



Rafael Saadi Dantas Teixeira

**Estimativa de curva de estado de saúde
de baterias de íon-lítio: Uma abordagem
usando redes neurais recorrentes**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial
para obtenção do grau de Mestre em Metrologia
pelo Programa de Pós-Graduação em Metrologia
(Área de concentração: Metrologia para Qualidade
e Inovação) da PUC-Rio.

Orientador: Prof. Rodrigo Flora Calili
Coorientador: Prof. Daniel
Ramos Louzada

Rio de Janeiro,
abril de 2021



Rafael Saadi Dantas Teixeira

**Estimativa de curva de estado de saúde
de baterias de íon-lítio: Uma abordagem
usando redes neurais recorrentes**

Dissertação apresentada como requisito parcial
para obtenção do grau de Mestre pelo Programa de
Pós-Graduação em Metrologia da PUC-Rio (Área de
concentração: Metrologia para Qualidade e
Inovação. Aprovada pela Comissão examinadora
abaixo:

Prof. Rodrigo Flora Calili

Orientador

Programa de Pós-Graduação em Metrologia - PUC-Rio

Prof. Daniel Ramos Louzada

Coorientador

Programa de Pós-Graduação em Metrologia - PUC-Rio

Prof. Guilherme Penello Temporão

Departamento de Engenharia Elétrica - PUC-Rio

Prof. Vitor Hugo Ferreira

Departamento de Engenharia Elétrica - UFF

Prof. Carlos Roberto Hall Barbosa

Programa de Pós-Graduação em Metrologia - PUC-Rio

Rio de Janeiro, 28 de abril de 2021

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

Rafael Saadi Dantas Teixeira

Graduou-se em Engenharia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro em 2017. Trabalhou no setor elétrico na área de comercialização de energia elétrica. Atualmente é mestrando do Programa de Pós-Graduação em Metrologia pela PUC-Rio.

Ficha Catalográfica

Teixeira, Rafael Saadi Dantas

Estimativa de curva de estado de saúde de baterias de íon-lítio: uma abordagem usando redes neurais recorrentes / Rafael Saadi Dantas Teixeira; orientador: Rodrigo Flora Calili; coorientador: Daniel Ramos Louzada. – 2021.

133 f.: il. color.; 29,7 cm

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Metrologia, 2021.

Inclui bibliografia

1. Metrologia - Teses. 2. Metrologia. 3. Bateria de íon-lítio. 4. Estado de saúde. 5. Estado de carga. 6. Redes neurais recorrentes. I. Calili, Rodrigo Flora. II. Louzada, Daniel Ramos. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Metrologia. IV. Título.

CDD: 389.1

A minha família

Agradecimentos

À Deus, por me dar forças para seguir em frente.

Ao meu orientador Prof. Rodrigo Flora Calili e ao meu co-orientador Prof. Daniel Ramos Louzada por todos os ensinamentos e ajuda para a realização deste trabalho.

À PUC-Rio, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

À toda minha família, em especial minha mãe Maristela, meu pai José Eduardo, meu irmão Rodrigo e meus avós Antônio e Leila pelo apoio em cada momento de dificuldade e por estarem sempre ao meu lado em todas as situações.

À todos os professores e funcionários do Programa de Pós-Graduação em Metrologia pelo apoio em cada etapa para a construção deste trabalho.

Ao professor Gusmão pela ajuda para tornar este trabalho possível.

À todos os amigos que me ajudaram a chegar até aqui

Aos professores que participaram da Comissão examinadora.

O presente trabalho foi desenvolvido dentro do Projeto de P&D PUC-Rio e Energy2Go que busca estabelecer soluções para implementação de energia elétrica móvel para smartphones. Assim agradeço à equipe da Energy2Go por todo apoio oferecido.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Resumo

Teixeira, Rafael Saadi Dantas; Calili, Rodrigo Flora (orientador); Louzada, Daniel Ramos (coorientador). **Estimativa de curva de estado de saúde de baterias de íon-lítio: Uma abordagem usando redes neurais recorrentes.** Rio de Janeiro, 2021. 133p. Dissertação de Mestrado – Programa de Pós-Graduação em Metrologia, Pontifícia Universidade Católica do Rio de Janeiro.

Por conta dos rápidos avanços tecnológicos, percebe-se uma mudança nos hábitos e das necessidades das pessoas. Há uma dependência cada vez maior de aparelhos eletrônicos como smartphones, notebooks etc. Construir baterias com grande capacidade energética é um dos desafios atuais para aumentar a autonomia dos aparelhos eletrônicos. Entretanto, uma alternativa que pode ajudar a manter aparelhos eletrônicos por mais tempo longe das tomadas é o compartilhamento de baterias. Existem na literatura muitos estudos envolvendo o compartilhamento de baterias no contexto de veículos elétricos, porém não são encontradas aplicações em smartphones. Um parâmetro importante a ser monitorado neste contexto é o estado de saúde (SoH). Até o momento, não há um consenso na literatura acerca do melhor modelo para estimar o SoH de baterias devido à falta de métodos bem estabelecidos. Assim, o objetivo geral desta dissertação foi construir um modelo para estimar a curva de estado de saúde, por meio do estado de carga, com vistas a estimar a saúde de baterias de íon-lítio. O modelo proposto foi baseado em redes neurais recorrentes. Para treinar e validar o modelo, foi construído um sistema para a realização de ensaios destrutivos, sendo possível estudar o comportamento de baterias de íon-lítio ao longo de toda vida útil. O modelo proposto foi capaz de estimar o SoH das baterias estudadas com boa exatidão, sob diferentes parâmetros de carga/descarga. O diferencial do modelo são baixa complexidade computacional, mesmo envolvendo modelos de redes neurais, e serem adotados parâmetros de entrada de fácil medição.

Palavras-chaves

Metrologia; Bateria de íon-lítio; Estado de Saúde; Estado de Carga; Redes Neurais Recorrentes.

Abstract

Teixeira, Rafael Saadi Dantas; Calili, Rodrigo Flora (Advisor); Louzada, Daniel Ramos (Co-Advisor). **Estimating the lithium-ion battery state of health: A recurrent neural network approach**. Rio de Janeiro, 2021. 133p. Dissertação de Mestrado - Programa de Pós-Graduação em Metrologia, Pontifícia Universidade Católica do Rio de Janeiro.

Because of the fast technological advances, there is a change in people's habits and needs. There is an increasing dependence on electronic devices such as smartphones, notebooks etc. Building batteries with great energy capacity is one of the current challenges to increase the autonomy of electronic devices. However, an alternative that can help keep electronic devices longer away from sockets is battery swap. There are many studies in the literature involving the sharing of batteries in the context of electric vehicles, but no applications are found in smartphones. An important parameter to be monitored in this context is state of health (SoH). To date, there is no consensus in the literature about the best model for estimating battery SoH due to the lack of well-established methods. Thus, the objective of this dissertation is to build a model to estimate the state of health curve, with a view to classifying the health of lithium-ion batteries, through state of charge curve, for applications involving battery swap aiming to use in smartphones. The proposed model was based on recurrent neural networks. To train and validate the model, a system was built to perform destructive tests, being possible to study the behavior of lithium-ion batteries throughout its useful life. The proposed model was able to estimate the SoH of the batteries studied with good precision, under different charge / discharge parameters. The distinction of the model is low computational complexity, even involving neural network models, and easy-to-measure input parameters are adopted.

Keywords:

Metrology; Lithium-ion battery; State of Health; State of charge; Recurrent Neural Network.

Sumário

1 Introdução	17
1.1. Definição do problema de pesquisa	23
1.2. Objetivos: geral e específicos	23
1.3. Metodologia	24
1.3.1. Fase exploratória e descritiva	25
1.3.2. Fase de pesquisa aplicada	27
1.3.3. Fase conclusiva	27
1.4. Estrutura da dissertação	27
2 Baterias secundárias e ensaios destrutivos	29
2.1. Tecnologias e conceitos de baterias secundárias	29
2.1.1. Processo de carga de baterias	36
2.1.2. Processo de descarga de baterias	40
2.1.3. Tempo de vida e ciclos de carga / descarga	41
2.2. Ensaios destrutivos de baterias secundárias	43
2.3. Considerações sobre o capítulo	45
3 Estimativa de curva de estado de carga e estado de saúde: conceitos e modelos	47
3.1. Métodos baseados em modelos físicos versus métodos baseados em dados	47
3.2. Modelos existentes para estimação de curva de estado de carga e estado de saúde de baterias secundárias	50
3.3. Estudos empíricos sobre aplicações de modelos para estimativa do estado de saúde de baterias de íon-lítio	54
3.4. Considerações sobre o capítulo	58
4 Estimativa de curva de estado de saúde e estado de carga: conceitos e modelo proposto	60
4.1. Coleta e tratamento dos dados de baterias de íon-lítio	60
4.1.1. Modularização do sistema de medição	61
4.1.2. <i>Hardware</i> do sistema de medição	62
4.1.3. <i>Software</i> do sistema de medição	69
4.2 Modelo proposto para estimar SoH de baterias de íon-lítio	74
4.2.1. Métricas para avaliação do modelo proposto	81
4.2.2. Parâmetros e funcionamento do modelo para estimar SoH de baterias de íon-lítio proposto	82

4.3. Considerações sobre o capítulo	86
5. Demonstração da aplicabilidade do modelo proposto	88
5.1 Modularização do sistema de medição	88
5.2 Resultados individuais das medições em baterias de íon-lítio	90
5.2.1. Resultados das baterias do grupo 1	90
5.2.2. Resultados das baterias do grupo 2	93
5.2.3. Resultados das baterias do grupo 3	95
5.2.4. Resultados das baterias do grupo 4	97
5.3 Comparação entre os grupos	100
5.4 Resultados do modelo para estimar a curva de SoH de baterias de íon-lítio	101
5.4.1. Camadas ocultas	103
5.4.2. <i>Units</i>	105
5.4.3. <i>Dropout</i>	107
5.4.4. Otimizador	109
5.4.5. Atraso de tempo	111
5.4.6. Curvas de SoH estimadas pelo modelo proposto	112
5.5. Discussões de resultados	118
6. Conclusões e recomendações para trabalhos futuros	122
7 Referências bibliográficas	126

Lista de siglas e abreviaturas

BI - Interpolação Bi-linear

BMS – *Battery Management System* (Sistema de Gerenciamento de Baterias)

BPNN - *Neural Network Backpropagation* (Rede Neural Backpropagation)

DoD – *Depth of Discharge* (Profundidade de Descarga)

EIS - *Electrochemical Impedance Spectroscopy* (Espectroscopia de impedância eletroquímica)

EKF - *Extended Kalman Filter* (Filtro de Kalman estendido)

EMF - *Electro-Motive Force* (Força eletromotriz)

GRU - *Gated Recurrent Unit*

Íon-lítio – íons de lítio

IR - *Impulse Response* (Resposta de Impulso)

KF - *Kalman Filter* (Filtro de Kalman)

LCO – Lítio-Cobalto

LFP – Fosfato de Ferro e Lítio

LMO – Óxido de Manganês de Lítio

LSTM - *Long Short Term Memory*

MAE - *Mean Absolute Error* (Erro Médio Absoluto)

MARS - *Multivariate Adaptive Regression Splines* (Splines de Regressão Adaptativa Multivariada)

MLP - *Multilayer Perceptron*

MSE - *Mean Squared Error* (Erro Quadrático Médio)

NASA - *National Aeronautics and Space Administration*

NCA – Óxido de Alumínio, Níquel e Cobalto

NLO - *Nonlinear Observer* (Observador Não-Linear)

NMC – Níquel-Manganês-Cobalto

OCV - *Open Circuit Voltage* (Tensão de Circuito Aberto)

PCI – Placa de Circuito Impresso

PF - *Particle Filter* (Filtro de Partícula)

PIO - *Proportional-Integral Observer* (Observador Integral Proporcional)

RBFNN - *Radial Basis Function Neural Network*

RBFNN - Rede Neural de Função de Base Radial

RLS - *Recursive Least Square* (Mínimos Quadrados Recursivo)

RMSE - *Root Mean Squared Error* (Erro Quadrático Médio)

RNA - Rede Neural Artificial

RNN - *Recurrent Neural Network* (Rede Neural Recorrente)

SADA - Sistema de Aquisição de Dados e Acionamento

SMO - *Sliding Mode Observer* (Observador de Modo Deslizante)

SoC – *State of Charge* (Estado de Carga)

SoH – *State of Health* (Estado de Saúde)

SPKF - *Sigma point Kalman Filter* (Filtro de Kalman Sigma-ponto)

SVM - *Support Vector Machine* (Vetor de Máquina de Suporte)

UAC - Unidade de Aquisição e Controle

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

VE – Veículo Elétrico

WNN - *Wavelet Neural Network* (Rede Neural Wavelet)

Lista de Figuras

Figura 1. 1 - Desenho da pesquisa, seus componentes e métodos.	25
Figura 1. 2 - Mapa conceitual da pesquisa	26
Figura 2. 1 - Esquema simplificado de uma bateria	30
Figura 2. 2 - Princípio de funcionamento da bateria de íon-lítio	34
Figura 2. 3 – Circuito de um carregador simples	37
Figura 4. 1 - Diagrama de blocos do sistema de carga / descarga	62
Figura 4. 2 - Sistema de medição proposto montado em protoboard	64
Figura 4. 3 - Protótipo monocanal em PCI	65
Figura 4. 4 - Protótipo montado em PCI após ajustes	66
Figura 4. 5 – Esquemático final dos circuitos de carga/descarga	67
Figura 4. 6 - Versão final do sistema de medições proposto	68
Figura 4. 7 - Linhas de interligação com a Unidade de Aquisição e Controle (UAC)	70
Figura 4. 8 - Tela do programa monocanal	72
Figura 4. 9 - Tela do programa de medições para 4 baterias	73
Figura 4. 10 - Tela do programa de medições para 12 baterias	73
Figura 4. 11 - Estrutura básica de uma rede neural	75
Figura 4. 12 – Estrutura básica de uma rede neural GRU	77
Figura 4. 13 – Estrutura do modelo proposto: treinamento das redes neurais GRU	84
Figura 4. 14 – Estrutura do modelo proposto: estimativa da curva de SoH de baterias de íon-lítio	85
Figura 5. 1 - Curva de tensão registrada em ciclos de carga / descarga ao longo do tempo com uma bateria de íon-lítio	89
Figura 5. 2 - Capacidade das baterias do grupo 1	92
Figura 5. 3 - Instabilidade de carga das baterias do grupo 1	93
Figura 5. 4 - Capacidade das baterias do grupo 2	89
Figura 5. 5 - Instabilidade de carga das baterias do grupo 2	95
Figura 5. 6 - Capacidade das baterias do grupo 3	96
Figura 5. 7 - Instabilidade de carga das baterias do grupo 3	97
Figura 5. 8 - Capacidade das baterias do grupo 4	99
Figura 5. 9 - Instabilidade de carga das baterias do grupo 4	100
Figura 5. 10 – Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Camadas ocultas	104
Figura 5. 11 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Units	107
Figura 5. 12 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Dropout	109
Figura 5. 13 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Otimizador	110
Figura 5. 14 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Atraso no tempo	112

Figura 5.15 - Cálculo de SOH de acordo com a definição inovadora: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4	111
Figura 5.16 - Cálculo de SOH de acordo com a definição inovadora: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4	112
Figura 5. 17 - Previsão de SOH de acordo com a definição tradicional: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4	114
Figura 5. 18 - Previsão de SoH de acordo com a definição através de SoC: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4	115
Figura 5. 19 - Erro SoH ao longo do tempo: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4	118

Lista de Quadros

Quadro 2. 1 - Exemplos de baterias recarregáveis	32
Quadro 2. 2 – Principais tipos de baterias de íon-lítio encontradas no mercado	35
Quadro 2. 3 – Principais parâmetros mensuráveis utilizados para estimar SoH	46
Quadro 3. 1 Vantagens e desvantagens dos métodos baseados em modelos e dos métodos baseados em dados	49
Quadro 3. 2 Métodos baseados em modelos para estimar SoC e SoH	50
Quadro 3. 3 Métodos baseados em dados para estimar SoC e SoH	51

Lista de Tabelas

Tabela 2. 1 - Características das baterias de íon-lítio de cobalto	36
Tabela 2. 2 - Tensão (V/Célula) x Capacidade	39
Tabela 2. 3 – Ciclos de descarga	42
Tabela 2. 4 - Ciclo de descarga e energia em função do nível de tensão	42
Tabela 5. 1 – Parâmetros utilizados em cada grupo de baterias	89
Tabela 5. 2 - Baterias do grupo 1	91
Tabela 5. 3 - Baterias do grupo 2	94
Tabela 5. 4 - Baterias do grupo 3	96
Tabela 5. 5 - Baterias do grupo 4	98
Tabela 5. 6: Parâmetros médios dos 4 grupos de baterias testadas	101
Tabela 5. 7 - Métricas de avaliação do modelo para diferentes números de camadas ocultas	104
Tabela 5. 8 - Métricas de avaliação do modelo para diferentes números de units	106
Tabela 5. 9 - Métricas de avaliação do modelo para diferentes números de Dropout	108
Tabela 5. 10 - Métricas de avaliação do modelo para diferentes otimizadores	110
Tabela 5. 11 - Métricas de avaliação do modelo para diferentes atrasos de tempo	111
Tabela 5. 12 - métricas de avaliação de rede neural	116
Tabela 5. 13 - erros de modelos de estimação de SoH de trabalhos mais relevantes atualmente encontrados na literatura	116

1

Introdução

Por conta dos rápidos avanços tecnológicos, percebe-se uma mudança nos hábitos e necessidades das pessoas. Observa-se que existe uma dependência cada vez maior da população por aparelhos eletrônicos como smartphones, notebooks etc., em virtude das facilidades que estes promovem no dia a dia. Dessa forma, é esperado que estes aparelhos consigam acompanhar a rotina cada vez mais movimentada de seus usuários. Para isso, são necessárias baterias que disponham da máxima capacidade de carga possível a fim de possibilitar maior autonomia aos equipamentos.

Baterias podem ser divididas em dois grandes grupos: primárias e secundárias. Baterias primárias são aquelas que não podem ser recarregadas, ou seja, chegando ao fim de sua carga, a bateria deve ser descartada. Baterias secundárias são recarregáveis, sendo vastamente utilizadas em equipamentos eletrônicos do dia a dia (*Battery University*, 2017).

Atualmente as baterias mais utilizadas em equipamentos eletrônicos são as baterias baseadas em íons de lítio (baterias íon-lítio). Estas possuem maiores níveis de potência e energia por unidade de massa, ou seja, é possível construir baterias de íon-lítio pequenas com grande capacidade energética. Elas também são menos danosas ao meio-ambiente, como a de chumbo-ácido, por exemplo e não apresentam problemas com memória de carga como as baterias de níquel-cádmio (*Battery University*, 2017).

Entretanto, construir baterias com grande capacidade energética, segurança e capazes de sofrer recarga rápida constituem alguns dos desafios atuais diretamente associados às necessidades de aumento da autonomia de aparelhos eletrônicos móveis.

Uma outra forma de enfrentar o problema de autonomia, o que ajudaria a manter aparelhos eletrônicos por mais tempo longe das tomadas é o compartilhamento ou troca de baterias (*battery swap*).

O mercado de compartilhamento de baterias vem crescendo no mundo inteiro (Infante *et al.*, 2016), com exemplos de aplicação em diferentes mercados que vão desde o automobilístico e de micro mobilidade urbana até o de telefonia móvel. Um exemplo de mercado de compartilhamento de baterias é o que se aplica a veículos elétricos (VEs). Para apoiar o crescimento do uso de VEs, diferentes modelos de estação de troca de bateria foram construídos, a fim de mitigar os principais fatores que limitam o uso de veículos elétricos, como o alto custo inicial destes dispositivos, autonomia da bateria, tempos de carregamento lentos e aumento abrupto de demanda de potência na rede elétrica (Infante *et al.*, 2016). Embora existam algumas pesquisas apontando para a viabilização desse modelo de negócio, alguns aspectos relacionados com a sustentabilidade ainda carecem de maiores aprofundamentos. Particularmente no tocante à previsão de visitas às estações de troca de bateria por consumidores donos de VEs e com o dimensionamento da demanda de carga na rede elétrica (Zhong *et al.*, 2020).

Infante *et al.* (2016) propuseram um sistema que fornece ao cliente apenas baterias com bom estado de saúde, descartando baterias consideradas impróprias ou realocando-as para outras áreas (sistemas fotovoltaicos isolados). Liu *et al.* (2017) e Yang *et al.* (2017) seguem na mesma linha metodológica proposta por Infante *et al.* (2016), entretanto, esse modelo pode ser criticado por gerar o descarte precoce de baterias que ainda não tenham chegado ao final da sua vida útil, aumentando os custos e reduzindo a oferta de baterias aos clientes.

Outro mercado ligado ao automobilístico que está cada vez mais dependente de baterias é o de aluguel de carros elétricos (Semanjski e Gautama, 2016). No entanto, a literatura sugere que o aluguel de veículos elétricos não está conseguindo alcançar uma viabilidade comercial satisfatória. Semanjski e Gautama (2016) indicam que o maior uso do veículo (característico deste tipo de serviço) e as implicações no estado de saúde (SoH, cujo acrônimo em língua inglesa significa *State of Health*) da bateria podem estar por trás deste problema.

O SoH pode ser definido como a capacidade de uma célula reter a carga por períodos prolongados, armazenar e fornecer energia, em relação à sua capacidade nominal. O conhecimento do SoH pode ser usado para observar a degradação contínua ou abrupta da bateria, evitando uma possível falha no sistema no qual a bateria esteja conectada (Kim e Cho, 2011). Assim, a previsão do SoH pode ser

subsídio importante para a elaboração de modelos de troca ou compartilhamento de baterias.

Uma variedade de modelos para estimar o SoH de uma bateria são encontrados na literatura, variando de medições manuais intermitentes de tensão e parâmetros eletrolíticos da bateria à supervisão online totalmente automatizada de vários parâmetros, medidos e/ou estimados, da bateria (Lee *et al.*, 2012). Os métodos de estimativa do SoH são divididos em duas abordagens (Berecibar *et al.*, 2016): métodos baseados em modelos físicos e métodos baseados em dados.

Métodos baseados em modelos físicos utilizam dados medidos e/ou calculados de baterias ao longo do tempo, sob diferentes condições de operação. Com estes dados e um conhecimento prévio sobre a influência dos principais parâmetros que afetam a bateria durante sua vida, uma estimativa do SoH pode ser realizada. Esta abordagem requer profundo conhecimento dos parâmetros físicos e eletroquímicos das baterias, a fim de traçar relações entre a operação da bateria e sua degradação. Modelos construídos com esta abordagem tendem a ser bastante exatos, porém não podem ser replicados em outros tipos de baterias e geralmente utilizam uma formulação matemática mais complexa para a construção dos modelos (Berecibar *et al.*, 2016).

Métodos baseados em dados determinam o SoH por meio de parâmetros sensíveis à degradação da célula da bateria. Estes parâmetros devem ser mensuráveis durante toda a operação da bateria. Esta abordagem oferece a vantagem de não precisar de muitos testes e simulações do comportamento da bateria. Isto garante uma melhor adaptabilidade em diferentes tipos de baterias, mas tem como desvantagem alta complexidade computacional e grande volume de dados de medição, o que pode dificultar a execução online dos modelos em aplicações reais (Berecibar *et al.*, 2016).

Ainda no tocante ao compartilhamento de baterias, Semanjski e Gautama (2016) realizaram um trabalho de previsão do SoH de baterias de dois veículos elétricos idênticos sendo usados em diferentes práticas de compartilhamento. Os resultados indicam que existe relação direta entre a forma de direção dos veículos e o comportamento de carga das baterias. Este resultado pode fornecer um ponto de referência valioso para os projetistas de sistemas de compartilhamento de veículos. Em particular, os resultados deste estudo mostraram que as baterias atingem o final de suas vidas úteis em tempos diferentes, dependendo das condições de uso e de

carregamento. Essa conclusão, pode, de certa maneira, ser transferida para outros sistemas de compartilhamento de baterias (baterias de telefones móveis, por exemplo).

Chen *et al.*, (2019), utilizaram o número do ciclo, valor da queda de tensão e variação da resistência interna ao longo do tempo como parâmetros para estimar o SoH de baterias de íon-lítio. O trabalho destes autores utiliza o modelo de lógica Fuzzy para estabelecer um método dinâmico de previsão de SoH.

Yu (2015) propôs um sistema de prognóstico de saúde da bateria, desenvolvido por meio de inferência bayesiana e modelo de espaço de estados que integra regressão logística e filtro de partículas. O modelo probabilístico de inferência bayesiana quantifica e indica o estado de saúde da bateria. Neste estudo, o modelo é capaz de oferecer a probabilidade de falha para as baterias monitoradas, o que intuitivamente está relacionado ao SoH. O modelo de espaço de estados é usado para modelar a propagação de integridade da bateria ao longo do tempo; além disso, uma regressão logística integrada a um filtro de partículas é utilizada para prever o restante da vida útil da bateria. Os resultados experimentais realizados em uma bateria de íon-lítio ilustram as possíveis aplicações do sistema proposto como uma ferramenta eficaz para o prognóstico da saúde de baterias.

Até o momento, não há um consenso na literatura acerca do melhor modelo para estimar o SoH de baterias devido à falta de métodos bem estabelecidos e técnicas confiáveis (Ungurean *et. al*, 2020). Ainda não são encontrados na literatura modelos aplicados de estimativa do SoH em baterias destinadas a uso específico em telefones móveis (smartphones).

A capacidade energética (capacidade da bateria em armazenamento de energia) é considerada um excelente indicador de SoH da bateria. Em geral, considera-se que uma bateria de íon-lítio chega ao fim de sua vida útil quando sua capacidade diminui em 20 % do valor nominal (*Battery University*, 2017). No entanto, é difícil medir a capacidade da bateria diretamente (Yu, 2015). Um parâmetro importante das baterias, que está atrelado à capacidade energética, é o estado de carga (SoC, acrônimo em língua inglesa que significa *State of Charge*). Este parâmetro mensura o percentual da capacidade atual da bateria em relação à capacidade máxima disponível. É geralmente utilizado para determinar a mudança na capacidade da bateria ao longo do tempo de um ciclo (*MIT Electric Vehicle Team*, 2008). No âmbito de equipamentos eletrônicos utilizados no dia a dia, este

parâmetro é utilizado para determinar o quanto de energia as baterias podem fornecer antes de serem descarregadas. Porém, há muitas outras aplicações para estado de carga.

O SoH pode ser expresso pelo percentual da capacidade máxima disponível em relação à capacidade máxima nominal, sendo assim uma medida da capacidade de longo prazo da bateria. Comparado ao SoH, o SoC é definido como a porcentagem da capacidade disponível, sendo uma medida de curto prazo da capacidade da bateria (Semanjski e Gautama, 2016). Utilizando uma analogia com veículos à combustão interna, enquanto o SoC corresponderia à função de medidor de combustível, o SoH representaria a capacidade de um tanque de combustível para armazenar este combustível. Nesta analogia, o tanque de combustível teria variações de volume disponível. Por exemplo, quando o SoH é baixo, o SoC indicaria tanque cheio, mas conteria menos combustível do que quando o carro era novo (Semanjski e Gautama, 2016).

Através da estimativa de SoC, é possível avaliar a qualidade da bateria e estimar seu SoH (*Battery University*, 2017). A estimativa de SoC vem sendo largamente estudada em aplicações que envolvam o uso de baterias em veículos elétricos (Hannan *et al.*, 2017). Entretanto, não se encontram na literatura muitos trabalhos que envolvam o uso das baterias em equipamentos eletrônicos, como smartphones, por exemplo. Estimativas exatas de SoC e SoH são importantes em aplicações práticas em que é necessário determinar a vida útil de baterias. (Kim e Cho, 2011). Para estimar SoH por meio de SoC, é necessário um modelo preciso de estimativa de SoC.

Os modelos atuais para estimativa da curva de SoH podem ser divididos em 5 (cinco) categorias: convencional, algoritmo de filtro adaptativo, algoritmo de aprendizagem, observador não-linear e outros métodos híbridos. (Hannan *et al.*, 2017). Cada um deles necessita de condições específicas do uso da bateria para que a estimativa possa ser a mais exata possível. Todos os modelos disponíveis na literatura atualmente são de alta complexidade ou de custo computacional elevado, tornando um desafio estimar SoH de forma confiável. Sendo assim, se faz necessário um estudo mais abrangente para a estimativa de SoH ao longo de toda a vida útil da bateria em aplicações envolvendo equipamentos eletrônicos do dia-a-dia, a fim de alcançar um modelo com boa exatidão para esta finalidade.

São utilizados os mesmos métodos para estimar SoC e SoH. Por esta razão, a previsão de SoH é muito semelhante à estimativa do SoC em termos de dificuldades de medição. Por exemplo, a análise de diminuição da capacidade energética ao longo do tempo é confiável, porém esta técnica assume que as baterias não sofrem alterações eletroquímicas ao longo do tempo, sendo impossível prever uma queda abrupta na capacidade de armazenar energia (Kim e Cho, 2011).

Um método de estimativa de SoH por meio da curva de SoC pode facilitar o sistema de medições necessário para extrair os dados necessários das baterias, pois a bateria não necessitaria ser completamente descarregada para o funcionamento do modelo (Kim e Cho, 2011).

Não há registros na literatura de trabalhos envolvendo a estimativa de SoH de baterias de íon-lítio utilizadas em sistemas de *battery swap* para carregamento de smartphones. Um modelo construído para este fim seria importante para cobrir duas lacunas encontradas na literatura: modelo de estimativa de SoH para sistemas de *battery swap* e para baterias de equipamentos do dia a dia. Este modelo poderia ser estendido para estudos envolvendo baterias de outros tipos de sistemas *battery swap* (bicicletas elétricas ou patinetes elétricos, por exemplo), desde que não sejam necessários parâmetros específicos da tecnologia da bateria, como aspectos construtivos.

Desta forma, é necessário o desenvolvimento de um modelo para estimativa de SoH que seja exato suficiente para aplicação em modelos de compartilhamento de baterias, que seja de fácil implementação e possua custo computacional reduzido, a fim de beneficiar os consumidores deste tipo de serviço a conhecerem o SoH de suas baterias, além de facilitar a estimativa da viabilidade econômica do negócio de troca ou compartilhamento de baterias. Ensaios destrutivos¹ são importantes para a implementação de tal modelo, visto que informações importantes acerca do funcionamento das baterias ao longo do tempo podem ser extraídas destes. Além disso, os ensaios são importantes para gerar dados para a construção de um modelo para estimar o SoH baseado em dados, servindo, por exemplo, como dados de entrada e validação para uma Rede Neural Artificial, que será utilizada nesta dissertação para a construção do modelo proposto.

¹ Técnicas utilizadas para análise de falhas, que possuem a finalidade de detectar características e verificar propriedades de interesse. A fim de obter um resultado relevante, os parâmetros utilizados no teste devem ser compatíveis ao projeto de interesse.

Esta dissertação insere-se na linha de pesquisa “*Smart Grid*” do Programa de Pós-graduação em Metrologia (PósMQI) da Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio).

1.1.

Definição do problema de pesquisa

Considerando o crescente uso de equipamentos que utilizam baterias de íon-lítio, a adoção de novos modelos de negócio envolvendo aluguel ou troca de baterias e a importância de conhecer e classificar o estado de saúde das baterias, definiu-se a seguinte questão principal a ser respondida ao longo da pesquisa:

“Qual o melhor modelo para estimar a curva de estado de saúde de baterias de íon-lítio, por meio da curva de estado de carga?”

1.2.

Objetivos: geral e específicos

Buscando dar uma contribuição para analisar as opções tecnológicas para estimativa do estado de saúde de forma apropriada para aplicação de uso em *smartphones*, o objetivo geral desta dissertação é construir um modelo para estimar a curva de estado de saúde, por meio do estado de carga, com vistas a estimar a saúde de baterias de íon-lítio.

Em termos específicos, a dissertação busca:

- Levantar o estado-da-arte sobre modelos para estimativa de curva de estado de saúde (SoH) e estado de carga (SoC) de baterias secundárias e referenciais normativos e exigências regulatórias aplicáveis a baterias de íon-lítio;
- Levantar e analisar os estudos empíricos sobre aplicações de modelos para estimativa de curva de estado de carga e curva de estado de saúde de baterias secundárias, visando estimar a saúde de baterias de íon-lítio;
- Caracterizar baterias de íon-lítio em determinados regimes de carga e descarga ao longo de sua vida útil, empregando-se ensaios destrutivos;
- Estabelecer a relação entre estado de saúde e estado de carga, de forma a identificar os parâmetros metrológicos que deverão ser considerados na fase de modelagem, a partir da análise dos estudos empíricos;

- Desenvolver um modelo para estimar o estado de saúde, a partir do estado de carga de baterias de íon-lítio, de forma otimizada;
- Demonstrar a aplicabilidade do modelo desenvolvido, mediante coleta de dados medidos em 16 baterias de íon-lítio de telefones celulares por meio de um ensaio destrutivo;
- Explicitar os diferenciais do modelo proposto em relação aos modelos que vêm sendo adotados no mundo para estimação do estado de saúde, a partir do estado de carga de baterias secundárias de íon-lítio;
- Propor recomendações para a utilização da estimação do estado de saúde de baterias de íon-lítio em novos modelos de negócio para o compartilhamento de baterias.

1.3. Metodologia

Segundo a taxonomia proposta por Vergara (2002), a pesquisa pode ser considerada aplicada, descritiva e metodológica (quanto aos fins). Quanto aos meios de investigação, a metodologia compreende: pesquisa bibliográfica e experimental; desenvolvimento de um modelo para estimar curva de estado de saúde ao longo de toda sua vida útil; ensaios destrutivos para demonstrar a aplicabilidade do modelo.

A figura 1.1 apresenta o desenho da pesquisa, destacando-se seus componentes e métodos, de acordo com três fases principais: exploratória e descritiva; pesquisa aplicada e conclusivo propositiva.

Detalham-se, a seguir, o desenvolvimento de cada fase e os resultados esperados em cada bloco da figura 1.1. Todo o desenho da pesquisa está alinhado aos objetivos propostos na seção 1.2 deste capítulo.

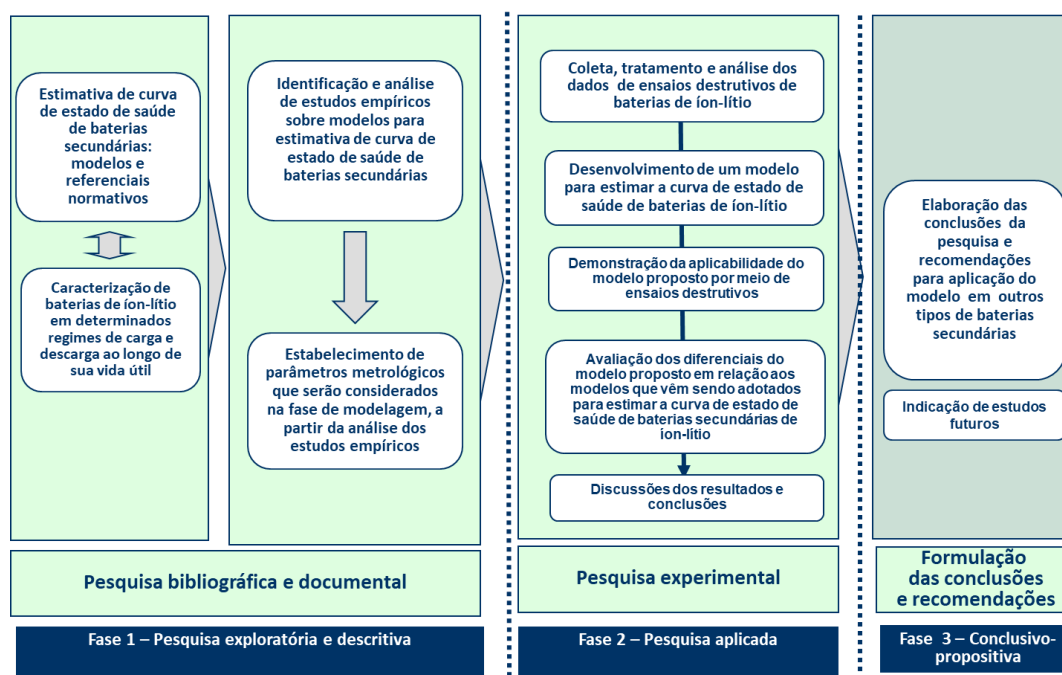


Figura 1. 1 - Desenho da pesquisa, seus componentes e métodos.

Fonte: Elaboração própria.

1.3.1. Fase exploratória e descritiva

A fase exploratória e descritiva foi iniciada com pesquisa bibliográfica e documental, com o objetivo de levantar trabalhos conceituais e documentos de referência para delimitação do tema central da pesquisa. Primeiramente, buscou-se conceituar as características gerais de baterias secundárias, dando destaque aos tipos de tecnologia e parâmetros importantes para estimar estado de saúde e estado de carga. Isto gerou subsídios para efetuar uma pesquisa bibliográfica mais assertiva quanto ao modo como os ensaios destrutivos devem ser realizados, assim como buscar modelos para estimação do estado de saúde presentes na literatura. A lacuna encontrada para a realização deste trabalho foi obtida a partir da pesquisa de estudos empíricos sobre esse tema, sendo identificada a escassez de aplicações realizadas em baterias de smartphones e em modelos de negócios envolvendo compartilhamento de baterias.

Apresenta-se na figura 1.2 uma visão geral e esquemática dos resultados desta primeira fase.

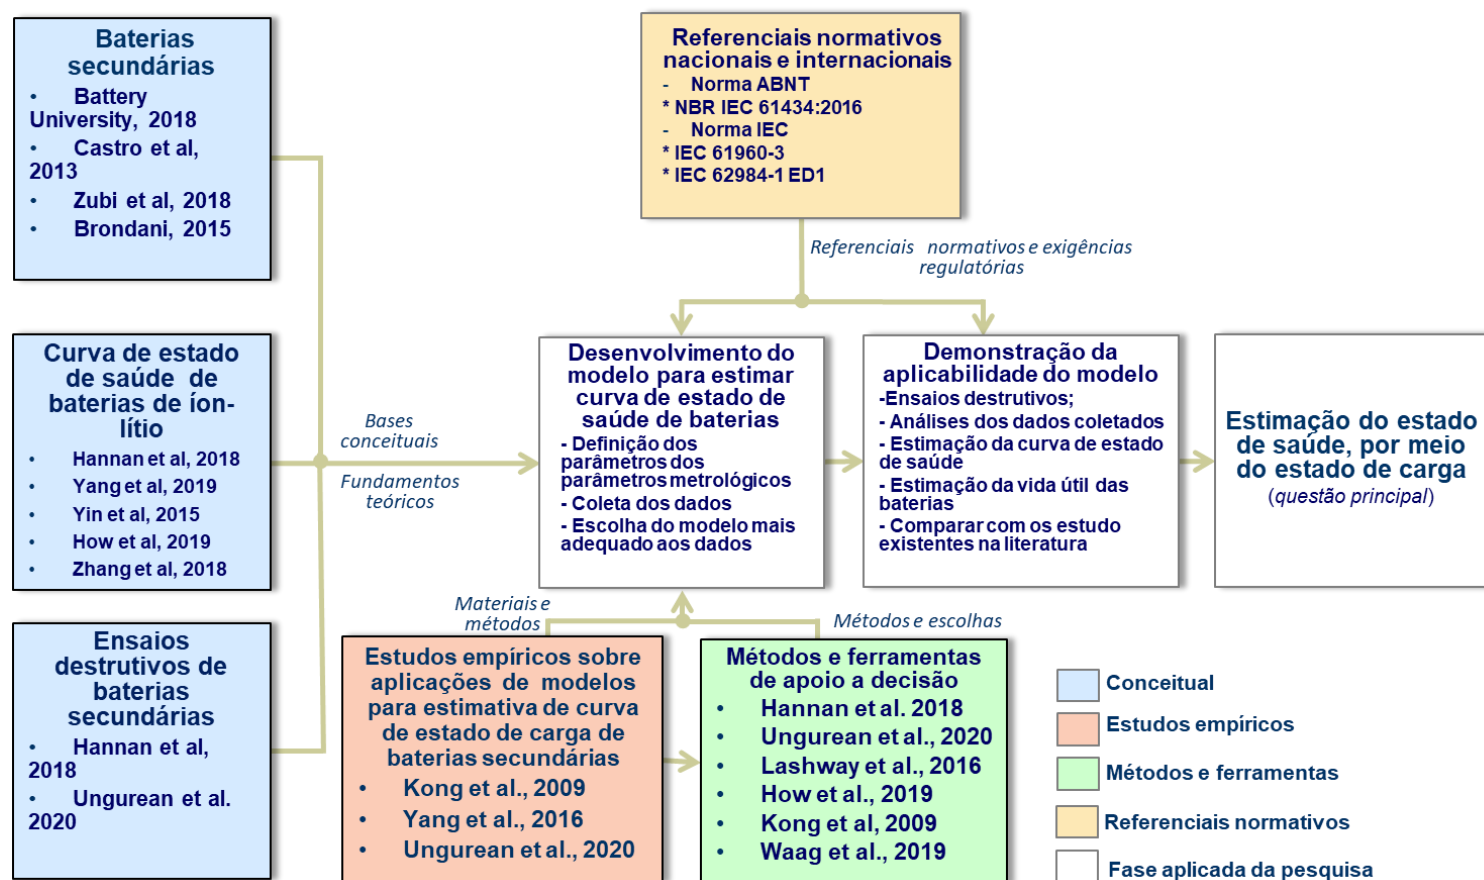


Figura 1. 2 - Mapa conceitual da pesquisa

Fonte: Elaboração própria.

O referencial teórico constituiu uma orientação conceitual para a pesquisa, ao compor o vocabulário especializado e organizar o conhecimento sobre modelos para estimar o estado de saúde, a partir do estado de carga de baterias secundárias de íon-lítio.

1.3.2.

Fase de pesquisa aplicada

Desenvolveu-se a fase da pesquisa aplicada propriamente dita, a partir dos resultados da revisão bibliográfica e documental, que nortearam a definição dos objetivos da pesquisa e o desenvolvimento do modelo para estimar o estado de saúde, a partir do estado de carga de baterias de íon-lítio.

1.3.3.

Fase conclusiva

Na terceira fase, elaboraram-se a conclusão geral e as específicas em relação a cada um dos objetivos enunciados na seção 1.2, formularam-se um conjunto de recomendações aos diversos atores interessados na aplicação do modelo de estimação e identificação do estado de saúde, a partir do estado de carga.

1.4.

Estrutura da dissertação

A dissertação encontra-se estruturada em seis capítulos, incluindo esta introdução.

O capítulo dois apresenta um estudo aprofundado acerca das tecnologias e conceitos de baterias secundárias e ensaios destrutivos. O capítulo está dividido em duas seções. Na primeira, abordam-se os conceitos fundamentais das baterias secundárias em geral, assim como as tecnologias mais utilizadas, dando ênfase à tecnologia de íon-lítio. A segunda seção apresenta subsídios para a estruturação dos ensaios destrutivos que serão realizados para a validação da aplicabilidade do modelo proposto.

O capítulo três aborda, na primeira seção, os modelos existentes atualmente para a estimação de curva de estado de saúde, buscando relacionar este parâmetro com o estado de carga de baterias secundárias, sendo apresentadas as vantagens e desvantagens de cada método, assim como o auxílio que cada um destes modelos pode oferecer para a criação do novo modelo de estimação da curva de estado de saúde de baterias secundárias proposto. Na segunda seção, serão abordados os estudos empíricos sobre aplicações de modelos para estimativa do estado de saúde, a partir da curva de estado de carga de

baterias secundárias. Este capítulo busca identificar os tipos de aplicações encontrados na literatura, dando suporte para a elaboração do novo modelo proposto.

No capítulo quatro está descrito o desenvolvimento do novo modelo para estimativa do estado de saúde, a partir da curva de estado de carga de baterias secundárias. O capítulo está dividido em três seções. A primeira aborda a coleta e tratamentos dos dados provindos de ensaios destrutivos para conhecimento do comportamento das baterias de íon-lítio ao longo de toda sua vida útil. Em seguida, a segunda seção apresenta o novo modelo obtido a partir deste trabalho, assim como as métricas para avaliação de erro utilizados para a construção do modelo. Na terceira seção, estão descritas as considerações sobre o capítulo.

O capítulo cinco apresenta a demonstração da aplicabilidade do novo modelo proposto. O capítulo está estruturado em cinco seções. Na primeira seção, é mostrada a modularização do sistema e as medições realizadas pelo sistema de medições. Na segunda seção são apresentados os resultados individuais de cada bateria, dividido por grupo. Na terceira seção, são apresentados os resultados comparativos entre os 4 grupos de bateria. Na quarta seção, são apresentados os resultados encontrados para a construção do modelo para se estimar SoH de baterias de íon-lítio. A discussão dos resultados é realizada na quinta seção.

O capítulo seis apresenta as conclusões e recomendações para trabalhos futuros para a utilização da classificação do estado de saúde de baterias de íon-lítio para a utilização em sistemas de compartilhamento de baterias.

2

Baterias secundárias e ensaios destrutivos

Neste capítulo é apresentado um estudo aprofundado acerca das tecnologias e conceitos de baterias secundárias (baterias recarregáveis) e ensaios destrutivos. O mesmo está dividido em duas seções. Na primeira, abordam-se os conceitos fundamentais das baterias secundárias, em geral, assim como as tecnologias mais utilizadas, dando ênfase à tecnologia de íon-lítio. A segunda seção apresenta subsídios para a estruturação dos ensaios destrutivos que foram realizados ao longo da dissertação e cujos resultados serviram para a validação da aplicabilidade do modelo proposto.

2.1.

Tecnologias e conceitos de baterias secundárias

De modo geral, uma bateria possui uma ou mais células eletroquímicas, as quais são constituídas de um eletrodo positivo (cátodo) e um negativo (ânodo). Reações químicas que ocorrem no interior das células são responsáveis por transformar energia química armazenada em energia elétrica.

Essas reações, denominadas reações de oxirredução, estabelecem uma diferença de potencial elétrico entre os eletrodos positivo e negativo, propiciando a passagem de corrente elétrica quando os mesmos são conectados por um condutor, o que responde pela alimentação do circuito conectado à bateria.

Em contraste com a corrente elétrica de alimentação do sistema externo, internamente as reações de oxirredução realizam o transporte de carga (íons) entre os eletrodos (ânodo e catodo) que estão ligados por uma solução de condução chamada de eletrólito (Brondani, 2015). Um esquema simplificado de uma célula eletrolítica está representado na figura 2.1, onde A^+ e B^+ são representações genéricas dos íons nos eletrodos.




Figura 2. 1 - Esquema simplificado de uma bateria

Fonte: Adaptado de *Battery University* (2017)

A caracterização de uma bateria se dá através da análise da evolução de seus parâmetros no tempo. Os principais parâmetros a serem observados em uma bateria são a tensão elétrica (expressa em volts) e a capacidade de carga (expressa em ampere-hora). Este último é o que determina o tempo que a bateria demora para descarregar. A capacidade, porém, não é uma grandeza fixa, sendo influenciada pelo modo em que a bateria é descarregada, temperatura de operação etc. (*Battery University*, 2017). Uma característica importante das baterias que está diretamente ligada ao tempo de descarga é o efeito de recuperação. Este consiste na reorganização dos elétrons no eletrólito quando a corrente de descarga é muito pequena ou nula. Isto faz com que a capacidade efetiva da bateria seja aumentada, ou seja, efetuar intervalos de uso de uma bateria aumenta o tempo de duração de sua carga (Brondani, 2015).

Outro efeito presente nas baterias é a de taxa de capacidade. Isto acontece quando a bateria é submetida a altas correntes de descarga, não havendo tempo suficiente para a reorganização dos elétrons. Assim, a capacidade efetiva da bateria diminui, visto que este efeito faz com que parte da carga não seja utilizada (Brondani, 2015).

O *MIT Electric Vehicle Team* (2008) apresenta algumas especificações de baterias que ajudam a compreendê-las melhor. Dentre os termos apresentados, destacam-se:

- Taxa-C - Para normalizar a capacidade das baterias, utiliza-se uma taxa (conhecida como C-Rate ou taxa-C) que expressa a corrente de carga e descarga das baterias. C-Rate é uma medida da taxa de carregamento da bateria na qual uma bateria é descarregada ou carregada em relação à sua capacidade máxima. A taxa de 1 C indica que a bateria irá ser descarregada ou carregada em 1 hora. Ou seja, uma bateria de 1 000

mAh, por exemplo, será carregada completamente em 1 hora caso seja utilizada uma corrente de 1 A para efetuar seu carregamento. Caso esta bateria seja carregada utilizando 5 A, ela teria uma taxa 5 C e seu carregamento seria mais rápido. Entretanto, a carga ou descarga efetuada em taxa C maior que 1 C pode causar danos a bateria, a menos que haja um sistema de controle para permitir tal carga ou descarga. Uma taxa de carregamento de 0,5 C indica que a bateria de 1 000 mAh é carregada com 0,5 A. A partir desta taxa é possível determinar o tempo de carregamento da bateria, em que 1 C indica que a bateria será carregada em torno de 1 hora, 0,5 C significa que a carga será completa em torno de 2 horas, 2 C terá o carregamento completo em torno 30 minutos e assim por diante. Embora a taxa-C seja representada pela letra C, esta não deve ser confundida com a unidade de carga elétrica.

- Estado de carga (SoC, do acrônimo em inglês, *State of Charge*) - Expressão percentual da capacidade atual da bateria em relação à capacidade máxima. É geralmente utilizado para determinar a mudança na capacidade da bateria ao longo do tempo em um ciclo.

- Estado de saúde (SoH, do acrônimo em inglês *State of Health*) - Expressão percentual da capacidade de carga máxima de uma bateria em relação a sua capacidade de carga nominal, em função do número de ciclos (carga/descarga) realizados. É geralmente utilizado para prever a vida útil de uma bateria.

- Profundidade de descarga (DoD, do acrônimo em inglês *Depth of Discharge*) - Capacidade da bateria que foi descarregada expressa em porcentagem da capacidade máxima. Uma descarga a partir de 80 % é considerada descarga profunda.

- Ciclo de vida - Quantidade de ciclos de carga e descarga que a bateria pode experimentar sem que apresente perda significativa de desempenho. O ciclo de vida das baterias é afetado pela taxa-C de carregamento, profundidade de descarga, temperatura e umidade. Usualmente, considera-se que a bateria terminou seu ciclo de vida quando apresenta capacidade entre 70 % e 80 % em relação a sua capacidade nominal.

- Corrente máxima de descarga contínua - Corrente máxima que a bateria pode ser descarregada de forma contínua. Este limite geralmente é definido pelo fabricante para evitar danos à bateria.

- Tensão de carga - Tensão utilizada para carregar a bateria até sua máxima capacidade. O esquema de carregamento de baterias geralmente consiste em uma carga de corrente constante até a bateria atingir determinada tensão. Na sequência, o

carregamento passa a ser no modo tensão constante, permitindo que a corrente de carga diminua conforme a bateria seja carregada até que não haja mais circulação de corrente ou a corrente seja muito pequena.

- **Corrente de Carga** - A corrente ideal na qual a bateria é inicialmente carregada (para aproximadamente 70 % SoC) sob a condição de corrente constante antes da transição para tensão constante.

- **Fuga térmica** - Energia convertida em calor causada pelas reações químicas internas das baterias. Defeitos estruturais podem levar ao superaquecimento das células a ponto de entrar em combustão. Baterias de íon-lítio, por exemplo, não devem ultrapassar a faixa de 45 °C durante sua operação.

- **Tensão de corte** - Tensão na qual a bateria é considerada totalmente descarregada. Caso a bateria seja descarregada a uma tensão menor que a de corte, pode haver danos a bateria, como estufamento, no caso de baterias de íon-lítio. Os danos podem ser irreversíveis, fazendo com que a bateria não possa mais ser utilizada.

De modo geral, existem dois grandes grupos de baterias: as primárias e secundárias. As baterias primárias não são recarregáveis, tendo como exemplo as baterias de zinco/dióxido de manganês (alcalina), zinco/óxido de prata, lítio/dióxido de enxofre etc. Já as baterias secundárias, objeto desta dissertação, são aquelas recarregáveis. O quadro 2.1 apresenta os principais tipos de baterias secundárias, assim como seus formatos e exemplos de aplicações.

Quadro 2. 1 - Exemplos de baterias recarregáveis

Tipo de bateria	Formato	Exemplos de aplicações
Níquel-cádmio	Cilíndrica, retangular ou em módulos	Equipamentos portáteis (brinquedos, controle remoto, lanterna etc.)
Níquel-hidreto metálico	Cilíndrica, retangular ou em módulos	Equipamentos portáteis (brinquedos, controle remoto, lanterna etc.), bicicletas elétricas, veículos híbridos
Íon-lítio	Cilíndrica, retangular, botão ou em módulos	Smartphones, bicicletas elétricas, notebooks, veículos híbridos ou elétricos
Chumbo-ácido	Retangular	Automóveis, motocicletas, ônibus, caminhões, máquinas agrícolas, empilhadeiras

Fonte: Adaptado de Castro *et al.* (2013)

O objeto de estudo desta pesquisa são as baterias de íon-lítio, uma vez que estas possuem maior densidade energética (quantidade de energia que a bateria consegue reter em relação a seu volume) que os outros tipos de baterias secundárias, além de serem vastamente utilizadas em equipamentos eletrônicos como smartphones e *notebooks* e, recentemente, começam a ser utilizadas em veículos elétricos, em substituição às baterias de chumbo-ácido (mais pesadas, por conta da menor densidade energética).

O princípio de funcionamento de uma bateria de íon-lítio possui diferenças em relação às demais tecnologias. O íon de lítio não é transferido por reações de oxirredução. Assim, os íons de lítio são transferidos do eletrodo negativo para o positivo por meio do eletrólito, ou seja, juntam-se aos materiais do ânodo e do cátodo (Castro *et al.*, 2013).

De modo geral, os materiais de eletrodos são formados por compostos de intercalação (compostos de estrutura aberta), que permitem a entrada e saída de íons de lítio. O grafite é o material mais utilizado no ânodo por possuir estrutura lamelar e por ser capaz de intercalar os íons de lítio entre suas camadas de carbono de forma reversível, sem causar alterações significativas em sua estrutura. O cátodo contém, geralmente, um óxido de estrutura lamelar (LiCoO_2 , LiNiO_2 etc.) ou espinel (LiMnO_2). Durante a descarga da bateria, a reação que ocorre no ânodo é a oxidação do carbono, permitindo a liberação dos íons de lítio para manter a eletro neutralidade do material. Durante o processo de descarga, os íons de lítio migram desde o interior do material que compõe o ânodo até o interior do material do cátodo e os elétrons movem-se através do circuito externo, conforme ilustrado na figura 2.2 (*Battery University*, 2018).

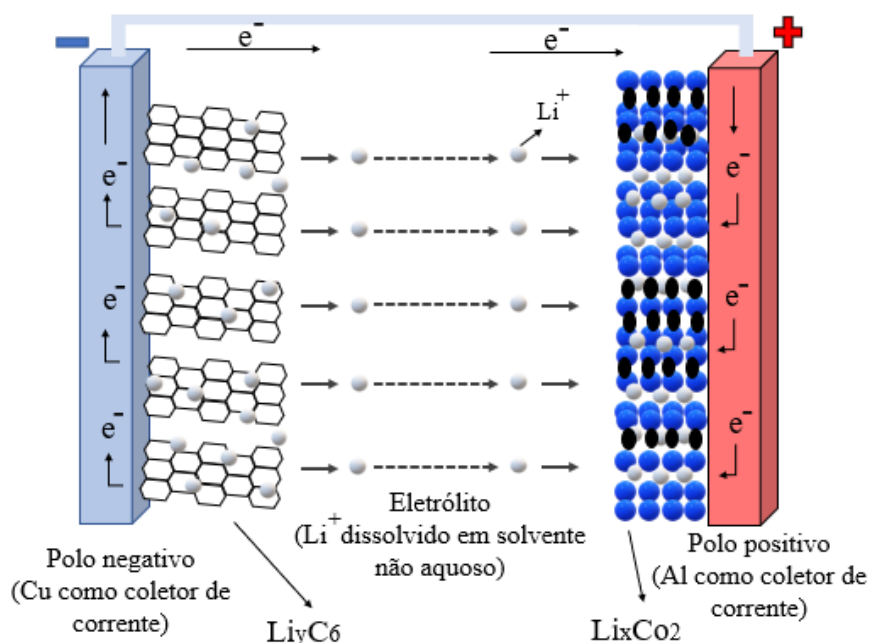


Figura 2. 2 - Princípio de funcionamento da bateria de íon-lítio

Fonte: Adaptado de *Battery University* (2016)

A temperatura de operação da bateria de íon-lítio durante o processo de carga (mesmo para carregamento rápido) deve estar na faixa de operação de 5 °C a 45 °C. Efetuar a carga de baterias de íon-lítio a uma temperatura inferior a 5 °C é prejudicial devido às taxas de difusão reduzidas do ânodo. A resistência interna da bateria aumenta quando exposta a baixas temperaturas, prologando o processo de carga (*Battery University*, 2017).

De modo geral, o íon-lítio tem um bom desempenho em temperaturas elevadas, mas a exposição prolongada ao calor reduz a longevidade. Carregar e descarregar baterias em altas temperaturas pode levar à geração de gases sob pressão, ocasionando o inchaço das células. Este estufamento da bateria é perigoso e pode levar à combustão. Além disso, a bateria de íon-lítio exposta a altas temperaturas tem perda de capacidade quando comparadas ao seu funcionamento em temperatura ambiente (*Battery University*, 2017).

O lítio é pequeno e leve e, por esta razão, as baterias deste tipo possuem maiores níveis de potência e energia por unidade de massa. Elas também são menos agressivas ao meio-ambiente, se comparada a outros tipos de baterias secundárias, como a de chumbo-ácido, por exemplo.

As baterias de íon-lítio não são de um tipo único, mas uma categoria de baterias que utiliza o lítio como componente (geralmente no cátodo e no eletrólito). Os ânodos e

cátodos podem conter variados materiais em suas composições. O material mais frequente para os ânodos é o grafite (C), enquanto os cátodos podem ser de vários tipos (Castro *et al.*, 2013), dentre os mais comuns, destacam-se os descritos no quadro 2.2.

Quadro 2. 2 – Principais tipos de baterias de íon-lítio encontradas no mercado

Anodo / Catodo	Vantagens	Desvantagens
C / LiCoO ₂ (LCO)	Elevada capacidade específica	Baixa segurança intrínseca
		Alto custo
		Baixa vida útil
		Faixa operacional de temperatura pequena
		Pouca disponibilidade de materiais (especialmente o cobalto - Co)
C / LiNiMnCoO ₂ (NMC)	Baixo custo	Menor eficiência das reações de carga e descarga
	Densidade energética 20 % superior à da LCO	Baixa estabilidade térmica
C / LiNiCoAlO ₂ (NCA)		Baixa retenção de capacidade
		Grande pico exotérmico durante a carga
C / LiMn ₂ O ₄ (LMO)	Baixo custo dos materiais	Perda de capacidade durante a descarga
	Abundância do manganês (Mn) superior em relação ao cobalto	
	Menor impacto ambiental	
C / LiFePO ₄ (LFP)	Excelentes características eletroquímicas	Menor tensão entre os materiais dos eletrodos positivos de lítio
	Baixo custo do ferro (Fe)	Baixo desempenho em operações envolvendo alta corrente de descarga
	Menor impacto ambiental	
	Maior estabilidade	
	Atinge muitos ciclos de carga e descarga	
	Menor custo em relação à bateria de cobalto	

Fonte: Adaptado de Castro *et al.* (2013)

O Li-Cobalto (LCO) possui alta energia específica e, por esta razão, é uma das escolhas mais comuns para telefones celulares (*smartphones*), *notebooks* e câmera

digitais. A bateria utilizada nos ensaios destrutivos realizados no contexto desta pesquisa é a de Li-Cobalto e, portanto, os parâmetros subsequentes referem-se a este tipo de bateria.

A bateria Li-Cobalto consiste em óxido de cobalto de lítio como cátodo e grafite como ânodo. O cátodo tem uma estrutura em camadas e, durante a descarga, íons de lítio se movem do ânodo para o cátodo, através do eletrólito. O fluxo iônico é revertido na carga, comportamento característico de baterias secundárias. A desvantagem desta tecnologia é o baixo tempo de vida útil, baixa estabilidade de carga, capacidades limitadas e baixa segurança (*Battery University*, 2018). As baterias de Li-Cobalto devem trabalhar dentro da faixa de operação indicada pelos fabricantes, pois estas baterias podem entrar em combustão caso sejam operadas de forma incorreta. As características das baterias de Li-Cobalto utilizadas nos ensaios destrutivos deste trabalho são apresentadas na tabela 2.1.

Tabela 2. 1 - Características das baterias de íon-lítio de cobalto

Óxido de cobalto de lítio: LiCoO₂ cátodo (~60% Co), grafite ânodo	
Forma abreviada: LCO ou Li-cobalto.	
Tensão	3,60 V nominal; faixa de operação típica 3,0–4,2 V/célula
Energia específica	150–200 Wh/kg.
Carga (C-rate)	0,7–1 C, tensão máxima 4,20 V (maioria das células) para 3 h de carga tipicamente. A corrente de carga acima de 1 C encurta a vida da bateria.
Descarga (C-rate)	1 C, 2,50 V. A corrente de descarga acima de 1 C reduz a autonomia da bateria.
Ciclo de vida	500–1000 ciclos, dependendo da profundidade de descarga, carga, temperatura e umidade.
Aplicações	Celulares, tablets, notebooks, câmeras.
Informações adicionais	Energia específica muito elevada, potência específica limitada. O cobalto é caro, por conta da baixa disponibilidade no mercado e, por conta disso, a quota de mercado estabilizou.

Fonte: Adaptado de *Battery University* (2017)

O modo de realização dos processos de carga e descarga de baterias de íon-lítio são importantes para a manutenção da saúde da bateria e para seu bom funcionamento. Nas próximas seções (2.1.1. e 2.1.2.) serão abordados como é realizado o processo de carga e descarga de baterias de íon-lítio, respectivamente.

2.1.1.

Processo de carga de baterias

Embora o processo de carga seja simples, é necessário implementar diversos recursos aos carregadores e até mesmo às baterias de forma a possibilitar o controle de tensão e corrente neste processo. Desta forma, se torna possível efetuar a recarga em menos tempo e com maior eficiência (com menor gasto de energia elétrica). Na figura 2.3 está ilustrado um carregador genérico simplificado. Um carregador simples consiste numa fonte elétrica que estabelece uma corrente em sentido contrário ao fluxo natural de corrente provocado na bateria, a qual deve ser carregada. Conforme ilustrado na figura 2.3, o carregador possui um transformador capaz de transformar a tensão ao nível desejado de utilização. Os diodos retificam a corrente alternada, tornando-a contínua (Instituto Newton C. Braga, 2017).




Figura 2. 3 – Circuito de um carregador simples

Fonte: Adaptado de Instituto Braga (2010)

Como a resistência interna da bateria varia com a sua carga (e normalmente possui valor muito baixo), é preciso agregar à essa fonte elétrica algum dispositivo que atue como limitador da corrente de carga, tornando a operação mais segura. O resistor R1 apresentado na figura 2.3 atua como este limitador de corrente (Instituto Newton C. Braga, 2017).

O processo de carga pode ser dividido em duas etapas: corrente constante e tensão constante. Na fase de carregamento em corrente constante, um valor de corrente é injetado, de acordo com a capacidade energética da bateria. Deste modo, a tensão da bateria aumenta ao longo do tempo. Ao atingir a tensão máxima fixada para a bateria, o carregamento entra na fase de tensão constante. Então, a corrente de carga diminui conforme a bateria é carregada. A carga completa ocorre quando a bateria atinge o limite de tensão e a corrente cai para aproximadamente 3 % da corrente nominal (*Battery*

University, 2018). Uma bateria também é considerada totalmente carregada se a corrente estiver nivelada e não puder diminuir ainda mais. Para baterias de íon-lítio, o carregador deve ser modificado, de forma a atender as duas etapas de carregamento.

Baterias de íon-lítio não devem ser carregadas e descarregadas com uma corrente maior que a correspondente a sua taxa de 1 C sem que haja nenhum tipo de tratamento, o qual ocorre em situações de carregamento rápido (*Battery University*, 2018). Isso significa que uma bateria de 5000 mAh, por exemplo, só deve ser carregada e descarregada até uma corrente de 5000 mA. Forçar uma carga rápida ou aplicar uma carga superior a 5000 mA causa superaquecimento. Para uma carga rápida ideal, os fabricantes recomendam uma taxa-C de 0,8 C (*Battery university*, 2018).

Conforme a tecnologia avança, mais rápido se torna o processo de carga das baterias. Atualmente, existem muitos estudos acerca da implementação de tecnologias de carregamento rápido (*fast charging*), ou seja, o carregamento mais rápido e eficiente de baterias. Smartphones e veículos elétricos são exemplos de equipamentos que dependem desta tecnologia para poderem garantir ao consumidor final maior disponibilidade e menor tempo de carregamento.

O carregamento de baterias de íon-lítio deve ser interrompido caso a temperatura varie acima de 10 °C sob velocidades de carregamento de até 1 C. O mesmo critério serve para baterias sendo descarregadas (Placke *et al.*, 2017).

A bateria de íon-lítio não precisa estar totalmente carregada, como acontece com baterias de chumbo-ácido, nem é desejável fazê-lo (Placke *et al.*, 2017). De fato, é melhor não carregar totalmente, porque uma alta tensão pode danificar a bateria, causando perda de sua vida útil. Na tabela 2.2, são apresentados os dados de tensão das células da bateria para diferentes níveis de carga.

Tabela 2. 2 - Tensão (V/Célula) x Capacidade

Tensão /célula (V)	Capacidade na tensão de corte	Tempo de carga	Capacidade máxima
		(min)	
3,8	60 %	120	~65 %
3,9	70 %	135	~75 %
4	75 %	150	~80 %
4,1	80 %	165	~90 %
4,2	85 %	180	~100 %

Fonte: Adaptado de Battery University (2018)

Sobrecarga em qualquer tipo de bateria pode apresentar riscos à segurança e provocar a sua completa ou parcial degradação. Em especial, as baterias de íon-lítio não podem ser submetidas a processos de sobrecarga, sob risco de ignição. Quando totalmente carregada, a corrente de carga deve ser cortada. Caso contrário, a segurança da bateria é comprometida, pois pode haver aquecimento excessivo das células, assim como perda de eficiência da bateria (Smith *et al.*, 2015).

Quando o carregamento é terminado e a fonte elétrica desconectada, a tensão na bateria passa por uma acomodação natural. Com o passar do tempo, a tensão de circuito aberto se estabiliza entre 3,90 V e 3,70 V/célula (Battery University, 2018). Quando as baterias de íon-lítio devem ser deixadas no carregador para prontidão operacional, alguns carregadores aplicam uma carga breve para compensar a pequena descarga automática que a bateria e seu circuito de proteção consomem. O carregador pode ser acionado quando a tensão de circuito aberto cai para 4,05 V/célula e se desliga novamente a 4,20 V/célula. Os carregadores feitos para prontidão operacional, ou modo de espera, geralmente deixam a voltagem da bateria cair para 4,00 V/célula e recarregam para apenas 4,05 V/célula em vez dos 4,20 V/célula. Isso prolonga a vida útil da bateria (Smith *et al.*, 2015).

Alguns fabricantes de carregadores ajustam o limite de tensão de carga para valores menores que o nominal, a fim de prolongar a vida útil da bateria. O carregamento da bateria de íon-lítio segue um perfil concebido para garantir segurança e longa vida útil sem comprometer seu desempenho. Se uma bateria de íon-lítio estiver profundamente descarregada (por exemplo, abaixo de 3 V), uma pequena carga com cerca de 10 % da corrente de carga total será aplicada. Isso impede que a célula superaqueça até que seja

capaz de aceitar a corrente completa associada à fase de corrente constante. Na realidade, essa fase raramente é necessária porque a maioria dos dispositivos móveis modernos é projetada para se desligar enquanto ainda resta alguma carga na bateria, pois a descarga profunda, assim como sobrecarga, pode danificar a célula (Smith *et al.*, 2015). Esse procedimento também permite que o usuário possa realizar chamadas de emergência mesmo que seu celular indique que está completamente descarregado.

2.1.2.

Processo de descarga de baterias

O modo de descarga das baterias também influencia o tempo de vida útil destes dispositivos. As baterias tendem a oferecer menor período de vida útil se descarregadas por pulsos, ou seja, quando a bateria é exposta a alta corrente de descarga e interrupção da descarga em intervalos de tempo pequenos, similar a uma onda quadrada. (*Battery University*, 2018). Em uma descarga de 2 C, por exemplo, a bateria apresenta uma corrente muito maior do que a de 1 C, podendo diminuir sua vida útil em mais de 100 ciclos. Isto acontece porque altas correntes em relação a capacidade máxima de retenção da bateria podem alterar suas reações eletroquímicas internas, podendo danificar a bateria de forma permanente.

A maioria das baterias é considerada inoperante quando a tensão da célula está abaixo de 2,8 V / 3 V, pois parte do metal no coletor de corrente do ânodo pode dissolver no eletrólito. Os íons, por sua vez, podem aderir ao ânodo durante a carga e causar dendritos (acúmulo de cristal de lítio, que pode formar uma camada de lítio sólido). Os dendritos podem causar um curto-circuito dentro da bateria. Entretanto, mesmo nessa situação, as células podem ser recarregadas novamente e reutilizadas. Para isso, a bateria é carregada com um limite de corrente de 0,1 C até atingir 3 V (*Battery University*, 2018c).

Quando a bateria é carregada e descarregada completamente, diz-se que ela completou 1 ciclo de carga / descarga. O tempo de vida das baterias está associado ao número de ciclos que ela é capaz de realizar. Entretanto, o conceito de ciclos não é exato, pois nem sempre a bateria será completamente carregada ou descarregada. Na próxima seção será abordada esta importante questão sobre as baterias.

2.1.3. Tempo de vida e ciclos de carga / descarga

A bateria de íon-lítio funciona por meio do movimento iônico entre os eletrodos positivos e negativos. Em teoria, tal mecanismo deve funcionar para sempre, mas o número de ciclos, a temperatura elevada e o envelhecimento diminuem o desempenho a longo prazo. Os fabricantes adotam uma abordagem conservadora e especificam a vida útil deste tipo de bateria como estando entre 300 e 500 ciclos de descarga/carga (*Battery University*, 2018).

A avaliação da vida útil da bateria por meio da contagem de ciclos não é conclusiva, porque uma descarga pode variar em profundidade e não há padrões claramente definidos sobre o que constitui um ciclo (*Battery University*, 2017). O desempenho de uma bateria é medido em capacidade energética, um indicador importante de saúde da bateria. A resistência interna e a autodescarga também afetam o tempo de vida das baterias, mas elas são menos significativas na previsão do fim da vida útil destas.

Um ciclo de descarga/carga é comumente entendido como a descarga total de uma bateria carregada com subsequente recarga, mas isso nem sempre é o caso (Smith *et al.*, 2015). As baterias de íon-lítio raramente são totalmente descarregadas e os fabricantes geralmente usam o parâmetro de 80 % de profundidade de descarga para avaliar uma bateria (apenas 80 % da energia disponível é fornecida e 20 % permanecem na reserva) (Smith *et al.*, 2015).

Semelhante a um dispositivo mecânico que se desgasta mais rapidamente com o uso pesado, a profundidade de descarga determina a contagem de ciclos da bateria. Quanto menor a descarga (baixa profundidade de descarga), maior a duração da bateria. Dessa forma, a descarga parcial de baterias de íon-lítio é recomendada para que a sua vida útil seja prolongada.

Na tabela 2.3 é apresentada a estimativa do número de ciclos de descarga/carga que baterias de íon-lítio podem fornecer em vários níveis de profundidade de descarga antes que a capacidade da bateria atinja 70 % da capacidade total (Smith *et al.*, 2015). A profundidade de descarga constitui uma carga completa, seguida de uma descarga para o nível de estado de carga indicado na tabela 2.3.

Tabela 2. 3 – Ciclos de descarga

Profundidade de descarga	Ciclo de descarga (NMC/LiPO4)
100%	~300 / 600
80%	~400 / 900
60%	~600 / 1,500
40%	~1,000 / 3,000

Fonte: Battery University (2018)

A bateria de íon-lítio sofre estresse tanto ao ser exposta ao calor excessivo (que eleva sua temperatura interna), quanto ao ter sua célula submetida à alta tensão de carga. Uma bateria com uma temperatura acima de 45 °C é considerada elevada e, para a maioria das baterias de íon-lítio, a tensão máxima admitida é de 4,20 V/célula (*Battery University*, 2018).

A maioria das baterias de íon-lítio carrega até uma tensão de 4,20 V/célula. Entretanto, cada redução na tensão de carga de pico de 0,10 V/célula pode duplicar a vida útil da bateria (*Battery University*, 2018). Por exemplo, uma célula de íon-lítio carregada para 4,20 V/célula normalmente fornece de 300 a 500 ciclos. Caso a bateria seja descarregada apenas para 4,10 V/célula, a vida útil pode ser prolongada para valores entre 600 e 1 000 ciclos; 4,0 V/célula deve fornecer de 1 200 a 2 000 ciclos e 3,90 V/célula deve fornecer 2 400 a 4 000 ciclos. A tabela 2.4 ilustra os ciclos de descarga máximos das baterias de íon-lítio em função do nível de tensão por célula.

Tabela 2. 4 - Ciclo de descarga e energia em função do nível de tensão

Nível de tensão por célula (V)	Ciclos de descarga	Energia armazenada disponível
4,2	300–500	100%
4,15	400–700	90–95%
4,1	600–1.000	85–90%
4,05	850–1.500	80–85%
4	1.200–2.000	70–75%

Fonte: Battery University (2018)

A maioria dos carregadores para telefones celulares, notebooks, tablets e câmeras digitais permite a carga até 4,20 V/célula. Isso permite a capacidade máxima, pois os consumidores exigem grande duração da bateria. A indústria, por outro lado, está mais preocupada com a longevidade e muitas escolhem limiares de tensão mais baixos (Placke *et al.*, 2017). Satélites e veículos elétricos são exemplos disso.

Ensaio destrutivo pode ajudar no estudo de todos os conceitos e características de baterias de íon-lítio expostas neste capítulo. Estes ensaios podem auxiliar na investigação de como a variação de diversos parâmetros das baterias de íon-lítio podem influenciar seu tempo de vida, assim como gerar dados para a construção de um modelo para estimar o SoH destas baterias. Na seção 2.2. serão abordados parâmetros importantes que devem ser observados para a construção de um bom sistema de testes para a realização dos ensaios destrutivos, a fim de validar na prática o que foi encontrado na literatura.

2.2.

Ensaio destrutivo de baterias secundárias

Ensaio destrutivo são aqueles que modificam o objeto de estudo, podendo deixá-lo inutilizado ou não. Este tipo de ensaio é amplamente utilizado nas indústrias para análise de falhas, possibilitando avaliar a evolução de uma série de propriedades do objeto em estudo ao longo do tempo e com respeito a estímulos externos (Lopes, 2001). Ensaio destrutivo são amplamente utilizados na área de engenharia mecânica, a fim de estudar a tração, compressão, cisalhamento etc. de materiais e/ou estruturas. A fim de obter as corretas propriedades do objeto de estudo, deve-se garantir a qualidade dos testes, para que não haja resultados que gerem falsas conclusões (Lopes, 2001).

Não existe regulamentação específica para ensaios destrutivos de baterias de íon-lítio. Porém, o Ato nº 3484, de 31 de maio de 2019, publicado pela ANATEL, fornece subsídios importantes para a construção do maquinário necessário para os testes, principalmente no que tange à segurança de manuseio das baterias. Este Ato tem como objetivo:

“Estabelecer os requisitos mínimos e procedimentos de ensaios a serem demonstrados na avaliação da conformidade de baterias de lítio portáteis recarregáveis utilizadas como fonte de energia em telefones celulares para efeito de homologação junto à Agência Nacional de Telecomunicações”.

Dentre os referenciais normativos utilizados para a construção do Ato nº 3484/2019, destaca-se a norma técnica internacional IEC 61960-3 – “*Secondary cells and batteries containing alkaline or other non-acid electrolytes - Secondary lithium cells and batteries for portable applications*”. Esta norma especifica testes de desempenho, designações, marcações, dimensões e outros requisitos para células individuais secundárias de lítio e

baterias para aplicações portáteis. A norma tem por objetivo fornecer aos compradores e usuários de baterias secundárias de íon-lítio um conjunto de critérios com os quais eles possam avaliar o desempenho das células e baterias secundárias de íon-lítio oferecidas por vários fabricantes. Este documento possui valiosas informações para a montagem do teste proposto nesta dissertação.

Os procedimentos de ensaios propostos na norma IEC 61960-3 estabelecem uma temperatura ambiente de 20 ± 5 °C. Nos ensaios elétricos, cada amostra deve ser testada individualmente, isto é, não devem ser interligadas em série ou paralelo. Os ensaios devem ser realizados em baterias com data de fabricação de no máximo 6 meses até o início dos testes. Isto garante que a bateria não tenha sofrido desgastes causados pelo tempo, mesmo que nunca tenham sido utilizadas.

Baterias de íon-lítio não podem ser carregadas com métodos tradicionalmente utilizados em outros tipos de baterias, ou seja, não podem ser carregadas por uma fonte de alimentação regular. O carregamento deve ser realizado até uma tensão específica e com corrente limitada, caso contrário, as baterias podem sofrer danos irreversíveis, podendo até mesmo explodir. A taxa C suportada para carga e descarga das baterias ensaiadas deve ser observada, de modo a evitar danos a bateria. Como colocado, usualmente, baterias de íon-lítio suportam cargas e descargas até uma taxa de 1 C. Taxas maiores podem causar danos à bateria.

Como explicitado anteriormente, o ciclo de carga de baterias de íon-lítio é efetuado em duas etapas: corrente constante e tensão constante. Na etapa de corrente constante, a bateria é conectada a uma fonte de corrente, ou seja, a fonte fornece uma corrente constante à bateria, geralmente limitada entre 50 % a 70 % da capacidade nominal da bateria (a taxa de carregamento é de 0,5 C a 0,7 C) e dura até a tensão da bateria atingir sua tensão nominal (geralmente 4,2 V). No final deste estágio, a carga da bateria está em torno de 70 % a 80 % da sua carga total. Baterias carregadas com tecnologia de carregamento rápido (*fast charging*) são submetidas a correntes maiores que sua capacidade nominal (taxas C maiores que 1) e são carregadas apenas por esta etapa de carga. Quando a bateria atinge sua tensão nominal, o carregador atua como uma fonte de alimentação com tensão limitada ao valor especificado. A tensão da bateria permanece constante enquanto a corrente de carga cai gradualmente. Quando a corrente de carga está entre 3 % e 10 % da capacidade nominal, a bateria é considerada totalmente carregada.

A maioria das baterias é considerada descarregada quando a tensão da bateria estiver entre 2,8 / 3 V. Caso a tensão atinja valores abaixo disto, a bateria deve ser

carregada com um limite de corrente de 0,1 C até atingir 3 V. Caso contrário, a bateria pode sofrer danos.

Nos ensaios destrutivos realizados neste estudo, foi desenvolvido um sistema de carga/descarga com 16 canais individuais. No capítulo 4, a total descrição desse dispositivo será apresentada.

2.3.

Considerações sobre o capítulo

A bateria selecionada para ser testada nesta dissertação é a de Li-Cobalto, por ser de uma tecnologia comumente utilizada na indústria para equipamentos eletrônicos, como *smartphones*, e *notebooks* por exemplo. Conforme apresentado neste capítulo, espera-se que a bateria seja capaz de funcionar corretamente por pelo menos 500 ciclos, de acordo com o modo de carga e descarga. Entretanto, é sabido que este tipo de tecnologia possui instabilidade quanto à retenção de carga e possui baixa vida útil. Estes aspectos serão testados e analisados por meio do ensaio destrutivo proposto neste capítulo.

Como não existe uma norma específica para o tipo de ensaio proposto neste trabalho, os procedimentos e o maquinário necessário para os testes foram estabelecidos baseando-se em normas e regulamentações envolvendo baterias de íon-lítio que se assemelham às utilizadas nesta dissertação. Ao final dos testes, é esperado ter uma base de dados diversificada e suficiente para a elaboração do modelo de estimação do SoH de baterias de íon-lítio, objetivo final deste trabalho.

Este capítulo expõe os principais parâmetros das baterias recarregáveis (baterias de secundárias), especialmente as baterias de íon-lítio. Os parâmetros mensuráveis resumidos no quadro 2.3 podem ser utilizados para a estimação do SoH de baterias íon lítio, principal objetivo deste trabalho.

Quadro 2. 3 – Principais parâmetros mensuráveis utilizados para estimar SoH

Parâmetro	Dificuldade de obtenção
Corrente de carga	Fácil
Tempo de carga	Fácil
Tensão de corte	Fácil
Profundidade de descarga	Moderada
Capacidade de carga	Moderada
Corrente instantânea	Fácil
Tensão instantânea	Fácil
Capacitância interna	Difícil
Tensão máxima	Fácil
Número de ciclos	Difícil devido a definição do conceito de ciclo
Resistência interna	Difícil
Estado de carga	Difícil
Temperatura	Fácil

Fonte: Elaboração própria

Para a construção do modelo de estimativa e previsão de SoH proposto neste trabalho, são escolhidos parâmetros de fácil mensuração, ou seja, aqueles que são possíveis de serem medidos por meio de sistemas de gerenciamento de baterias (BMS, acrônimo em inglês que significa *Battery Management System*), presentes na maioria dos equipamentos eletrônicos atuais. Esses parâmetros são tensão máxima, tensão de corte e corrente de carregamento, além do SoC, que também deve ser mensurado.

A partir dos conceitos abordados neste capítulo, é possível criar modelos para estimar o SoH de baterias de íon-lítio. No próximo capítulo serão abordados os métodos encontrados na literatura para estimar o SoC e SoH de baterias de íon-lítio. Além disso, serão apresentados estudos que deram subsídios para a construção do modelo proposto nesta dissertação (abordado no capítulo 4 e validado no capítulo 5).

3

Estimativa de curva de estado de carga e estado de saúde: conceitos e modelos

Os métodos para estimar o estado de saúde (*State of Health* – SoH) e o estado de carga (*State of Charge* – SoC) das baterias são os mesmos, alterando-se apenas a forma de implementação. Conforme mencionado no capítulo 2, a capacidade de retenção da bateria é um bom parâmetro para a estimar o SoH de baterias. O SoC é um parâmetro estimado a partir da capacidade instantânea e da capacidade máxima da bateria, portanto, aliado a outros parâmetros, pode ser um bom parâmetro para estimar o SoH. Para uma boa estimativa de SoH por meio de SoC, faz-se necessário uma boa estimativa de SoC associado a parâmetros da bateria que possam definir SoH. Isto é, o modelo para estimar o SoH de baterias, além do SoC, deve receber como dados de entrada parâmetros que definam o SoH das baterias. É importante que todos estes parâmetros de entrada (inclusive SoC) sejam exatos o suficiente para não gerar resultados duvidosos de SoH.

Na seção 3.1 será abordado, de forma abrangente, o que são métodos baseados em modelos físicos e métodos baseados em dados. Estes são usualmente utilizados para classificar os métodos existentes para estimar o SoH e SoC de baterias. Na seção 3.2 serão descritos em maiores detalhes os modelos disponíveis na literatura para estimar SoH e SoC. Na seção 3.3 serão analisados 3 trabalhos encontrados na literatura envolvendo estimativa de SoH de baterias de íon-lítio. Estes estudos geraram subsídios para a elaboração do modelo de estimativa de SoH proposto nesta dissertação.

3.1.

Métodos baseados em modelos físicos versus métodos baseados em dados

A maioria dos métodos para calcular SoH encontrados na literatura podem ser classificados em dois grandes grupos: métodos baseados em modelos físicos e métodos baseados em dados (Zhang *et al.*, 2018).

A abordagem de estimativa de uma grandeza baseada em modelos físicos é conhecida como abordagem convencional, que pode resolver muitos problemas, especialmente no domínio da engenharia (Li *et al.* 2017). Esta abordagem geralmente necessita de uma compreensão profunda do sistema ou processo analisado, a fim de construir regras robustas que podem modelar o comportamento do sistema com exatidão (Li *et al.* 2017). A estimativa de SoH baseado em modelos físicos pode ser extremamente poderosa e com excelente exatidão, pois são construídos a partir de parâmetros robustos e específicos da bateria em análise. Desta maneira, modelos deste tipo tendem a ter boa exatidão para o tipo de bateria estudada, mas não podem ser estendidos a outros tipos de baterias (Zhang et al, 2018).

Muitos problemas de engenharia e da física dependem de uma abordagem baseada em modelos físicos. Por exemplo, modelar a força gravitacional da terra, modelar a trajetória de um projétil etc. No entanto, existem preocupações práticas e teóricas para obter o modelo perfeito de qualquer sistema (How *et al.*, 2019). Do lado prático, o desenvolvimento de um modelo robusto, que melhor descreva um sistema, normalmente requer uma grande quantidade de tempo e experimentos trabalhosos.

Do ponto de vista teórico, os métodos baseados em modelos físicos necessitam de uma profunda compreensão teórica do sistema. Por exemplo, Li *et al.* (2017) projetaram um modelo eletroquímico simplificado de baterias de íon-lítio, a fim de estimar SoC por meio da relação entre o número estequiométrico de eletrodos e SoC. Para a construção deste modelo, levou-se em consideração aspectos eletroquímicos das baterias experimentadas, tais como tensão de circuito aberto, fase sólida, difusão de fase líquida, polarização de reação e polarização ôhmica. Cada elemento do modelo é composto por equações matemáticas complexas que dificultam a determinação dos parâmetros da bateria. O conhecimento prévio limitado sobre o sistema, inevitavelmente produz um modelo de baixa qualidade. Portanto, é imperativo o conhecimento de vários aspectos do sistema, como os detalhes mecânicos, elétricos, eletrônicos, químicos e outros, para desenvolver um modelo robusto. Em geral, modelos deste tipo são aplicados em apenas um tipo de bateria, não sendo possível estendê-los a outros devido à necessidade de conhecimentos específicos da tecnologia da bateria estudada.

As estimativas de SoH baseada em dados representam abordagens relativamente novas, possibilitadas pelo advento da capacidade de armazenar grande quantidade de dados e velocidade de processamento em computadores poderosos. Os métodos orientados a dados são construídos com base em observações empíricas e com um

conhecimento mínimo ou inexistente de processos secundários (Yang *et al.*, 2019). Dessa forma, dependem amplamente da análise de dados do processo em questão, não exigindo uma compreensão profunda e específica do objeto de estudo (Yang *et al.*, 2019). Essa abordagem pode ser útil para desenvolver um modelo de estimativa de SoH com informações prévias limitadas sobre as características internas e reações químicas da bateria.

Nesta perspectiva, a abordagem orientada a dados requer menor tempo e conhecimento para modelar um sistema complexo em comparação a abordagem baseada em modelos físicos. Por exemplo, modelos baseados em redes neurais artificiais podem examinar SoH com boa exa, monitorando apenas variáveis obtidas em medições da bateria, como corrente de carga, tensão e temperatura. Evita-se, desta forma, a necessidade de informações sobre a química interna da bateria, reações complexas e estimativa de parâmetros do modelo (Chemali *et al.*, 2018). No entanto, a utilização de métodos orientados a dados implica que a qualidade e a quantidade destes determine (em grande parte) a exatidão e o desempenho do modelo. A utilização de uma base de dados não validada, com observações erradas ou faltantes diminui a qualidade do modelo, prejudicando a tomada de decisão (Chemali *et al.*, 2018). Em essência, uma abordagem orientada a dados só é eficiente se houver uma grande quantidade de dados representativos do processo que se deseja modelar.

O quadro 3.1 destaca os principais benefícios e desvantagens dos métodos baseados em modelos físicos e baseado em dados.

Quadro 3. 1 Vantagens e desvantagens dos métodos baseados em modelos físicos e dos métodos baseados em dados

Método	Vantagens	Desvantagens
Baseado em modelos físicos	Confiável e com boa exatidão	Necessário conhecimento profundo do objeto de estudo
	Validação universal	Tempo de desenvolvimento elevado
Baseado em dados	Exige pouco tempo de desenvolvimento	Requer grande quantidade de dados
	Não é necessário conhecimento aprofundado do objeto de estudo	Pode apresentar resultados ruins se a base de dados não for boa

Fonte: Adaptado de How *et al.* (2019)

Na próxima seção, serão abordados os modelos, baseado em modelos físicos e baseado em dados, existentes para estimar o SoH de baterias de íon-lítio disponíveis na literatura.

3.2.

Modelos existentes para estimação de curva de estado de carga e estado de saúde de baterias secundárias

O quadro 3.2 apresenta os métodos baseados em modelos disponíveis na literatura atualmente para a estimativa de SoC e SoH. De modo geral, os métodos baseados em modelo físico são fáceis de implementar, têm baixo custo e possuem alta exatidão. Entretanto, os parâmetros utilizados nos modelos físicos mudam conforme o uso e o estado de degradação da bateria, além de ser necessário um modelo para cada tipo de bateria. Estes métodos são amplamente utilizados em laboratórios para o estudo de baterias, com aplicações em avaliação da conformidade, construção de novos modelos etc.

Quadro 3. 2 Métodos baseados em modelos físicos para estimar SoC e SoH

Método	Vantagens	Desvantagens	Trabalhos
Tensão de circuito aberto (Em inglês, <i>Open circuit voltage</i> - OCV)	Fácil de implementar Alta exatidão	Necessário longo período com a bateria em aberto para atingir as condições de equilíbrio Só pode ser aplicado com equipamento fora de uso	He <i>et al.</i> , 2012 Kim <i>et al.</i> , 2012 Truchot <i>et al.</i> , 2014 Lee <i>et al.</i> , 2007
Força eletromotriz (<i>Electro-Motive Force</i> - EMF)	Método simples Baixo custo	Necessário interromper a corrente do circuito por um tempo significativo; Resultados pouco exatos dependendo de distúrbios inesperados	Waag <i>et al.</i> , 2013 Coleman <i>et al.</i> , 2007
Resistência interna	Simple e fácil implementação	Só possui alta exatidão durante o período final de descarga Resistência muda ao longo do ciclo	Wang <i>et al.</i> , 2013 Zheng <i>et al.</i> , 2016
Espectroscopia de impedância eletroquímica (<i>Electrochemical Impedance Spectroscopy</i> - EIS)	Online, baixo custo Boa exatidão se a impedância é normalizada	Resultados sofrem impacto com a temperatura e vida útil restante da bateria	Andre <i>et al.</i> , 2011 Domenico <i>et al.</i> , 2011 Xia <i>et al.</i> , 2017

Fonte: Elaboração própria

Dentre os métodos apresentados no quadro 3.2, o método OCV é um dos mais utilizados, pois é de fácil implementação e possui alta exatidão. Entretanto, o tempo para estimar SoH ou SoC é maior em relação aos demais métodos. Todos os outros métodos dependem de sistemas de medição bem calibrados durante toda a vida da bateria, pois os parâmetros de análise mudam sensivelmente ao longo do funcionamento da bateria e também ao longo do tempo. O método EIS é o mais viável de ser implementado de forma online, porém é necessário cuidado em relação à temperatura e ao tempo de uso da bateria, pois estes são parâmetros que afetam a qualidade das medições.

O quadro 3.3 apresenta os métodos baseados em dados disponíveis na literatura atualmente para a estimativa de SoC e SoH. De modo geral, os métodos baseados em dados apresentam alta exatidão na medida em que possuam dados confiáveis para a construção dos modelos de estimativa. Estes métodos, em geral, não demandam conhecimento aprofundado do funcionamento interno das baterias, o que facilita a construção de modelos para operar de forma online, ou seja, é possível estimar SoC e / ou SoH durante o uso real da bateria. Porém, geralmente é exigida grande capacidade de memória computacional para armazenar os dados necessários para que o modelo apresentar bom desempenho. Os métodos baseados em dados estão sendo muito usados em aplicações envolvendo veículos elétricos, monitoramento da saúde de baterias em indústrias, baterias utilizadas em satélites etc.

Quadro 3. 3 Métodos baseados em dados para estimar SoC e SoH

Método	Vantagens	Desvantagens	Trabalhos
Contagem de Coulomb	Fácil de implementar Pouco gasto energético	Pode ser muito impreciso dependendo das condições de uso Difícil de determinar o valor inicial de SOC, causando erro cumulativo	Ng <i>et al.</i> , 2009 Leng <i>et al.</i> , 2014 Zhang <i>et al.</i> , 2014 Ng <i>et al.</i> , 2009
Filtro de Kalman (<i>Kalman Filter</i> - KF)	Estima com exatidão os estados afetados por distúrbios externos, como ruídos governados por uma distribuição gaussiana.	KF não pode ser diretamente utilizado para previsão de sistemas não lineares Alta complexidade matemática Possibilidades de divergência devido a um modelo impreciso e complexidade matemática	Zeng <i>et al.</i> , 2018 Hou <i>et al.</i> , 2019 Wang <i>et al.</i> , 2019 Dai <i>et al.</i> , 2012 Urbain <i>et al.</i> , 2007
Filtro de Kalman extendido (<i>Extended Kalman Filter</i> - EKF)	Boa exatidão com sistemas dinâmicos não-lineares	Robustez limitada Se o sistema for fortemente não linear, pode ocorrer erro de linearização	Xiong <i>et al.</i> , 2013 Chen <i>et al.</i> , 2019 Mastali <i>et al.</i> , 2013
Filtro de Kalman Unscented (<i>Unscented Kalman Filter</i> - UKF)	Matriz Jacobiana e ruídos gaussianos não são necessários para o cálculo Boa exatidão para estados do sistema até a terceira ordem de qualquer sistema não linear	Sofre de baixa robustez devido à incerteza na modelagem e distúrbios no sistema	Peng <i>et al.</i> , 2017 Sun <i>et al.</i> , 2011 Du <i>et al.</i> , 2014
Filtro de Kalman Sigma-ponto (<i>Sigma point</i>)	Tem complexidade de cálculo idêntica à EKF	Desenvolvimento complexo	Li <i>et al.</i> , 2013 He <i>et al.</i> , 2012

Kalman Filter - SPKF)			
	Boa exatidão e robustez	Complexidade matemática	
Filtro de Partícula (Particle Filter - PF)	Menor tempo computacional	Ferramentas matemáticas complexas para resolução de problemas	Gao <i>et al.</i> , 2011 Schwunk <i>et al.</i> , 2013
	Alta exatidão		
Filtro Hoo	Performance satisfatória em termos de exatidão, complexidade computacional e eficiência	Exatidão do sistema prejudicada pela idade da bateria, histerese e temperatura	Charkhgard <i>et al.</i> , 2015
Mínimos quadrados recursivo (Recursive least square - RLS)	Alta exatidão	Alta complexidade matemática	Hu <i>et al.</i> , 2011
	Elimina ruídos causados pela medição de tensão	Operação instável se o valor do fator de esquecimento não for apropriado	
Rede Neural Artificial	Capaz de trabalhar com baterias em condições não lineares	Necessária grande memória para guardar os dados de treinamento	Lipu <i>et al.</i> , 2017 Ungurean <i>et al.</i> , 2020 Yang <i>et al.</i> , 2016
Lógica Fuzzy	Bom desempenho na modelagem de sistemas não lineares dinâmicos Eficaz em qualquer estado de carga, tempo de uso e temperatura	Requer grande capacidade de memória Alta complexidade computacional Alto custo de processamento	Salkind <i>et al.</i> , 1999 Singh <i>et al.</i> , 2006 Awadallah e Venkatesh, 2016
Vetor de máquina de suporte (Support vector machine - SVM)	Bom desempenho com sistemas não lineares Previsão de SoC rápida e exata quanto utilizada uma boa base de treinamento	Alta complexidade computacional Processo de tentativa e erro é necessário para ajustar os parâmetros do modelo	Zhao <i>et al.</i> , 2017 Hansen e Wang, 2005 Antón <i>et al.</i> , 2013
Algoritmo genético	Alta exatidão Robusto contra ruídos	Alta complexidade computacional Necessário ajustes finos de parâmetros para obter resultados efetivos Atraso no tempo de resposta da otimização	Cao <i>et al.</i> , 2014
Observador de modo deslizante (Sliding mode observer - SMO)	Possui controle de rastreamento aprimorado para garantir estabilidade e robustez	Difícil ajustar o ganho de comutação para controlar o regime deslizante	Ning <i>et al.</i> , 2016 Xiong <i>et al.</i> , 2017 Du <i>et al.</i> , 2016
Observador integral proporcional (Proportional-integral observer - PIO)	Boa exatidão de estimação de SOC com baixo tempo computacional A robustez do modelo é aprimorada contra a incerteza do modelo	Pode fornecer resultados imprecisos se o controlador não for projetado corretamente	Cao <i>et al.</i> , 2014 Xu <i>et al.</i> , 2014

Observador não-linear (<i>Nonlinear observer</i> - NLO)	Desempenho aprimorado em termos de exatidão, velocidade e custo de computação. Robusto contra distúrbios	Difícil encontrar uma matriz de ganho adequada para reduzir o erro	Xia <i>et al.</i> , 2014
Splines de regressão adaptativa multivariada (<i>Multivariate adaptive regression splines</i> - MARS)	Alta exatidão	Baixa exatidão no início e fim do SOC	Álvarez <i>et al.</i> , 2013
Interpolação Bi-linear (BI)	Desempenho estável Alta exatidão	SOC 3D é um desafio ainda	Liye <i>et al.</i> , 2013
Resposta de Impulso (<i>Impulse response</i> - IR)	Valor estimado de SOC mais próximo ao valor real	Pode fornecer baixa exatidão se a largura do pulso de corrente não for suficientemente menor que a menor constante de tempo	Ranjbar <i>et al.</i> , 2012

Fonte: Elaboração própria

Além dos métodos apresentados nos quadros 3.2 e 3.3, também existem os métodos híbridos. Estes combinam características de dois métodos descritos anteriormente para a construção de um novo modelo. Esta abordagem pode produzir resultados de estimativas aprimorados e confiáveis, porém elevam a complexidade, além de serem suscetíveis a grandes erros, caso não sejam bem ajustados. Dependendo dos métodos combinados, o custo computacional pode ser muito elevado e tornar o modelo proibitivo (Hannan *et al.*, 2017).

As Redes Neurais Artificiais (RNAs) têm sido um método popularmente empregado em muitos trabalhos recentes envolvendo a estimação do SoH e / ou SoC de baterias. Tong *et al.* (2016) propuseram um modelo baseado em RNA para estimativa de SoC por meio da categorização dos diferentes modos de operação de baterias de íon-lítio utilizadas em veículos elétricos: inativo (bateria fora de operação), carga e descarga. Desta maneira, o trabalho propõe 3 Redes Neurais treinadas em paralelo, de acordo com o modo de operação da bateria. O modelo proposto atinge um erro percentual médio de SoC de 3,8%, tendo desempenho compatível a outros modelos de rede neural.

Kang *et al.* (2014) sugeriram o modelo baseado em *radial basis function neural network* (RBFNN) para estimar o SoH a partir da temperatura das baterias, ciclos de acionamento e efeitos de envelhecimento. O modelo é testado em baterias de íon-lítio com capacidade de 6 Ah e relatou erro médio absoluto (MAE) abaixo de 0,05 Ah.

No trabalho desenvolvido por Chaoui *et al.* (2017), o modelo de estimativa SoH baseado em redes neurais é avaliado para baterias de íon-lítio sob cargas e temperaturas

de corrente de pulso. O modelo obtém menor erro quadrático médio (RMSE) e maior tempo de execução em comparação com o método *multilayer perceptron* (MLP).

Embora os smartphones disponíveis no mercado estejam cada vez mais robustos e capazes de monitorar a saúde da bateria (por meio de aplicativos como Ampere, por exemplo), ainda não são encontrados na literatura trabalhos para estimativa e previsão em tempo real (*online*) de SoC e SoH com aplicações envolvendo modelos de negócios de *battery swap*.

Para pesquisa da presente dissertação, será utilizado o método de redes neurais recorrentes GRU (*Gated Recurrent Unit*) para a construção do modelo para estimar o SoH de baterias de íon-lítio por meio do SoC com aplicação em *smartphones*. Este método foi escolhido por não necessitar de conhecimento profundo acerca do funcionamento interno das baterias, o que ajuda a estender o modelo para outras tecnologias de bateria. Além disso, a rede neural GRU exige baixa capacidade computacional, quando comparada a outras redes neurais recorrentes (Ungurean *et al.*, 2020). Os ensaios destrutivos irão fornecer dados para alimentar a rede neural, sendo possível construir um modelo robusto e com dados confiáveis. O método de contagem de Coulomb, por possuir boa exatidão e ser de fácil implementação, será utilizado para a estimação de SoC das baterias.

Na próxima seção, serão apresentados 3 trabalhos envolvendo a estimativa de SoC e SoH. Estes estudos serviram de base para a construção do modelo proposto nesta dissertação.

3.3.

Estudos empíricos sobre aplicações de modelos para estimativa do estado de saúde de baterias de íon-lítio

Foram encontrados na literatura 3 estudos que podem fornecer valiosos subsídios para a construção do novo modelo proposto nesta pesquisa. São estes: Ng *et al.* (2009), Yang *et al.* (2016) e Ungurean *et al.* (2020). O trabalho de Ng *et al.* (2009) foi importante por utilizar de forma eficiente o método de contagem de Coulomb, sendo um dos trabalhos com menores erros encontrados na literatura. O trabalho de Yang *et al.* (2016) apresenta um sistema de testes que foi utilizado para o treinamento de uma rede neural para estimar SoH. Este trabalho forneceu subsídios para a construção do sistema de testes proposto nesta dissertação. O trabalho de Ungurean *et al.* (2020) foi importante por ser bastante atual e por utilizar redes neurais recorrentes para estimar SoH, mesmo tipo de

rede neural utilizado no modelo proposto nesta dissertação. Foi possível obter informações importantes para a construção do modelo proposto.

No trabalho de Ng *et al.* (2009), os autores utilizaram o método de contagem de Coulomb para estimar o SoC e monitorar o SoH de baterias de íon-lítio de 2350 mAh de capacidade. Dentre os trabalhos encontrados na literatura envolvendo estimativa de SoC por meio da técnica de contagem de Coulomb, este possui baterias de testes semelhantes às usadas nesta dissertação. Os modelos matemáticos apresentados podem ser adaptados para o modelo proposto.

No trabalho de Yang *et al.* (2016), o SoH de baterias de íon-lítio é estimado por meio do uso de uma rede neural *back propagation*. As baterias utilizadas nos ensaios deste trabalho possuem 10 Ah de capacidade e são destinadas para uso em veículos elétricos. Este trabalho apresenta um sistema de testes para carga / descarga das baterias, a fim de colher dados para alimentar a RNA proposta. Este sistema gerou subsídios para a construção do sistema construído nesta dissertação para a realização dos ensaios destrutivos.

No trabalho de Ungurean *et al.* (2020), foi desenvolvido um método de previsão de SoH por meio do uso de uma rede neural GRU (*gated recurrent unit*). Esta é um tipo de rede neural recorrente, que tem como característica processar dados de forma a considerar sua evolução no tempo. Este trabalho foi determinante para a escolha de redes neurais GRU para o modelo proposto nesta dissertação, visto suas vantagens em relação a RNAs convencionais, como a menor necessidade de capacidade computacional.

O modelo proposto nesta dissertação terá o SoC como um dos parâmetros para estimar o SoH de baterias de íon-lítio. Segundo o trabalho de Ng *et al.* (2009), o método de contagem de Coulomb tem como vantagem não ser necessário o conhecimento da resistência interna e da tensão de corte das baterias. Estes parâmetros são afetados pelo desgaste da bateria e, portanto, variam com o tempo. O método de contagem de coulomb calcula a capacidade restante simplesmente acumulando a carga transferida dentro ou fora da bateria. No entanto, faz-se necessário monitorar a capacidade da bateria a longo prazo, o que exige grande capacidade de armazenamento de dados. Visto que é possível dispor de grande capacidade de armazenamento atualmente, é viável utilizar este método para aplicações em tempo real. Essencialmente, o SoC é uma razão entre a capacidade instantânea e a capacidade máxima da bateria.

No trabalho de Yang *et al.* (2016), a capacidade da bateria é calculada a partir da integração da corrente de descarga ao longo do tempo. Os dados utilizados são

provenientes de um sistema de testes que carrega e descarrega as baterias. Este sistema é ligado a um computador por meio de um conversor analógico / digital. A temperatura ambiente foi mantida constante em 25 °C. São medidos e enviados para o computador a tensão e corrente das baterias.

No trabalho de Ng *et al.* (2009), as capacidades iniciais das baterias de teste são obtidas por meio da técnica de tensão em circuito aberto (*open circuit voltage* – OCV). Este envolve a organização dos dados em tabela da relação entre a tensão em circuito aberto e o SoC, executando intensas experiências em laboratório para caracterizar os comportamentos da bateria e obter o mapeamento da relação entre SoC e OCV. A qualidade de medição de carga e descarga são consideradas para dar maior robustez ao método. A capacidade máxima disponível da bateria é recalibrada dinamicamente ao longo dos ciclos e o SoH da bateria é avaliado ao mesmo tempo.

Embora o método para o cálculo da capacidade das baterias utilizado por Ng *et al.* (2009) geralmente gere resultados mais exatos, o método utilizado por Yang *et al.* (2016) é mais fácil de ser implementado em modelos que trabalham em tempo real. Isto porque o método OCV necessita que o circuito seja desligado por um grande período, sendo mais indicado para ser utilizado em laboratório. Portanto, para aplicações envolvendo *battery swap*, o método utilizado por Yang *et al.* (2016) mostra-se mais adequado para o cálculo da capacidade energética.

No trabalho de Ng *et al.* (2009), a capacidade nominal da bateria é substituída pela capacidade estimada no segundo ciclo de medição. Isto porque o modo de operação da bateria influencia sua retenção de carga, alterando sua capacidade máxima, podendo ser diferente da capacidade nominal fornecida pela fabricante da bateria. Isto também foi realizado no modelo proposto nesta dissertação.

Para a estimativa de SoC, o trabalho de Ng *et al.* (2009) calcula a profundidade de descarga (DoD, em inglês, segundo a equação 3.1). Para isto, a corrente de carga ou descarga é medida e integrada no tempo, tendo como resultado a capacidade instantânea fornecida pela bateria. A DoD é definida percentualmente pela razão da capacidade instantânea calculada (Q_{calc}) e capacidade nominal da bateria (Q_{nom}), fornecida pelo fabricante.

$$DoD(\%) = \left(\frac{Q_{calc}}{Q_{nom}} \right) \cdot 100 \quad (3.1)$$

É possível descrever DoD em função do tempo, por meio da equação 3.2.

$$DoD(t) = DoD(t_0) + \Delta DoD \quad (3.2)$$

Onde $DoD(t_0)$ é o valor inicial de DoD e ΔDoD é obtido por meio de uma corrente de carga / descarga medida (I_b) em um tempo τ , conforme a equação 3.3.

$$\Delta DoD = \frac{-\int_t^{t+\tau} I_b(t) dt}{Q_{nom}} \quad (3.3)$$

Onde I_b é positivo caso esteja sendo considerado o processo de carga e negativo, caso o sistema esteja operando em descarga.

O SoC é definido percentualmente como a razão entre capacidade disponível da bateria e a capacidade nominal. Em termos de DoD, o SoC pode ser calculado por meio da equação 3.4.

$$SoC(\%) = 100 - (DoD(t)) \quad (3.4)$$

Para o cálculo de SoH, a bateria, completamente carregada, é totalmente descarregada e a corrente de descarga é medida e integrada no tempo, tendo como resultado a capacidade máxima ($Q_{m\acute{a}x}$) da bateria. Quanto maior for a degradação da bateria, menor será a capacidade máxima em relação à capacidade nominal. Então, usualmente, a avaliação do SoH da bateria é feita a partir da equação 3.5.

$$SoH(\%) = \frac{Q_{m\acute{a}x}}{Q_{nom}} \quad (3.5)$$

Conforme mencionado anteriormente, o trabalho de Yang *et al.* (2016) utiliza RNAs *back propagation* para estimar o SoH de baterias. A rede neural utilizada possui 3 camadas, sendo uma camada de entrada, uma camada oculta e uma camada de saída. Os parâmetros de entrada são o SoC da bateria, resistência ôhmica, resistência de polarização e capacitância de polarização. Estes 3 últimos são parâmetros extraídos do modelo de circuito equivalente de primeira ordem, que é um dos mais utilizados para modelar baterias. Os parâmetros extraídos do modelo equivalente de primeira ordem sofrem alterações ao longo do tempo em que as baterias são utilizadas. Isto faz com que estes precisem ser constantemente calculados. Para a construção da rede neural, foram utilizados dados de 5 baterias para o treinamento da rede e dados de outras 5 baterias para testes e validação dos resultados.

Enquanto Ng *et al.* (2009) e Yang *et al.* (2016) calculam o SoH das baterias por meio da equação 3.5, no trabalho de Ungurean *et al.* (2020), SoH é determinado segundo a equação 3.6. A diferença entre estes métodos para o cálculo de SoH será explorada nesta dissertação no capítulo 5, a fim de determinar qual equação é melhor de ser utilizada para os fins propostos nesta dissertação.

$$SoH (\%) = \begin{cases} 100\% \text{ se } \frac{Q_{m\acute{a}x}}{Q_{nom}} > 1 \\ \left(1 - \frac{Q_{m\acute{a}x}}{SoH_0}\right) \cdot 100 \\ 0\% \text{ se } \frac{Q_{m\acute{a}x}}{Q_{nom}} < SoH_0 \end{cases} \quad (3.6)$$

Onde $Q_{m\acute{a}x}$ é a capacidade de retenção de carga atual total da bateria, Q_{nom} é a capacidade nominal da bateria e SoH_0 é o SoH escolhido para determinar que o fim da vida útil da bateria foi alcançado. SoH_0 é geralmente determinado como 0,2 ou 0,3, ou seja, quando a bateria perde 20 % ou 30 % de sua capacidade nominal, onde é definido como o final de sua vida útil.

O trabalho de Ungurean *et al.* (2020) utiliza um banco de dados da *National Aeronautics and Space Administration* (NASA) de carga / descarga de diversos tipos de baterias de íon-lítio. Os erros de estimação tiveram variação de 2,5 % a 5 %. O trabalho conclui que o modelo proposto, em comparação com outros modelos de SoH, apresenta bons resultados para o fim proposto pelo estudo. O modelo apresenta desempenho semelhante a outros modelos que utilizam rede neural recursiva, entretanto redes neurais GRU exigem menos capacidade computacional, o que torna este tipo de rede mais vantajosa neste quesito em relação a outras redes neurais recursivas ou não recursivas. Para fins de comparação, o trabalho de Yang *et al.* (2016) possui erro dos resultados estimados em relação aos resultados reais medidos em torno de 7,2 %. Portanto, a Rede Neural recursiva proposta por Ungurean *et al.* (2020) mostra-se mais exata em comparação com o modelo proposto por Yang *et al.* (2016).

3.4. Considerações sobre o capítulo

Neste capítulo foram abordados os métodos utilizados para estimar o estado de saúde (SoH) e o estado de carga (SoC) de baterias secundárias de íon-lítio. Cada método

possui vantagens e desvantagens, não havendo um consenso na literatura acerca do melhor deles a ser utilizado. Para este trabalho, foi escolhido utilizar redes neurais recorrentes para estimar o SoH de baterias de íon-lítio, por ser um método orientado a dados que não necessita de grande capacidade computacional em comparação a outros métodos baseados em dados encontrados na literatura. Para estimar o SoC, foi escolhido o método contagem de coulomb, por ser de fácil implementação e apresentar bons resultados, desde que todo o sistema de medições esteja bem calibrado. Os trabalhos empíricos apresentados neste capítulo forneceram valiosas contribuições para a construção do modelo proposto nesta dissertação, que será descrito em detalhes no próximo capítulo.

Foi escolhido o uso de RNA nesta dissertação pela boa capacidade de estimativa de variáveis não lineares e pela possibilidade de construção de uma RNA eficiente a partir de parâmetros fáceis de serem medidos. Desta maneira, é possível utilizar o modelo proposto nesta dissertação para uso em baterias de outras tecnologias, desde que sejam colhidos dados suficientes para o treinamento e validação da RNA.

A RNA a ser utilizada nesta dissertação será GRU, visto que este tipo de rede possui bons resultados (vide o trabalho de Ungurean *et al.* (2020)) e capacidade computacional reduzida em comparação a outros tipos de RNA. Além disso, redes neurais recorrentes consideram a evolução do objeto de estudo ao longo do tempo. Visto que o modelo desta dissertação propõe a estimação do SoH das baterias ao longo de sua vida útil, a Rede Neural GRU se mostra adequada aos objetivos propostos.

Neste capítulo foram observadas duas expressões matemáticas para o cálculo de SoH (3.5 e 3.6). As duas expressões serão utilizadas para avaliar o SoH das baterias nesta dissertação. Os resultados gerados por ambas serão discutidos, a fim de determinar qual é a mais adequada para o uso em aplicações envolvendo modelos de *battery swap*.

4

Estimativa de curva de estado de saúde e estado de carga: conceitos e modelo proposto

Neste capítulo, será apresentado o modelo proposto nesta dissertação para estimação da curva de estado de vidas de baterias. Na seção 4.1, é apresentado o sistema de testes que foi construído para realizar a medição, a coleta e o tratamento dos dados que mais tarde pudessem ser utilizados no treinamento e validação de uma rede neural proposta. Na seção 4.2, apresenta-se a elaboração do modelo proposto para estimar o estado de vida (SoH) de baterias de íon-lítio por meio do estado de carga (SoC) destas baterias. Na seção 4.3 são realizadas as considerações sobre o capítulo.

4.1.

Coleta e tratamento dos dados de baterias de íon-lítio

A presente seção descreve o desenvolvimento do sistema que foi utilizado para testar a influência dos parâmetros que caracterizam os ciclos de carga e descarga na vida útil de baterias de íon-lítio. O sistema que foi construído serve para guardar todos os dados medidos para serem utilizados no treinamento e validação do modelo de estimação de SoH de baterias de íon-lítio proposto nesta dissertação. Esta fase do trabalho é importante, pois este sistema será utilizado nesta dissertação para realizar ensaios destrutivos de baterias de íon-lítio.

Desta forma, será detalhado o desenvolvimento do sistema que controla os ciclos de carga, circuito aberto e descarga das baterias, sendo descrita a modularização adotada para este sistema, que foi idealizado para operar com 16 baterias íon-lítio para *smartphones*. São apresentadas as premissas utilizadas para a escolha dos valores dos parâmetros de carga e descarga adotados.

O sistema construído tem a possibilidade de medir e testar o efeito sobre o tempo de vida útil das 16 baterias de íon-lítio examinadas simultaneamente, além de alguns dos parâmetros que caracterizam as etapas de carga e descarga desse tipo de bateria. Os parâmetros considerados para o desenvolvimento do sistema foram:

- I_c : corrente característica da fase de carga com corrente constante;

- V_C : tensão limite que caracteriza o fim da fase de carga a corrente constante;
- V_A : tensão em aberto da bateria medida entre a passagem da fase de carga para descarga;
- I_{Dmin} : corrente que estabelece o fim da fase com tensão constante e início da fase de descarga;
- R_D : resistência utilizada para descarregar a bateria;
- I_{Dmax} : corrente característica do início da fase de descarga (V_C/R_D);
- V_{min} : tensão limite que estabelece o fim da fase de descarga;

Além desses parâmetros, o sistema calcula (por meio de software elaborado no projeto) ao final de cada ciclo de carga / descarga, a capacidade de armazenamento de carga da bateria (Q), segundo a equação 4.1:

$$Q = \int_{t_i}^{t_f} I_D(t).dt \quad (4.1)$$

Onde: $I_D(t)$ é a corrente de descarga ao longo do tempo, t_i é o tempo inicial de descarga e t_f é o tempo final de descarga.

Por meio da evolução da capacidade da bateria ao longo do tempo, é possível determinar o tempo de vida útil de cada bateria. Nas próximas subseções, serão apresentados, de forma detalhada, os critérios para a modularização do sistema, assim como o funcionamento do *hardware* e *software* empregados na construção do sistema ora mencionado. Além disso, a metodologia de medição e armazenamento dos dados realizadas também é descrita.

4.1.1. Modularização do sistema de medição

O sistema possui uma configuração modular, em que as 16 baterias de teste são agrupadas em 4 grupos de 4 baterias cada. Os parâmetros de carga e descarga podem ser controlados por *hardware* e *software*. Os parâmetros de cada grupo serão variações de corrente e tensão das baterias.

Para todos os grupos, a fase de descarga tem início quando a corrente de carga é igual a 10 % do valor da corrente durante a fase de carregamento a corrente constante. Para todas as baterias, $R_D = 1,64 \Omega$.

Os parâmetros medidos pelo sistema são tensão (carga, circuito aberto e descarga) e a temperatura das baterias ao longo do tempo. O dado de temperatura é importante para a segurança do sistema, visto que baterias com temperatura próxima aos 50 °C pode causar danos nas baterias. Além disso, o sistema calcula a capacidade de carga das baterias a partir da medição de tensão (o sistema calcula a corrente e integra o resultado no tempo para o cálculo de capacidade de carga).

Para coletar todos os dados citados, foram utilizadas duas placas de aquisição de dados, uma contendo 48 canais (utilizada para as medições de 3 grupos de 4 baterias cada) e outra, 16 canais (usada para as medições de 1 grupo com 4 baterias). Nas próximas subseções serão apresentados a construção e funcionamento do hardware e software do sistema.

4.1.2.

Hardware do sistema de medição

Inicialmente, foi projetado um sistema simplificado para uma única bateria. Dessa forma, foi possível analisar melhor o funcionamento do sistema proposto. O diagrama em blocos da figura 4.1 apresenta os componentes desse sistema. Três blocos se destacam no diagrama: o circuito de carga (CC), o sistema de aquisição de dados e acionamento (SADA) e o microcomputador que rodará o *software* de supervisão e controle (PC).

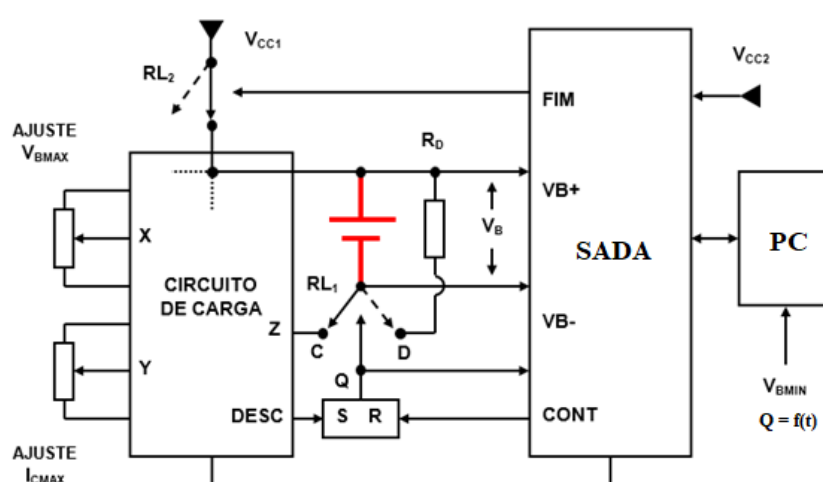


Figura 4. 1 - Diagrama de blocos do sistema de carga / descarga

Fonte: Elaboração própria

Embora a figura 4.1 indique apenas os ajustes de V_c e I_c , o circuito de carga também permite que I_{Dmin} seja ajustado internamente. A variação do valor de I_c é feita

externamente ao circuito de carga por meio da mudança do resistor R_D , enquanto V_{min} tem seu valor estabelecido por *software*.

A tensão VB entre os terminais da bateria é permanentemente supervisionada pelo SADA, tanto durante a fase de carga (terminal negativo conectado a C), quanto na fase de descarga (terminal negativo conectado a D). O relé R_{L1} , que faz a transferência do contato de carga C para o contato de descarga D, é comandado por um circuito *latch* que é acionado pelo CC ao fim da fase de saturação (isto é, quando $I_c = I_{cmin}$) e resetado pela saída do SADA ao fim da fase de descarga (isto é, quando $V = V_{min}$). A corrente de descarga da bateria é capaz de circular somente através de R_D , uma vez que as entradas $V+$ e $V-$ do SADA são caracterizadas por impedâncias muito elevadas.

O SADA possui uma segunda saída digital, FIM, que comanda o fim do teste por meio do acionamento de R_{L2} , e uma entrada digital CONT que é conectada ao sinal de saída do *latch* e utilizada pelo software para contabilizar os ciclos de carga / descarga. O fim do teste é determinado quando a carga Q da bateria no último ciclo for igual a 70 % da carga nominal.

É importante ressaltar que o modelo de redes neurais proposto neste trabalho considera o fim da vida útil de uma bateria quando ela alcança 80 % da carga nominal, entretanto o sistema de testes finaliza as medições em 70 % para coletar dados do funcionamento das baterias mesmo quando ela está considerada “inapta” para operação.

O circuito de carga é um circuito linear realimentado, capaz de implementar as duas fases de carga (corrente constante e tensão constante). Seu projeto foi baseado no circuito de um carregador de bateria conforme ilustrado na figura 2.3, o qual foi alterado de forma a atender aos requisitos do sistema de teste (capacidade de realizar as duas etapas de carga necessárias para baterias de íon-lítio, capacidade de corrente de carga ampliado, inclusão de recurso de controle da fase de descarga, utilização de referência de tensão de alta estabilidade térmica etc.). Para tornar o sistema de carga mais robusto e confiável foi introduzido um circuito que permite a supervisão e controle da temperatura da bateria, cujos dados são guardados via *software*.

Além disso, foi introduzido um circuito de temporização para controle da leitura da tensão da bateria em circuito aberto. Deste modo, é possível medir a tensão, sem a influência tanto do circuito de carga, quanto da indutância interna da bateria ao final de cada ciclo de carga completa.

Por fim, foram acrescentados componentes para processar os sinais digitais enviados e recebidos pelo *software*. O circuito proposto foi montado em *protoboard* para testes e está ilustrado na figura 4.2.




Figura 4. 2 - Sistema de medição proposto montado em *protoboard*

Fonte: Elaboração própria

Os testes realizados em *protoboard* demonstraram oscilações de tensão no circuito, gerando instabilidade e diminuindo a confiabilidade das medições. Este problema levou a uma análise profunda de cada componente para identificar a causa das oscilações. Após um longo período de testes foram substituídos os Amp-Ops por componentes alternativos mais modernos e eficientes, capazes de operar até os limites de alimentação. O transistor BJT foi substituído por um MOSFET canal P, visando aumento de rendimento e a leitura não-diferencial da tensão da bateria. Também foram introduzidas referências de tensão mais estáveis (termicamente e ao longo do tempo) para controle dos limites da tensão da bateria e da corrente de carga.

A partir do sistema montado em *protoboard*, foi possível montar um circuito protótipo monocal em PCI (figura 4.3). Este protótipo visava, principalmente, verificar se um layout desenhado especificamente para esse fim poderia contornar as oscilações observadas (e não totalmente eliminadas) no *protoboard*.




Figura 4. 3 - Protótipo monocanal em PCI

Fonte: Elaboração própria

Apesar do circuito, nesta nova configuração, ter se apresentado mais estável ao longo das 3 etapas de seu funcionamento (carga, leitura em aberto e descarga), chaveamentos espúrios foram observados nas passagens entre essas etapas. Foi constatado que esses chaveamentos eram provocados por instabilidades na operação dos *latches* (multivibradores biestáveis) utilizados no circuito, que foram implementados por portas NOR realimentadas e eram comandados por transições.

A lógica de acionamento das etapas precisou então ser alterada, substituindo-se os *latches* por chaves transistorizadas comandadas por níveis. Essas modificações na lógica de acionamento das etapas foram implementadas na própria placa e podem ser percebidas comparando-se a figura 4.3 com a figura 4.4, que retrata o circuito protótipo ao final dos testes.



Figura 4. 4 - Protótipo montado em PCI após ajustes

Fonte: Elaboração própria

O *chip* TTL que implementava os *latches* foi substituído por uma pequena placa contendo 2 transistores. Além desta, foram realizadas outras modificações feitas na placa em consequência de falhas observadas no circuito ou de simplificações decididas ao longo dos testes (por exemplo, a eliminação de um dos 3 relés originais).

Ao final dos testes realizados com o protótipo monocanal, chegou-se a uma configuração estável que operava em conjunto com a Unidade de Aquisição e Controle de acordo com as especificações de projeto. Partiu-se, então, para a confecção de um *layout* definitivo para cada uma das 4 placas (com 4 canais cada) que compõem o sistema de teste de vida útil de baterias de íon-lítio.

O esquemático final dos circuitos de carga / descarga de 4 baterias é apresentado na figura 4.5. Ao todo, foram confeccionadas 4 placas, sendo cada uma de um grupo de parâmetros ilustrado na tabela 4.1.

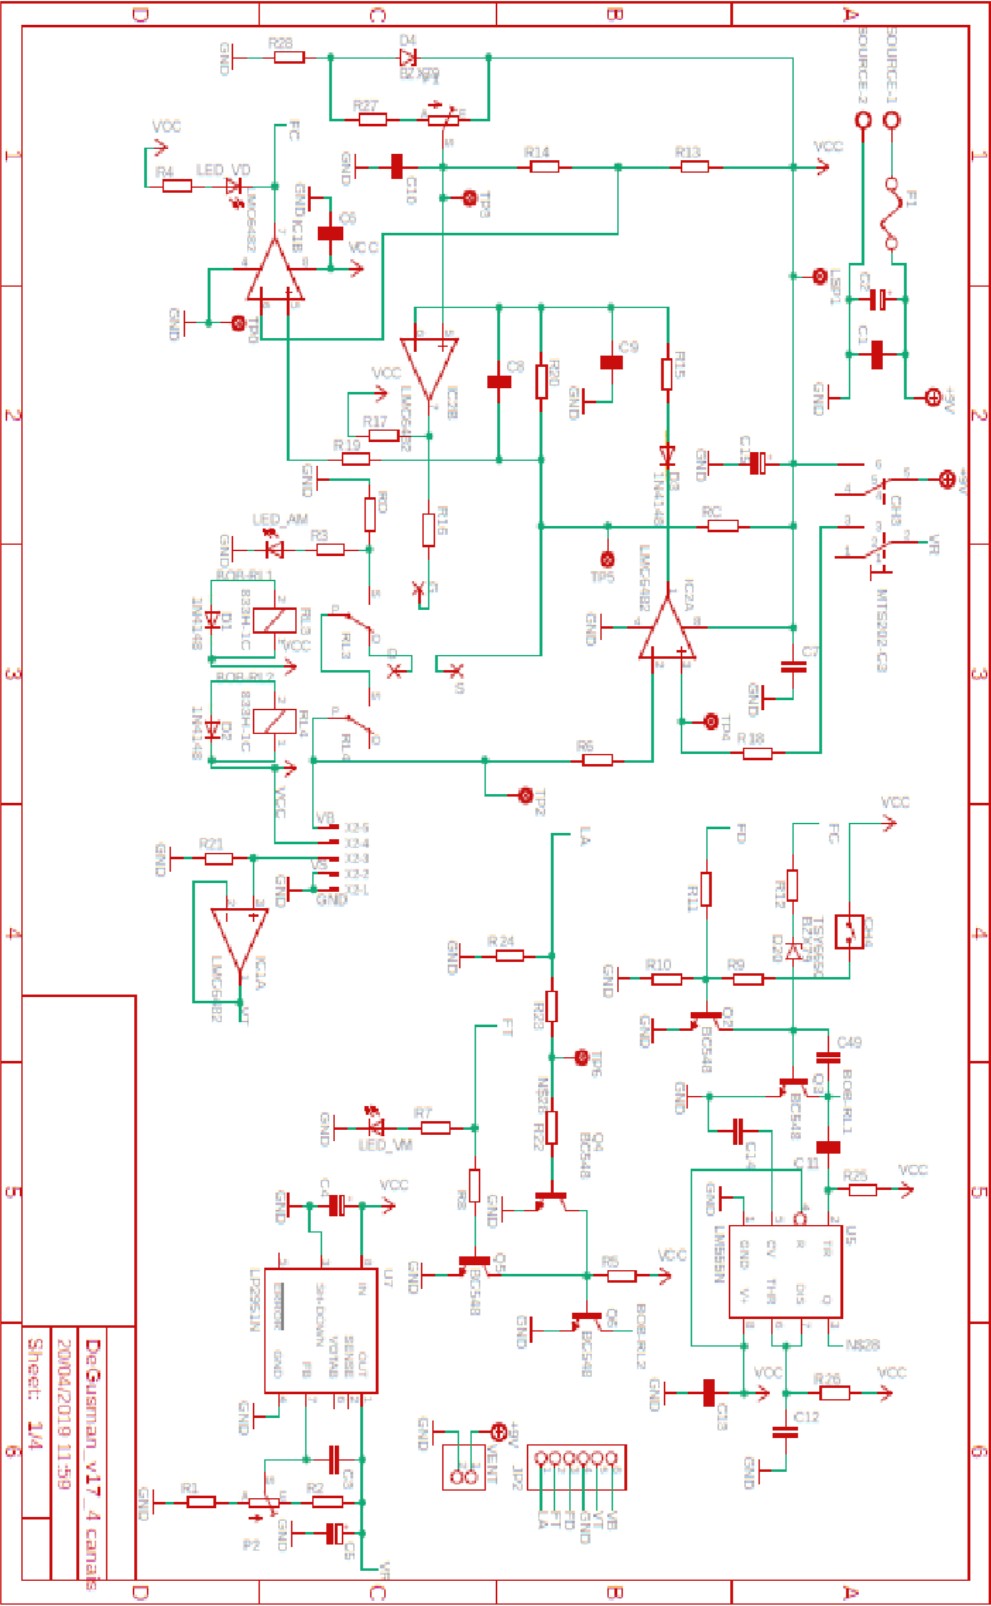


Figura 4. 5 – Esquemático final dos circuitos de carga/descarga

Fonte: Elaboração própria

A figura 4.6 ilustra as 4 placas já montadas e prontas para testes. Foram utilizadas baterias já desgastadas para efetuar o teste das placas. Assim, as baterias novas que serviram para as medições deste projeto puderam ser preservadas contra possíveis danos, além de evitar a degradação e redução em sua vida útil.



Figura 4. 6 - Versão final do sistema de medições proposto

Fonte: Elaboração própria

Foi observado durante os testes com as baterias usadas, a ausência intermitente de recebimento (no *software*) do sinal de fim de carga (a partir do *hardware*). Essa ocorrência desalinhava o controle digital, fazendo com que o programa não percebesse que a bateria já teria passado para a descarga. Visto que por projeto a atribuição de indicar a tensão mínima de descarga (para iniciar novamente uma carga) era do *software*, o controle nunca enviava este comando, provocando um descarregamento excessivo. Para sanar este problema, foram substituídos os capacitores de comando do monoestável de temporização do pulso de leitura em aberto (responsáveis por indicar o fim de carga) por unidades de maior valor, dando mais tempo para o *software* receber o sinal.

Um outro problema detectado se relaciona aos múltiplos canais de medição simultânea. Foi observado que o fim de descarga de uma bateria e consequente início de carregamento, poderia influenciar outras baterias (em elevado estágio de carregamento, mas ainda não totalmente carregadas) a iniciarem seu processo de descarga. Em outras palavras, quando uma bateria passava de descarga para a carga, outras baterias da mesma placa que estavam em carga passavam para descarga. Isto acontecia devido ao aumento súbito da corrente circulando no sistema, provocando uma oscilação na corrente de

referência adotada para comparação com a corrente injetada na bateria, provocando uma situação irreal de carregamento completo. Para sanar este problema, os capacitores de desacoplamento de fonte foram aumentados quanto a sua capacitância e substituídos por unidades de baixa resistência em série equivalente.

Frente a uma interrupção de energia no laboratório (visto que as medições ocorrem de forma ininterrupta por meses), fatalmente se daria o desligamento tanto dos computadores (e dessa forma todo o sistema de controle via *software*), assim como as fontes de alimentação do *hardware* (alimentação das baterias). Esta ocorrência gera a interrupção das medições, sendo um inconveniente. Entretanto, observou-se que no caso de a energia ser reativada sem a presença física de algum pesquisador no laboratório, a fonte seria reiniciada automaticamente sem que o mesmo ocorresse com os computadores. Esse cenário proporcionaria um ensaio de carga / descarga sem controle via *software*. Como o sistema foi originalmente pensado para iniciar os testes em descarga, não haveria nunca uma sobrecarga (com riscos de incêndio), mas sim risco de drenagem excessiva da carga e consequente destruição da bateria.

Assim, para aumentar a segurança do sistema de medição, foi implementado um circuito de proteção a partir de um circuito monoestável alimentado (via *software*) por uma onda quadrada de 1 kHz de frequência. Deste modo, caso o *software* pare de atuar, as fontes são colocadas em modo de espera, evitando que as baterias permaneçam indefinidamente em descarga. É importante frisar que a solução adotada protege o sistema de medição quando há ocorrência de uma interrupção do controle digital, nos casos de queda de energia e de algum travamento do *software*.

4.1.3.

Software do sistema de medição

O *software* foi idealizado para controlar o sistema de carga / descarga por meio da Unidade de Aquisição e Controle (UAC). Foram definidas as linhas de entrada e saída da UAC, conforme ilustrado na figura 4.7.

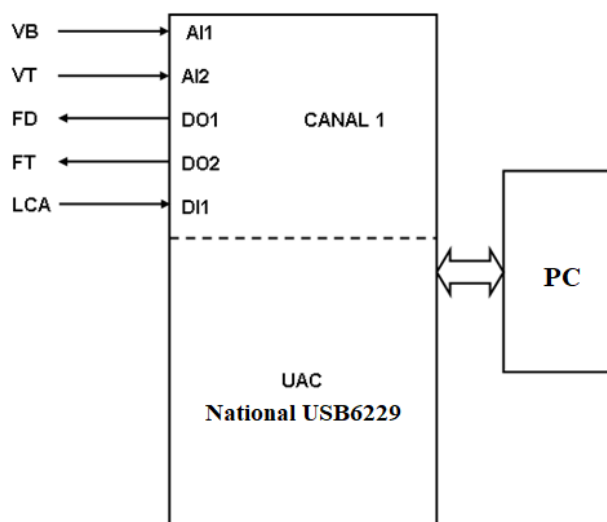


Figura 4. 7 - Linhas de interligação com a Unidade de Aquisição e Controle (UAC)

Fonte: Elaboração própria

Onde: *VB*: Linha analógica de entrada 1 - tensão da bateria;

VT: Linha analógica de entrada 2 - temperatura da bateria;

FD: Linha digital de saída 1 - fim da etapa de descarga;

FT: Linha digital de saída 2 - fim do teste;

LCA: Linha digital de entrada 1 - comando para leitura da tensão em aberto da bateria.

O *software* foi desenvolvido em ambiente *LabView* (linguagem G) e tem a função de armazenar os dados do ensaio destrutivo e controlar o sistema de carga / descarga das baterias por meio da Unidade de Aquisição e Controle (UAC). A UAC recebe do circuito a tensão (medida em circuito aberto e fechado) e a temperatura da bateria. O software armazena estes dados no formato .csv. Foi adotado este formato por não haver limitação no número de linhas que o arquivo pode suportar, além de ser capaz de armazenar uma grande quantidade de dados utilizando pouco espaço de armazenamento. O ensaio ocorre em 3 etapas: carga, circuito aberto e descarga.

Por padrão, o programa é iniciado no modo de carga, passando para o modo de circuito aberto quando é identificado o fim do período de carregamento com tensão constante. Durante os testes iniciais, foi identificado que a tensão varia abruptamente na passagem entre os estados de carregamento e circuito aberto. O mesmo ocorre quando o sistema muda para o modo de descarga. Então, para que não seja perdida nenhuma informação, foi verificada a necessidade de armazenar os dados a cada 1 s. Este valor de

período foi obtido a partir de observações empíricas de testes variando o valor do período de 0,1 s até 10 s.

O programa é responsável pelo controle sobre a descarga, iniciando um novo ciclo de carregamento, medição em circuito aberto e descarga. O *software* também indica o final do ensaio destrutivo, quando identificado que a carga total da bateria é inferior a 70 % de sua carga total inicial. Esse controle ocorre por meio de sinais digitais enviados ao fim de cada processo. Assim, o *software* é responsável por armazenar os dados e controlar a carga e descarga das baterias de forma automática.

Conforme mencionado anteriormente, os dados de tensão (em circuito aberto e fechado) e temperatura são armazenados em formato de tabela. Além destes dados, também são armazenados os dados de capacidade total ao fim de cada ciclo. Este dado é calculado pelo *software* por meio da integral da corrente ao longo do tempo. Estas informações foram utilizadas para analisar a vida útil das baterias ao longo do tempo e, também, foram importantes para construir o modelo proposto neste trabalho.

O *software* também é responsável pela garantia da segurança do circuito. Isto é realizado por meio da coleta dos dados de temperatura das baterias. Caso este parâmetro seja maior que 50 °C, o circuito é desligado e é informada na tela do programa que o circuito foi interrompido devido à alta temperatura. Além disso, para garantir a integridade das baterias, foi estabelecida uma tensão de descarga limite de 2,6 V para o caso de o *hardware* falhe em algum comando e a bateria descarregue ininterruptamente. Dessa forma, ao se atingir esta tensão o sistema entra em alarme e desconecta a bateria, deixando-a em circuito aberto.

A figura 4.8 ilustra a tela do *software* programado para a medição de 1 bateria, utilizado para os testes do protótipo do circuito de carga / descarga. Depois de sanados todos os problemas encontrados no protótipo do circuito e no programa, este pode ser estendido para trabalhar com as 16 baterias.

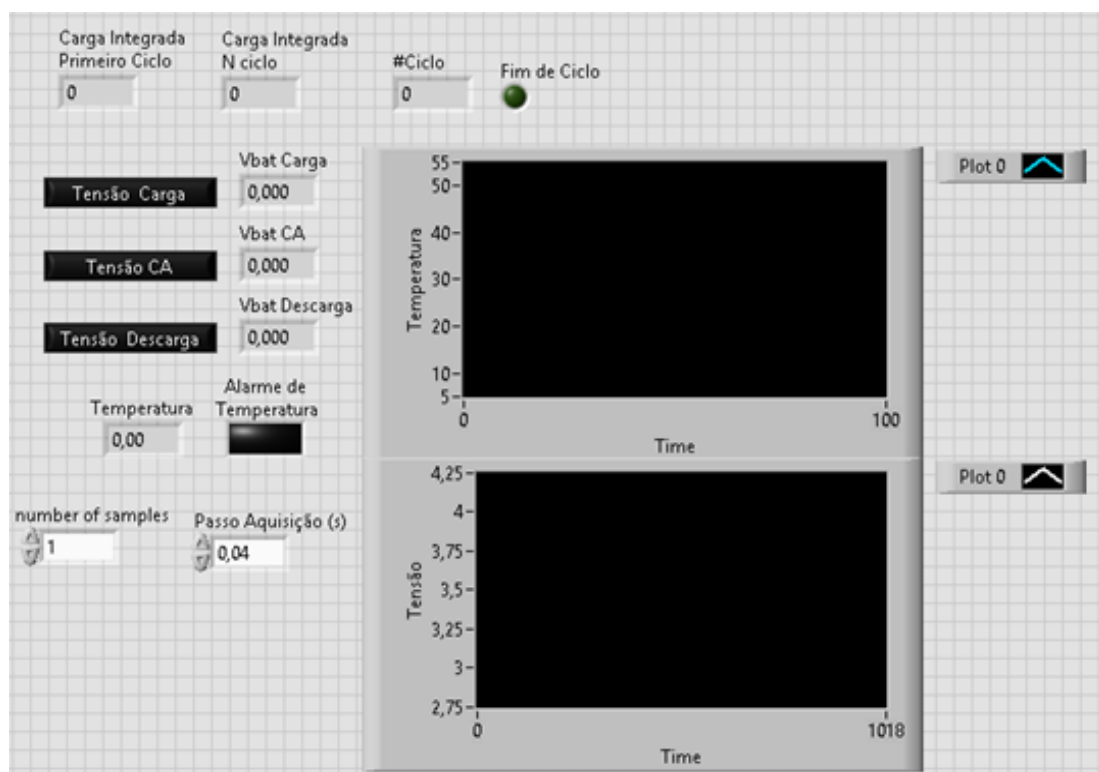


Figura 4. 8 - Tela do programa monocanal

Fonte: Elaboração própria

O projeto inicial previa que um único *software* seria estendido para controlar as medições das 16 baterias, porém isto exigiria alta capacidade computacional, o que poderia ocasionar problemas a longo prazo. Por esta razão, foi adquirida uma segunda Unidade de Aquisição e Controle (UAC), permitindo que as 16 baterias pudessem ser divididas entre os dois sistemas de aquisição. Assim, foram elaborados 2 programas para controle e registro das medições. Um ficou responsável por operar as medições de 4 baterias (grupo 4) e o outro pela operação das 12 baterias restantes (grupos 1, 2 e 3).

As telas dos programas estão ilustradas nas figuras 4.9 e 4.10. Em cada *software*, a tela possui 3 abas, cada qual com informações distintas. A primeira aba mostra, para cada bateria, o número de ciclos realizados, a primeira e última capacidades medidas, a tensão em tempo real nas etapas de carregamento, circuito aberto e descarga, a temperatura e um alarme que é acionado caso haja algum problema no circuito. Além disso, é possível especificar na tela a tensão mínima de descarga para cada bateria. A segunda aba mostra os gráficos em tempo real das tensões em cada bateria, enquanto a terceira aba mostra os gráficos de temperatura.



Figura 4. 9 - Tela do programa de medições para 4 baterias

Fonte: Elaboração própria



Figura 4. 10 - Tela do programa de medições para 12 baterias

Fonte: Elaboração própria

Os dados medidos pelo sistema de testes apresentados nesta seção serão utilizados para o treinamento e validação do modelo proposto, que será apresentado na próxima seção.

4.2

Modelo proposto para estimar SoH de baterias de íon-lítio

Uma rede neural artificial (RNA) é um algoritmo computacional que tem o seu processamento de informação inspirado no cérebro humano. Desta maneira, uma rede neural é capaz de aprender, generalizar e tomar decisões baseadas em seu próprio aprendizado (Fleck et al., 2016). Assim como o cérebro humano, uma RNA necessita de treinamento para aprender. Uma das formas de se treinar uma RNA é através do aprendizado supervisionado. Para tanto, faz-se necessário fornecer informações (dados de entrada) para que a rede as processe gerando uma resposta, ou saída. O aprendizado ocorre por meio da comparação da saída gerada pela RNA e uma informação de referência, conhecida *a priori*. Ao se analisar o erro entre o que foi gerado pela RNA e o valor de referência, a RNA ajusta seu processamento interno em vista a minimizar o erro encontrado (Fleck et al., 2016). Esse processo é conhecido como ajuste dos pesos (pesos sinápticos) associado a cada um dos neurônios da RNA. Deste modo, pode se afirmar que ao se repetir o processo de apresentação de dados à rede, comparação da sua saída com o valor conhecido e finalmente ajuste dos pesos se está realizando o treinamento da RNA e aferindo a ela a capacidade de armazenamento de conhecimento em toda a sua rede de conexão neuronal (Fleck et al., 2016).

É importante observar que toda RNA ao ser treinada tende a minimizar o erro relacionado aos dados que são utilizados para o seu treinamento. Entretanto, deve-se ter o cuidado de não treinar em excesso a RNA (super-treinamento) de forma que ela só consiga representar estes dados, o que representaria uma perda de poder de generalização (Haykin, 2001).

A estrutura básica de uma rede neural consiste em uma formação de três camadas, como mostrado na figura 4.11. Para estimativa de SoH, geralmente a camada de entrada contém o vetor de valores instantâneos de corrente, tensão e temperatura. A camada de saída é o valor do SoH. No modelo proposto, os parâmetros de entrada serão o SoC (estimado por meio do método contagem de coulomb), a tensão máxima da bateria, o tempo de carregamento e a corrente de carga na fase de corrente constante.

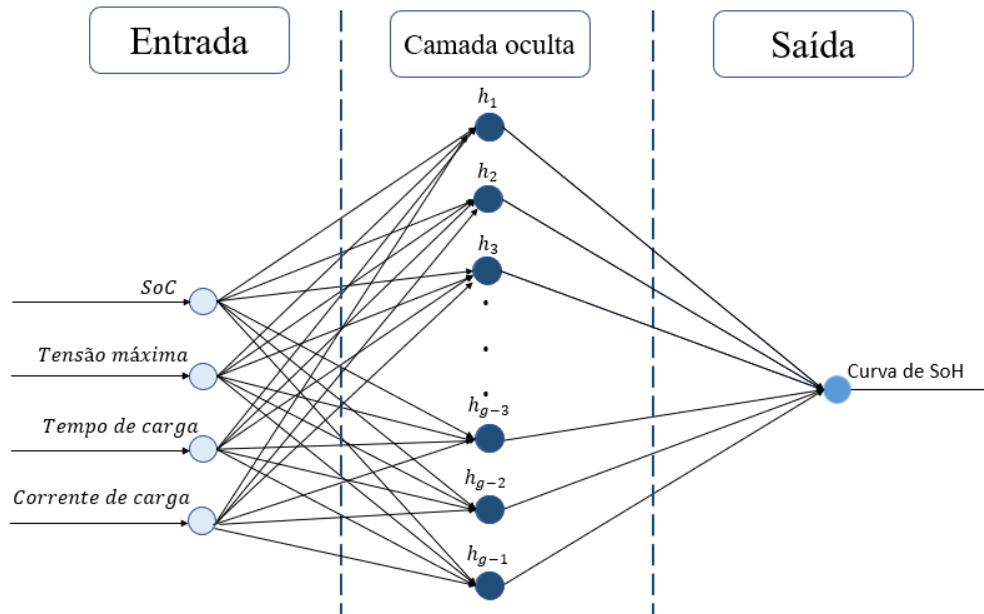


Figura 4. 11 - Estrutura básica de uma rede neural

Fonte: Elaboração própria

De acordo com Braga *et al.* (2007), um modelo básico de RNA possui diversos componentes, dentre eles:

- Conjunto de sinapses: conexões entre os neurônios da RNA. Cada uma delas possui um peso sináptico;
- Função de ativação: responsável por restringir a amplitude do valor de saída de um neurônio;
- *Bias*: valor aplicado externamente a cada neurônio e tem o efeito de aumentar ou diminuir o valor de entrada da função de ativação.

Ao treinar a rede neural com os pares de entrada e saída, ela é capaz de formar um mapa não linear capaz de modelar com exatidão a relação de entrada e saída sem nenhum conhecimento prévio da estrutura interna da bateria (Hannan *et al.*, 2017). A relação entre a camada de entrada e a camada de saída é desenvolvida usando um número adequado de camadas ocultas, neurônios ocultos e função de ativação. A partir dos dados de entrada recebidos por n neurônios (y_i), o neurônio k (h_k) calcula a sua saída por meio da equação 4.2.

$$h_k = f \left\{ \sum_{i=1}^n (W_{ki} h_i + \theta_k) \right\} \quad (4.2)$$

Onde h_i é a saída calculada pelo neurônio i , W_{ki} representa o peso sináptico entre os neurônios i e k , $\theta_{j,k}$ é o valor de *bias* e f_i representa a função de ativação. Caso o neurônio esteja ligado às entradas, o termo h_i é substituído pelas entradas fornecidas.

A estimação dos pesos sinápticos e *bias* se dá por meio do treinamento da rede, isto é, por meio de um processo iterativo onde os parâmetros iniciais são utilizados até a convergência do processo (Fleck *et al.*, 2016).

Várias configurações de rede neural são relatadas na literatura, incluindo rede neural *backpropagation* (BPNN), rede neural de função de base radial (RBFNN), rede neural recorrente (RNN), rede neural *wavelet* (WNN) etc. No entanto, o conceito fundamental de trabalho dessas variações permanece semelhante.

Optou-se por utilizar neste trabalho uma rede neural artificial GRU (*gated recurrent unit*). Esta é um tipo de rede neural recorrente, que tem como característica processar dados de forma a considerar sua evolução no tempo. O SoH das baterias sofre alterações ao longo do tempo, de modo que quanto maior o número de ciclos realizado pela bateria, menor será o seu SoH esperado. Deste modo, a rede neural recorrente é adequada para estimar o SoH de baterias.

As redes neurais recorrentes têm como característica a rapidez de aprendizado, sendo necessárias poucas iterações de treinamento (geralmente menos de 1 000), além de precisarem de menos parâmetros de entrada e fornecerem melhor generalização (Fleck *et al.*, 2016).

As informações de iterações passadas são armazenadas nas camadas ocultas das redes neurais recorrentes. A camada oculta das redes neurais clássicas recebe sinais apenas da camada de entrada, enquanto a camada oculta da rede neural recorrente recebe sinais tanto da camada de entrada quanto da camada oculta na iteração de tempo anterior, conforme ilustrado na figura 4.12.

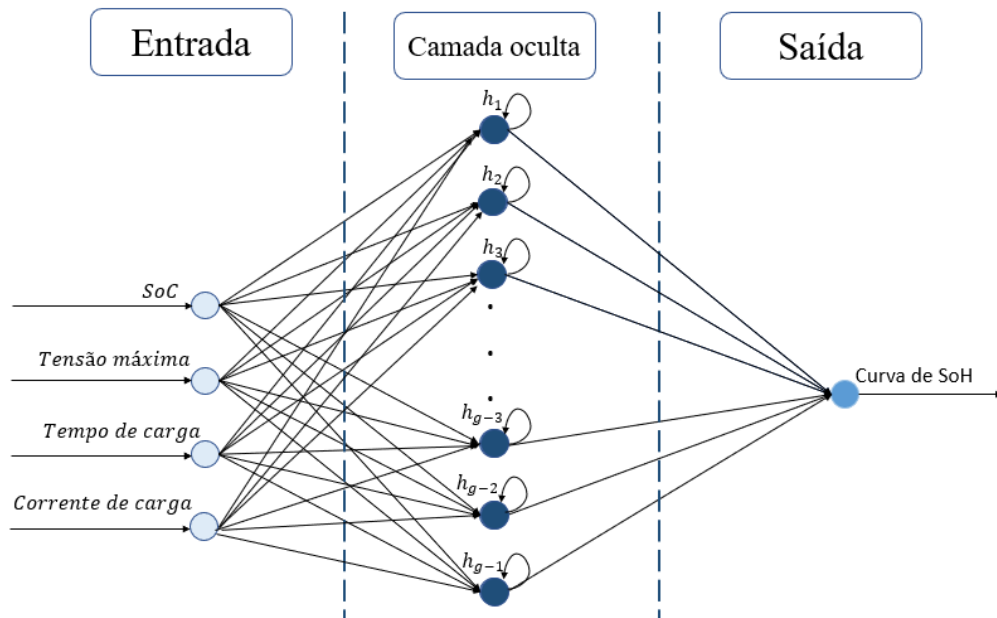


Figura 4. 12 – Estrutura básica de uma rede neural GRU

Fonte: Adaptado de Ungurean *et al.* (2017)

A camada oculta funciona como uma memória, onde a cada período no tempo, a rede neural armazena informações observadas naquele período de tempo e também recupera informações de estados ocultos anteriores. Matematicamente, o processo de levar a memória adiante pode ser descrita pela equação 4.3.

$$h_t = f(Wx_t + Uh_{t-1}) \quad (4.3)$$

O estado oculto (também conhecido como *unit*) na etapa de tempo atual t é h_t , que é uma função dos dados de entrada do mesmo instante de tempo (x_t), multiplicada por uma matriz de pesos W , adicionada ao estado oculto do tempo anterior (h_{t-1}), multiplicado pela matriz de transição (U). As matrizes de pesos W e U são filtros que determinam quanta importância deve ser dada tanto à entrada atual quanto ao estado oculto passado. Assim como nas redes neurais clássicas, também há uma função de ativação (f) para restringir a amplitude de saída do neurônio (Fleck *et al.*, 2016).

Redes neurais recorrentes, de forma geral, não funcionam bem com dados ruidosos, porém a rede neural GRU é construída para identificar oscilações nos dados e não utilizar dados que possam ser não confiáveis, conseguindo desta forma, lidar bem com ruídos (Ungurean *et al.*, 2020). Os dados utilizados para treinamento do modelo proposto possuem ruídos, tornando este tipo de rede neural uma boa opção para ser utilizado no modelo proposto.

A rede neural GRU tem a vantagem de captar estados de saúde passados da bateria, sendo uma informação adicional para a melhoria do desempenho da rede.

Todas as baterias têm valores de capacidade nominal expressos pelo fabricante. No entanto, dependendo do modo de uso, a bateria pode não reter toda a carga prometida, não entregando assim a capacidade nominal da bateria. Durante os ensaios destrutivos, baterias idênticas são testadas em diferentes modos de uso, apresentando diferentes capacidades, mesmo tendo as mesmas especificações. Então, para melhor funcionamento da rede neural, um dos parâmetros da bateria a ser considerado será o estado de carga (SoC). Além disso, utilizar SoC como parâmetro faz com que não seja necessário descarregar a bateria completamente para estimar seu SoH, já que o algoritmo ajusta automaticamente a capacidade nominal da bateria de acordo com seu SoC atual.

Conforme descrito no capítulo 3 desta dissertação, existem muitos métodos para estimar SoC, tendo diferentes níveis de complexidade. O objetivo final do modelo proposto neste trabalho é a estimação de SoH ao longo de toda a vida útil da bateria, sendo SoC um dos parâmetros de entrada da rede. Pelo fato de SoC não ser o objetivo final do modelo proposto, o método escolhido para o cálculo de SoC foi o de contagem de coulomb, por ser de fácil implementação, garantir bons resultados e ter a possibilidade de ser estimado de forma *online*.

O sistema de testes montado para esta dissertação é capaz de realizar o cálculo de SoC por meio deste método de forma automática. O método de contagem de coulomb é o método mais utilizado na estimativa de SoC (Lashway *et al.*, 2016). Neste método, SoC é estimado medindo a corrente de descarga de uma bateria e integrando-a ao longo do tempo (How *et al.*, 2019). O SoC é calculado pela equação 4.4.

$$SOC(t) = SOC_0(t_0) - \frac{1}{Q_n} \int_{t_0}^t I(t) dt \quad (4.4)$$

Onde $SOC(t_0)$ é o estado inicial da carga, $I(t)$ é a corrente de descarga instantânea da bateria e Q_n é a capacidade máxima que a bateria consegue reter no presente ciclo. Para realizar a integração, foi feito o somatório da corrente multiplicada pelo período de aquisição dos dados (1 s).

A vantagem deste método é sua simplicidade e estabilidade. Também é bastante exato, desde que o SoC inicial da bateria seja conhecido e os sensores de corrente estejam calibrados com boa exatidão (How *et al.*, 2019). A capacidade máxima disponível da

bateria deve ser recalibrada adequadamente sob várias condições de operação e níveis de degradação da bateria (How *et al.*, 2019).

Erros na estimativa do SoC podem ser inevitáveis. Um pequeno erro na medição pode ser significativo devido ao efeito cumulativo como resultado da operação de integração. Assim, o valor inicial $SoC(t_0)$ e o sensor de corrente também precisam ser exatos para a operação eficiente do algoritmo (How *et al.*, 2019). Devido a essas deficiências, o método é comumente utilizado em combinação com outros métodos, sejam baseados em modelo ou baseados em dados, para aumentar a confiabilidade.

Neste trabalho, o sistema responsável pelos ensaios destrutivos calcula de forma automática a capacidade da bateria, realizando a integração da corrente de descarga ao longo do tempo. Por meio desta informação, o SoC pode ser calculado.

O parâmetro Q_n da equação 4.4 será definido neste trabalho como sendo a capacidade inicial da bateria, ou seja, a capacidade de retenção de carga no início de sua vida útil de acordo com seu modo de operação. Q_n é caracterizado como a capacidade nominal da bateria, mas sem necessariamente ter o mesmo valor indicado pelo fabricante, visto que o modo de uso da bateria altera sua capacidade de retenção de carga. De modo geral, considera-se Q_n para o cálculo de SoC como sendo a capacidade máxima disponível da bateria no presente ciclo de medições, o que difere da definição atribuída a esta variável nesta dissertação.

A consideração feita para estabelecimento do Q_n neste trabalho não busca fornecer uma indicação realista da quantidade de carga disponível em um ciclo, mas sim avaliar a saúde da bateria ao longo dos ciclos. Assim, a definição de Q_n adotada nesta dissertação diminui a complexidade do modelo proposto, visto que diminui substancialmente a quantidade de dados e cálculos matemáticos, e fornece resultados de igual qualidade. Portanto, o objetivo de utilizar SoC como parâmetro é uma maneira de normalizar o valor da capacidade, melhorando o desempenho da rede neural.

Além do SoC, os outros parâmetros da bateria necessários para a construção da rede são a tensão máxima, corrente de carga e tempo de carregamento. Vale ressaltar que o parâmetro tempo de carregamento não é encontrado na literatura para estimar SoH, sendo um parâmetro inovador do modelo proposto desta dissertação. Todos estes dados são medidos por meio do sistema de testes utilizado nos ensaios destrutivos proposto neste trabalho.

Por se tratar de uma rede neural recorrente, isto é, com unidades de memória, dados de diferentes baterias não devem ser misturados, pois isso poderia influenciar

negativamente o resultado da rede. Ou seja, os dados de cada bateria devem ser armazenados independentemente, separados pelo grupo a qual elas pertencem (de acordo com a tabela 4.1).

A definição clássica de SoH é descrita pela equação 4.5. Nesta dissertação, busca-se estimar SoH por meio de SoC, então a equação 4.5 será adaptada para este fim. Logo, a definição de SoH utilizada neste trabalho está expressa na equação 4.6.

$$SoH(\%) = \frac{Q_{m\acute{a}x}}{Q_{nom}} \quad (4.5)$$

$$SoH(\%) = \frac{Q_{m\acute{a}x}}{Q_{nom} (SoC_1 - SoC_2)} \quad (4.6)$$

Onde: $Q_{m\acute{a}x}$ é a capacidade máxima que a bateria consegue armazenar no ciclo atual de medição e Q_{nom} é a capacidade nominal da bateria. SoC_1 e SoC_2 são o SoC inicial e final da bateria, respectivamente.

Ungurean *et al.* (2020) propõe uma nova abordagem para definir SoH. Os detalhes do método utilizado pelos autores são descritos na seção 3.2. SoH nesta nova abordagem é determinado segundo a equação 4.7.

$$SoH(\%) = \begin{cases} 100\%, \frac{Q_{m\acute{a}x}}{Q_{nom}} > 1 \\ \left(1 - \frac{1 - \frac{Q_{m\acute{a}x}}{Q_{nom}}}{SoH_0}\right) \cdot 100 \\ 0\%, \frac{Q_{m\acute{a}x}}{Q_{nom}} < SoH_0 \end{cases} \quad (4.7)$$

Onde $Q_{m\acute{a}x}$ é a capacidade máxima de retenção de carga atual da bateria, Q_{nom} é a capacidade nominal da bateria e SoH_0 é o SoH escolhido para determinar que o fim da vida útil da bateria foi alcançado.

No modelo proposto nesta dissertação, SoH_0 foi determinado sendo igual a 0,2, pois considera-se que a bateria chega ao fim de sua vida útil ao atingir 80 % de SoH, embora os dados coletados tenham sido levantados com uma profundidade de carga de 30 %.

O modelo proposto nesta dissertação irá avaliar SoH seguindo ambos os critérios, sendo denominados a partir de agora como critério tradicional (equação 4.6) e critério inovador (equação 4.7). Ao final dos testes, será possível avaliar as vantagens e desvantagens de cada critério e em quais situações cada um deles pode ser utilizado.

Na próxima subseção serão apresentadas as métricas utilizadas para avaliar o modelo proposto. Estas são essenciais para a construção de um modelo robusto capaz de estimar com exatidão o SoH de baterias de íon-lítio.

4.2.1. Métricas para avaliação do modelo proposto

O modelo proposto neste trabalho é baseado em redes neurais recorrentes, um tipo de rede neural artificial apropriada para problemas de modelos de regressão. A qualidade da rede neural foi avaliada por meio do erro quadrático médio (*Mean Squared Error* - MSE). Essa métrica calcula o erro de acordo com valor do estado de saúde estimados (pelo modelo) e os medido com os dados reais (ensaio destrutivo). O cálculo do MSE é expresso de acordo com a equação 4.8.

$$MSE = \frac{1}{N} \sum_{i=1}^N (\widehat{SoH} - SoH)^2 \quad (4.8)$$

Onde: N é o número de estados de saúde, \widehat{SoH} e SoH são os valores estimados e medidos de SoH, respectivamente.

O MSE eleva o erro ao quadrado, trazendo a vantagem de possuir valores sempre positivos e de penalizar erros grandes, o que o torna uma excelente métrica de avaliação para problemas onde grandes erros não são tolerados. No entanto, um ponto negativo do uso dessa métrica é a sua falta de interpretação direta, uma vez que a unidade do MSE é o quadrado da unidade da variável em análise. Por essa razão, o erro de raiz quadrático médio (*Root Mean Squared Error* – RMSE) também será analisado. Este erro, conforme pode ser observado na equação 4.9, é a raiz quadrada do MSE. Isto resolve o problema de interpretação causado pelo MSE. Tanto MSE, quanto RMSE são bons parâmetros para avaliar a qualidade da rede neural e são vastamente utilizados na literatura para este fim, por esta razão, serão estimadas as duas métricas, a fim de ser possível comparar os resultados da rede neural com o máximo de trabalhos possíveis.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\widehat{SoH} - SoH)^2} \quad (4.9)$$

Onde: N é o número de estados de saúde, \widehat{SoH} e SoH são os valores estimados e medidos de SoH, respectivamente.

Outra métrica utilizada para se medir a qualidade de modelos de estimação de SoH é o erro médio absoluto (*Mean Absolute Error* – MAE). Embora MSE e RMSE sejam parâmetros mais adequados para a avaliação, MAE também será considerado neste trabalho, pois por meio dele é possível comparar os resultados da rede com muitos trabalhos encontrados na literatura. O cálculo de MAE está descrito na equação 4.10.

$$MAE = \frac{1}{N} \sum_{i=1}^N |\widehat{SoH} - SoH| \quad (4.10)$$

Onde: N é o número de estados de saúde, \widehat{SoH} e SoH são os valores estimados e medidos de SoH, respectivamente.

Foram testadas, sob diferentes parâmetros, muitas redes neurais até que se fosse encontrada a rede com os menores erros. Os dados de entrada da rede neural são divididos entre dados de treinamento e dados de teste / validação. No caso desta dissertação, 12 baterias foram utilizadas para o treinamento da rede neural GRU e 4 para teste. Todos os dados medidos de cada bateria foram utilizados ora como treinamento, ora como teste. Assim, foi possível encontrar o conjunto de treinamento que otimiza o desempenho da rede neural GRU. Na próxima subseção, serão apresentados o algoritmo e os parâmetros internos do modelo proposto, avaliados sob as métricas propostas nesta subseção.

4.2.2.

Parâmetros e funcionamento do modelo para estimar SoH de baterias de íon-lítio proposto

A rede neural foi programada em *Python*, pois é uma linguagem de programação amplamente utilizada e de código aberto. Os dados utilizados para treinar a rede foram extraídos do sistema de testes apresentado na seção 4.1, que também serviu para validar os testes.

Várias redes neurais foram testadas sob parâmetros diferentes (camadas ocultas, unidades de memória, otimizadores etc.) até que a rede com os menores erros fosse encontrada. Três baterias de cada grupo foram usadas como dados de treinamento e uma bateria de cada grupo como teste.

Para a obtenção dos melhores resultados possíveis, os dados de treinamento foram divididos em três grupos, de acordo com a corrente de carga. Assim, baterias que foram carregadas com 1 A na fase de corrente constante representam o grupo 1, baterias carregadas com 2 A formam o grupo 2 e baterias carregadas com 3 A representam o grupo 3.

Foram construídas quatro redes neurais GRU. Uma rede recebe os dados de treinamento de todas as baterias, independente da corrente de carga. As demais redes recebem dados de treinamento de baterias referentes a um determinado grupo (de acordo com a corrente de carga na fase de corrente constante). Assim, a rede neural GRU 1 recebe dados de treinamento do grupo 1, a rede neural GRU 2 recebe dados de treinamento do grupo 2 e a rede neural GRU 3 recebe dados de treinamento do grupo 3. Todas as redes neurais possuem as mesmas configurações.

Quando uma bateria é submetida para a previsão de seu SoH ao longo do tempo, o algoritmo identifica sua corrente de carga na fase de corrente constante e faz a estimação da curva do SoH a partir da rede treinada pelas baterias com a mesma corrente de carga. Também é realizada a estimação do SoH a partir da rede neural GRU 4 que contém dados de treinamento de todas as baterias disponíveis. Os parâmetros RMSE, MSE e MAE são comparados e a saída do algoritmo é a curva de SoH cujos valores das métricas adotadas para comparação são menores.

A rede neural GRU tem como objetivo prever a curva de SoH da bateria ao longo do tempo a partir das informações de corrente de carga, tensão máxima, tempo de carregamento e SoC.

O algoritmo para previsão de SoH pode ser resumido por meio da estrutura mostrada nas figuras 4.13 e 4.14. Na figura 4.13, é mostrado o treinamento das redes neurais GRU do modelo proposto. Na figura 4.14, é mostrada a estruturação de como é realizada a estimativa da curva de SoH de baterias de íon-lítio.

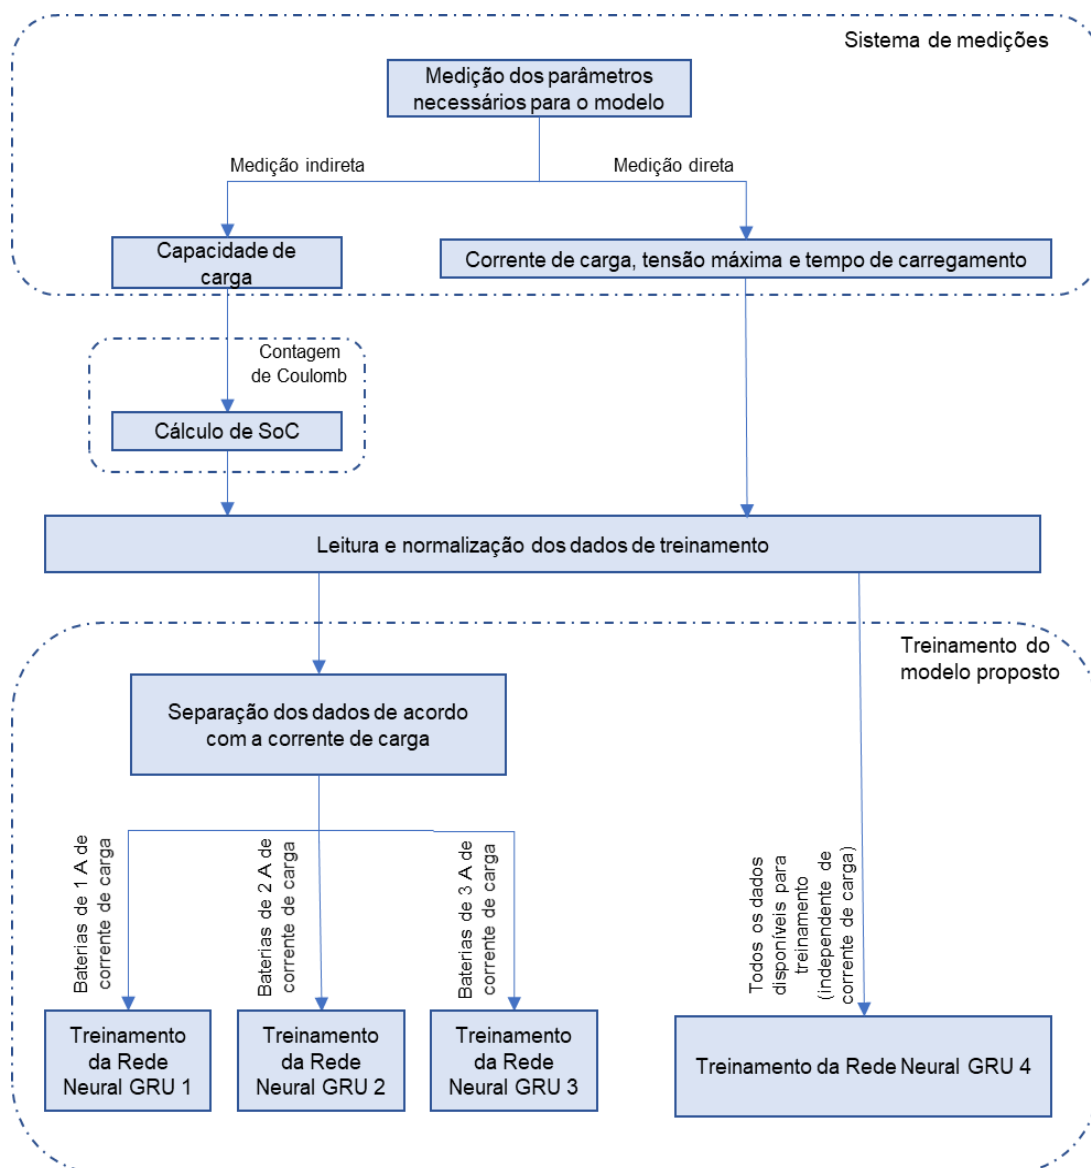


Figura 4. 13 – Estrutura do modelo proposto: treinamento das redes neurais GRU

Fonte: Elaboração própria

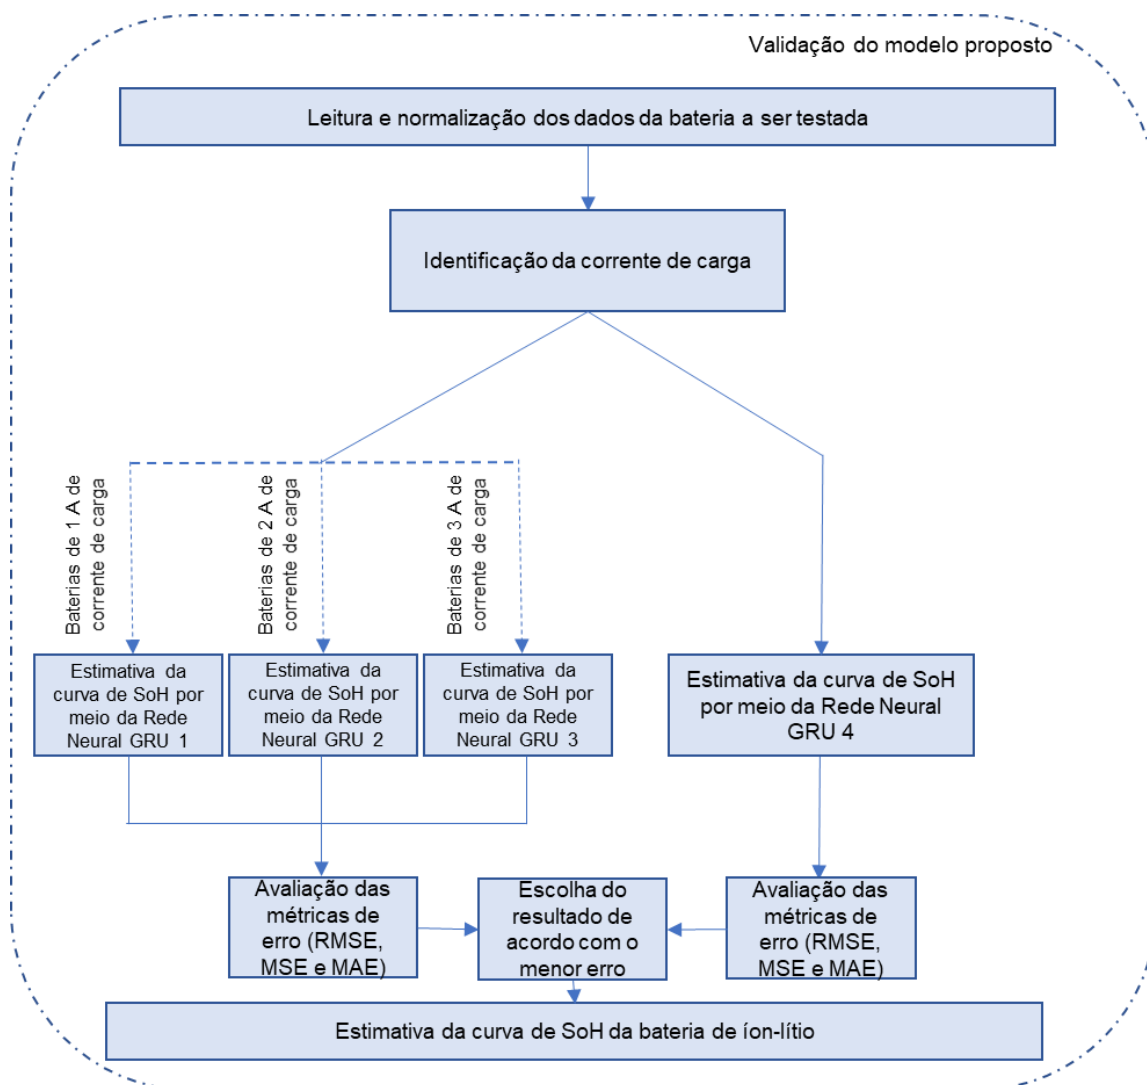


Figura 4. 14 – Estrutura do modelo proposto: estimativa da curva de SoH de baterias de íon-lítio

Fonte: Elaboração própria

A rede neural GRU proposta funciona usando um modelo de regressão que usa os últimos 10 dados de bateria medidos. Possui 4 camadas ocultas, sendo 3 camadas do tipo GRU e 1 camada densa (tipo de camada vista em redes neurais tradicionais). Para a primeira camada oculta são utilizadas 300 *units*, que são as células de memória da rede. As demais camadas têm 250 *units*. O parâmetro *unit* é equivalente ao chamado neurônio de redes neurais tradicionais, porém com capacidade de recuperar informações de neurônios de tempos anteriores. Também foram utilizadas camadas *dropout* com taxa de 0,3. A camada *dropout* define aleatoriamente unidades de entrada para 0 com uma taxa determinada em cada etapa durante o tempo de treinamento, o que ajuda a evitar *overfitting* (super treinamento da rede neural).

O otimizador utilizado foi o RMSprop. A essência do RMSprop é manter uma média móvel (descontada) do quadrado dos gradientes e dividir o gradiente pela raiz desta média. Outro parâmetro importante da rede neural é o número de épocas. Este é o número de vezes que a rede é treinada. Em cada época, a rede apresenta um desempenho diferente, sendo armazenados os pesos de treinamento da época que houve o melhor desempenho.

No modelo proposto, foram utilizadas 400 épocas, mas com *Early Stopping*. A técnica *Early stopping* faz com que a rede neural pare de treinar quando o desempenho não apresenta melhorias após consecutivos treinos. Neste trabalho, quando a rede neural apresenta 10 épocas seguidas sem melhorar o desempenho, o treinamento é concluído. Além disso, a cada 5 épocas seguidas sem melhorias, a taxa de aprendizado é reduzida. Isso pode permitir que o desempenho da rede neural melhore nos treinamentos seguintes.

A forma como a rede neural foi construída permite que o menor erro possível seja encontrado, mas sem um alto custo computacional. A rede apresenta como resultado uma curva contendo a previsão do SoH da bateria em estudo. Dois métodos foram utilizados para definir o SoH, de modo que uma curva de cada método é apresentada pela rede neural. Os resultados e o desempenho da rede neural serão analisados no próximo capítulo.

4.3.

Considerações sobre o capítulo

Neste capítulo foram apresentados a construção do sistema de testes utilizado para os ensaios destrutivos e o modelo proposto para prever o SoH de baterias de íon-lítio baseado em redes neurais GRU. O sistema de testes foi montado de forma a preservar a saúde das baterias, deixando que estas degradem de forma natural, sem interferências externas. Para isto, foram respeitadas todas as limitações de baterias de íon-lítio apresentadas no capítulo 2. O sistema de testes é responsável por gerar dados para o treinamento e validação da rede neural proposta. O modelo foi pensado para trabalhar com baterias de íon-lítio, porém os parâmetros de entrada da rede são gerais de qualquer tipo de bateria, fazendo com que o modelo possa ser utilizado para outros tipos de bateria, desde que sejam medidos de forma correta.

No próximo capítulo serão descritos os resultados gerados pelo sistema. Serão discutidos os resultados que foram responsáveis pela escolha de cada parâmetro do modelo proposto neste capítulo. As baterias testadas serão separadas em quatro grupos

para a melhor avaliação de como a mudança de parâmetros de carga / descarga alteram o comportamento das baterias quanto à capacidade de reter carga. O modelo proposto será validado a partir dos resultados obtidos da estimativa da curva de SoH de quatro baterias de teste, cada uma oriunda de um dos grupos de teste mencionado.

5. Demonstração da aplicabilidade do modelo proposto

Neste capítulo serão discutidos os resultados obtidos por meio dos ensaios destrutivos e das diversas Redes Neurais construídas para o desenvolvimento do modelo proposto para prever o SoH de baterias de íon-lítio. A análise dos resultados apresentada neste capítulo gerou subsídios para a construção do modelo proposto no capítulo 4. Os parâmetros da Rede Neural GRU apresentados no capítulo 4 foram definidos a partir das configurações da Rede Neural que obteve os menores erros RMSE, MSE e MAE.

Nas próximas seções, serão abordados os resultados observados em cada bateria, de acordo com o agrupamento a ser realizado neste capítulo, sendo mostrado na seção 5.1 a modularização do sistema e as medições realizadas pelo sistema de medições. Na seção 5.2 são apresentados os resultados individuais de cada bateria, dividido por grupo. A seção 5.3 apresenta resultados comparativos entre os 4 grupos de baterias. Na seção 5.4 são apresentados os resultados encontrados para a construção do modelo para se prever SoH de baterias de íon-lítio, principal objetivo desta dissertação.

5.1 Modularização do sistema de medição

Após a implementação e teste do sistema de medição proposto na seção 4.2, foram realizadas medições em 16 baterias novas (nunca utilizadas), de acordo com os parâmetros descritos na tabela 5.1. Como é possível observar, o sistema possui uma configuração modular, em que as 16 baterias de teste são agrupadas em 4 grupos de 4 baterias cada. Esses parâmetros foram escolhidos com base nos diferentes modos de carga utilizados no mercado de baterias de para *smartphones*. A tensão mínima de descarga foi fixada em 3,3 V para todos os grupos visando maior durabilidade das baterias.

Tabela 5. 1 – Parâmetros utilizados em cada grupo de baterias

Parâmetro	Grupo 1	Grupo 2	Grupo 3	Grupo 4
I_c [A]	1,0	2,0	2,0	3,0
V_c [V]	4,1	4,1	4,2	4,1
V_{mn} [V]	3,3	3,3	3,3	3,3

Fonte: Elaboração própria

As baterias utilizadas eram de íon-lítio (Li-Cobalto) com 5 000 mAh de capacidade nominal. O sistema de medição, além de ser responsável por carregar e descarregar automaticamente as baterias, ainda era capaz de arquivar os dados medidos, bem como gerar um sinal de alerta quando algo saísse da normalidade.

Inicialmente foi feito um teste do sistema com o ensaio referente a 5 ciclos de carga e descarga. Na figura 5.1 é ilustrada uma curva de tensão característica do processo de carga / descarga de uma das baterias medidas por meio do sistema de testes. Como é possível observar, foram necessárias mais de 20 horas para a bateria completar estes 5 ciclos de carga / descarga, o que evidenciou o longo tempo necessário para que todo o experimento pudesse ser completado.




Figura 5. 1 - Curva de tensão registrada em ciclos de carga / descarga ao longo do tempo com uma bateria de íon-lítio

Fonte: Elaboração própria

Todas as baterias apresentaram o mesmo formato de curva de tensão, diferenciando-se ligeiramente no tempo de ciclo e na derivada da tensão (principalmente durante o carregamento a corrente constante e descarga).

Como mencionado anteriormente, um ciclo é composto por 3 fases (as quais são possíveis de serem observadas na figura 5.1): carga, circuito em aberto e descarga.

Para se chegar a curva de estado de carga (SoC), foram considerados somente os valores da tensão durante a fase de descarga. Todas as baterias foram descarregadas por meio de um resistor de $1,64 \, \Omega$ que, dispersava a energia com o auxílio de um dissipador de calor. Esse método também facilitava o cálculo da corrente de descarga, visto que bastava dividir a tensão de descarga por 2 para obtê-la na sequência.

Na próxima seção, serão apresentados os resultados medidos em cada bateria, de acordo com o agrupamento apresentado na tabela 5.1, sendo estes divididos em quatro grupos.

5.2

Resultados individuais das medições em baterias de íon-lítio

Nesta seção serão apresentados os principais resultados dos ensaios destrutivos realizados com baterias de íon-lítio. Foram ensaiadas 16 baterias, as quais foram divididas em 4 grupos de regimes de carga diferenciados. Os diferentes parâmetros associados aos grupos estão descritos na tabela 5.1. Nas próximas subseções, serão apresentados os resultados das medições realizadas por grupo de baterias.

5.2.1.

Resultados das baterias do grupo 1

Conforme descrito na tabela 5.1, o grupo 1 possui como parâmetros de carregamento, a corrente (fase de carregamento a corrente constante) de 1 A e tensão de 4,1 V (limite de tensão na fase de carregamento a tensão constante). A tensão de corte de descarga (valor da tensão na bateria que determina o mínimo de carga útil) é de 3,3 V para todas as 4 baterias deste grupo.

As baterias ensaiadas foram acopladas ao *hardware* (placa de circuito impresso – PCI) com exatamente 4 entradas, uma para cada bateria, as quais são identificadas com a numeração 1, 2, 3 e 4.

Nesta configuração de carregamento, um ciclo completo de carga e descarga dura um tempo médio que oscila dentro de uma faixa de 6,29 horas à 6,43 horas para ser

concluído. A média de tempo observada, considerando somente o carregamento das baterias foi de 4,34 horas, e na tabela 5.2 são mostrados os resultados individuais para cada bateria. São apresentados o número de ciclos realizados durante o ensaio, o tempo médio de ciclo, tempo médio de carga, capacidade média, a amplitude da capacidade (diferença entre o maior e menor valores registrados) e o desvio padrão da capacidade (medida que expressa o grau de dispersão de um conjunto de dados).

A capacidade de carga média das baterias deste grupo foi de 3773,44 mAh. Isto representa 75,47 % da capacidade nominal das baterias (segundo a fabricante). A tabela 5.2 indica que baterias carregadas até 4,1 V retém 80 % da capacidade nominal de 5 000 mAh. A capacidade de carga medida está coerente com o esperado, conforme a teoria apresentada no capítulo 2, estando um pouco abaixo devido à tensão terminal de descarga (3,3 V) que é superior aos 3 V utilizados pelas fabricantes.

Tabela 5. 2 - Baterias do grupo 1

	Número de ciclos	Tempo médio de ciclo (h)	Tempo médio de carga (h)	Capacidade média (mAh)	Amplitude (Q _{máx} - Q _{min}) (mAh)	Desvio padrão (mAh)
Bateria 01	213	6,43	4,34	3812,04	335,85	71,08
Bateria 02	214	6,37	4,36	3743,54	478,99	125,10
Bateria 03	217	6,29	4,21	3685,44	1792,29	158,44
Bateria 04	214	6,43	4,45	3852,75	430,03	104,97

Fonte: Elaboração própria

A figura 5.2 mostra as capacidades de carga das quatro baterias deste grupo ao longo dos ciclos de carga e descarga durante o ensaio destrutivo. O comportamento das baterias, de modo geral, segue padrões esperados. As capacidades de carga possuem linhas de tendência decrescente, ou seja, as capacidades estão diminuindo conforme as baterias se desgastam ou degradam. Pode-se observar (figura 5.2) que a bateria 03 chegou ao fim de sua vida útil, tendo completado 217 ciclos. Este comportamento, evidenciado pela rápida queda na capacidade de carga medida, não foi observado nas demais baterias deste ensaio, e este achado será discutido com maiores detalhes no próximo capítulo. Visto que foi a única bateria a apresentar problema nesta fase das medições, é possível concluir que esta bateria possui algum problema interno, fazendo sua vida útil ser menor que o esperado.




Figura 5. 2 - Capacidade das baterias do grupo 1

Fonte: Elaboração própria

Conforme visto no capítulo 2, baterias de íon-lítio possuem como característica uma instabilidade de carga, o que pode ser uma desvantagem (*Battery University*, 2017). A figura 5.3 ilustra esta instabilidade, podendo ser observadas retenções de carga diferentes em cada ciclo. É possível perceber que há uma queda mais acentuada da capacidade em torno do ciclo 80 nas baterias 1, 2 e 4. Novas instabilidades puderam ser observadas em torno do ciclo 150 nas baterias 1 e 4. A amplitude de capacidade observada nas baterias do grupo 1 variam de 335,85 mAh a 1792,29 mAh, conforme mostrado na tabela 5.2. Esta última amplitude se deu por conta da bateria 03 que apresentou problemas de funcionamento. De modo geral, a instabilidade não foi grande e a queda de capacidade ao longo do tempo é algo esperado.




Figura 5. 3 - Instabilidade de carga das baterias do grupo 1

Fonte: Elaboração própria

5.2.2. Resultados das baterias do grupo 2

Conforme descrito na tabela 5.1, o grupo 2 possui como parâmetros de carregamento, a corrente de carga de 2 A (fase de corrente constante) e 4,1 V de tensão na etapa de tensão constante. A tensão de corte de descarga foi novamente de 3,3 V para todas as 4 baterias deste grupo.

As baterias inseridas nesta placa (PCI) foram identificadas numericamente como baterias 5, 6, 7 e 8. Nesta configuração, um ciclo completo de carga e descarga durou um tempo que variou entre 3,50 horas e 3,76 horas para ser concluído, e a média de tempo para carregamento das baterias foi de 1,87 horas. Na tabela 5.3 é mostrado, para cada bateria, o número de ciclos realizados, o tempo médio de ciclo, tempo médio de carga, capacidade de carga média, a amplitude da capacidade e o desvio padrão da capacidade de carga.

A capacidade de carga média das baterias deste grupo foi de 3131,37 mAh. Isto representa 62,63% da capacidade de carga nominal das baterias (5000 mAh, segundo a fabricante). Esta capacidade de carga média, observada para este grupo, está consideravelmente inferior ao que é previsto na literatura, que é 80 % da capacidade

nominal para os parâmetros de tensão deste grupo. Visto que o único parâmetro diferente do grupo 2 para o grupo 1 é a corrente de carregamento, pode-se supor que a corrente de carga influencia a capacidade de retenção de carga das baterias.

Tabela 5. 3: Baterias do grupo 2

	Número de ciclos	Tempo médio de ciclo (h)	Tempo médio de carga (h)	Capacidade média (mAh)	Amplitude (Q _{máx} - Q _{mín}) (mAh)	Desvio padrão (mAh)
Bateria 05	364	3,76	1,96	3233,99	414,94	71,41
Bateria 06	379	3,62	1,96	3138,00	286,00	50,70
Bateria 07	391	3,50	1,68	3074,85	274,20	67,32
Bateria 08	391	3,52	1,87	3078,64	365,04	88,12

Fonte: Elaboração própria

Na figura 5.4, é mostrada a evolução das capacidades de carga das quatro baterias deste grupo ao longo dos ciclos. O comportamento das baterias, de modo geral, segue padrões esperados, com as capacidades de carga possuindo linhas de tendência negativa, ou seja, as capacidades estão diminuindo conforme as baterias se desgastam.




Figura 5. 4 - Capacidade das baterias do grupo 2

Fonte: Elaboração própria

As baterias deste grupo também possuem instabilidade de carga, sendo observadas algumas mudanças abruptas de retenção de carga ao longo dos ciclos (figura 5.5). Estas instabilidades ocorrem por causa das reações eletroquímicas presentes nas baterias. O estresse ao qual as baterias estão submetidas (medições sem interrupção por meses) faz com que estas reações mudem a capacidade de retenção de carga das baterias ao longo do

tempo. A amplitude de capacidade observada nas baterias do grupo 2 varia de 274,20 mAh a 414,94 mAh, conforme mostrado na tabela 5.3. A instabilidade de carga vista no grupo 2 foi maior que a observada no grupo 1, mas também está dentro dos valores esperados.




Figura 5. 5 - Instabilidade de carga das baterias do grupo 2

Fonte: Elaboração própria

5.2.3. Resultados das baterias do grupo 3

Conforme descrito na tabela 5.1, o grupo 3 possui como parâmetros de carregamento a corrente de 2 A (fase de corrente constante) e tensão de 4,2 V (fase de tensão constante). A tensão de corte de descarga foi mantida no valor de 3,3 V para todas as 4 baterias deste grupo, as quais foram identificadas como baterias 9, 10, 11 e 12. Nesta configuração, um ciclo completo de carga e descarga levou entre 4,43 horas a 4,65 horas para ser concluído. A média de tempo para carregamento das baterias foi de 2,29 horas.

Na tabela 5.4 são mostrados, para cada bateria, o número de ciclos realizados, o tempo médio de ciclo, o tempo médio de carga, a capacidade de carga média, a amplitude da capacidade de carga e o desvio padrão da capacidade. A capacidade de carga média das baterias deste grupo foi de 4.006,24 mAh. Isto representa 80,12 % da capacidade nominal das baterias (5000 mAh, segundo a fabricante). As baterias deste grupo são

carregadas até a tensão máxima permitida (4,2 V), porém são descarregadas até 3,3 V, valor acima do que é comumente praticado pelas fabricantes (3 V). Isto faz com que as baterias não consigam apresentar a capacidade máxima, porém é esperado que desta maneira a vida útil seja ampliada (*Battery University*, 2017). Visto que o único parâmetro diferente do grupo 3 para o grupo 2 é a tensão na fase de tensão constante, verifica-se que as baterias conseguem apresentar, em média, 22,81 % mais carga quando carregadas até 4,2 V.

Tabela 5. 4 - Baterias do grupo 3

	Número de ciclos	Tempo médio de ciclo (h)	Tempo médio de carga (h)	Capacidade média (mAh)	Amplitude (Q _{máx} - Q _{min}) (mAh)	Desvio padrão (mAh)
Bateria 09	305	4,65	2,38	4060,07	511,60	141,52
Bateria 10	298	4,59	2,35	4076,70	531,55	141,03
Bateria 11	307	4,44	2,21	3945,86	492,38	157,65
Bateria 12	307	4,43	2,20	3942,32	505,37	157,54

Fonte: Elaboração própria

Na figura 5.6 é apresentada a evolução das capacidades de carga das quatro baterias deste grupo ao longo dos ciclos de carga e descarga. O comportamento das baterias, de modo geral, segue padrões esperados. As capacidades possuem linhas de tendência decrescentes, ou seja, as capacidades de carga estão diminuindo conforme as baterias se desgastam.




Figura 5. 6 - Capacidade das baterias do grupo 3

Fonte: Elaboração própria

As baterias deste grupo também possuem instabilidade de carga, sendo observada uma mudança abrupta no registro de carga das baterias 11 e 12 em torno do ciclo 110. As baterias 9 e 10 apresentaram registros de carga mais instáveis a partir do ciclo 180. Isto pode ser observado na figura 5.7. As instabilidades observadas neste grupo são menores que as dos grupos 1 e 2.




Figura 5. 7 - Instabilidade de carga das baterias do grupo 3

Fonte: Elaboração própria

5.2.4. Resultados das baterias do grupo 4

Conforme descrito na tabela 5.1, o grupo 4 possui como parâmetros de carregamento a corrente de 3 A (fase de corrente constante) e tensão de 4,1 V(fase de tensão constante). A tensão de corte de descarga foi definida para o valor de 3,3 V em todas as 4 baterias deste grupo, identificadas numericamente como bateria13, 14, 15 e 16. Nesta configuração, um ciclo completo de carga e descarga variava em entre 2,86 horas e 3,30 horas para ser concluído. A média de tempo para carregamento das baterias era de 1,66 horas. Na tabela 5.5 são mostrados, para cada bateria, o número de ciclos realizados, o tempo médio de ciclo, tempo médio de carga, capacidade de carga média, a amplitude da capacidade de carga e o desvio padrão da capacidade. A capacidade de carga média das baterias deste grupo foi de 2858,77 mAh, o que representa 57,18 % da capacidade

nominal das baterias (5000 mAh, segundo a fabricante). A capacidade de carga média observada para este grupo está consideravelmente inferior ao que é previsto na literatura, que é 80 % da capacidade nominal para os parâmetros de tensão deste grupo. Visto que o único parâmetro diferente do grupo 4 em relação aos grupos 1 e 2 é a corrente de carregamento, pode-se supor que a corrente de carga influencia a capacidade de retenção de carga das baterias.

A bateria inicialmente alocada no *slot* 13 teve o fim de sua vida útil precocemente. Visto que haviam sido efetuados poucos ciclos e que foi a única que apresentou tal comportamento (neste grupo), foi levantada a hipótese de que a mesma apresentava algum problema de fábrica, não podendo gerar nenhum dado conclusivo para os testes realizados neste projeto. Então, a bateria foi trocada por outra nova. Isto fez com que o *slot* 13 tivesse uma diferença de ciclos concluídos consideravelmente menor em relação às outras 3 baterias deste grupo. Por esta razão, esta bateria não será incluída em qualquer análise que dependa do número de ciclos concluídos, visto que os dados gerados por esta bateria não se mostraram confiáveis.

As cargas observadas pelas baterias deste grupo foram as menores em relação a todos os outros grupos, indicando que quanto mais alta a corrente de carga, menor será a capacidade da bateria de reter carga. Em compensação, estas são carregadas num tempo consideravelmente menor. Durante o ensaio, as baterias do grupo 4 conseguiram completar, em média, 473 ciclos (desconsiderando a bateria 13).

Tabela 5. 5 - Baterias do grupo 4

	Número de ciclos	Tempo médio de ciclo (h)	Tempo médio de carga (h)	Capacidade média (mAh)	Amplitude (Q _{máx} - Q _{min}) (mAh)	Desvio padrão (mAh)
Bateria 13	297	2,95	1,68	2954,10	115,62	28,63
Bateria 14	476	2,89	1,69	2870,66	318,37	73,84
Bateria 15	482	2,86	1,65	2826,05	381,16	84,90
Bateria 16	461	3,30	1,63	2784,26	468,77	94,42

Fonte: Elaboração própria

Na figura 5.8 são mostradas as capacidades de carga das quatro baterias deste grupo ao longo dos ciclos. O comportamento das baterias, de modo geral, segue padrões esperados. As capacidades possuem linhas de tendência decrescentes, ou seja, as capacidades estão diminuindo conforme as baterias se desgastam.




Figura 5. 8 - Capacidade das baterias do grupo 4

Fonte: Elaboração própria

As baterias deste grupo também possuem o efeito de instabilidade de carga entre ciclos de carga e descarga. Estas instabilidades decorrem por causa das reações eletroquímicas presentes nas baterias. Visto que estas baterias são carregadas com uma corrente maior em relação aos outros grupos, o estresse submetido a elas é maior, fazendo com que fiquem mais instáveis (figura 5.9). A maior amplitude observada neste grupo foi de 468,77 mAh. Isto significa que, mesmo as baterias tendo uma instabilidade de carga perceptível, a capacidade de carga destas não se alteram de um ciclo para o outro em uma taxa considerável (no máximo, em torno de 5 % de alteração entre um ciclo e outro) (*Battery University*, 2018). Entretanto, a bateria 13 apresentou comportamento inesperado quanto sua linha de tendência. Isto porque esta apresentou grande instabilidade até completar 125 ciclos, não tendo sido encontrados motivos que possam explicar tal efeito. Vale ressaltar, porém, que a amplitude da capacidade da bateria 13 foi a menor de todo o grupo 4 (115,62 mAh), o que evidencia que apesar do comportamento inesperado, ela está em boas condições de operação. Caso os dados desta bateria fossem divididos em dois momentos, sendo o primeiro do ciclo zero ao ciclo 130 e o outro do ciclo 131 até o fim das medições, ambos os momentos apresentariam retas de tendências decrescente.




Figura 5. 9 - Instabilidade de carga das baterias do grupo 4

Fonte: Elaboração própria

5.3 Comparação entre os grupos

As medições indicaram que os parâmetros de carregamento alteram significativamente o comportamento das baterias ao longo da sua vida útil. O modo de uso das baterias durante os testes não seguiu os parâmetros dados pelo fabricante (a tensão de corte, por exemplo, foi de 3,3 V nos testes, enquanto o fabricante recomenda a descarga até 3 V). Assim, nenhuma bateria atingiu a capacidade de carga nominal descrita pelo fabricante. Na tabela 5.6 é apresentado o número médio de ciclos realizados durante as medições, o tempo médio do ciclo, o tempo médio de carregamento e a capacidade de carga média de cada grupo de baterias. Como esperado, o grupo 4 (3 A de corrente na fase de corrente constante) apresentou um tempo menor para carregar as baterias. Assim, o número de ciclos realizados é maior do que os realizados pelos outros grupos. Por outro lado, a carga retida por esse grupo foi a menor registrada. O Grupo 4 apresenta maior instabilidade de carga devido ao estresse submetido às baterias no constante processo de carregamento e descarregamento, sendo este grupo o de maior corrente de carga, o que afeta as reações eletroquímicas internas da bateria.

O Grupo 3 teve a maior capacidade média registrada, tendo como único parâmetro diferente do grupo 2 a tensão na fase de tensão constante, conclui-se que este é um parâmetro decisivo para a capacidade das baterias de reter a carga. No entanto, as baterias do grupo 3 demoram mais tempo para serem carregadas quando comparadas com as baterias do grupo 2.

Tabela 5. 6: Parâmetros médios dos 4 grupos de baterias testadas

	Número de ciclos	Tempo médio do ciclo (h)	Tempo médio de carregamento (h)	Capacidade média (mAh)
Grupo 1	215	6,38	4,34	3777,79
Grupo 2	381	3,60	1,87	3131,37
Grupo 3	304	4,53	2,29	4006,24
Grupo 4	473	3,00	1,66	2858,77

Fonte: Elaboração própria

As baterias do grupo 1 são carregadas com uma corrente de 1 A. Isso naturalmente torna seu tempo de carregamento mais longo do que os outros grupos, o que fez com que as baterias deste grupo fossem submetidas a menos ciclos de carga e descarga. Por essa razão, os dados gerados para serem utilizados nas redes neurais durante o seu treinamento foram muito menores em relação aos outros grupos.

5.4

Resultados do modelo para estimar a curva de SoH de baterias de íon-lítio

Os resultados medidos por três baterias de cada grupo foram usados para treinamento da rede neural (proposta na seção 4.2) e os resultados da bateria restante (cada grupo) como teste para validar o modelo. As baterias utilizadas para a validação da rede neural foram: 2 (grupo 1), 7 (grupo 2), 12 (grupo 3) e 13 (grupo 4). Todos os dados de entrada da rede das baterias foram utilizados ora para treinamento, ora para teste. Deste modo, definiu-se qual o melhor grupo de baterias a ser utilizado como grupo de teste, sendo as baterias restantes utilizadas para o treinamento da rede neural. A avaliação das redes neurais testas foi feita a partir das métricas de erro apresentadas no capítulo 4 (RMSE, MSE e MAE).

Conforme descrito no capítulo 4, foram utilizadas redes neurais recorrentes para a construção do modelo proposto. Este tipo de rede neural possui memória, portanto cada camada oculta considera as informações de tempos passados para estimar a curva de SoH das baterias de íon-lítio. As Redes Neurais recorrentes são eficientes para trabalhar com séries temporais, sendo uma boa escolha para modelos de regressão. O SoH de baterias é afetado pelo tempo, visto que quanto maior o número de ciclos em que a bateria for

submetida, menor será o SoH esperado dela. Assim, é benéfico para o modelo proposto considerar informações oriundas de resultados anteriores. Este foi o motivo da escolha de utilizar redes neurais recorrentes na construção do modelo proposto.

Dentre as Redes Neurais recorrentes, destacam-se as Redes Neurais LSTM (*Long Short Term Memory*) e as Redes Neurais GRU (*Gated Recurrent Units*). Ambas são capazes de gerar bons resultados, entretanto a Rede Neural LSTM necessita de maior capacidade computacional e os valores de RMSE, MSE e MAE não se mostraram superiores àqueles gerados pela rede neural GRU. Por estas razões, optou-se por utilizar redes neurais GRU para o modelo proposto.

Foram testados diferentes parâmetros de entrada para a Rede Neural GRU, sendo selecionados aqueles que apresentaram melhores resultados de desempenho da rede. Os parâmetros selecionados como entrada para a Rede Neural GRU foram a corrente de carga na fase de corrente constante, a tensão máxima, o tempo de carregamento e o SoC da bateria.

Conforme visto nos resultados encontrados nas seções anteriores, a corrente de carga é um parâmetro capaz de modificar o comportamento das baterias, visto que a capacidade de reter carga entre os 4 grupos apresentou diferenças. Este comportamento influencia no treinamento da Rede Neural GRU, pois esta considera informações provenientes de dados passados. Como o comportamento de baterias de grupos diferentes possui diferenças relevantes, o treinamento da rede foi prejudicado, gerando resultados com grandes erros.

Para contornar o problema de treinamento causado pelo comportamento das baterias de grupos diferentes, foram construídas três Redes Neurais GRU: uma recebendo dados para treinamento de baterias do grupo 1 (1 A de corrente de carga), uma com dados de baterias dos grupos 2 e 3 (2 A de corrente de carga) e outra com dados de baterias do grupo 4 (3 A de corrente de carga). Deste modo, a corrente de carga na fase de corrente constante tornou-se um parâmetro para definir qual rede neural GRU deve ser utilizada para estimar o SoH da bateria que se deseja testar. Além destas três redes, também foi construída uma rede que recebe dados dos quatro grupos de baterias para treinamento.

Ao realizar a previsão do SoH de uma bateria, o algoritmo identifica a corrente de carga desta bateria, realiza a estimativa utilizando a rede de acordo com a corrente de carga e também produz a estimativa dada pela rede treinada com todos os dados disponíveis dos quatro grupos de baterias. Então, a estimativa de SoH entregue na saída da rede é aquela que obteve os menores valores de RMSE, MSE e MAE. Esta solução

exige maior capacidade computacional à utilização apenas uma rede neural GRU, porém produz resultados com menores erros.

Após a escolha do tipo de rede a ser utilizada, dos parâmetros de entrada e da solução de utilizar quatro redes neurais GRU, foram ajustados os parâmetros internos da rede por meio de consecutivos testes, tendo como objetivo os menores valores de RMSE, MSE e MAE possíveis sem ter necessidade de um custo computacional excessiva. Nas próximas subseções serão discutidos os resultados obtidos para a definição dos diferentes parâmetros internos da Rede Neural GRU (número de camadas ocultas, *units*, *dropout*, otimizador e atraso de tempo para a previsão do SoH).

5.4.1. Camadas ocultas

Conforme mencionado no capítulo 4, as camadas ocultas das redes neurais recorrentes recebem sinais tanto da camada de entrada quanto da camada oculta na iteração de tempo anterior, ou seja, a camada oculta funciona como uma memória, onde a cada período no tempo, a rede neural recupera informações do estado anterior e armazena informações dos dados observados naquele período no tempo. Deste modo, o número de camadas ocultas é um parâmetro importante para o funcionamento da rede.

Para encontrar o número ideal de camadas ocultas para o modelo proposto, diversas redes neurais GRU foram testadas, todas mantendo parâmetros idênticos e alterando-se apenas o número de camadas ocultas. Seguindo a métrica de avaliação de erros adotada no capítulo 4, o número de camadas ocultas foi definido a partir da rede neural GRU que obteve os menores RMSE, MSE e MAE.

Na tabela 5.7, são mostrados os resultados encontrados para três redes testadas. As redes apresentadas têm como objetivo ilustrar como funciona o modelo proposto ao utilizar poucas camadas ocultas (coluna 1), muitas camadas ocultas (coluna 3) e o número de camadas ocultas utilizadas no modelo proposto (coluna 2). É possível observar que a rede com 3 camadas ocultas obteve desempenho superior para a estimação da curva do SoH das baterias dos grupos 1, 2 e 3. O grupo 4 apresentou desempenho um pouco superior ao utilizar 6 camadas ocultas.

Tabela 5. 7: Métricas de avaliação do modelo para diferentes números de camadas ocultas

Parâmetro modificado: camadas ocultas			
	1 Camada ocultas	3 Camadas ocultas	6 Camadas ocultas
Baterias do grupo 1			
RMSE	0,0517	0,0418	0,0495
MSE	0,0027	0,0017	0,0024
MAE	0,0393	0,0138	0,0087
Baterias do grupo 2			
RMSE	0,7020	0,0708	0,2099
MSE	0,4928	0,0050	0,0440
MAE	0,6356	0,0143	0,1216
Baterias do grupo 3			
RMSE	0,0784	0,0595	0,3141
MSE	0,0061	0,0035	0,0987
MAE	0,0562	0,0261	0,2676
Baterias do grupo 4			
RMSE	0,0981	0,0820	0,0707
MSE	0,0096	0,0067	0,0050
MAE	0,0113	0,0454	0,0170

Fonte: Elaboração própria

Na figura 5.10 é mostrado um gráfico de barras contendo as médias de RMSE, MSE e MAE dos quatro grupos de baterias. É possível observar que ao utilizar 3 camadas ocultas, as métricas utilizadas para a avaliação da rede apresentaram valores inferiores aos resultados encontrados para os dois outros cenários. Portanto, escolheu-se utilizar 3 camadas ocultas para o modelo proposto.




Figura 5. 10 – Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Camadas ocultas

Fonte: Elaboração própria

Na próxima subseção, será apresentada a discussão de resultados envolvendo a escolha do número de *units*, que é a unidade de memória da rede neural GRU.

5.4.2. *Units*

O parâmetro *unit* é a célula de memória da rede neural GRU. Este parâmetro está associado a cada camada da rede neural, sendo possível ter quantidades diferentes de *units* para cada camada.

Para encontrar o número ideal de *units* para cada camada do modelo proposto, diversas redes neurais GRU foram testadas, todas mantendo parâmetros idênticos e alterando-se apenas o número de *units* em cada camada. Seguindo a métrica de avaliação de erros adotada no capítulo 4, o número de unidades de memória foi definido a partir da rede neural GRU que obteve os menores RMSE, MSE e MAE. Entretanto, para este parâmetro também foi considerado o custo computacional envolvido para treinar a rede, pois foi percebido que quanto maior o número de *units* em cada camada, maior será o processamento. Isto porque um dos objetivos pretendidos pelo modelo proposto é obter um baixo custo computacional para operar o modelo quando comparado a outros modelos envolvendo redes neurais.

Na tabela 5.8, são mostrados os resultados encontrados para três redes testadas. As redes apresentadas têm como objetivo ilustrar como funciona o modelo proposto ao utilizar poucos *units* (coluna 1, rede 1), muitos *units* (coluna 3, rede 3) e o número de *units* utilizadas no modelo proposto (coluna 2, rede 2). Após sucessivos testes, foi observado que utilizar mais *units* na camada de entrada em relação às camadas ocultas gera resultados semelhantes ao se fossem utilizados o mesmo número de *units* nas camadas ocultas e de entrada. Entretanto, utilizar menos *units* nas camadas ocultas exige um menor custo computacional.

É possível observar, por meio da tabela 5.8, que as redes 2 e 3 apresentaram resultados superiores aos obtidos pela rede 1. Os resultados obtidos pelas redes 2 e 3 são bastante semelhantes, porém o custo computacional necessário para operar a rede 3 foi muito superior aos das demais redes.

Tabela 5. 8: Métricas de avaliação do modelo para diferentes números de units

Parâmetro modificado: <i>units</i>			
	Primeira camada:200 Demais camadas:150	Primeira camada:400 Demais camadas:350	Primeira camada:600 Demais camadas:550
Baterias do grupo 1			
RMSE	0,0595	0,0418	0,04300
MSE	0,0035	0,0017	0,0018
MAE	0,0261	0,0138	0,0114
Baterias do grupo 2			
RMSE	0,0675	0,0708	0,0576
MSE	0,0045	0,0050	0,0033
MAE	0,0127	0,0143	0,0120
Baterias do grupo 3			
RMSE	0,1256	0,0595	0,0707
MSE	0,0158	0,0035	0,0050
MAE	0,1002	0,0261	0,0471
Baterias do grupo 4			
RMSE	0,0607	0,0820	0,0601
MSE	0,0037	0,0067	0,0036
MAE	0,0182	0,0454	0,0264

Fonte: Elaboração própria

Na figura 5.11 é mostrado um gráfico de barras contendo as médias de RMSE, MSE e MAE dos quatro grupos de baterias. É possível observar que, em média, os resultados obtidos pela rede 3 são superiores aos das demais redes. Entretanto, o custo computacional necessário para treinar esta rede foi muito grande, tendo causado problemas na operação da máquina responsável por executar o modelo. Por esta razão e visto que os resultados das métricas utilizadas para avaliação das redes não são muito menores que o da rede 2, foi escolhido utilizar 400 *units* na camada de entrada e 350 *units* nas demais camadas.




Figura 5. 11 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – *Units*

Fonte: Elaboração própria

Na próxima subseção, será apresentada a discussão de resultados envolvendo a escolha do valor de *dropout*.

5.4.3. **Dropout**

A camada *dropout* define aleatoriamente unidades de entrada para 0 com uma taxa determinada em cada etapa durante o tempo de treinamento, o que ajuda a evitar *overfitting* (super treinamento da rede neural). Para configurar este parâmetro, define-se uma porcentagem de dados que serão atribuídos com valor 0.

Para encontrar o valor ideal para as camadas *dropout* do modelo proposto, diversas redes neurais GRU foram testadas, todas mantendo parâmetros idênticos e alterando-se apenas o valor de *dropout* em cada camada. Seguindo a métrica de avaliação de erros adotada no capítulo 4, o valor de *dropout* foi definido a partir da rede neural GRU que obteve os menores RMSE, MSE e MAE.

Na tabela 5.9, são mostrados os resultados encontrados para três redes testadas. As redes apresentadas têm como objetivo ilustrar como funciona o modelo proposto ao utilizar um baixo valor de *dropout* (coluna 1, rede 1), alto valor de *dropout* (coluna 3, rede 3) e o valor de *dropout* utilizado no modelo proposto (coluna 2, rede 2).

É possível observar, por meio da tabela 5.9, que a rede 2 apresentou resultados superiores às duas outras redes. Isto significa que um baixo valor de *dropout*

possivelmente causa *overfitting*, enquanto um valor alto de *dropout* faz com que a base de treinamento perca muitos dados, piorando o desempenho da rede. Então, o valor escolhido de *dropout* para todas as camadas foi de 0,3, pois os resultados foram superiores a todas as outras redes testadas

Tabela 5. 9: Métricas de avaliação do modelo para diferentes números de *Dropout*

Parâmetro modificado: <i>Dropout</i>			
Erros	<i>Dropout</i> = 0,1	<i>Dropout</i> = 0,3	<i>Dropout</i> = 0,6
Baterias do grupo 1			
RMSE	0,0504	0,0418	0,0565
MSE	0,0025	0,0017	0,0032
MAE	0,0106	0,0138	0,0217
Baterias do grupo 2			
RMSE	0,0684	0,0708	0,3245
MSE	0,0047	0,0051	0,1053
MAE	0,0119	0,0143	0,269
Baterias do grupo 3			
RMSE	0,1238	0,0595	0,1366
MSE	0,0153	0,0035	0,0186
MAE	0,1023	0,0261	0,0804
Baterias do grupo 4			
RMSE	0,0837	0,082	0,1456
MSE	0,0076	0,0067	0,0212
MAE	0,0133	0,0454	0,0684

Fonte: Elaboração própria

Na figura 5.12 é mostrado um gráfico de barras contendo as médias de RMSE, MSE e MAE dos quatro grupos de baterias. É possível confirmar que os valores obtidos pela rede 2 foram superiores, conforme mostraram os dados apresentados na tabela 5.9.




Figura 5. 12 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – *Dropout*

Fonte: Elaboração própria

Na próxima subseção, será apresentada a discussão de resultados envolvendo a escolha do valor do otimizador utilizado no modelo proposto.

5.4.4. Otimizador

Os otimizadores são responsáveis por atualizar os pesos das camadas ocultas da rede neural. Existem inúmeros otimizadores e foram testadas redes neurais GRU com todos os otimizadores disponíveis na biblioteca do programa utilizado para programar a rede neural GRU.

Para encontrar o otimizador ideal, diversas redes neurais GRU foram testadas, todas mantendo parâmetros idênticos e alterando-se apenas o otimizador. Seguindo a métrica de avaliação de erros adotada no capítulo 4, o otimizador foi definido a partir da rede neural GRU que obteve os menores RMSE, MSE e MAE.

Na tabela 5.10, são mostrados os resultados encontrados para três redes testadas. Estes foram os três otimizadores que geraram os melhores resultados. Os otimizadores apresentados são o Adam (coluna 1, rede 1), Adamax (coluna 3, rede 3) e o RMSprop (coluna 2, rede 2). Os três otimizadores apresentados são indicados para serem utilizados em problemas envolvendo modelos de regressão.

É possível observar, por meio da tabela 5.10, que a rede 2 apresentou resultados superiores às duas outras redes. Então, o otimizador escolhido foi o RMSprop.

Tabela 5. 10: Métricas de avaliação do modelo para diferentes otimizadores

Parâmetro modificado: Otimizador			
	Adam	RMSprop	Adamax
Baterias do grupo 1			
RMSE	0,0448	0,0418	0,0456
MSE	0,0020	0,0017	0,0021
MAE	0,0216	0,0138	0,0225
Baterias do grupo 2			
RMSE	0,0883	0,0708	0,0837
MSE	0,0078	0,0050	0,0070
MAE	0,0656	0,0143	0,0513
Baterias do grupo 3			
RMSE	0,1306	0,0595	0,0880
MSE	0,0171	0,0035	0,0077
MAE	0,1058	0,0261	0,0607
Baterias do grupo 4			
RMSE	0,1018	0,0820	0,1120
MSE	0,0104	0,0067	0,0125
MAE	0,0225	0,0454	0,0285

Fonte: Elaboração própria

Na figura 5.13 é mostrado um gráfico de barras contendo as médias de RMSE, MSE e MAE dos quatro grupos de baterias. É possível confirmar que os valores obtidos pela rede 2 foram superiores, conforme mostraram os dados apresentados na tabela 5.10.




Figura 5. 13 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Otimizador

Fonte: Elaboração própria

Na próxima subseção, será apresentada a discussão de resultados envolvendo a escolha do valor de atraso no tempo utilizado no modelo proposto.

5.4.5. Atraso de tempo

O SoH das baterias ao longo dos ciclos realizados pode ser modelado como uma série temporal. Por esta razão, o modelo proposto utiliza n valores atrasados no tempo para prever os valores futuros de SoH. Foram testadas diversas redes neurais GRU com parâmetros idênticos, alterando-se apenas o valor de n (atraso).

Seguindo a métrica de avaliação de erros adotada no capítulo 4, o melhor atraso no tempo foi definido a partir da rede neural GRU que obteve os menores RMSE, MSE e MAE.

Na tabela 5.11, são mostrados os resultados encontrados para três redes testadas. As redes apresentadas têm como objetivo ilustrar como funciona o modelo proposto ao utilizar um pequeno atraso (coluna 1, rede 1), grande atraso (coluna 3, rede 3) e o número de valores atrasados utilizados no modelo proposto (coluna 2, rede 2). É possível observar que a rede 2 obteve desempenho superior para a estimação da curva de SoH das baterias de todos os grupos.

Tabela 5. 11: Métricas de avaliação do modelo para diferentes atrasos de tempo

Parâmetro modificado: atraso de tempo			
	5 dados anteriores	10 dados anteriores	20 dados anteriores
Baterias do grupo 1			
RMSE	0,0579	0,0418	0,0438
MSE	0,0033	0,0017	0,0019
MAE	0,0225	0,0138	0,0073
Baterias do grupo 2			
RMSE	0,0899	0,0708	0,1197
MSE	0,0081	0,0050	0,0143
MAE	0,0445	0,0143	0,0608
Baterias do grupo 3			
RMSE	0,1887	0,0595	0,2512
MSE	0,0356	0,0035	0,0631
MAE	0,1585	0,0261	0,2306
Baterias do grupo 4			
RMSE	0,0746	0,0820	0,1603
MSE	0,0056	0,0067	0,0257
MAE	0,0388	0,0454	0,1359

Fonte: Elaboração própria

Na figura 5.14 é mostrado um gráfico de barras contendo as médias de RMSE, MSE e MAE dos quatro grupos de baterias. Os gráficos reforçam os resultados observados na tabela 5.11. Assim, foram utilizados 10 dados anteriores como atraso de tempo no modelo proposto.




Figura 5. 14 - Média das métricas de desempenho do modelo proposto dos 4 grupos de baterias – Atraso no tempo


Fonte: Elaboração própria

Na próxima subseção, serão apresentados os resultados do modelo proposto contendo todos os parâmetros escolhidos nestas últimas subseções.

5.4.6.

Curvas de SoH estimadas pelo modelo proposto

Para a validação do modelo proposto, foram estimadas as curvas de 4 baterias, sendo uma bateria de cada grupo de testes. A curva de SoH destas baterias foram calculadas a partir dos ensaios destrutivos, a fim de ser possível comparar as curvas estimadas com as calculadas. Na figura 5.15 estão apresentadas as curvas calculadas de SoH de acordo com a definição tradicional.






Figura 5. 15 - Cálculo de SOH de acordo com a definição tradicional: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4

Fonte: Elaboração própria

Na figura 5.16 estão apresentadas as curvas de SoH calculadas das 4 baterias de teste segundo a definição inovadora. Nota-se que a curva possui as mesmas características daquelas apresentadas na figura 5.15, exceto pelos valores de SoH que tendem a ser mais punitivos na definição inovadora.

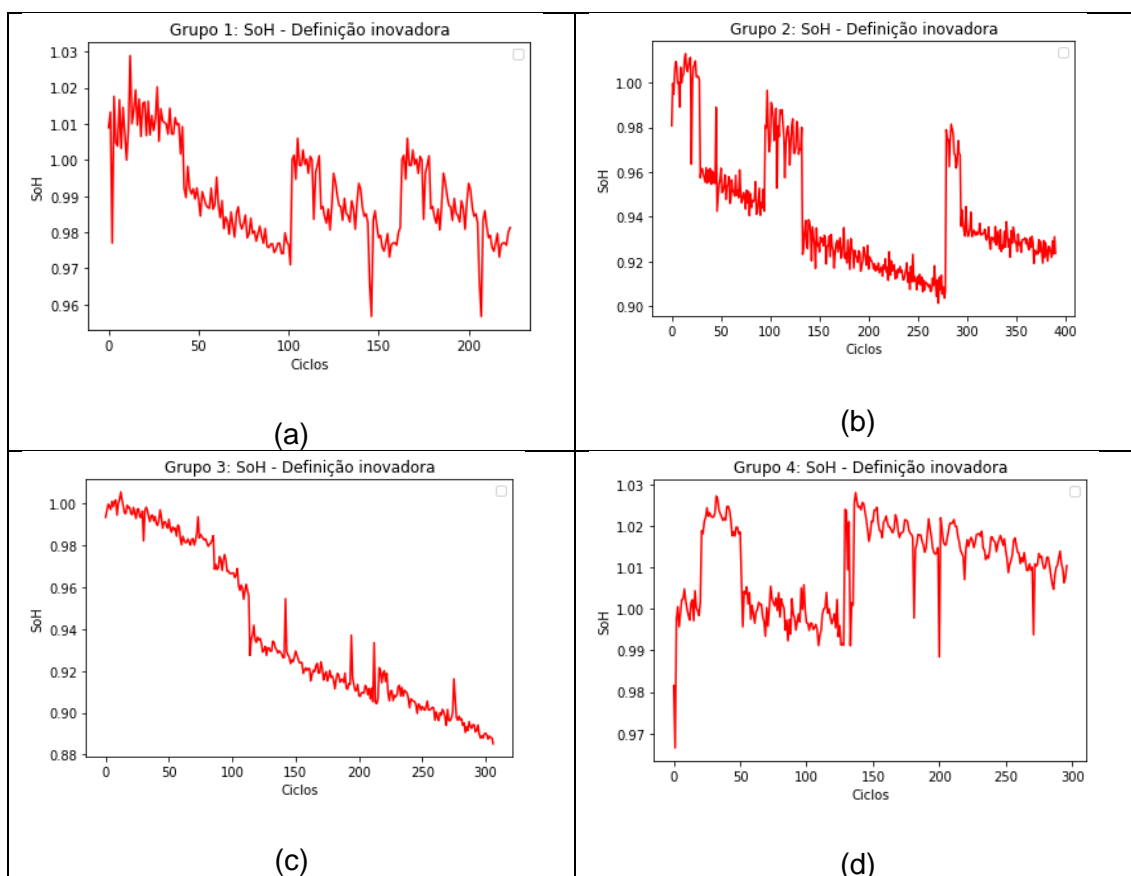


Figura 5. 16 - Cálculo de SOH de acordo com a definição inovadora: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4

Fonte: Elaboração própria

Na figura 5.17 são mostradas as curvas SoH geradas pelo modelo proposto nesta dissertação, com base na definição tradicional de SoH (equação 4.6). Cada curva representa o estado de saúde ao longo da vida útil da bateria de cada grupo. Nota-se que a rede neural pode rastrear satisfatoriamente a tendência da bateria ao longo do tempo. Como mencionado na seção 2.1 e validado nos ensaios destrutivos, as baterias Li-Cobalto (usadas nestes testes) apresentam instabilidade de retenção de carga. Esse aspecto ficou evidente durante as medições, sendo observada uma grande variação na capacidade das baterias ao longo do tempo, o que refletiu em no SoH. Nenhuma bateria chegou ao fim de sua vida útil (80 % SoH) de acordo com este critério de definição de SoH.

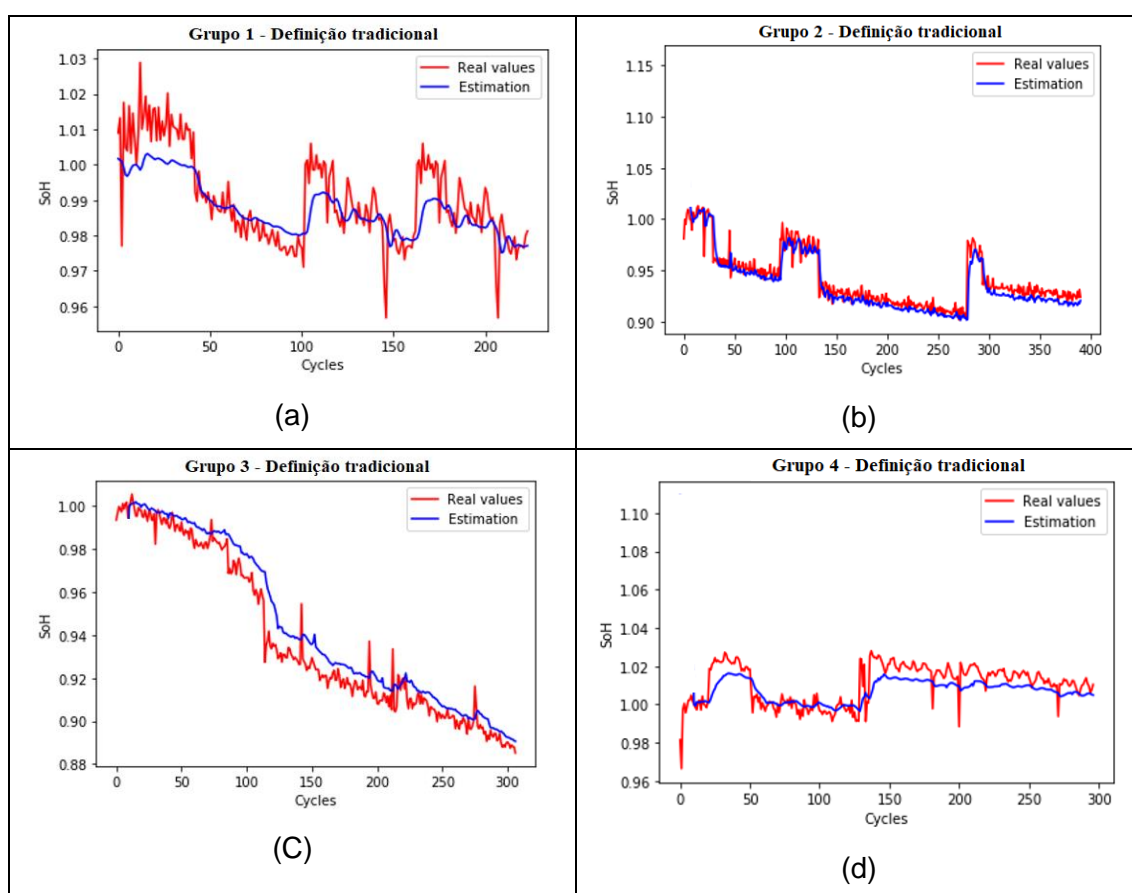


Figura 5. 17 - Previsão de SOH de acordo com a definição tradicional: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4

Fonte: Elaboração própria

Na figura 5.18 são mostrados os resultados obtidos nos testes realizados com uma bateria de cada grupo utilizando a definição de SoH expressa na equação 4.7. Nota-se que este novo método é mais punitivo em relação ao SoH das baterias, uma vez que as baterias

dos grupos 2 e 3 foram consideradas no final de suas vidas úteis, enquanto pelo método tradicional de definição de SoH, elas ainda são consideradas utilizáveis. Embora a bateria do grupo 3 tenha perdido uma capacidade significativa de retenção de carga ao longo do tempo, a bateria terminou os testes funcionando satisfatoriamente, assim como a bateria do grupo 2. Portanto, a definição inovadora de SoH é mais indicada para aplicações em que as baterias não podem estar muito degradadas, indicando um SoH mais punitivo e preservando a qualidade de funcionamento das baterias, enquanto o método tradicional pode ser usado em aplicações em que não é necessário tanto rigor em relação ao SoH das baterias. É importante observar que o método tradicional de calcular SoH reflete melhor a degradação na bateria, indicando quando a bateria realmente não funciona mais de forma satisfatória.

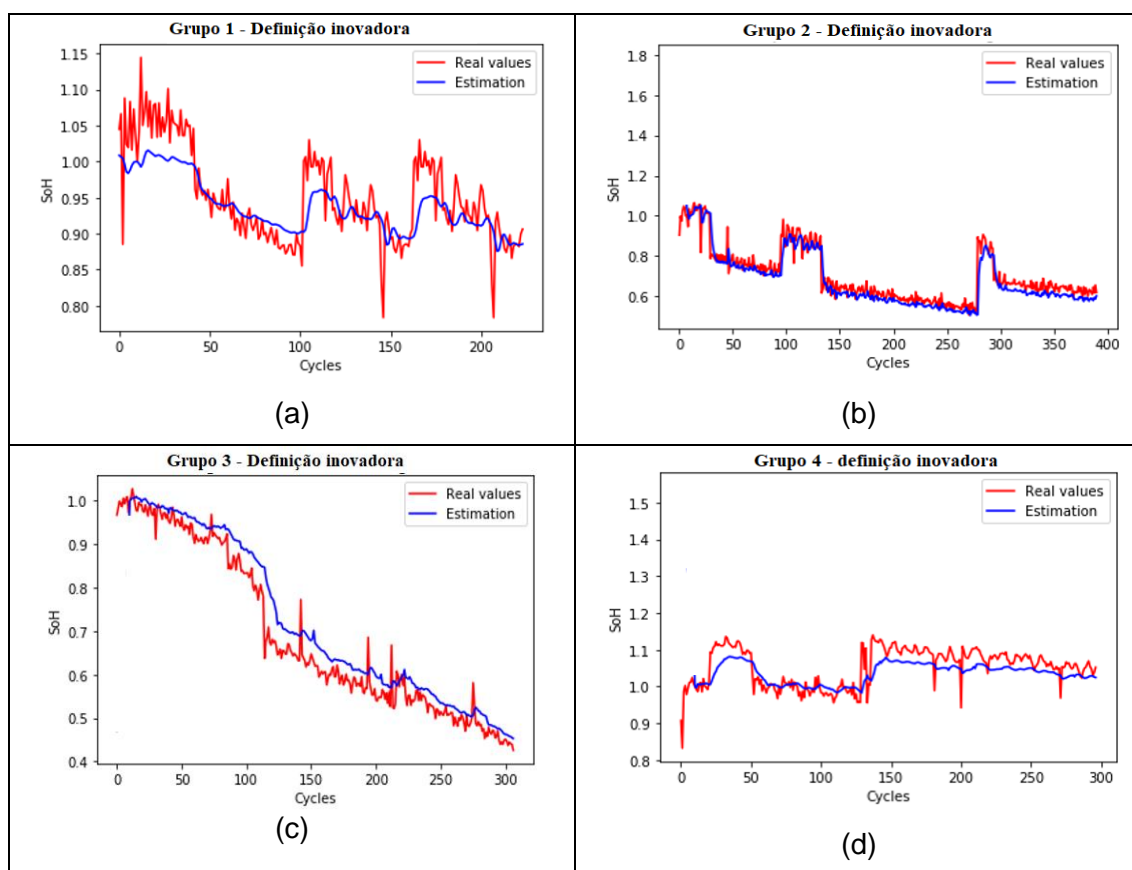


Figura 5. 18 - Previsão de SoH de acordo com a definição através de SoC: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4

Fonte: Elaboração própria

Na tabela 5.12 são mostrados os resultados obtidos com as métricas de erro utilizadas para avaliar a rede neural. A rede neural apresentou bom desempenho,

apresentando valores compatíveis com os melhores modelos de estimativa da curva de SoH encontrados na literatura (tabela 5.13). No entanto, apesar de ser uma rede neural, o modelo apresentado neste trabalho apresenta baixo custo computacional, pois a base de treinamento necessária para construir uma boa rede neural não precisa ser extensa, devido às características das redes neurais recorrentes. Vale ressaltar, no entanto, que se a base de treinamento fosse maior, a rede neural apresentaria resultados ainda melhores.

Tabela 5. 12 - métricas de avaliação de rede neural

	RMSE	Mse	Mae
Grupo 1	0,0418	0,0017	0,0138
Grupo 2	0,0708	0,0050	0,0143
Grupo 3	0,0595	0,0035	0,0261
Grupo 4	0,0820	0,0067	0,0454

Fonte: Elaboração própria

A tabela 5.13 apresenta os trabalhos mais relevantes atualmente envolvendo a estimação de SoH de baterias de íon-lítio. É possível perceber que os valores de erros encontrados se assemelham aos encontrados nesta dissertação. Isto confirma que o modelo proposto está compatível com o que é encontrado na literatura e serve para o fim proposto. Vale ressaltar que o modelo proposto nesta dissertação apresenta baixo custo computacional e parâmetros de fácil medição, sendo permitido seu uso de forma online sem grandes custos computacionais. Os modelos apresentados na tabela 5.13 que possuem erros muito inferiores aos alcançados no modelo proposto nesta dissertação são de alta complexidade matemática e computacional, além de necessitar de parâmetros de difícil cálculo / medição.

Tabela 5. 13: Erros de modelos de estimação de SoH de trabalhos mais relevantes atualmente encontrados na literatura

Autor	Método	RMSE	MSE	MAE
Chen <i>et al.</i> (2020)	Machine learning metabólico extremo combinando modelo de estado de degradação e compensação de erro	0,0635	0,0040	0,0193
Semanjski e Gautama (2016)	Aproximação linear	0,1304	0,0170	
Zhou <i>et al.</i> (2018)	Tensão integrada	0,0184	0,0003386	0,0155
Zenati <i>et al.</i> (2012)	Lógica Fuzzy e resistência interna	-	-	0,03
Chiang e Sean (2009)	Observador adaptativo	-	-	0,05
Zhang <i>et al.</i> (2018)	Processo Gaussiano	0,015	0,000225	0,011
Xia e Qahouq (2020)	Rede neural e dados de impedância de 1kHz	0,4142	0,1716	0,044

Hu <i>et al.</i> (2018)	Cálculo de ordem fracionária	-	-	0,01
Shen <i>et al.</i> (2016)	Algoritmo de mínimos quadrados recursivo	-	-	0,0209
Yang <i>et al.</i> (2017)	Análise da corrente de carga	0,025	0,000625	0,015
Chaoui e Ekeocha (2017)	Rede neural recorrente	0,4547	0,2067	-
Lin <i>et al.</i> (2012)	Rede neural probabilística	-	-	0,0028
Dai <i>et al.</i> (2018)	Rede neural e cadeia de markov	0,16155	0,0261	0,03849
Cao <i>et al.</i> (2019)	Rede neural baseado na estimativa do limite superior inferior (LUBE)	0,0407	0,001656	-
Cui e Hu (2020)	Método de fusão de modelo de dados (rede neural LSTM e UKF)	0,069	0,004761	-
Kim <i>et al.</i> (2019)	Rede neural com dados experimentais reduzidos medidos pelo teste de desempenho de referência	-	-	0,0187
Landi e Gross (2014)	Lógica Fuzzy e rede neural	-	-	0,05
Khan <i>et al.</i> (2020)	Redes neurais eficientes com perfis de carregamento de vários canais	0,0259	0,0006708	0,0197
Xiong <i>et al.</i> (2020)	Rede neural	0,0185	0,0003423	-
You <i>et al.</i> (2017)	Rede neural recorrente	0,0246	0,0006052	-
Zhou <i>et al.</i> (2016)	Rede neural de regressão generalizada	-	-	0,0292
Shu <i>et al.</i> (2020)	Machine learning	0,05196	0,0027	0,02
Li <i>et al.</i> (2020)	Análise de componente de transferência semissupervisionada	-	-	0,0129
Jia <i>et al.</i> (2020)	Processo Gaussiano com Indicadores Indiretos de Saúde	0,0117	0,0001369	-
Berecibar <i>et al.</i> (2016)	Análise preditiva	-	-	0,0314
Yang <i>et al.</i> (2016)	Rede neural	-	-	0,08

Fonte: elaboração própria

Os erros apresentados pelo modelo proposto nesta dissertação poderiam ser menores caso houvesse mais dados de treinamento para a rede neural. A instabilidade de carga apresentada pelas baterias também dificultou o treinamento da rede, apresentando muitas vezes aumento ou diminuição abrupta de retenção de capacidade, conforme pode ser observado na figura 5.16 (b).

Na figura 5.19 são exibidos os gráficos da raiz do erro quadrático em cada medição para as quatro baterias testadas. É possível notar que alguns ciclos de carga e descarga, apresentaram erros mais elevados que outros, em todos os 4 grupos. Estes erros ajudam a aumentar a média do erro, comprometendo o desempenho da rede neural.

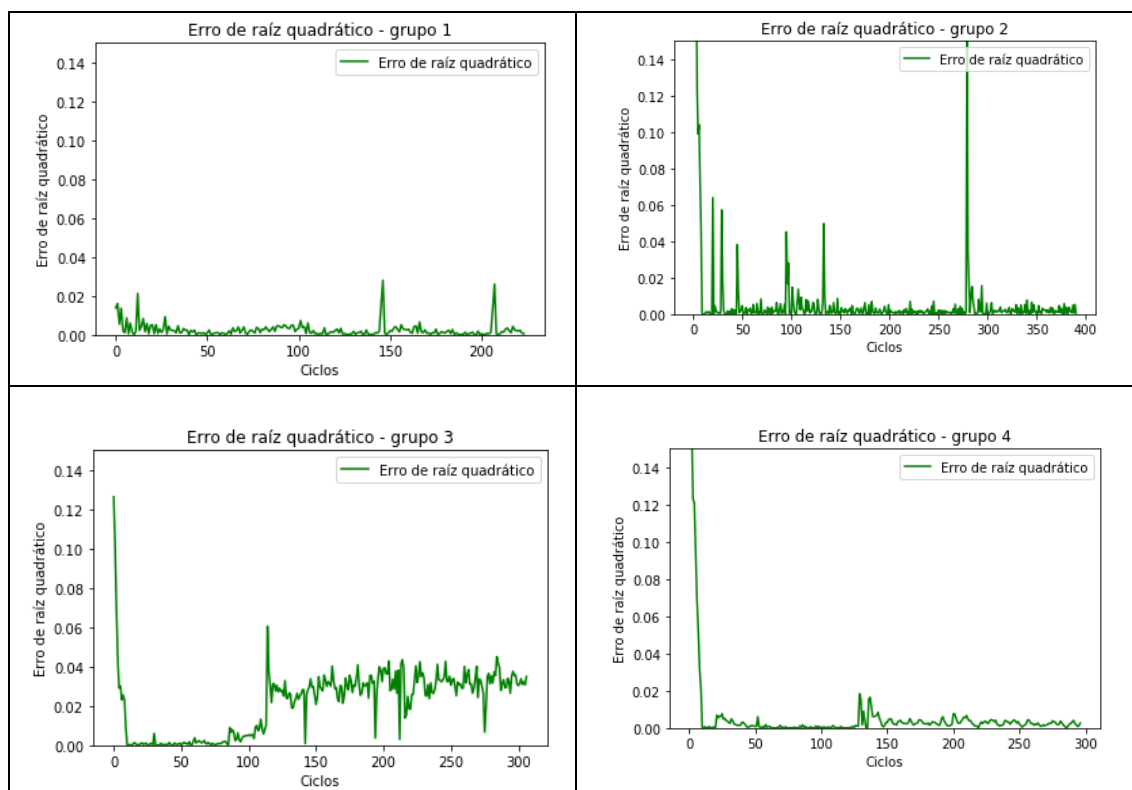


Figura 5. 19 -. Erro SoH ao longo do tempo: (a) Bateria do Grupo 1; (b) Bateria do Grupo 2; (c) Bateria do Grupo 3; (d) Bateria do Grupo 4

Fonte: Elaboração própria

Na próxima seção serão apresentadas as discussões de resultados gerados pelo sistema de medições e pelo modelo proposto. Serão avaliados os pontos fortes e fracos do modelo e os possíveis motivos para existência de limitações do modelo.

5.5. Discussões de resultados

Neste capítulo foram apresentados os principais resultados encontrados pelo sistema de testes para ensaios destrutivos e pelo modelo para prever SoH de baterias de íon-lítio. As baterias se comportaram de forma compatível com o que a literatura sugere (apresentado nesta dissertação no capítulo 2). Foi percebido que a alteração da corrente de carga na fase de corrente constante é capaz de alterar a capacidade de retenção de carga das baterias. Conforme esperado, a tensão máxima da bateria também influencia nesta

questão. O modelo proposto foi capaz de seguir a tendência de todas as baterias e apresentou erros compatíveis com os encontrados nos melhores trabalhos vistos na literatura, ilustrados na tabela 5.13. É importante ressaltar que o diferencial do modelo proposto é a facilidade de implementação, de forma a ser possível ser utilizado online e baixo custo computacional, mesmo sendo utilizada uma rede neural.

As baterias utilizadas nos testes possuem capacidade de carga nominal de 5 000 mAh. Entretanto, a retenção de carga das baterias muda de acordo com os parâmetros de carga / descarga utilizados. Para o uso em sistemas envolvendo compartilhamento de baterias, recomenda-se uma corrente de carga de 0,4 C (2 A para baterias de 5 000 mAh), pois o tempo de carga é muito menor em relação ao grupo de baterias carregadas a 0,2 C (1 A para baterias de 5 000 mAh) e possuem retenção de carga semelhante às baterias deste mesmo grupo.

Para o uso de baterias em que se necessita de maior retenção de carga possível, os resultados obtidos mostraram que o recomendado seria ajustar os valores da tensão máxima em 4,2 V. Entretanto, caso seja importante que a bateria tenha a maior vida útil possível, recomenda-se utilizar tensão máxima inferior a 4,2 V. Nos testes realizados, as linhas de tendências decrescente das curvas de SoH das baterias do grupo 3 (2 A de corrente de descarga e 4,2 V de tensão máxima) se mostraram mais acentuadas que as observadas nas baterias do grupo 2 (2 A de corrente de descarga e 4,1 V de tensão máxima).

O grupo 4 foi o que apresentou o menor tempo de carga, sendo submetido a uma taxa-C de carga de 0,6 C (3 A para baterias de 5 000 mAh) de corrente de carga. Nesta configuração, o tempo de carga diminui em relação às baterias dos demais grupos, entretanto a retenção de carga é menor. Uma maior taxa-C garante tempo de carga ainda menor, todavia não foram efetuados estudos para correntes de carga maiores que 0,6 C nesta dissertação. Quanto maior a taxa-C, mais preparado o sistema deve ter para que a bateria consiga suprir a corrente de carga ou descarga.

As medições mostraram que a corrente de carga (na fase de corrente constante), tensão limite máximo (na fase de carregamento à tensão constante) e tempo de carregamento se mostraram parâmetros muito importantes para determinar a retenção de carga das baterias, assim como a vida útil de cada uma delas. Deste modo, estes parâmetros foram utilizados como entrada da Rede Neural GRU. Em especial, foi observado que a corrente de carga é um parâmetro determinante para o comportamento das baterias. Por esta razão, foi necessário separar as baterias em grupos de acordo com

sua corrente de carga. Foram construídas 3 Redes Neurais GRU idênticas, cada uma delas recebendo os parâmetros de entrada de um grupo de baterias para treinamento. Isto porque foi observado que uma única Rede Neural GRU tende a apresentar resultados com maior erro quando todas as baterias, independentes da corrente de carga, eram colocadas juntas para o treinamento da rede.

Foi montada uma quarta Rede Neural GRU contendo todos os dados disponíveis para treinamento. Deste modo, o algoritmo seleciona como saída da rede os resultados de SoH que obtiveram menores erros.

Os parâmetros internos das redes neurais foram escolhidos com base nas métricas utilizadas para avaliar o desempenho das redes neurais GRU. Entretanto, também foi considerado o custo computacional necessário para o funcionamento do modelo. Deste modo, o parâmetro *units*, por exemplo, não foi escolhido a partir do modelo que apresentou menores erros, mas sim aquele que obteve um bom custo computacional, com erros próximos ao encontrado na melhor rede testada.

Os testes mostraram que utilizar 3 camadas ocultas melhora o desempenho do modelo proposto e, valores acima deste número de camadas ocultas, aumentam o custo computacional e não melhoram o desempenho das redes neurais GRU. Por outro lado, quanto maior o valor de *dropout*, menor o custo computacional, porém pior será o desempenho da rede. Entretanto, um baixo valor de *dropout* pode causar super treinamento da rede, gerando, desta maneira, grandes erros. Um valor de *dropout* igual a 0,3 mostrou-se o valor ótimo a ser utilizado no modelo proposto. Da mesma maneira, quanto maior o atraso no tempo utilizado, pior o desempenho do modelo, sendo encontrado um valor de 10 unidades de atraso no tempo um valor ideal para uma rede neural GRU eficiente.

Um parâmetro importante de redes neurais é o otimizador utilizado. Dentre os disponíveis a serem utilizados para o modelo proposto, o RMSprop mostrou-se mais eficiente, gerando redes neurais GRU com menores erros em relação às redes neurais GRU que foram construídas utilizando outros otimizadores.

Foram apresentadas duas definições de SoH, sendo tratadas como método tradicional e método inovador. Ambos se mostraram eficientes em estimar o SoH de baterias, porém para aplicações diferentes. O método inovador é mais punitivo em relação ao SoH das baterias, sendo recomendado para aplicações em que a bateria precise ter um excelente desempenho por toda sua vida útil. O método tradicional é indicado para aplicações onde seja possível utilizar a bateria por mais tempo, mesmo que ela perca

alguma capacidade ao longo dos ciclos. Para os fins desta dissertação, o método tradicional se mostra mais adequado, já que em sistemas envolvendo *battery swap*, deseja-se utilizar as baterias pelo maior tempo possível. Visto que o método tradicional define de forma satisfatória o fim da vida de uma bateria, seu uso se torna mais aderente a este objetivo.

Foram utilizadas poucas baterias para compor o sistema de testes proposto nesta dissertação, fazendo com que a variação de parâmetros de carga / descarga não fosse completamente explorada. Isto limitou os parâmetros de treinamento da Rede Neural GRU proposta. Caso fossem criados mais grupos com diferentes parâmetros de corrente de carga e tensões de corte e máxima, a Rede Neural seria mais bem treinada e os erros possivelmente seriam menores. Além disso, as baterias foram testadas em ambiente controlado, com a temperatura ambiente sendo mantida constante. A mudança de temperatura pode afetar o comportamento das baterias, porém esta variável não foi considerada neste trabalho.

6.

Conclusões e recomendações para trabalhos futuros

O estado de saúde (SoH) é um importante parâmetro de caracterização de uma bateria. Por meio dele, é possível avaliar a aptidão das baterias para uso, assim como efetuar o planejamento de compras para estoque e reposição. Para sistemas envolvendo *battery swap*, conhecer o SoH das baterias é importante tanto para quem oferece o serviço, quanto para os clientes que poderão usufruir de baterias em bom estado de funcionamento. Entretanto, determinar o estado de saúde de uma bateria pode ser uma tarefa difícil, não havendo na literatura um consenso sobre o melhor método para se realizar a sua estimativa.

A presente dissertação teve como objetivo geral construir um modelo para estimar a curva de estado de saúde, por meio do estado de carga, com vistas a prever a saúde de baterias de íon-lítio. O modelo foi pensado para ser utilizado em sistemas de compartilhamento de bateria, mais especificamente para baterias de íon-lítio utilizadas em *smartphones*.

Para atingir o objetivo proposto, foram definidos objetivos específicos a serem alcançados. O primeiro a ser concluído foi o levantamento do estado-da-arte sobre modelos de estimativa de SoH e referenciais normativos aplicáveis para a construção do modelo alternativo. A pesquisa revelou duas lacunas na literatura: a necessidade de um modelo para estimar SoH pensando em sistemas de *battery swap* e para baterias utilizadas em *smartphones*. Os trabalhos mais relevantes sobre o tema foram estudados, de modo a gerar subsídios para a construção do novo modelo proposto. O modelo alternativo proposto nesta dissertação cobre estas lacunas, visto que é de fácil implementação, baixo custo operacional e utiliza parâmetros fáceis de serem medidos por máquinas utilizadas em sistemas de *battery swap*.

Foi escolhido utilizar redes neurais recorrentes para estimar SoH. O uso de redes neurais GRU (*Gated Recurrent Units*) foi essencial para alcançar o objetivo desta dissertação, visto que o custo computacional deste método é inferior quando comparado a outras redes neurais recorrentes, como a LSTM, que é uma das redes neurais recorrentes mais utilizadas atualmente. Além disso, a limitação de tamanho da base de dados

disponível para o treinamento da rede neural artificial (RNA) tem maior impacto em uma rede tradicional do que em uma GRU. Isto porque a Rede Neural GRU possui memória, ou seja, avalia a evolução da variável ao longo do tempo, dando maior robustez ao modelo proposto. Esta característica da GRU faz sentido para a determinação da curva de SoH, haja vista que há um padrão de evolução da vida da bateria ao longo do tempo. Desta forma, foi possível avaliar o comportamento das baterias de íon-lítio estudadas ao longo de toda suas vidas úteis.

Para reunir a série de dados necessários para o treinamento e teste da rede neural GRU proposta, foi idealizado e desenvolvido um sistema de ensaios destrutivos capaz de medir múltiplos parâmetros de 16 baterias (simultaneamente) ao longo de ciclos de carga e descarga. Além disso, o sistema é capaz de ser ajustado (via *software* e *hardware*) para definir os parâmetros de carregamento que se deseja testar.

A partir do estudo aprofundado sobre baterias secundárias, em especial baterias de íon-lítio, foi possível atingir o segundo objetivo específico desta dissertação, que era caracterizar as baterias utilizadas nos testes, de modo a ser possível testar como alterações de parâmetro podem afetar a saúde de baterias de íon-lítio. O sistema de testes é de fácil utilização, sendo possível implementá-lo em máquinas de sistemas de compartilhamento de energia móvel, alcançando, deste modo, mais um dos objetivos específicos. Assim, as próprias máquinas que armazenam e recarregam as baterias podem coletar os dados necessários para a sua estimativa do SoH. Deste modo, o modelo proposto pode ser embarcado em sistemas envolvendo *battery swap*.

O objetivo geral desta dissertação foi alcançado, visto que o modelo proposto é de fácil implementação, tem baixo custo computacional, utiliza parâmetros de fácil medição e possui erro compatível com o encontrado na literatura e satisfatório para os objetivos pretendidos neste trabalho. Para obter melhores resultados, foram construídas 3 redes neurais GRU idênticas, alterando-se apenas os dados recebidos para treinamento de acordo com a corrente de carga na fase de corrente constante. Entretanto, o número de dados disponíveis para treinamento ficou pequeno para as redes 1 e 3. Para sanar este problema, uma quarta rede neural GRU foi construída, com todos os dados disponíveis para treinamento, independente da corrente de carga. Deste modo, o modelo é capaz de identificar qual rede neural obteve melhor desempenho para ser a resposta de saída.

O trabalho teve como limitação o baixo número de baterias disponíveis para serem utilizados no sistema de medição. Por esta razão, não foi possível realizar experimentos com uma maior diversidade de mudança de parâmetros da bateria. Além disso, a perda

de qualquer bateria por motivos de mal funcionamento faz com que a rede neural perca dados para treinamento, o que pode comprometer o desempenho do modelo. Este fato ocorreu com a bateria 13, que teve de ser substituída por mau funcionamento. Caso ocorresse com mais alguma bateria do grupo 4, talvez fosse inviável utilizar o modelo para estimar o SoH de baterias submetidas a 3 A de corrente (na fase de carga em corrente constante).

O diferencial do modelo proposto em relação aos demais trabalhos encontrados na literatura, são os parâmetros utilizados e o baixo custo computacional, mesmo sendo utilizado um método baseado em dados para a construção do modelo proposto. Por não utilizar nenhum parâmetro específico de baterias de íon-lítio (como aspectos construtivos), o modelo pode ser utilizado para baterias de outros tipos aos estudados nesta dissertação, desde que haja um banco de dados para treinamento da rede neural. O modelo também se diferencia dos demais trabalhos por utilizar o SoC da bateria para definir o SoH e não a capacidade total. Isto dá liberdade para que o SoH da bateria seja estimado a partir de qualquer nível de descarga da bateria, não sendo necessário descarregar a bateria completamente. Isto facilita ainda mais a utilização do modelo.

O modelo foi capaz de atender às demandas que este tipo de operação requer, como baixo custo e fácil implementação. Este trabalho também foi importante para conhecer como diversos parâmetros da bateria que influenciam sua vida útil, de modo especial foi possível estudar o comportamento de baterias utilizadas para uso em smartphones.

Como recomendações para trabalhos futuros, faz-se necessário compor um banco de dados maior para treinamento da rede neural. Com isto, espera-se que o erro alcançado seja menor, mantendo todos os benefícios do modelo já apontados anteriormente. Recomenda-se testar apenas uma rede neural GRU quando disponíveis mais dados para treinamento da rede e comparar com os resultados obtidos por meio de um modelo composto por 4 redes neurais GRU. Também é necessário levar em conta a temperatura ambiente como um parâmetro a ser considerado para a construção do modelo. Também é recomendado realizar trabalhos com outros tipos de testes nas baterias para validar a hipótese de que o modelo proposto pode ser utilizado para baterias de outros tipos e aplicações mantendo desempenho semelhante. Também é recomendada a ampliação do sistema de testes, sendo adicionados novos grupos de baterias com corrente de carga diferentes, podendo ser aplicado também em sistemas de carregamento rápido. Recomenda-se o estudo de baterias submetidas a processos de carregamento rápido para entender seu comportamento e se estimar seu SoH. Também é recomendado como

trabalho futuro o cálculo das incertezas de medição da saída da rede neural. Por fim, é recomendado integrar o modelo proposto a um sistema de *battery swap* e testar a previsão do modelo por meio de *machine learning*.

ALTAF, F.; EGARDT, B. **Gain-Scheduled Control of Modular Battery for Thermal and State-of-Charge Balancing**. In: Proceedings Paper. 8th IFAC Symposium on Advances in Automotive Control (AAC), 2016. P. 62-69

ALTAF, F.; EGARDT, B., Comparative Analysis of Unipolar and Bipolar Control of Modular Battery for Thermal and State-of-Charge Balancing. **IEEE Transactions on Vehicular Technology**, v.66, n.4, p.2927-2941, 2017

ALTAF, F; EGARDT, B; MARDH, L. J. Load Management of Modular Battery Using Model Predictive Control: Thermal and State-of-Charge Balancing. **IEEE Transactions on Control Systems Technology**, v.25, n.1, p.47-62, 2017

ANANTO, P.; SYABANI, F.; INDRA, W.D.; WAHYUNGGORO, O.; CAHYADI, A. I. **The State Of Health of Li-Po Batteries Based on the Battery's Parameters and a Fuzzy Logic System**. In: 2013 Joint International Conference on Rural Information & Communication Technology and Electric-Vehicle Technology (rICT & ICeV-T), 2013

BARILLAS, J. B.; LI, J.; GÜNTHER, C.; DANZER, M. A. A comparative study and validation of state estimation algorithms for Li-ion batteries in battery management systems. **Applied Energy**, v.155, p.455-462, 2015

BATTERY UNIVERSITY. **BU-205, Types of Lithium-Ion Batteries**. 2018a. Disponível em <https://batteryuniversity.com/learn/article/types_of_lithium_ion> Acesso em: 15 out 18.

BATTERY UNIVERSITY. **BU-213, Cycle Performance of NiCd, NiMH and Li-Ion Batteries**. 2016. Disponível em <https://batteryuniversity.com/learn/article/cycle_performance_of_nicd_nimh_and_li_ion> Acesso em: 15 out 18.

BATTERY UNIVERSITY. **BU-409, Charging Lithium-Ion Batteries**. 2018b. Disponível em <https://batteryuniversity.com/learn/article/charging_lithium_ion_batteries> Acesso em: 15 out 18.

BATTERY UNIVERSITY. **BU-501, Basics about Discharging**. 2017. Disponível em <https://batteryuniversity.com/learn/article/discharge_methods> Acesso em: 15 out 18.

BATTERY UNIVERSITY. **BU-501a, Discharge Characteristics of Li-Ion Batteries**. 2018c. Disponível em <https://batteryuniversity.com/learn/article/discharge_characteristics_li> Acesso em: 15 out 18.

BATTERY UNIVERSITY. **BU-808, How to Prolong Lithium-based Batteries**.2017. Disponível em https://batteryuniversity.com/learn/article/how_to_prolong_lithium_based_batteries> Acesso em: 15 out 18.

BERECIBAR, M.; DEVRIENDT, F.; DUBARRY, M.; VILLARREAL, I.; OMAR, N.; VERBEKE, W.; MIERLO, J. V. Online state of health estimation on NMC cells based on predictive analytics. **Journal of Power Sources**, v. 320, p. 239-250, 2016.

BRAGA, A. P.; LUDENIR, T. B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais: teorias e aplicações. Livros Técnicos e Científicos**, Rio de Janeiro. 2007.

BRONDANI, M. F. **Modelagem Matemática do Tempo de Vida de Baterias de Lítio Íon Polímero utilizando Algoritmos Genéticos**. Dissertação (Mestrado em modelagem matemática) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul. Unijuí, p. 102. 2015

CABANA, J.; MONCONDUIT, L.; LARCHER, D.; PALACIN, M. R. Beyond Intercalation-Based Li-Ion Batteries: The State of the Art and Challenges of Electrode Materials Reacting Through Conversion Reactions. **Advanced Materials**, v.22, n.35, p.170-192, 2010

CAMARGO, C.; IMPINNISI, P. R.; ANDRADE, J. Battery storage system for customer electricity applications. **Espaço Energia**, n.21, p.1-11, 2014

CAO, M.; ZHANG, T.; YU, B.; LIU, Y. A Method for Interval Prediction of Satellite Battery State of Health Based on Sample Entropy. **IEEE Access**, v. 7, p. 141549-141561, 2019.

CASTRO, B. H. R.; BARROS, D. C.; VEIGA, S. G. Baterias automotivas: panorama da indústria no Brasil, as novas tecnologias e como os veículos elétricos podem transformar o mercado global. BNDES Setorial, Rio de Janeiro, n. 37, p. 443–396, 2013.

CHAOUI, H.; IBE-EKEOCHA, C. C. State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks. **IEEE Transactions on Vehicular Technology**, v.66, n.10, p.8773-8783, 2017

CHAOUI, H.; IBE-EKEOCHA, C. C. State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks. **IEEE Transactions on Vehicular Technology**, v. 66, n. 10, p. 8773-8783, 2017.

CHARKHGARD, M.; FARROKHI, M. State-of-Charge Estimation for Lithium-Ion Batteries Using Neural Networks and EKF. **IEEE Transactions on Industrial Electronics**, v.57, n.12, p.4178-4187, 2010

CHEMALI, E.; KOLLMEYER, P. J.; PREINDL, M.; EMADI, A. State-of-charge estimation of Li-ion batteries using deep neural networks: A machine learning approach. **Journal of Power Sources**, v.400, p.242-255, 2018

CHEN, Z.; SONG, X.; XIAO, R.; SHEN, J.; XIA, X. (2019). State of Health Estimation for Lithium-Ion Battery Based on Long ShortTerm Memory Networks. **DEStech Transactions on Environment, Energy and Earth Sciences**, 2019.

CHEN, Z.; XUE, Q.; XIAO, R.; LIU, Y.; SHEN, J. State of Health Estimation for Lithium-Ion Batteries Based on Fusion of Autoregressive Moving Average Model and Elman Neural Network. **IEEE Access**, p. 1-1, 2019.

CHIANG, Y.; SEAN, W. **Dynamical estimation of State-of-Health of batteries by using adaptive observer**. In: *2nd International Conference on Power Electronics and Intelligent Transportation System (PEITS)*, 2009, Shenzhen, China, p. 110-115.

CUI, X.; HU, T. State of Health Diagnosis and Remaining Useful Life Prediction for Lithium-ion Battery Based on Data Model Fusion Method. **IEEE Access**, v. 8, p. 207298-207307, 2020.

DAI, H.; ZHAO, G.; LIN, M.; WU, J.; ZHENG, G. A Novel Estimation Method for the State of Health of Lithium-Ion Battery Using Prior Knowledge-Based Neural Network and Markov Chain. **IEEE Transactions on Industrial Electronics**, v. 66, n. 10, p. 7706-7716, 2018.

EL MEJDOUBI, A.; OUKAOUR, A.; CHAOUI, H.; GUALOUS, H.; SABOR, J.; SLAMANI, Y. State-of-Charge and State-of-Health Lithium-Ion Batteries' Diagnosis According to Surface Temperature Variation. **IEEE Transactions on Industrial Electronics**, v. 63, n.4, p.2391-2402, 2016.

EOM, S.; KIM, M.; KIM, I.; MOON, S.; SUN, Y.; KIM, H. Life prediction and reliability assessment of lithium secondary batteries. **Journal of Power Sources**, v.174, n.2, p.954-958

ERLANGGA, G.; PERWIRA, A.; WIDYOTRIATMO, A. **State of charge and state of health estimation of lithium battery using dual kalman filter method**. In: 2018 International Conference on Signals and Systems (ICSigSys). 2018

FAN, Y.; CHEN, X.; LEGUT, D.; ZHANG, Q. Modeling and theoretical design of next-generation lithium metal batteries. **Energy Storage Materials**, v.16, p.169-193

FENG, F.; LU, R.; ZU, C. A combined state of charge estimation method for lithium-ion batteries used in a wide ambient temperature range. **Energies**, v.7, n.5, p.3004-3032, 2014

FENG, X.; SUN, J.; OUYANG, M.; HE, X.; LU, L.; HAN, X.; FANG, M.; PENG, H. Characterization of large format lithium-ion battery exposed to extremely high temperature. **Journal of Power Sources**, v.272, p.457-467, 2014

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes Neurais Artificiais: princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v.1, n.13, p.47-57, 2016

FORTENBACHER, P.; MATHIEU, J.; ANDERSSON, G. **Modeling, Identification, and Optimal Control of Batteries for Power System Applications**. In: 2014 Power Systems Computation Conference, 2014

GALEOTTI, M.; CINÀ, L.; GIAMMANCO, C.; CORDINER, S.; DI CARLO, A. Performance analysis and SOH (state of health) evaluation of lithium polymer batteries through electrochemical impedance spectroscopy. **Energy**, v.89, p.678-686, 2015

GREY, C. P.; TARASCON, J. M. Sustainability and in situ monitoring in battery development. **Nature Materials**, v.16, n.1, p.45-56, 2017

GUO, P.; CHENG, Z.; YANG, L. A data-driven remaining capacity estimation approach for lithium-ion batteries based on charging health feature extraction. **Journal of Power Sources**, v. 412, p. 442-450, 2019.

HANNAN, M. A.; LIPU, M. S. H.; HUSSAIN, A.; MOHAMED, A. A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations. **Renewable and Sustainable Energy Reviews**, v.78, p.834-854, 2017

HE, H.; XIONG, R.; FAN, J. Evaluation of Lithium-Ion Battery Equivalent Circuit Models for State of Charge Estimation by an Experimental Approach. **Energies**, v.4, p.582-598, 2011

HOW, D. N. T.; HANNAN, M. A.; HOSSAIN LIPU, M. S.; KER, P. J. State of Charge Estimation for Lithium-Ion Batteries Using Model-Based and Data-Driven Methods: A Review. **IEEE Access**, v. 7, p. 136116-136136, 2019.

HSIEH, G.; CHEN, L.; HUANG, K. **Fuzzy-Controlled Active State-of-Charge Controller for Fastening the Charging Behavior of Li-ion Battery**. In: IECON'99. Conference Proceedings. 25th Annual Conference of the IEEE Industrial Electronics Society (Cat. No.99CH37029), 1999

HSIEH, G.; CHEN, L.; HUANG, K. Fuzzy-Controlled Li-Ion Battery Charge System with Active State-of-Charge Controller. **IEEE Transactions on Industrial Electronics**, v.48, n.3, p.585-593, 2001

HU, X.; YUAN, H.; ZOU, C.; LI, Z.; ZHANG, L. Co-Estimation of State of Charge and State of Health for Lithium-Ion Batteries Based on Fractional-Order Calculus. **IEEE Transactions on Vehicular Technology**, v. 67, n. 11, p. 10319-10329, 2018.

HU, Y.; YURKOVICH, S. Battery cell state-of-charge estimation using linear parameter varying system techniques. **Journal of Power Sources**, v.198, p.338-350, 2012

HUANG, H. et al. Electrochemical characterization of commercial lithium manganese oxide powders. **Solid State Ionics**, v.127, n.1-2, p.31-42, 2000

HAYKIN, S. **Redes Neurais-Princípios e Práticas**. BOOKMAN, São Paulo, 2ª ed. 2001. 900p

IEEE. **IEEE Guide for the Characterization and Evaluation of Lithium-Based Batteries in Stationary Applications**, 2018. New York, 2017. 47 p.

INSTITUTO NEWTON BRAGA. ART1522: Carregador de baterias simples. 2017. Disponível em: <<https://www.newtoncbraga.com.br/index.php/projetos/12993-carregador-de-baterias-simples-art1522.html>> Acesso em: 16 out 18.

INTERNATIONAL ELECTROTECHNICAL COMMISSION. IEC 61960-3: Secondary cells and batteries containing alkaline or other non-acid electrolytes - Secondary lithium cells and batteries for portable applications. 2017.

INFANTE, W. F.; MA, J.; CHI, Y. **Operational strategy and load profile sensitivity analysis for an electric vehicle battery swapping station**. In: 2016 IEEE International Conference on Power System Technology (POWERCON), Wollongong, NSW, Australia, p. 1-6, 2016.

ITO, A.; KAWASHIMA, A.; SUZUKI, T.; INAGAKI, S.; YAMAGUCHI, T.; ZHOU. Model Predictive Charging Control of In-Vehicle Batteries for Home Energy Management Based on Vehicle State Prediction. **IEEE Transactions on Control Systems Technology**, v.26, n.1, p.51-64, 2018

JIA, J.; LIANG, J.; SHI, Y.; WEN, J.; PANG, X.; ZENG, J. SOH and RUL Prediction of Lithium-Ion Batteries Based on Gaussian Process Regression with Indirect Health Indicators. **Energies**, v. 13, n. 2: 375, 2020.

JIANG, F.; LIU, K.; WANG, Z.; TONG, X.; GUO, L. Theoretical analysis of lithium-ion battery failure characteristics under different states of charge. **Fire and Materials**, v.42, n.6, p.680-686, 2018

KANG, L. W.; ZHAO, X.; MA, J. A new neural network model for the state-of-charge estimation in the battery degradation process. **Applied Energy**, v. 121, pp. 20-27, 2014.

KHAN, N.; ULLAH, F. U. M.; AFNAN; ULLAH, A.; LEE, M. Y.; BAIK, S. W. Batteries State of Health Estimation via Efficient Neural Networks With Multiple Channel Charging Profiles. **IEEE Access**, v. 9, p. 7797-7813, 2021.

KIM, J. *et al.* Data-Driven State of Health Estimation of Li-Ion Batteries With RPT-Reduced Experimental Data. **IEEE Access**, v. 7, p. 106987-106997, 2019.

KIM, J.; CHO, B. H. State-of-Charge Estimation and State-of-Health Prediction of a Li-Ion Degraded Battery Based on an EKF Combined With a Per-Unit System. **IEEE Transactions on Vehicular Technology**, v.60, n.9, 2011

LANDI, M.; GROSS, G. Measurement Techniques for Online Battery State of Health Estimation in Vehicle-to-Grid Applications. **IEEE Transactions on Instrumentation and Measurement**, v. 63, n. 5, p. 1224-1234, 2014.

LASHWAY, C. R.; IDOWU, P. A test system for advanced lead acid battery state-of-charge and state-of-health research. **Journal of Smart Grid and Clean Energy**, v. 5, n. 1, pp. 41-55, 2016.

LEE, J.; CHOI, W. Novel state-of-charge estimation method for lithium Polymer batteries using electrochemical impedance spectroscopy. **Journal of Power Electronics**, v.11, n.2, p.237-243, 2012

LI, L.; REN, Y.; WANG, C.; JEN, C. A new method to estimate the state of charge of the green battery. **Microelectronics Reliability**, v.79, p.306-313, 2017

LI, Y.; SHENG, H.; CHENG, Y.; STROE, D. TEODORESCU, R. State-of-health estimation of lithium-ion batteries based on semi-supervised transfer component analysis. **Applied Energy**. V. 277, 2020.

LI, Y.; STROE, D.; CHENG, Y.; SHENG, H.; SUI, X.; TEODORESCU, R. On the feature selection for battery state of health estimation based on charging–discharging profiles. **Journal of Energy Storage**, v. 33, 2021.

LI, Z.; HUANG, J.; LIAW, B. Y.; ZHANG, J. On state-of-charge determination for lithium-ion batteries. **Journal of Power Sources**, v.348, p.281-301, 2017

LIN, H.; LIANG, T.; CHEN, S. Estimation of Battery State of Health Using Probabilistic Neural Network. **IEEE Transactions on Industrial Informatics**, v. 9, n. 2, p. 679-685, 2012.

LINDA, O.; WILLIAM, E.J.; HUFF, M.; MANIC, M.; GUPTA, V.; NANCE, J.; HESS, H.; RUFUS, F.; THAKKER, A.; GOVAR, J. **Intelligent Neural Network Implementation for SOCI Development of Li/CFx Batteries**. In: 2009 2nd International Symposium on Resilient Control Systems, 2009

LIU, J.; LI, G.; FATHY, H. K. An Extended Differential Flatness Approach for the Health-Conscious Nonlinear Model Predictive Control of Lithium-Ion Batteries. **IEEE Transactions on Control Systems Technology**, v.25, n.5, p.1882-1889, 2017

LOPES, J. T. B. Estrutura e propriedades dos materiais. Apostila. Disponível em: <<http://jorgeteofilo.files.wordpress.com/2011/08/epm-apostila-capc3adtulo09-propriedades.pdf>>. Acesso em 12 nov 2018.

MCCURLIE, L.; PREINDL, M.; EMADI, A. Fast Model Predictive Control for Redistributive Lithium-Ion Battery Balancing. **IEEE Transactions on Industrial Electronics**, v.64, n.2, p.1350-1357, 2017

MIT ELETRIC VEHICLE TEAM. A Guide to Understanding Battery Specifications, 2008. Convênio.

NG, K. S.; MOO, C.; CHEN, Y.; HSIEH, Y. Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries. **Applied Energy**, v.86, n.9, p.1506-1511, 2009

PATIL, C.; NAGHSHTABRIZI, P.; VERMA, R.; TANG, Z.; SMITH, K.; SHI, Y. **Optimal Battery Utilization Over Lifetime For Parallel Hybrid Electric Vehicle to Maximize Fuel Economy***. In: 2016 American Control Conference (ACC), 2016

PILATOWICZ, G.; MARONGIU, A.; DRILLKENS, J.; SINHUBER, P.; SAUER, D. U. A critical overview of definitions and determination techniques of the internal resistance using lithium-ion, lead-acid, nickel metal-hydride batteries and electrochemical double-layer capacitors as examples. **Journal of Power Sources**, v.296, p.365,376, 2015

PLACKE, T.; SCHMUCH, R.; DÜHNEN, S.; WINTER, M. Lithium-Ion, Lithium Metal and Alternative Rechargeable Battery Technologies: The Odyssey for High Energy Density. **Journal of Solid State Electrochemistry**, 2017.

REMMLINGER, J.; BUCHHOLZ, M.; MEILER, M.; BERNREUTER, P.; DIETMAYER, K. State-of-health monitoring of lithium-ion batteries in electric vehicles by on-board internal resistance estimation. **Journal of Power Sources**, v.196, n.12, p.5357-5363, 2011

SASAKI, T.; UKYO, Y.; NOVÁK, P. Memory effect in a lithium-ion battery. **Nature Materials**, v.12, n.6, p. 569-575, 2013

SEMANJSKI, I; GAUTAMA, S. Forecasting the State of Health of Electric Vehicle Batteries to Evaluate the Viability of Car Sharing Practices. **Energies**, v.9, n. 12: 1025, 2016.

SHAO, S.; BI, J.; YANG, F.; WEI, G. On-line estimation of state-of-charge of Li-ion batteries in electric vehicle using the resampling particle filter. **Transportation Research Part D-Transport And Environment**, v.32, p.207-217, 2014

SHEN, P.; OUYANG, M.; LU, L.; LI, J.; FENG, X. The Co-estimation of State of Charge, State of Health, and State of Function for Lithium-Ion Batteries in Electric Vehicles. **IEEE Transactions on Vehicular Technology**, v.67, n.1, p.92-103, 2018

SHEN, P.; OUYANG, M.; LU, L.; LI, J.; FENG, X. The Co-estimation of State of Charge, State of Health, and State of Function for Lithium-Ion Batteries in Electric Vehicles. **IEEE Transactions on Vehicular Technology**, v. 67, n. 1, p. 92-103, 2018.

SHI, W. et al. Influence of memory effect on the state-of-charge estimation of large-format Li-ion batteries based on LiFePo₄ cathode. **Journal of Power Sources**, p. 55-59, 2016

SHU, X.; LI, G.; ZHANG, Y.; SHEN, J.; CHEN, Z.; LIU, Y. Online diagnosis of state of health for lithium-ion batteries based on short-term charging profiles. **Journal of Power Sources**, v. 471, 2020.

SMITH, K.; SHI, Y.; SANTHANAGOPALAN, S. **Degradation mechanisms and lifetime prediction for lithium-ion batteries – A control perspective**. In: 2015 American Control Conference (ACC), 2015

SUN, K.; SHU, Q.; **Overview of the Types of Battery Models**. In: Proceedings of the 30th Chinese Control Conference, 2011

TIAN, H.; QIN, P.; LI, Q.; ZHAO, Z. A review of the state of health for lithium-ion batteries: Research status and suggestions. **Journal of Cleaner Production**, v.261, 2020.

TONG, S.; LACAP, J. H.; PARK, J. W. Battery state of charge estimation using a load-classifying neural network. **Journal of Energy Storage**, v. 7, p. 236-243, 2016.

TOPAN, P.; RAMADAN, M. N.; FATHONI, G.; CAHYADI, A. I.; WAHYUNGGORO, O. **State of Charge (SOC) and State of Health (SOH) Estimation on Lithium Polymer Battery via Kalman Filter**. In: 2016 2nd International Conference on Science and Technology-Computer (ICST). 2016

TORCHIO, M.; MAGNI, L.; BRAATZ, R.D.; RAIMONDO, D.M. **Optimal Charging of a Li-ion Cell: A Hybrid Model Predictive Control Approach**. In: 2016 IEEE 55th Conference on Decision and Control (CDC), 2016

TORCHIO, M.; MAGNI, L.; BRAATZ, R.D.; RAIMONDO, D.M. **Optimal Health-aware Charging Protocol for Lithium-ion Batteries: A Fast Model Predictive Control Approach**. In: Proceedings Paper. 11th IFAC Symposium on Dynamics and Control of Process Systems including Biosystems, 2016.

TRAN, N. et al. SOC estimation of multiple lithium-ion battery cells in a module using a nonlinear state observer and online parameter estimation. **Energies**, v.10, n.7, p.1-14, 2018

UNGUREAN, L.; MICEA, M. V; CÂRSTOIU, G. Online state of health prediction method for lithium-ion batteries, based on gated recurrent unit neural networks. **International Journal of Energy Research**, v. 44, n. 8, pp. 6767-6777, 2020.

VERGARA, S. C. **Metodologia do trabalho científico**. São Paulo: Cortez, 2002.

VIDAL, C.; MALYSZ, P.; KOLLMEYER, P.; EMADI, A. Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art. **IEEE Access**, v. 8, p. 52796-52814, 2020.

WAAG, W.; KÄBITZ, S.; SAUER, D. U. Experimental investigation of the lithium-ion battery impedance characteristic at various conditions and aging states and its influence on the application. **Applied Energy**, v.102, p.885-897, 2013

WANG, T.; CHEN, S.; REN, H.; ZHAO, Y. Model-based unscented Kalman filter observer design for lithium-ion battery state of charge estimation. **International Journal of Energy Research**, v.42, n.4, p.1603-1614, 2017

WOOD III, D. L.; LI, J.; DANIEL, C. Prospects for reducing the processing cost of lithium-ion batteries. **Journal of Power Sources**, v.275, p.234-242, 2015

XIA, Z.; QAHOUQ, J. A. **State of Health Estimation of Lithium-Ion Batteries Using Neuron Network and 1kHz Impedance Data**. In: *IEEE Energy Conversion Congress and Exposition (ECCE)*, 2020, Detroit, MI, USA, p. 1968-1972.

XIONG, R.; LI, L.; JINPENG, T. Towards a smarter battery management system: A critical review on battery state of health monitoring methods. **Journal of Power Sources**. V. 405, p. 18-29, 2018.

XIONG, W.; MO, Y.; YAN, C. Online State-of-Health Estimation for Second-Use Lithium-Ion Batteries Based on Weighted Least Squares Support Vector Machine. **IEEE Access**, v. 9, p. 1870-1881, 2021.

XU, K.; LI, H.; YANG, H. D. Local-Properties-Embedding-Based Nonlinear Spatiotemporal Modeling for Lithium-Ion Battery Thermal Process. **IEEE Transactions on Industrial Electronics**, v.65, n.12, p.9767-9776, 2018

YAMIN, R.; RACHID. **A.Embedded state of charge and state of health estimator based on Kalman filter for electric scooter battery management system**. In: 2014 IEEE Fourth International Conference on Consumer Electronics Berlin (ICCE-Berlin). 2014

YANG, J.; XIA, B.; HUANG, W.; MI, C. **On-board state-of-health estimation based on charging current analysis for LiFePO4 batteries**. In: 2017 IEEE Energy Conversion Congress and Exposition (ECCE). 2017

YANG, J.; XIA, B.; HUANG, W.; MI, C. **On-board state-of-health estimation based on charging current analysis for LiFePO4 batteries**. In: *IEEE Energy Conversion Congress and Exposition (ECCE)*, 2017, Cincinnati, OH, p. 5229-5233.

YANG, N.; FENG, J.; SUN, Q.; LIU, T.; ZHONG, D. **Online estimation of state-of-health for lithium-ion batteries based on charge curves**. In: 2016 11th International Conference on Reliability, Maintainability and Safety (ICRMS). 2016

YOU, G.; PARK, S.; OH, D. Diagnosis of Electric Vehicle Batteries Using Recurrent Neural Networks. *IEEE Transactions on Industrial Electronics*, v. 64, n. 6, p. 4885-4893, 2017.

YU, J. State-of-Health Monitoring and Prediction of Lithium-Ion Battery Using Probabilistic Indication and State-Space Model. **IEEE Transactions on Instrumentation and Measurement**, v.64, n.11, p.2937-2949, 2015

ZENATI, A.; DESPREZ, P.; RAZIK, H.; RAEL, S. **A methodology to assess the State of Health of lithium-ion batteries based on the battery's parameters**

and a Fuzzy Logic System. In: IEEE International Electric Vehicle Conference, 2012, Greenville, SC, USA, p. 1-6.

ZEYUAN, L.; YUNLONG, S.; NAXIN, C.; CHENGHUI, Z. **The Prediction Method for Battery Open Circuit Voltage Based on GM (1, 1) Grey Model.** In: 2015 34th Chinese Control Conference (CCC), 2015

ZHANG, Y.; ZHANG, H.; TIAN, Z. **The Application of Gaussian Process Regression in State of Health Prediction of Lithium Ion Batteries.** In: *IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 2018, Chongqing, China, p. 515-519.

ZHENG, L.; ZHU, J.; WANG, G.; LU, D.D.; MCLEAN, P.; HE, T. **Model predictive control based balancing strategy for series-connected lithium-ion battery packs.** In: 2017 19th European Conference on Power Electronics and Applications (EPE'17 ECCE Europe), 2017

ZHENG, Y.; OUYANG, M.; HAN, X.; LU, L.; JIANQIU, L. Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles. **Journal of Power Sources**, v.377, p.161-188, 2018

ZHONG, L.; PEI, M. Optimal Design for a Shared Swap Charging System Considering the Electric Vehicle Battery Charging Rate. **Energies** 13, n. 5: 1213, 2020.

ZHOU, Y.; HUANG, M.; CHEN, Y.; TAO, Y. A novel health indicator for on-line lithium-ion batteries remaining useful life prediction. **Journal of Power Sources**, 2016.

ZHOU, Y.; HUANG, M.; PECHT, M. **An Online State of Health Estimation Method for Lithium-ion Batteries Based on Integrated Voltage.** In: *IEEE International Conference on Prognostics and Health Management (ICPHM)*, 2018, Seattle, WA, USA, 2018, p. 1-5.

ZHU, Y.; YAN, F.; KANG, J.; DU, C. **State of Charge Estimation Based on State of Health Correction for Lithium-ion Batteries.** In: 2018 IEEE Intelligent Vehicles Symposium (IV). 2018

ZOU, C.; KLINTBERG, A.; WEI, Z.; FRIDHOLM, B.; WIK, T.; EGARDT, B. Power capability prediction for lithium-ion batteries using economic nonlinear model predictive control. **Journal of Power Sources**, v.396, p.580-589, 2018

ZOU, C.; MANZIE, C.; NEŠIĆ, D. Model Predictive Control for Lithium-Ion Battery Optimal Charging. **IEEE/ASME Transactions on Mechatronics**, v.23, n.2, p.947-957, 2018