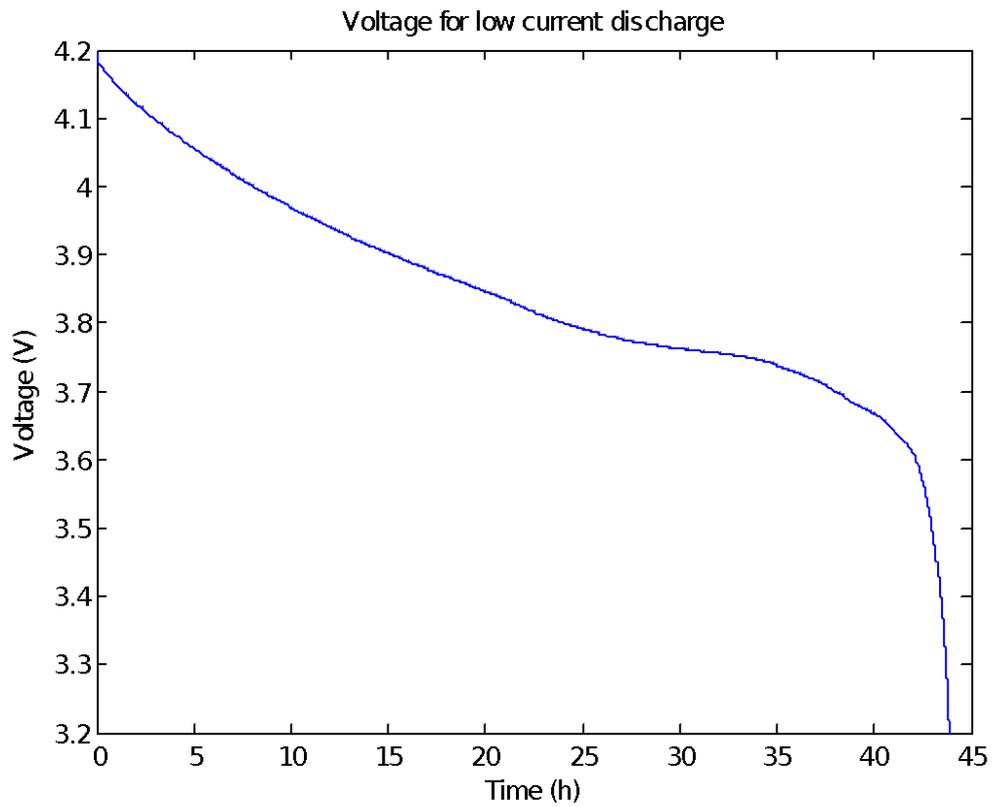
TINE LEFEBVRE AND HERMAN BRUYNINCKX. **Kalman Filters for Nonlinear Systems: A Comparison of Performance.** International Journal of Control, 2002.

TORRES, Rubião G. Jr.; MACHADO, Maria Augusta Soares; SOUZA, Reinaldo Castro. Previsão de Séries Temporais de Falhas em Manutenção Industrial Usando Redes Neurais. **ENGEVISTA**, Niterói, v.7, n. 2, p. 4-18, 2005.

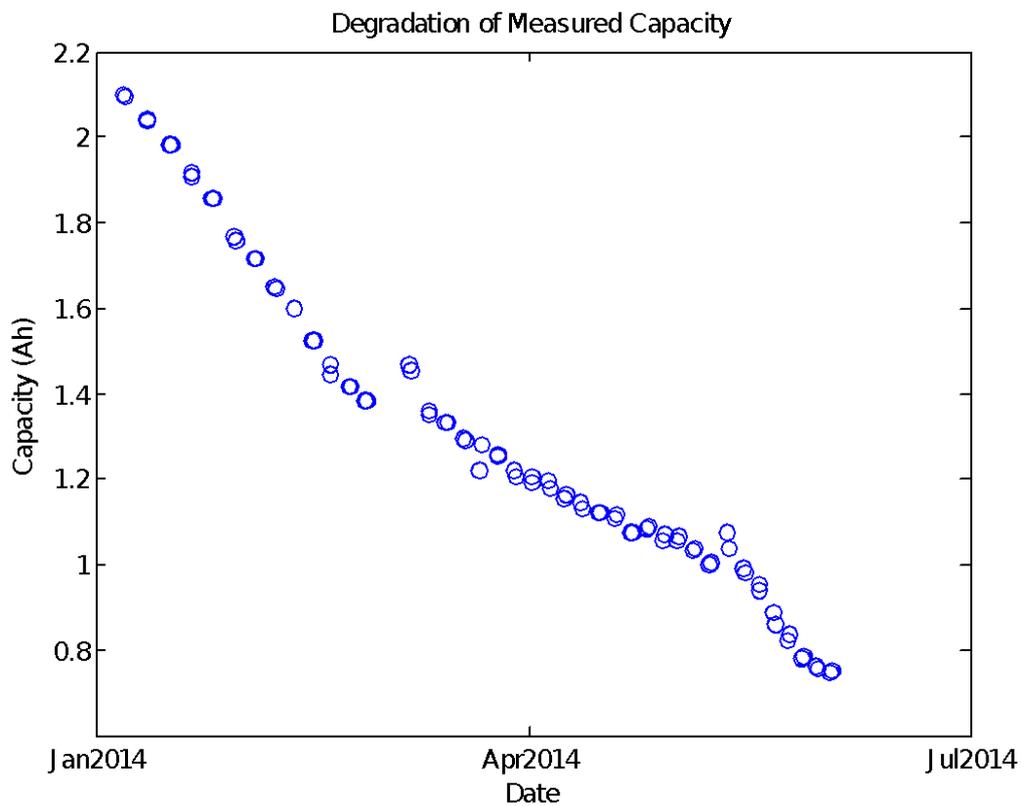
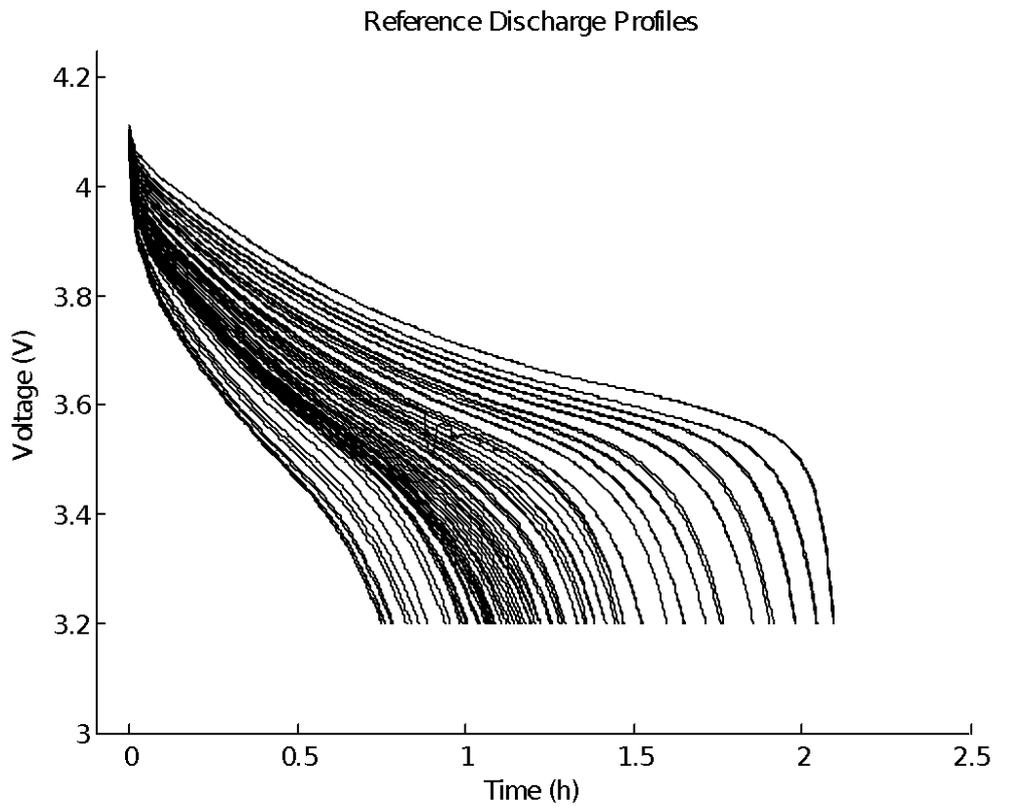
UCKUN, S.; GOEBEL, K.; LUCAS, P. J. Standardizing research methods for prognostics. **International Conference on Prognostics and Health Management**, Denver, U.S.A., Oct. 2008.

WOLPERT, DANIEL; GHAHRAMANI, ZOUBIN. **Computational principles of movement neuroscience**. Nature Neuroscience, 2000.

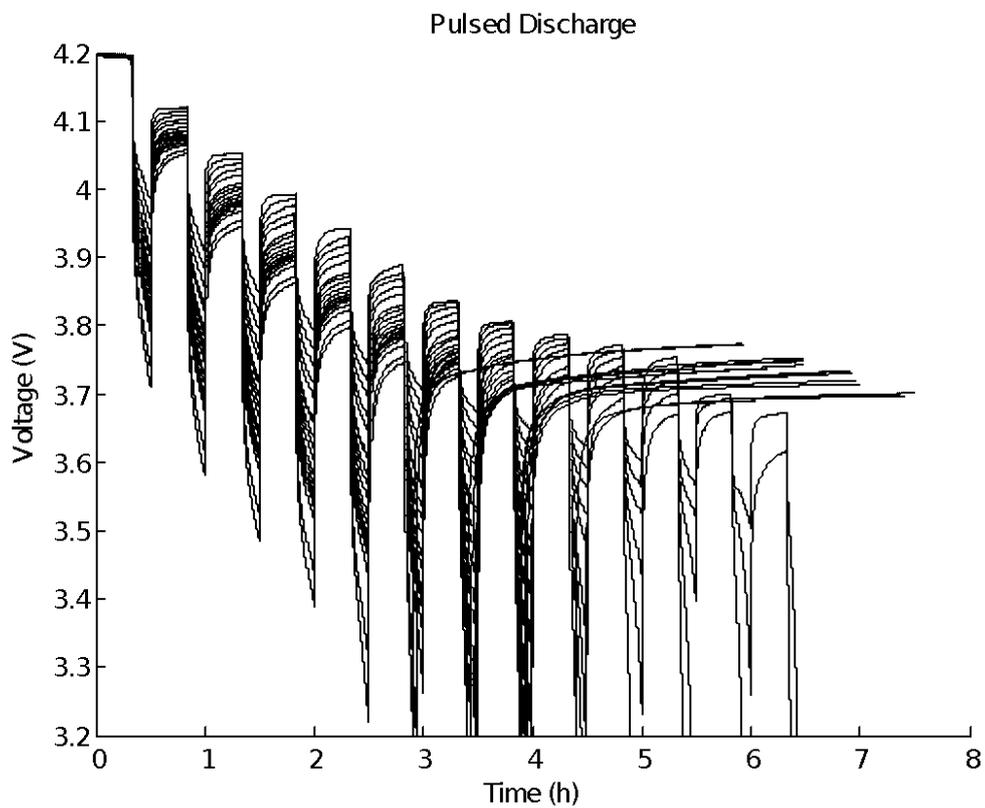
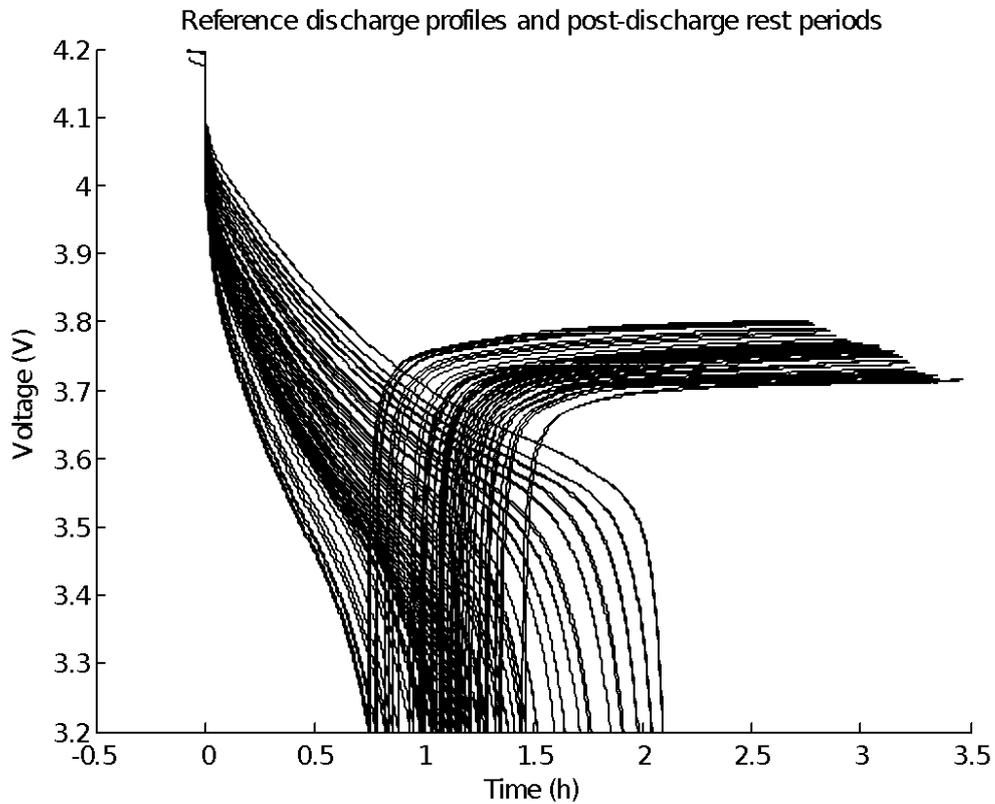
**ANEXO A – IMAGENS DO ÚLTIMO CICLO DE DESCARGA DE TENSÃO COM
BAIXA CORRENTE PARA O CICLO DE DESCARGA DA BATERIA RW9**



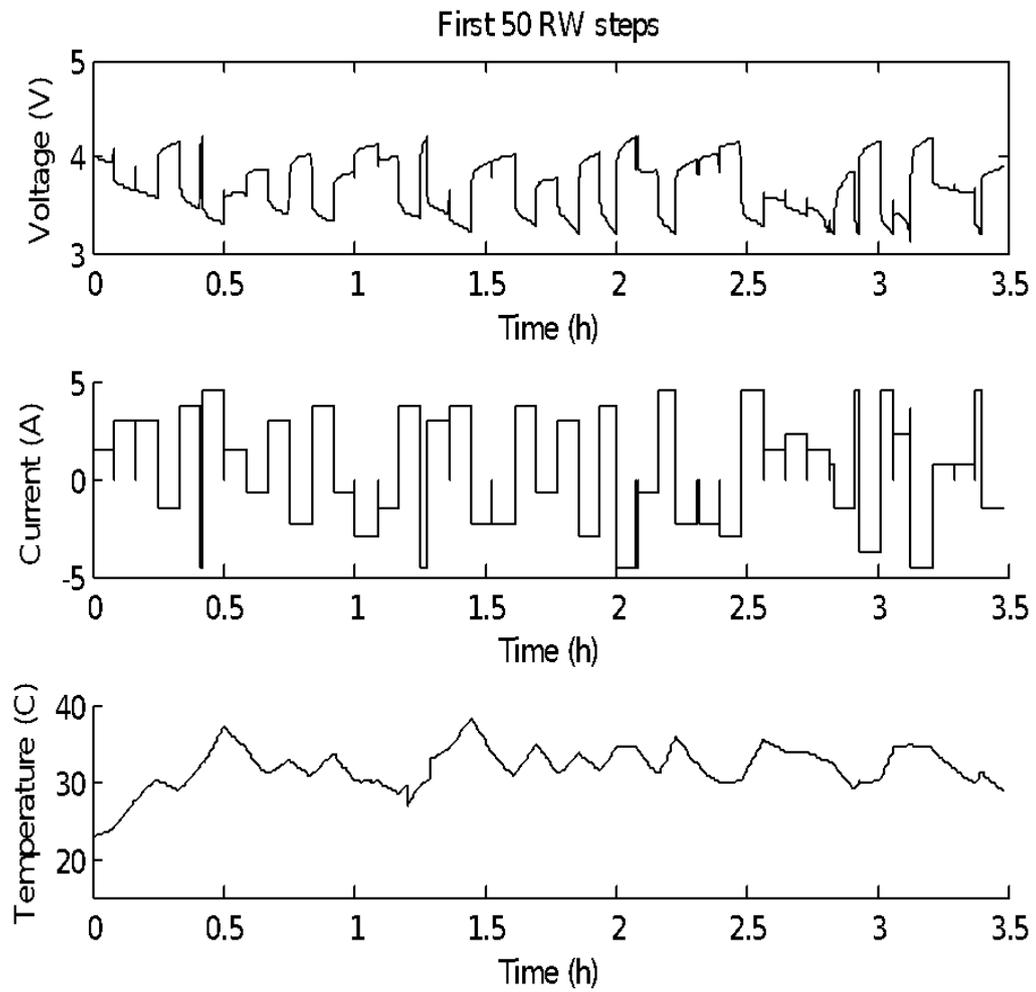
ANEXO B – IMAGENS DO PERFIL DE TENSÃO DE DESCARGA E DA DEGRADAÇÃO DA CAPACIDADE DA BATERIA RW9



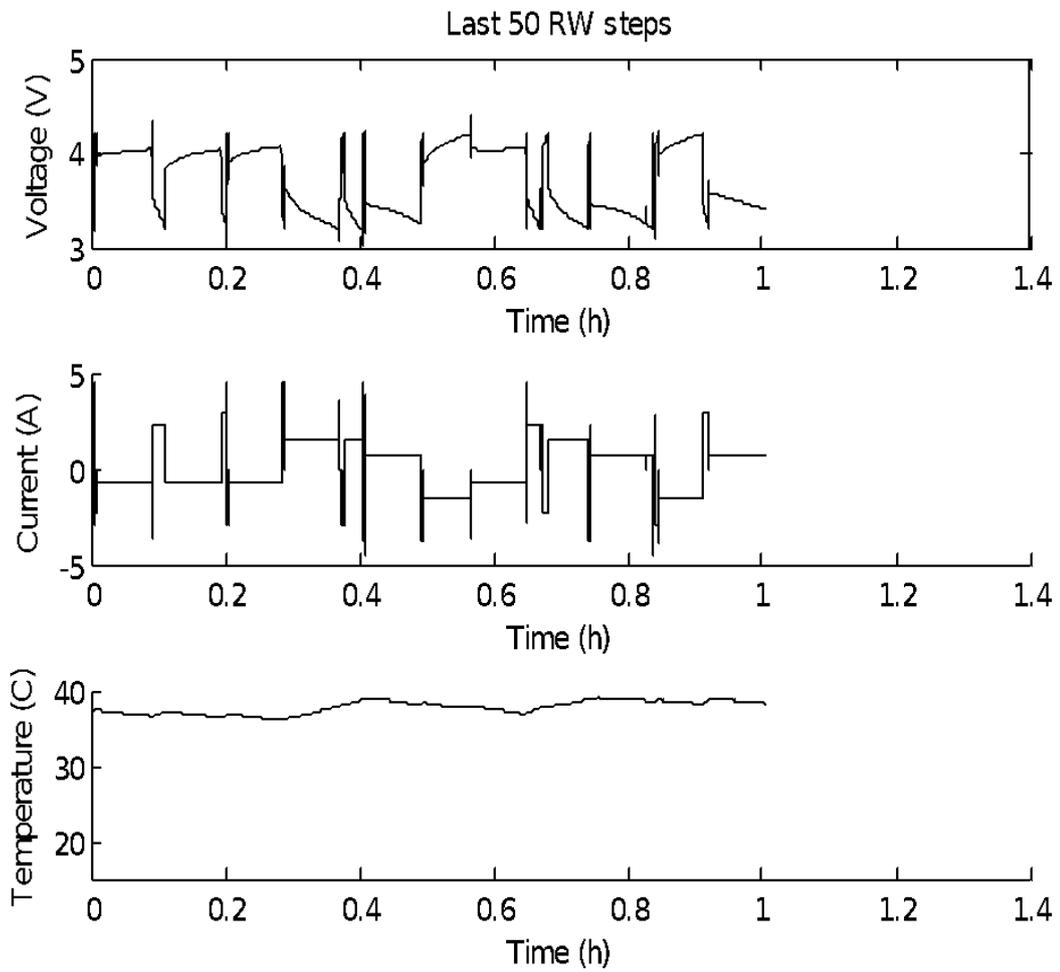
**ANEXO C – IMAGENS DA REFERÊNCIA DE DESCARGA COM PERÍODO APÓS
DESCARGA DE TENSÃO E PULSOS DE DESCARGA DE TENSÃO DA BATERIA
RW9**



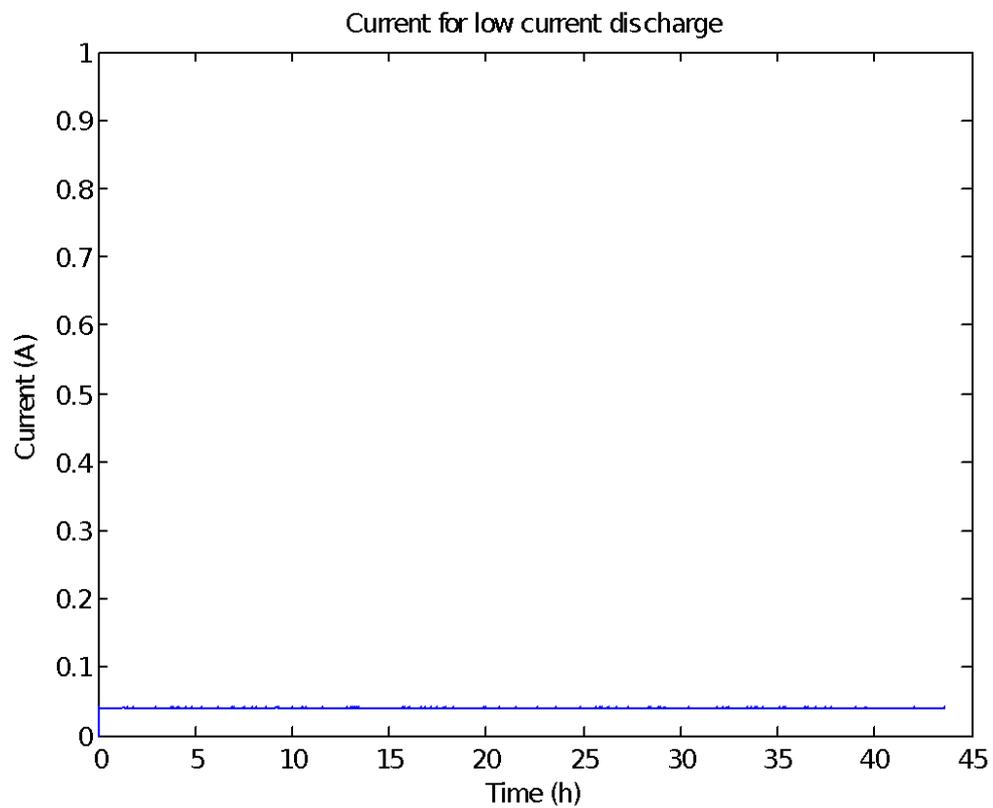
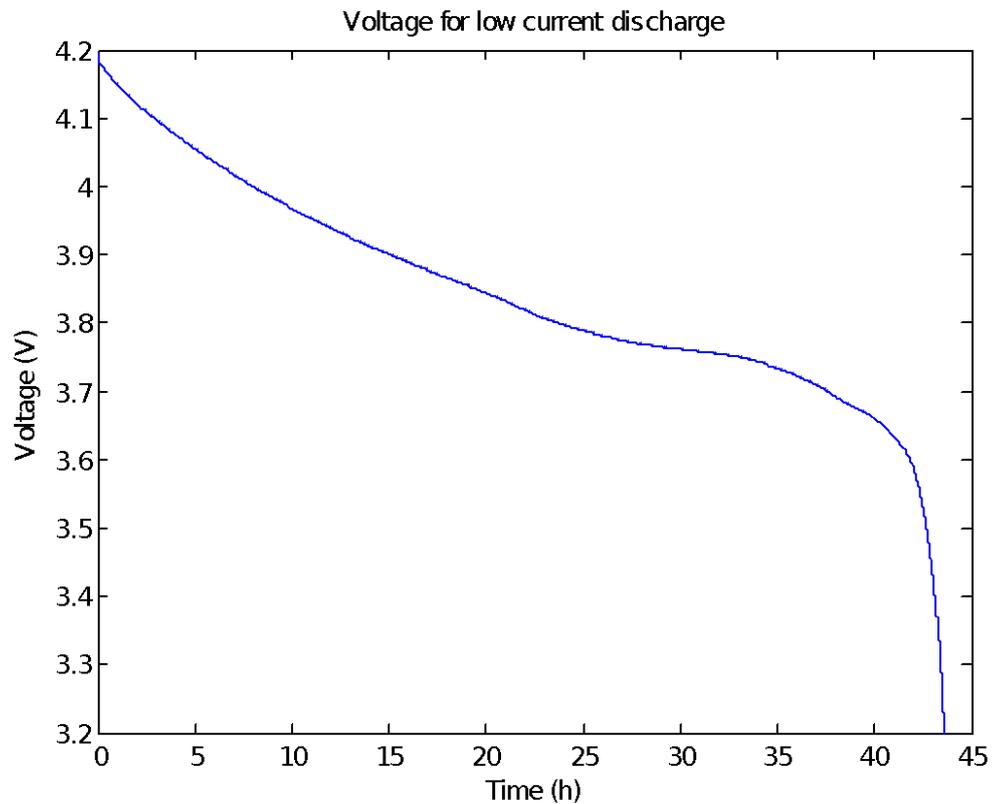
**ANEXO D – IMAGENS DOS 50 PRIMEIROS PONTOS DE TENSÃO, DA
CORRENTE E TEMPERATURA DA BATERIA RW9**



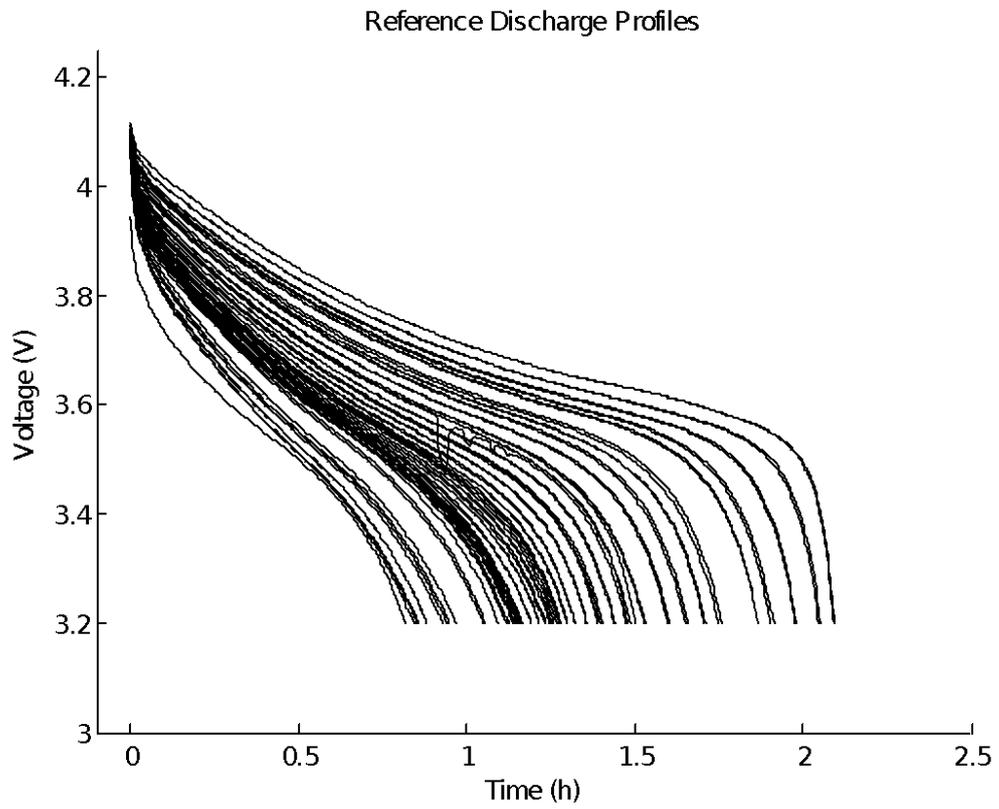
**ANEXO E – IMAGENS DOS ÚLTIMOS 50 PONTOS DE TENSÃO, DE CORRENTE
E DE TEMPERATURA DA BATERIA RW9**

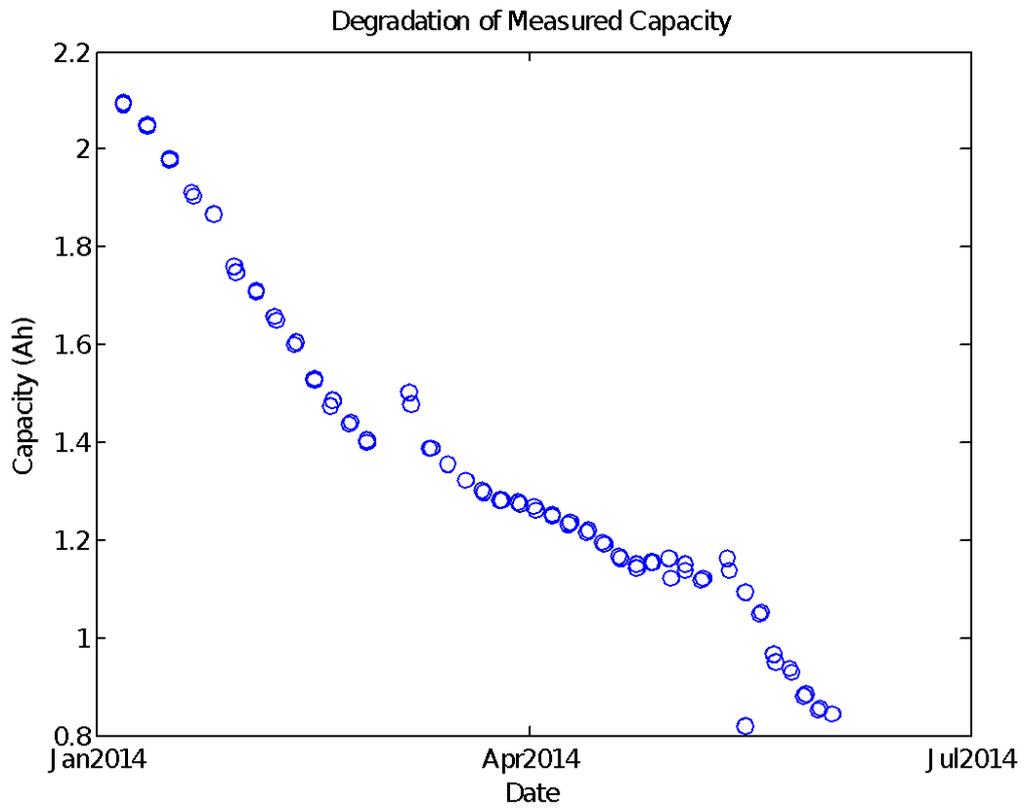


**ANEXO F – IMAGENS DO ÚLTIMO CICLO DE DESCARGA DE TENSÃO COM
BAIXA CORRENTE PARA O CICLO DE DESCARGA DA BATERIA RW10**

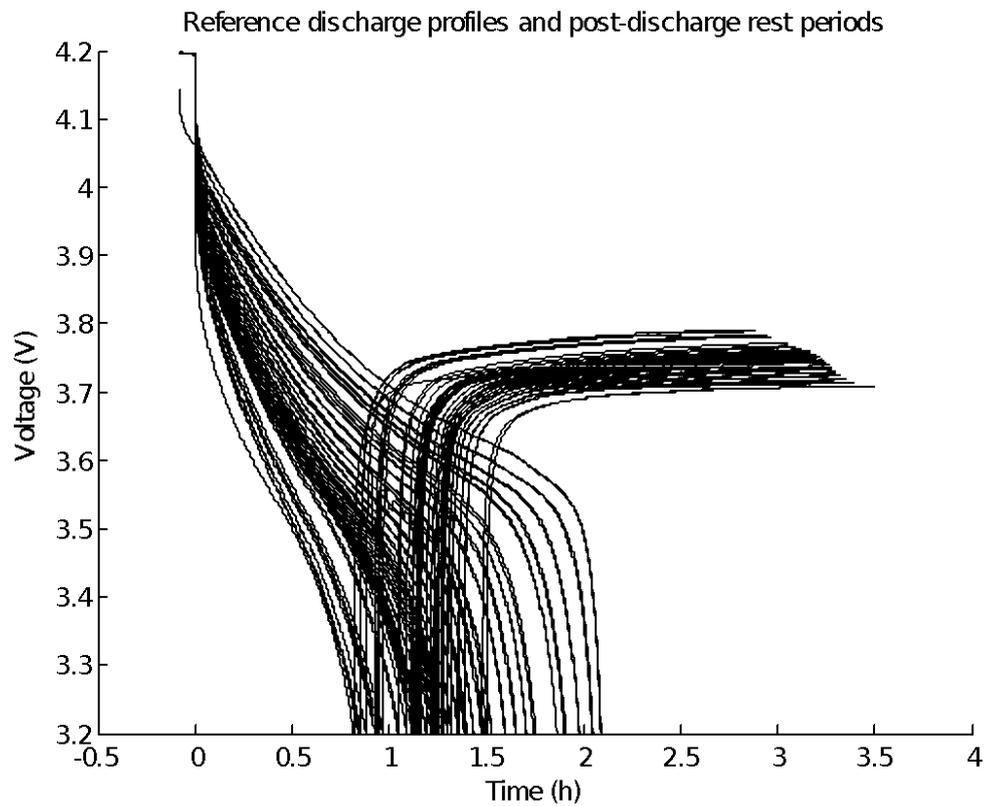
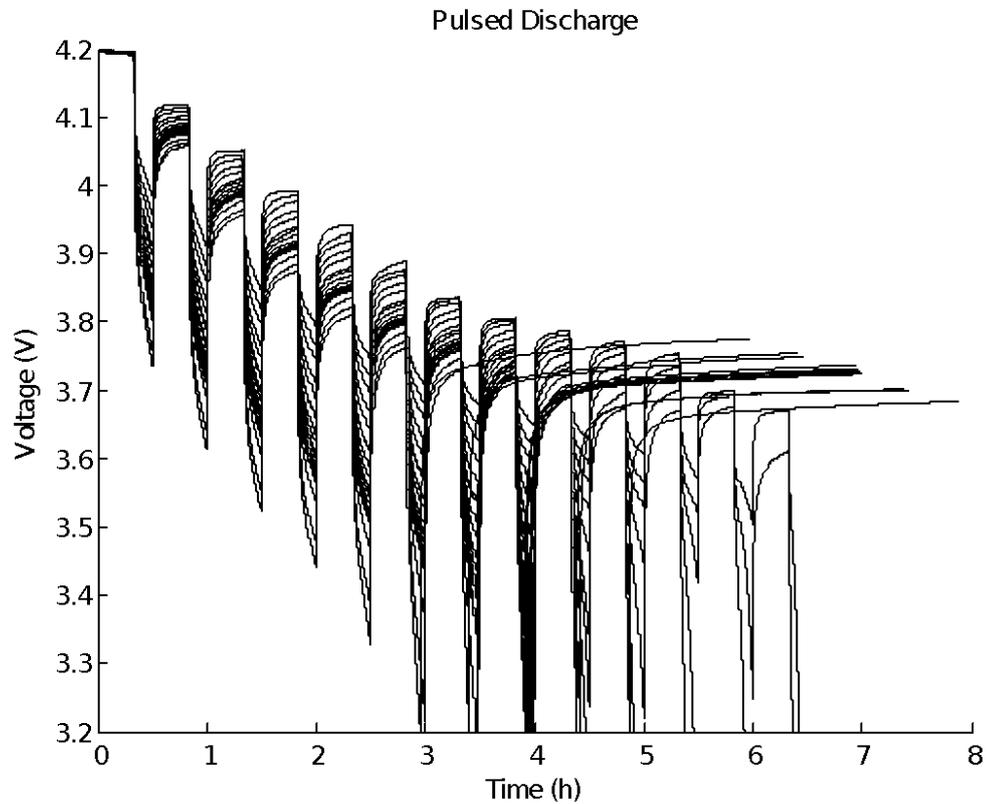


**ANEXO G – IMAGENS DO PERFIL DE TENSÃO DE DESCARGA E DA
DEGRADAÇÃO DA CAPACIDADE DA BATERIA RW10**

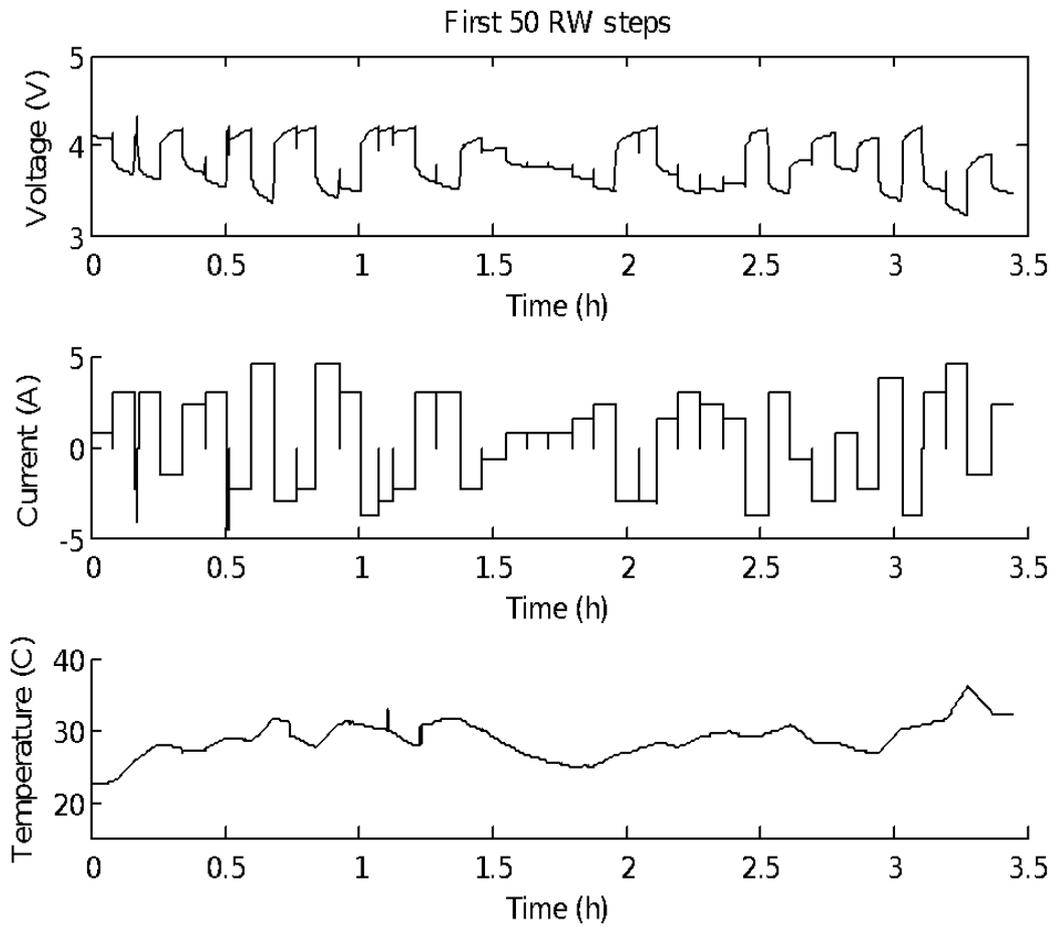




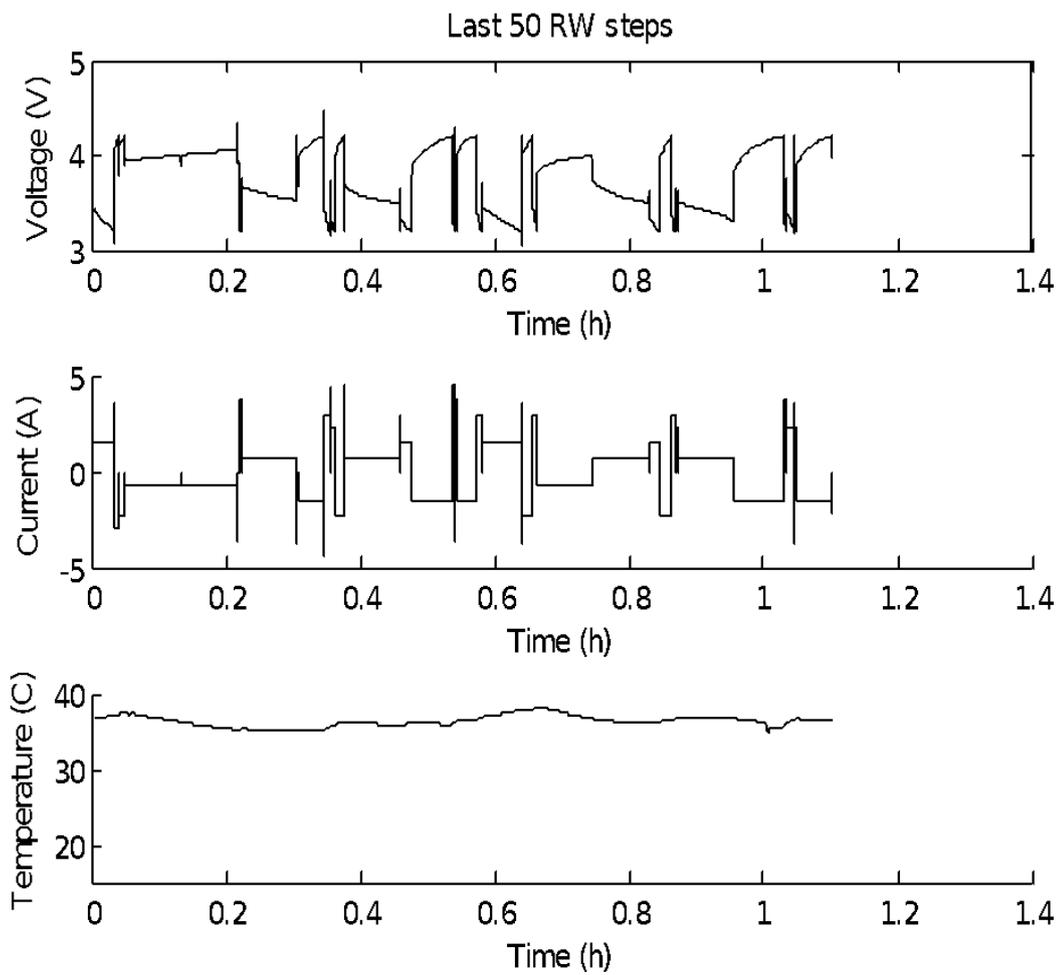
**ANEXO H – IMAGENS DA REFERÊNCIA DE DESCARGA COM PERÍODO APÓS
DESCARGA DE TENSÃO E PULSOS DE DESCARGA DE TENSÃO DA BATERIA
RW10**



**ANEXO I – IMAGENS DOS 50 PRIMEIROS PONTOS DE TENSÃO, DA
CORRENTE E TEMPERATURA DA BATERIA RW10**



ANEXO J – IMAGENS DOS ÚLTIMOS 50 PONTOS DE TENSÃO, DE CORRENTE E DE TEMPERATURA DA BATERIA RW10



ANEXO L – VALORES DE PREDIÇÃO DOS DADOS DE CAPACIDADE E ESTIMAÇÃO DO MODELO COM TODOS OS MÉTODOS

Estimação dos dados da bateria RW9				
Métodos	RUL mínima	RUL	RUL máxima	Falha
RNA ELM	49	55	61	55
LMS	49	54	59	55
KF	49	55	61	55
PF	49	54	59	55
UKF	49	55	62	55
Estimação dos dados da bateria RW10				
Métodos	RUL mínima	RUL	RUL máxima	Falha
RNA ELM	48	53	59	53
LMS	49	55	62	53
KF	49	55	61	53
PF	49	54	59	53
UKF	51	55	60	53
Estimação do Modelo com a bateria RW9				
Métodos	RUL mínima	RUL	RUL máxima	Falha
RNA ELM	49	55	61	55
LMS	49	54	58	55
KF	49	55	61	55
PF	51	55	60	55
UKF	52	56	61	55
Estimação do Modelo com a bateria RW10				
Métodos	RUL mínima	RUL	RUL máxima	Falha
RNA ELM	50	55	60	53
LMS	48	54	61	53
KF	49	55	60	53
PF	52	57	62	53
UKF	52	55	58	53