

**UNIVERSIDADE FEDERAL DA PARAÍBA
CAMPUS I - JOÃO PESSOA**

THOMAS MATEUS SANTANA NUNES

**ALGORITMO PARA ESTIMAÇÃO DO ESTADO DE CARGA
E ESTADO DE SAÚDE DE BATERIAS DE LÍTIO-ÍON
UTILIZANDO MACHINE LEARNING**

JOÃO PESSOA

2019

THOMAS MATEUS SANTANA NUNES

ALGORITMO PARA ESTIMAÇÃO DO ESTADO DE
CARGA E ESTADO DE SAÚDE DE BATERIAS DE
LÍTIO-ÍON UTILIZANDO MACHINE LEARNING

**Trabalho de Conclusão de Curso sub-
metido à Universidade Federal da Pa-
raíba, como pré-requisito para obten-
ção do grau Bacharel em Engenharia
de Elétrica.**

João Pessoa, Setembro de 2019

Catálogo na publicação
Seção de Catalogação e Classificação

N972a Nunes, Thomas Mateus Santana.

ALGORITMO PARA ESTIMAÇÃO DO ESTADO DE CARGA E ESTADO DE SAÚDE DE BATERIAS DE LITHIUM-ION UTILIZANDO MACHINE LEARNING / Thomas Mateus Santana Nunes. - João Pessoa, 2019.

72 f. : il.

Orientação: Juan Moises Mauricio Villanueva.
Monografia (Graduação) - UFPB/CEAR.

1. Preditor, Lithium-Ion, SoC, SoH, Machine Learning. I. Villanueva, Juan Moises Mauricio. II. Título.

UFPB/BC

UNIVERSIDADE FEDERAL DA PARAÍBA

THOMAS MATEUS SANTANA NUNES

Orientador(a): Dr. Juan Moises Mauricio
Villanueva
Universidade Federal da Paraíba - UFPB

Examinador: Ma. Maria de Fátima Rosolem
Centro de Pesquisa e Desenvolvimento em
Telecomunicações (CPQD)

Examinador: Dr. Lucas Vinícius Hartmann
Universidade Federal da Paraíba - UFPB

Examinador: Dr. Fabiano Salvadori
Universidade Federal da Paraíba - UFPB

João Pessoa, 24 de setembro de 2019

Agradecimentos

Primeiramente agradeço a Deus por me permitir chegar até este momento e principalmente por me proporcionar muitas situações de aprendizado durante esta fase da minha vida.

Aos meus pais, por todos os ensinamentos e valores que me foram passados até hoje, pelo apoio constante e absoluto, bem como por todo amor e carinho. Sem eles, eu jamais teria conquistado meus objetivos. Ao meu irmão, por todo apoio e momentos de alegria que me proporcionou.

A todos os membros da minha família que fizeram parte da minha trajetória.

Ao formulário Elétrico UFPB, por me proporcionar muito aprendizado e motivação para continuar no curso. Por principalmente me proporcionar uma aproximação com a área de veículos elétricos.

Aos meus amigos Antônio Felix, Felipe Fauze, Luan Caruzo, Renato Fonseca, Dielço Jorge e Deybson Santos pelo companheirismo e por terem me proporcionado muitos momentos de alegria durante a graduação.

Aos meus amigos João Vitor e Juan Carlos por sempre me ajudarem nos momentos de dificuldade, pela boa convivência e pelos momentos de lazer.

Aos meus amigos Luan, Heelijonson, Marcelo, Vitor, Igor, Wellington, Antônio e Donivan pelos momentos de lazer e alegria na banda Só refrão.

Um agradecimento especial ao meu amigo Abymael Oliveira por se mostrar muito leal, por sempre me motivar e aconselhar a buscar melhorar a cada dia.

Ao meu amigo Caio Luiz, por ter me ajudado desde o início dos meus estudos na área de baterias.

Ao meu orientador professor Juan Moisés Maurício Villanueva, por acreditar na minha capacidade, pelos bons conselhos em relação ao meu desenvolvimento pessoal e profissional e por ser extremamente solícito.

Por fim, agradeço a todos aqueles que de modo direto ou indireto me ajudaram durante minha graduação.

Resumo

Nos dias atuais, há uma crescente demanda de diversos dispositivos eletrônicos que dependem de baterias como fonte de alimentação, fato que ocorre em diversos setores, como por exemplo, nos mercados automobilístico, eletroeletrônico, aeroespacial, micro geração de energia e entre outros. Desta forma, há uma forte tendência no desenvolvimento de tecnologias inovadoras relacionadas a células de bateria, possibilitando um progresso excelente em seu desempenho, autonomia e sua geometria. Um problema que tornou-se crucial no processo de aprimoramento delas é o tempo de vida útil, desenvolver tecnologias que elevem o período de vida útil dessas células não é uma tarefa fácil devido ao comportamento não-linear da curva de tensão delas, torna a estimação do tempo de vida útil bastante complexo. Neste cenário, este Trabalho de Conclusão de Curso tem como objetivo principal o desenvolvimento de algoritmos para a estimação do Estado de Carga (SoC) e Estado de Saúde (SoH) de baterias, cuja implementação será baseada em algoritmos de Aprendizado em Máquina (Machine Learning). No processo de treinamento e teste foi utilizado um banco de dados real mantido pela NASA e nele está presente diversos ensaios de baterias de Lithium-Ion com características propícias para o aproveitamento na concepção de modelos preditores.

Palavras-chave: Preditor, Estimador, Lithium-Ion, Estado de Carga, Estado de Saúde, NARX, Machine Learning.

Abstract

Nowadays, there is a growing demand for several electronic devices that depend on batteries as a power source, a fact that occurs in various sectors, such as the automotive, electro-electronic, aerospace, power microgeneration and others markets. Thus, there is a strong trend in the development of innovative technologies related to battery cells, enabling excellent progress in their performance, range and geometry. A problem that has become crucial in their enhancement process is their lifespan, disabling the elevating technologies, or the lifespan of these cells is not an easy task due to nonlinear behavior of the stress curve on them, It becomes difficult. quite complex lifetime. In this scenario, this Course Conclusion Work has as main objective the development of algorithms for the application of Charge (SoC) and Health Status (SoH) of batteries, whose application is applied in the Machine Learning algorithm. No training and testing processes have been used in an actual NASA-maintained database and are present in several lithium-ion battery trials with features useful for harnessing predefined predictor models.

Keywords: Predictor, Estimator, Lithium-Ion, Charge Status, Health Status, NARX,

Machine Learning.

Lista de ilustrações

Figura 1 – Gráfico comparativo entre as opções de fontes de energia	24
Figura 2 – Estrutura das baterias de Chumbo-ácido	25
Figura 3 – Estrutura das baterias de NiCd	26
Figura 4 – Estrutura das baterias de NiMH	27
Figura 5 – Estrutura das baterias de auto descarga	28
Figura 6 – Estrutura do Preditor-Corretor do KF	33
Figura 7 – Diagrama de Venn em IA	35
Figura 8 – Diagrama de uma RNA básica	36
Figura 9 – Modelo de Neurônio	37
Figura 10 – Comportamento da função logsig	38
Figura 11 – Representação de problemas não-linearmente separáveis	39
Figura 12 – Modelo representativo da NARX	41
Figura 13 – Diagrama do algoritmo de [1]	44
Figura 14 – Gráfico da área sob a curva de tensão	44
Figura 15 – Visão geral do algoritmo	45
Figura 16 – Diagrama interno de blocos do algoritmo	46
Figura 17 – Exemplo de um ensaio realizado em uma bateria	48
Figura 18 – Ensaio da bateria 27	49
Figura 19 – Gráfico das variações	51
Figura 20 – Representação do Preditor de SoC	52
Figura 21 – Representação do Preditor de SoH	53
Figura 22 – Degradação da capacidade da bateria	54
Figura 23 – Diagrama da base de dados para o preditor SoC	55
Figura 24 – Diagrama do preditor de SoC	56
Figura 25 – Gráfico da desempenho da rede	57
Figura 26 – Resposta do Preditor de SoC	58
Figura 27 – Vetores de entrada da rede no primeiro teste	59
Figura 28 – Gráfico da melhor resposta	59
Figura 29 – Diagrama de blocos do Preditor de SoH	60
Figura 30 – Resposta do Preditor de SoH	61
Figura 31 – Trecho dos vetores de entrada da rede	61
Figura 32 – Trecho dos vetores de entrada da rede	62

Lista de tabelas

Tabela 1 – Especificações técnicas da bateria	47
Tabela 2 – Tabela das tensões adquiridas	71
Tabela 3 – Tabela das variações calculadas	72

Lista de abreviaturas e siglas

BMS	Sistema de Gerenciamento de Baterias (Battery Management System)
SoC	Estado de Carga (State of Charge)
SoH	Estado de Saúde (State of Health)
SoF	Estado de Função (State of Function)
NiCd	Níquel Cádmio
NiMH	Níquel Metal-Hidreto
Lithion-Ion	Íon de Lítio
HEV	Veículo Elétrico Híbrido (Hybrid Electric Vehicle)
PHEV	Veículo Elétrico Plug-in Híbrido (Plug-in Hybrid Electric Vehicle)
BoL	Começo da vida útil (Begining of Life)
EoL	Fim de Vida (End of Life)
OCV	Tensão de Circuito Aberto (OCV)
KF	Filtro de Kalman (Kalman Filter)
EKF	Filtro de Kalman Estendido (Extended Kalman Filter)
PF	Filtro de Partícula (PF)
UKF	Filtro de Kalman (Unscented Kalman Filter)
BP	Backpropagation (BP)
LM	Levenberg-Marquardt (LM)

IA	Inteligência Artificial (Artificial Intelligence)
ML	Aprendizagem em Máquina (Machine Learning)
DP	Aprendizagem Profunda (Deep Learning)
FFNN	Rede Neural Feedforward (Feedforward Neural Network)
GRNN	Rede Neural de Regressão Generalizada (Generalized Regression Neural Network)
PNN	Rede Neural Probabilística (Probabilistic Neural Network)
ANFIS	Sistema Adaptativo de Inferência Neuro-Fuzzy (Adaptive Neural Fuzzy Inference System)
NARX	Rede Auto-Regressivo Não-linear com Entradas Exógenas (Nonlinear Autoregressive Exogenous Artificial)
LSTM	Memória de Curto e Longo Prazo (LSTM)
RBFNN	Rede Neural baseada em funções radiais(Radial basis function Neural Network)
ELM	Máquina de Aprendizagem Extrema (Extreme Learning Machine)
BSA	Algoritmo de Busca Backtracking (Backtracking Search Algorithm)
RMSE	Erro Quadrático Médio (Root Mean Square Error)
MAE	Erro Absoluto Médio (Mean Absolute Error)
MAPE	Erro Percentual Absoluto Médio (Mean Absolute Percentual Error)
NASA	Administração Nacional da Aeronáutica e Espaço (National Aeronautics and Space Administration)

Sumário

1	INTRODUÇÃO	19
1.1	Problemática	21
1.1.1	Objetivo	22
1.1.1.1	Objetivo Geral	22
1.1.1.2	Objetivos Específicos	22
1.2	Organização	22
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	História da Bateria	23
2.2	Química da bateria	23
2.2.1	Chumbo-Ácido	24
2.2.2	Níquel	25
2.2.3	Lítio-íon	27
2.3	Definições importantes	29
2.4	Técnicas de determinação do SoC e SoH	30
2.4.1	Tensão de Circuito Aberto (OCV)	31
2.4.2	Coulomb Counting para SoC	31
2.4.3	Coulomb Counting para SoH	32
2.4.4	Filtros de Kalman	32
2.4.5	Algoritmos de aprendizado	34
2.4.5.1	Aprendizado em Máquina (Machine Learning)	34
2.4.5.2	Aprendizado Profundo (Deep Learning)	34
2.4.5.3	Redes Neurais	35
2.4.5.4	Redes Neurais Recorrentes	40
2.5	Estado da Arte	41
2.5.1	Algoritmos para SoC	41
2.5.2	Algoritmos para SoH	43
3	ALGORITMOS PROPOSTOS	45
3.1	Panorama geral	45
3.2	Visão interna	46
3.2.1	Base de Dados	47
3.2.2	Seleção de variáveis	50
3.2.3	Preditor de Carga (SoC)	51
3.2.4	Preditor de Saúde (SoH)	53

4	RESULTADOS	55
4.1	Preditor de SoC	56
4.1.1	Resultados do Preditor de SoC	57
4.2	Preditor de SoH	60
4.2.1	Resultados do preditor de SoH	60
5	CONCLUSÃO	63
	REFERÊNCIAS	65
	ANEXOS	69

1 Introdução

A partir da revolução industrial, sempre houve uma inclinação mundial para aproveitar cada vez mais combustíveis fósseis, tais como: gás natural, carvão e principalmente petróleo. A partir dos anos 90, começou a observar-se um crescimento gradativo da importância das fontes renováveis de energia no conjunto de matrizes energéticas que se verifica até hoje, desta forma acabaram ganhando o seu espaço em um mercado quase que exclusivamente dominado pelos combustíveis fósseis.

Nos dias atuais, o consumo energético mundial encontra-se em ascensão, de forma que a previsão é de que esse comportamento mantenha-se até 2040 [2]. Em virtude deste aumento das necessidades energéticas, ocorre paralelamente uma mudança na utilização das fontes primárias.

A crescente conscientização dos impactos ambientais provocados pelas formas convencionais de produção e consumo de energia, foi um dos principais fatores que promoveram essas mudanças nas fontes primárias. Aliado a esta conscientização, o fato das fontes de combustíveis fósseis não serem renováveis e seu custo aumentar conforme esses recursos vão se esgotando, o que proporcionou o avanço intensivo de estudos e pesquisas para a diversidade da matriz energética, implantando fontes energéticas alternativas e renováveis. No decorrer da década de 80, surgiu o conceito de desenvolvimento sustentável que busca satisfazer a demanda de recursos da geração atual sem prejudicar a capacidade das gerações futuras de satisfazerem as próprias necessidades [3]. Outro ponto extremamente importante, é a tentativa de alguns países em reduzir a sua dependência energética, já que a maioria deles estão suscetíveis a instabilidades dos países importadores de fontes energéticas como petróleo carvão e gás natural.

Com base neste conceito de desenvolvimento sustentável, surgiram inovações tecnológicas capazes de promover essa transformação das matrizes energéticas dos países. Uma inovação tecnológica resultante das políticas aplicadas pelos países em virtude desse conceito é a mobilidade elétrica, este setor recentemente tem ganhado cada vez mais espaço no mercado mundial. Em particular, os veículos elétricos são uma das ramificações da mobilidade elétrica que mais tem ganhado destaque no contexto mundial. Conforme um relatório recente, a previsão é de que os veículos elétricos tomem conta do mercado automotivo global, os quais, devem passar de 2 milhões para uma frota de mais de 56 milhões de unidades até 2040 [4].

A disseminação dos veículos elétricos no mercado mundial tem como principal efeito uma gradual redução de seus custos, sendo que o componente que representa a maior fatia desses custos em um veículo elétrico é o sistema de baterias. Ainda segundo o relatório [4],

a principal justificativa para esta projeção otimista se dá em grande parte pela queda nos preços das baterias a partir de 2010, os custos por quilowatt/hora caíram 85% devido em grande parte a melhorias no processo produtivo das indústrias proporcionando resultados próximos ao esperado, bem como uma redução nos custos de produção e no aumento nas economias de escala. Outro fator importante que deve estimular essa expansão dos veículos elétricos é o aumento da capacidade das baterias, pois conforme a capacidade aumenta a autonomia do veículo elétrico também aumenta e por consequência disso elevando o interesse do consumidor, tornando natural o investimento de entidades públicas e privadas na pesquisa e desenvolvimento de baterias.

A relevância do desenvolvimento das baterias vai além do setor de transportes, pois poderá resultar em um importante desenvolvimento no mercado de acumulação de energia. Atualmente, a energia solar é uma das fontes renováveis de energia que encontra-se em maior ascensão, tendo potencial para ser implementada nas mais diversas formas partindo da micro e minigeração até os grandes parques de energia solar. Em 2018, o número de conexões de micro e mini geração no Brasil ultrapassou a marca de 20 mil instalações, atendendo a 30 mil unidades consumidoras e representando uma potência instalada de 247,30 MW [5]. Neste contexto, normalmente em alguns horários do dia a produção de energia é maior que o consumo, assim uma das soluções encontradas para evitar esse desperdício é acumular o excedente em sistema de baterias, desta forma o micro-produtor pode ser capaz de beneficiar-se através da utilização da energia mais barata em períodos de baixo consumo, outra possibilidade de exploração dessa energia armazenada é vendê-la para a distribuidora de energia local em períodos onde a energia está mais cara.

Com evolução das tecnologias sustentáveis, houve um enorme salto de consumo das baterias, visto que, a maioria dos dispositivos atuais dependem de uma fonte de energia que os acompanhe. Assim, para suprir toda essa demanda em ritmo crescente, surgiram tecnologias relacionadas as baterias possibilitando um progresso que se deu de maneira bastante lenta. Em comparação com a Lei de Moore que dobrou a quantidade de transistores em circuitos embarcados a cada dois anos, o ganho de capacidade nas baterias de Lítio-íon foi de cerca de 8% a cada ano nas últimas duas décadas.

Nas últimas décadas, apareceram diversos tipos de químicas de baterias para suprir a demanda em várias áreas do mercado. A seguir, estão listados os principais processos químicos atualmente utilizados, sendo que cada uma tem um direcionamento onde é mais aplicada:

- Chumbo/Ácido;
- Níquel/Cádmio e Níquel Metal-Híbrido;
- Lítio-íon;

Dentre as várias químicas de baterias utilizadas atualmente, destaca-se as baterias a base de Lítio-íon devido a sua diferenciada densidade de potência volumétrica o que proporciona um volume de pacote menor quando comparado com outras químicas existentes além de uma vida útil longa. Resumidamente, a densidade de potência volumétrica de uma bateria corresponde a quantidade de energia por unidade de volume de uma fonte, no capítulo posterior a definição de densidade de potência volumétrica será melhor abordada.

1.1 Problemática

Em virtude da necessidade de sistemas de armazenamento de energia cada vez maiores, foi inevitável a indústria agregar cada vez mais baterias aos sistemas de armazenamento suprimindo esta demanda. Desta forma, observou-se que afim de manter a integridade desses sistemas era indispensável produzir tecnologias para realizar o gerenciamento e o monitoramento desses sistema de bateria. Neste contexto, surgiram os primeiros Sistemas de Gerenciamento de Baterias (BMS) que tinham como principais tarefas a estimativa em tempo real do estado de carga (SoC, do inglês State of Charge), estado de saúde (SoH, do inglês State of Health) e estado de função (SoF, do inglês State-of-Function), idade e vida útil restante da bateria, além de executar a equalização da tensão do sistema de baterias, controle de segurança e gerenciamento térmico [6]. Sucintamente, o SoC corresponde a quantidade de energia que uma bateria pode fornecer a uma carga e o SoH mensura a quantidade de vida útil restante de uma bateria, essas definições serão melhor abordadas no capítulo 2.

Diante do que foi apresentado no parágrafo anterior, o SoC e o SoH são parâmetros que tem um destaque maior, pois exigem uma dificuldade maior em suas determinações. A principal adversidade encontrada na determinação deste dois estados da bateria, decorrem do comportamento altamente não-linear delas. Em outras palavras o grande problema que tem se mostrado bastante relevante e que deve ser considerado é desenvolver algoritmos de cálculos matemáticos que consigam reproduzir com precisão o comportamento das baterias e, a partir disto, conseguir determinar com assertividade seu estado de carga atual e sua degradação. Os dispositivos de gerenciamento para sistema de baterias disponíveis no mercado produzem um erro de estimação demasiadamente grande principalmente quando trata-se de SoH, há também outros algoritmos que estimam os parâmetros com maior precisão, porém demandam uma capacidade computacional elevada inviabilizando comercialmente a produção de dispositivos com esses algoritmos [7].

Devido a problemática demonstrada acima, neste trabalho tem-se como objetivo o desenvolvimento de novos algoritmos de estimação do SoC e SoH baseados em aprendizado de máquina (em inglês, Machine Learning).

1.1.1 Objetivo

1.1.1.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver um modelo computacional baseado em Machine Learning para estimar o Estado de Carga e o Estado de Saúde de baterias.

1.1.1.2 Objetivos Específicos

Diante do desenvolvimento do trabalho e do objetivo geral apresentado a cima, destaca-se os seguintes objetivos específicos:

- Utilização de um banco de dados real, realizando um processo de tratamento para remoção de *outliers* e adequação dos vetores;
- Construção de modelos computacionais de preditores do SoC e SoH baseados em algoritmos de Machine Learning;
- Relacionar as variáveis inerentes ao processo de carga e descarga de baterias para a estimação do SoC e SoH.

1.2 Organização

O presente trabalho está organizado em seis capítulos. No primeiro capítulo, será apresentada uma introdução em relação ao tema, tratando a relevância e a motivação. Além disso, foram expostos os objetivos gerais e específicos.

O segundo capítulo, contém a fundamentação teórica e algumas considerações em relação aos tipos de químicas existentes, bem como uma abordagem as técnicas de estimação de SoC e SoH existentes, além das limitações existentes nesses algoritmos.

No terceiro capítulo, serão abordados conceitos relevantes em relação as técnicas de Machine Learning utilizadas no trabalho. Além disso, também serão feitas observações quanto aos dados utilizados no desenvolvimento, bem como o processo de tratamento desses dados.

O quarto capítulo trata de mostrar os resultados obtidos com o algoritmo, particionando o processo de construção do algoritmo, bem como utilizando-se de gráficos e diagramas afim de proporcionar um melhor entendimento.

No quinto capítulo, será feito uma conclusão do trabalho, onde constará comentários em relação aos resultados obtidos.

Por último, o sexto capítulo será apresentados todas as referências bibliográficas que serviram de base para este trabalho.

2 Fundamentação Teórica

2.1 História da Bateria

O conceito de bateria foi introduzido por Benjamin Franklin, em 1748, quando colocou frascos de vidro conectados em série que conseguiam armazenar energia elétrica. No ano de 1800. O físico italiano Alessandro Volta desenvolveu uma pilha capaz de armazenar energia elétrica que seria utilizada em seus experimentos químicos. O princípio de funcionamento da pilha era simples, consistia em converter energia química em elétrica com base em um par de discos de cobre e zinco, os quais eram empilhados com uma camada de material encharcado com uma solução salina.

Em 1836, o químico britânico John Frederic Daniell criou uma pilha através de lâminas de zinco imersas em sulfato de zinco numa vasilha de barro poroso, esta vasilha é imersa em um pote de cobre com solução de sulfato de cobre. A pilha de Daniell foi utilizada em grandes escalas nas redes de telégrafos.

A primeira bateria recarregável que se tem conhecimento foi criada em 1859 pelo físico francês Gaston Planté, esta bateria era constituída por uma placa de óxido de chumbo e outra de chumbo metálico imersas em ácido sulfúrico, as reações químicas produzem sulfato de chumbo.

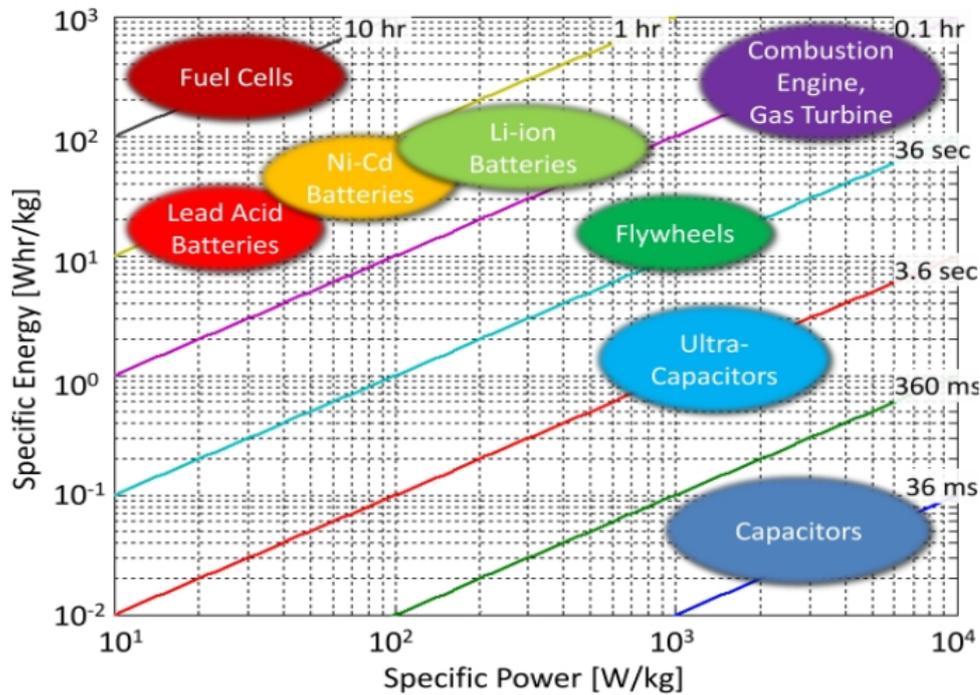
Em 1866, foi a pilha seca desenvolvida pelo engenheiro elétrico francês Georges Leclanché, a precursora da pilha. A pilha funcionava a base de um cilindro de zinco envolvido por um tipo de papel poroso e com manganês em pó, imersos em uma solução de cloreto de amônio e zinco.

2.2 Química da bateria

Atualmente existem diversas químicas de baterias, algumas possuem um nicho específico de aplicação em virtude de suas características de descarga. As químicas de baterias mais comuns encontradas atualmente são chumbo ácido, níquel e lítio, cada química possui um sistema de carregamento específico e tem uma regulamentação específica de transporte e descarte.

Na industria automotiva, as aplicações requerem um equilíbrio entre energia e potência específica. Uma alternativa que tem se mostrado bastante válida entre as opções apresentadas são as baterias a base de lítio, elas prometem um razoável compromisso entre energia e potência específica. Desta forma, nesse tipo de aplicação, essas baterias tem se mostrado uma escolha bastante atrativa.

Figura 1 – Gráfico comparativo entre as opções de fontes de energia



Fonte: Adaptado de Mohammed F., 2019

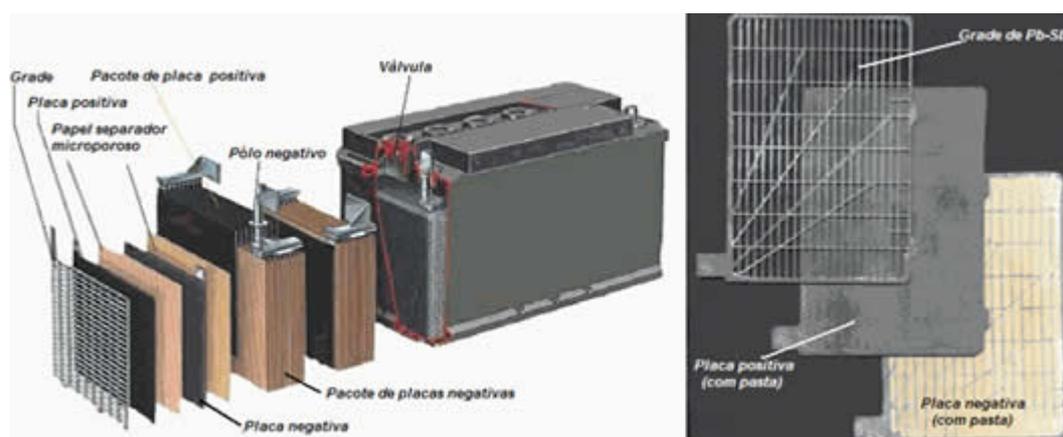
A Figura 1 expõe a diferença entre a densidade de potência e energia para diferentes sistemas de fontes de alimentação. Observando o gráfico, as fontes de alimentação baseadas em combustão são as mais empregadas atualmente em consequência de suas altas densidades de potência e energia. Os ultra capacitores dispõem de uma alta densidade de potência e também podem fornecer picos de potência em curtos períodos de tempo, porém possuem uma densidade de energia muito baixa. Na outra extremidade do gráfico está as baterias a combustível, elas possuem uma energia específica muito alta, entretanto precisam de longos períodos de tempo para carregar e descarregar.

2.2.1 Chumbo-Ácido

As baterias produzidas utilizando chumbo-ácido foram as primeiras baterias recarregáveis a serem difundidas comercialmente, apesar de existir a bastante tempo a química de chumbo-ácido ainda é muito utilizada devido ao ácido de chumbo ser confiável e barato. Hoje em dia há poucas baterias que fornecem energia tão barata quanto as baterias com química de chumbo-ácido, além disso esse tipo de química possui uma importante característica, ela suporta picos de corrente extremamente altos devido a sua alta densidade de potência. Portanto, isso a torna uma bateria perfeita para aplicações em automóveis, carros de golfe, empilhadeiras, fontes de alimentação ininterruptas (No-break) e embarcações marítimas.

As baterias de chumbo-ácido geralmente são construídas utilizando várias placas empilhadas [8], as placas positivas (cátodo) são placas de chumbo com óxido (PbO_2) e as placas negativas são formadas por placas de chumbo (Pb), normalmente nas placas negativas (ânodo) são empregados alguns materiais aditivos pois o chumbo puro não tem sustentação mecânica suficiente. Por exemplo, o cálcio reduz os efeitos de auto descarga, o antimônio e o estanho reduzem o desgaste causado por descarga profundas. Na Figura 2, pode-se visualizar a estrutura de uma bateria de Chumbo-ácido.

Figura 2 – Estrutura das baterias de Chumbo-ácido



Fonte: Adaptado de BRASIL ESCOLA, 2019

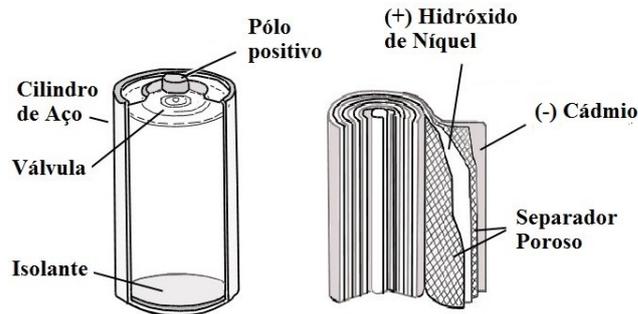
A química de chumbo-ácido apresenta algumas desvantagens como descargas profundas que diminuem rapidamente a vida útil da bateria, a baixa relação peso-energia, o processo de carga lento, deve ser armazenada em condição carregada para evitar a sulfatação, a versão com eletrólito líquido requer reposição da solução e causa desgaste ambiental grande.

2.2.2 Níquel

NiCd

A tecnologia de NiCd é uma das mais antigas no mercado, porém atualmente encontra-se praticamente estagnada no tocante a avanços técnicos. Em virtude dessa estagnação, outras químicas surgiram com densidade de potência bem acima como é o caso das baterias de NiMH e auto descarga. A Figura 3 mostra um exemplo estrutural de uma bateria a base de NiCd. Geralmente, as baterias de NiCd são utilizadas em aplicações que necessitam de baterias com uma grande quantidade de ciclos de vida, robustez e preço baixo. Além disso, as baterias de NiCd oferecem uma ampla gama no tocante a sua geometria, ou seja, estão disponíveis no mercado em diferentes tamanhos e opções. As principais aplicações das baterias de NiCd são telefones sem fio, walkie-talkies, equipamentos médicos, ferramentas elétricas e aviação civil.

Figura 3 – Estrutura das baterias de NiCd



Fonte: Adaptado de STA Eletrônica, 2019

As baterias de NiCd são robustas e tolerantes, porém necessitam de cuidados para atingir uma longevidade maior. Um exemplo desses cuidados é seu método de carga, enquanto que a carga em baterias de outras químicas é contínua e lenta, nas baterias de NiCd a carga é realizada de maneira pulsada e rápida. Outra informação importante é que as baterias de NiCd precisam ser descarregadas completamente (podem ser armazenadas com SoC em níveis baixos), pois poderá ocorrer a formação de cristais nas placas das baterias, esse fenômeno é denominado efeito memória [9]. Além dos problemas com efeito memória, as baterias de NiCd também padecem dos efeitos da auto descarga. O fato desse tipo de química apresentar bastante robustez sob condições rigorosas de operação (altas ou baixas temperaturas, condições de sobrecarga, regime de trabalho com altas correntes e entre outras), é o principal motivo para este tipo de química ser utilizado ainda hoje [10].

Uma circunstância que acarretou em uma queda no uso da química NiCd, foi a presença de metais tóxicos que não podem ser descartados no meio ambiente e devido a isso alguns países estão impondo regras para a utilização desse tipo de química.

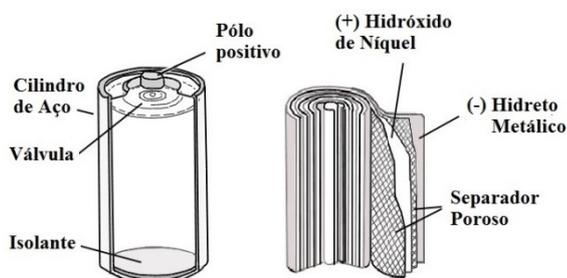
NiMH

Atualmente, as baterias com química de NiMH tem substituído as baterias de NiCd nos mercados de comunicações sem fio e computação móvel. Elas são capazes de fornecer cerca de 40% a mais de energia específica do que as baterias de NiCd. Em relação as baterias de NiCd, as baterias de NiMH são mais frágeis e tem uma inclinação menor a sofrer com efeito memória. Além disso, necessitam de um processo de carga mais complexo e lento, pois elas geram mais calor durante o processo de carga e necessitam de um tempo maior.

Outra característica de muita importância é o efeito de auto descarga, geralmente a bateria de NiMH sofre uma auto descarga de 20% após a primeira carga e mais 10% de auto descarga por mês de uso [11]. Com o propósito de atenuar os efeitos da auto descarga e reduzir a corrosão da liga, utiliza-se materiais incorporados ao hidreto metálico, porém

esse procedimento reduz a energia específica. O método de atenuação da auto descarga é geralmente utilizado para baterias que compõem acumuladores de veículos elétricos. Na figura 4 observa-se a estrutura empregada na concepção de uma bateria de NiMH.

Figura 4 – Estrutura das baterias de NiMH



Fonte: Adaptado de STA Eletrônica, 2019

O processo de envelhecimento das baterias de NiMH é muito intensificado após elas suportarem repetidos ciclos de descargas, as descargas profundas também estimulam o decaimento da vida útil delas. Em geral, afim de obter a melhor eficiência desse tipo de bateria, o ideal é aplicar descargas parciais com corrente de amplitude na faixa de 0.2C até 0.5C.

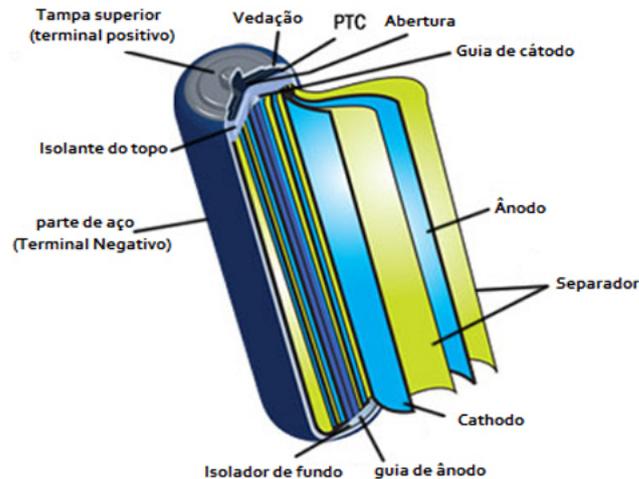
Além das características anteriormente apresentadas, na composição química desse tipo de bateria são usados elementos pouco prejudiciais ao meio ambiente, é importante salientar que o alto teor de níquel disponível após o fim de vida torna a reciclagem desse tipo de bateria bastante rentável. Outra vantagem extremamente importante dessas baterias é a facilidade na logística delas, tanto o armazenamento quanto o transporte são bem simples, pois não estão sujeitos a controles regulatórios.

2.2.3 Lítio-íon

Recentemente, as baterias a base de lítio tem alcançado uma importância cada vez maior, visto que, elas estão sendo utilizadas em diversas aplicações que impactam diretamente no cotidiano, desde dispositivos como notebooks, celulares, câmeras digitais e outros dispositivos eletrônicos. Tanta notoriedade se dá por várias razões, o fato de sofrer menos com os efeitos da auto descarga e perdas por histerese, além de não ter problemas causados pelo efeito memória são algumas justificativas que resultaram na vasta gama de aplicações. Em comparação com as químicas a base de níquel, as baterias de lítio possuem o dobro da energia específica e sofrem menos com auto descarga. Passível de envelhecimento, mesmo se não tiver em uso, as baterias de lítio necessitam de um local de armazenamento com temperaturas em torno de 25°C e a 40% de SoC desacelera o processo de envelhecimento. Além disso, as químicas a base de lítio oferecem tanto alta tensão quanto excelente capacidade, resultando em uma grande energia específica, por

este motivo essas baterias são muito utilizadas em veículos puramente elétricos, HEV e PHEV [12].

Figura 5 – Estrutura das baterias de auto descarga



Fonte: Adaptado de Blog BB Baterias, 2018

Apesar de tantas vantagens, as baterias de lítio apresentam algumas inconveniências. Elas são frágeis e necessitam de um sistema de gerenciamento de baterias (BMS, do inglês Battery Management System) para manter um desempenho satisfatório. Normalmente, esses sistemas são projetados para limitar a tensão de pico de cada bateria durante a carga e previne que a tensão da bateria caia muito durante a descarga. Além de limitar tensão, esses circuitos limitam a máxima corrente de carga e descarga, a temperatura da bateria também deve ser monitorada para prevenir temperaturas extremas [10].

Conforme exposto anteriormente, as baterias de lítio precisam de cuidados especiais como por exemplo, evitar curto-circuitos, sobrecargas, esmagamentos, perfurações e altas temperaturas. Em virtude das altas temperaturas da cápsula resultante do abuso da bateria, o rompimento do envólucro pode causar danos físicos devido ao eletrólito ser altamente inflamável.

Após muitos estudos, foi descoberto que o ciclo de carga e descarga provocava alterações no eletrodo de lítio. Essas transformações reduzem a estabilidade térmica, causando potenciais condições de fuga térmica. Quando esse comportamento ocorria, a temperatura da bateria rapidamente aproxima-se do ponto de derretimento do lítio, resultando em uma violenta reação. Em consequência da instabilidade do metal lítio, em particular no processo de carga, estudos resultaram em uma bateria de lítio não-metálica que usa íons de lítio [12].

2.3 Definições importantes

Nesta seção, será apresentada definições sobre baterias para a descrição de parâmetros, características e propriedades importantes para facilitar a compreensão.

- Tensão de terminal: Tensão mensurada entre os terminais da bateria quando a mesma está conectada a uma carga;
- Tensão de circuito aberto: Tensão medida entre os terminais da bateria quando ela não está conectada a uma carga;
- Tensão de Cut-off: Tensão mínima da bateria quando o SoC indica zero;
- Capacidade nominal: Quantidade total de carga que pode ser drenada de uma bateria quando a mesma está com 100% de SoC até a tensão mínima (Tensão de Cut-off). A Capacidade pode ser calculada multiplicando o tempo de descarga pela corrente de descarga [13];
- Taxa de carga (C-Rate): Parâmetro que representa uma taxa de carga ou descarga em relação a capacidade nominal da bateria, por exemplo, uma taxa de carga de 1C corresponde a quantidade de corrente necessária para descarregar ou carregar completamente a bateria em uma hora;
- Estado de Carga(SoC): O estado de carga significa o parâmetro do gerenciador de baterias (BMS) que de forma geral é definido como a relação entre a capacidade restante utilizável e a capacidade nominal da bateria [14]. Enquanto que o acumulador de baterias atua como o tanque de combustível em um veículo, o SoC da bateria é o medidor de combustível [15]. O estado de carga é um valor percentual representativo que varia de zero até um, onde um indica que a bateria está com carga completa, porém zero não indica uma bateria vazia, significa que a bateria não pode ser mais descarregado sem que cause um problema irreversível;
- Ciclo de vida: Parâmetro que indica o número de ciclos que resta a bateria para que ela atinja o fim de vida útil (EoL, do inglês End of Life);
- Estado de Saúde (SoH): Indicador que determina a inclinação da bateria para armazenar carga, este parâmetro decresce gradualmente de acordo com o envelhecimento da bateria. O SoH indicando 100% significa uma bateria nova, já o SoH em 80% indica uma bateria envelhecida [16]. O SoH pode ser determinado como uma perda de capacidade ou um crescimento da resistência interna da bateria [17]. Em geral, nas aplicações voltadas para veículos elétricos, o EoL é definido quando a bateria atinge uma das seguinte condições [18]:

- A capacidade atual da bateria cai abaixo do nível de 80% em relação a capacidade nominal dela;
- A potência máxima da bateria está em um nível abaixo dos 80% quando comparada com a potência máxima quando a bateria é nova;
- Densidade de potência: A densidade de potência é um parâmetro que indica a quantidade de energia gerada em uma unidade de volume. A alta densidade de potência permite a miniaturização de aplicações e dispositivos finais e é extremamente importante para aplicações portáteis;
- Densidade de energia: Parâmetro que indica a relação entre a quantidade de energia contida em um dado sistema ou região do espaço e o volume ou a massa;

2.4 Técnicas de determinação do SoC e SoH

Nos últimos anos, pesquisas vem sendo desenvolvidas para aprimorar os Sistemas de Gerenciamento de Baterias (BMS) e a exatidão de seus preditores (SoH e SoC). O monitoramento do estado da bateria é importante para determinar em tempo real o SoC e o SoH para evitar a operação em condições perigosas do sistema de baterias e minimizar o erro na realização da lógica de controle. Enquanto o SoC é um indicador da carga que a bateria pode fornecer durante um ciclo, o SoH mostra a capacidade disponível da bateria em relação ao primeiro ciclo de utilização [19]. Em geral, os métodos de determinação de SoC e SoH são classificados em três categorias:

- Métodos diretos: Essa abordagem geralmente é utilizada em métodos de medição direta como Coulomb Counting, método de tensão de circuito aberto e modelos baseados em medição da resistência interna da bateria [6].
- Métodos baseados em modelos: Nesta maneira de determinação, as abordagens são realizadas estabelecendo fórmulas empíricas relacionando elementos passivos como capacitores e resistores [6].
- Métodos data-driven: Os métodos data-driven são baseados no conhecimento prévio do fenômeno analisado, ou seja, na construção do modelo tem como base um banco de dados relacionados ao fenômeno em questão. Este tipo de abordagem vem tornando-se cada vez mais atrativa na definição tanto do SoH quanto do SoC. Através de modelos por data-driven, extraem-se características importantes disponíveis e são bastante flexíveis por empregar técnicas de Machine Learning [6].

Em seguida, serão abordados de maneira sucinta alguns exemplos que possuem características dos métodos descritos anteriormente.

2.4.1 Tensão de Circuito Aberto (OCV)

O método de tensão de circuito aberto normalmente é utilizado em aplicações onde a bateria está em estado de repouso por longos períodos de tempo, observando a tensão de circuito aberto decair durante longos períodos. A partir dessa observação, o SoC pode ser determinado utilizando tabelas de equivalência (LUT, Look-up Tables). Essas LUT são tabelas que relacionam o OCV com o SoC e usadas para a estimação do SoC por meio de técnicas de interpolação.

Como mostrado anteriormente, o método por OCV é bastante válido para determinar SoC em aplicações onde a bateria permanece em repouso. Entretanto, em aplicações onde há um comportamento dinâmico na tensão da bateria este modelo não pode ser utilizado, pois a precisão é afetada pelas variações de temperatura e histerese [18]. Afim de solucionar este problema, a técnica de OCV-SoC pode ser utilizada em conjunto com o método de determinação de SoC por Coulomb Counting [20].

2.4.2 Coulomb Counting para SoC

O método para estimação de Coulomb Counting é atualmente um dos mais utilizados pela indústria, devido a sua facilidade de implementação. Como a carga e a descarga da bateria estão diretamente relacionadas com o fluxo de corrente, o estado de carga da bateria pode ser definido como a integral da corrente ao longo do tempo de carga ou descarga na bateria, dado pela seguinte equação:

$$SoC = SoC_0 + \frac{100}{C_n} * \int_{t_0}^{t_0+\tau} I_{bat} dt; \quad (2.1)$$

Onde o SoC_0 representa o estado de carga inicial, C_n corresponde a capacidade nominal da bateria, I_{bat} representa o fluxo de corrente na bateria, t_0 é o instante de tempo que a carga ou descarga é iniciada na bateria e τ corresponde ao intervalo de tempo entre o começo e o fim do ciclo.

Contudo, este método de cálculo perde a confiabilidade em consequência do erro acumulativo e a imprecisão na estimativa do erro inicial. Diversos pesquisadores relataram essas limitações e propuseram algumas soluções para resolvê-las. Por exemplo, para evitar o erro acumulativo, um coeficiente é adicionado a equação 2.1. A precisão do SoC inicial afeta severamente o SoC estimado, uma vez que o SoC_0 é um termo aditivo, de acordo com a definição 2.1. Posteriormente, precisamos estimar o SoC_0 com rigor e facilitar o acesso ao SoC inicial, neste caso para solucionar este problema o método OCV-SoC é relevante pois o OCV proporciona um SoC instantâneo devido a uma mapeamento bem realizado entre OCV e SoC [21].

2.4.3 Coulomb Counting para SoH

Há princípio, para definir o Estado de Saúde de uma bateria é necessário fazer algumas considerações como por exemplo, a bateria está nova quando possui 100% de SoH, quando a bateria está desgastada o SoH indica 0%, porém após a utilização de alguns artifícios matemáticos essa indicação passa a corresponder a 80% da capacidade quando a bateria é nova [17].

$$SoH(C) = \frac{\left(\frac{C}{C_n} - 80\%\right)}{20\%} \quad (2.2)$$

Onde C_n corresponde a capacidade nominal e neste caso é considerada como a capacidade da bateria quando nova, C representa a capacidade atual da bateria. Os termos percentuais presentes na equação servem apenas para converter o SoH de um intervalo de 100% até 80%, para um intervalo de 100% até 0%. A capacidade pode ser calculada como a taxa de carga acumulada dada uma variação de SoC em um determinado período de tempo, as equações 2.3 e 2.4 descrevem em termos matemáticos a afirmação anterior.

$$\Delta SoC = \frac{\Delta Ah}{C} \quad (2.3)$$

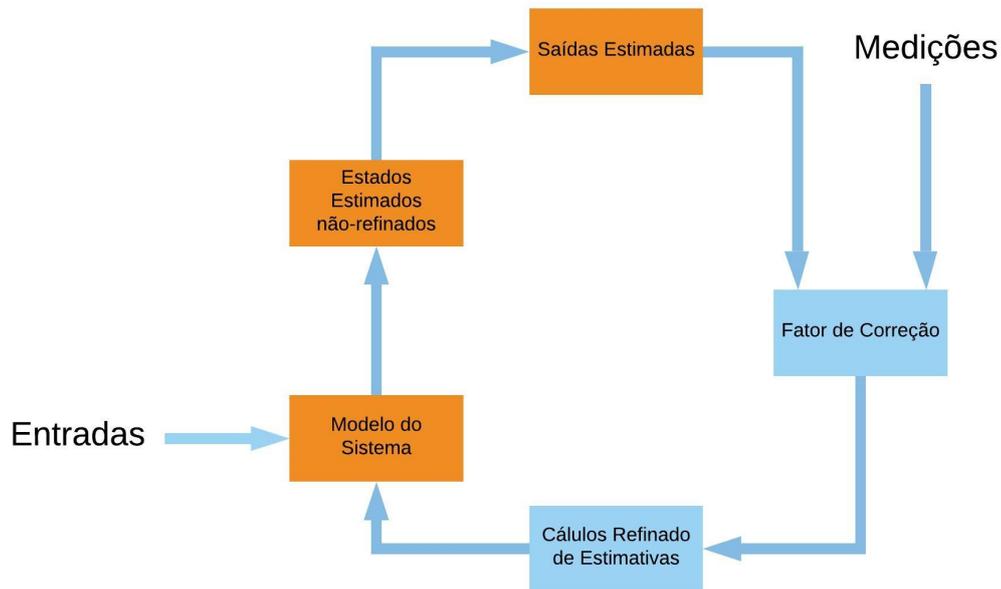
$$C_{\alpha,\beta} = \frac{\Delta Ah}{\Delta SoC} = \frac{\int_{t_\alpha}^{t_\beta} I_{cell}(t) dt}{SoC(t_\alpha) - SoC(t_\beta)} \quad (2.4)$$

Na equação 2.3, o ΔAh corresponde a carga acumulada na bateria durante um período de tempo. Já na equação 2.4, t_α e t_β representam os instante de tempo inicial e final durante um ciclo observado respectivamente, I_{cell} corresponde a corrente aplicada na bateria.

2.4.4 Filtros de Kalman

O Filtro de Kalman (KF, do inglês Kalman Filter) surgiu em 1960 como um ótimo modelo recursivo proposto com base em algoritmos de processamento de dados utilizando filtros lineares. Entretanto, empregar este modelo em sistemas com comportamento não linear mostrou ser um problema bastante relevante. Na Figura 6, observa-se uma estrutura básica de um sistema aplicando o modelo KF para corrigir suas estimativas.

Figura 6 – Estrutura do Preditor-Corretor do KF



Fonte: Adaptado pelo autor

A partir do KF, uma extensa pesquisa foi desenvolvida resultando em sua forma modificada para abordar sistemas não-lineares, conhecido como Filtro de Kalman Estendido (EKF) [18]. Com o objetivo de aprimorar a resposta a comportamento altamente não-linear, o esquema de filtros duplos pode ter uma aplicabilidade, uma vez que apresentam um feedback mais satisfatório.

Além do modelo EKF, existe a técnica de PF que usa um conjunto de partículas (também chamadas amostras) para representar a distribuição posterior de algum processo estocástico, devido a observações ruidosas ou parciais, ela também é uma ferramenta bastante válida para problemas não-lineares. Entretanto a eficiência computacional está estritamente relacionada ao número de partículas, bem como a precisão do algoritmo está correlacionada positivamente com o número de partículas. Sendo assim, sua eficiência pode ser menor em comparação com a eficiência do EKF. A partir deste cenário, surgiu uma alternativa para o problema da eficiência do algoritmo. Afim de equilibrar as vantagens e desvantagens dos métodos anteriormente citados, surgiu o modelo UKF que é superior ao EKF na resolução de problemas com alta linearidade e sua complexidade computacional é bem menor quando comparada a do PF [22].

Em geral, os modelos baseados na abordagem de Filtros de Kalman apresentaram-se como uma alternativa válida quando aplicados na determinação de SoC. Contudo, são algoritmos de implementação complexa e demandam recursos computacionais altos [23], devido a isto, a gama de aplicações desses algoritmos é bastante limitada.

2.4.5 Algoritmos de aprendizado

Desde que os computadores foram criados, estes têm incorporado algoritmos baseados em inteligência artificial (IA), com a finalidade de imitar aspectos humanos como a capacidade de aprendizagem, raciocínio e evolução. A busca por eliminar o fator humano na tomada de decisões em situações com alto grau de relevância resultou em vários algoritmos avançados, por exemplo, uma máquina pode aprender com base em registros médicos a realizar a detecção de uma doença e indicar ao paciente a melhor opção de tratamento, utilizar uma máquina para análise de mercado e elaborar uma previsão detalhada de como o mercado internacional poderá se comportar a curto e médio prazo ou mesmo proporcionar a um motorista um veículo autônomo capaz de adaptar-se as mais diversas condições do trânsito ou até mesmo de clima, analisar a probabilidade em determinadas situações que podem resultar em acidentes. Diante disso, faz-se necessário uma percepção detalhada das informações para aprendizado de máquina podem resultar em uma melhor compreensão tanto das habilidades quanto das deficiências de aprendizado humano.

2.4.5.1 Aprendizado em Máquina (Machine Learning)

Segundo [24], a definição de aprendizado de máquina pode ser conceituado de forma ampla, incluindo qualquer programa de computador que evolua sua performance em determinada atividade através do conhecimento adquirido ao longo de sua execução. Assim, entende-se por aprendizado em máquina como sendo:

"Diz-se que um programa de computador aprende com a experiência E com relação a alguma classe de tarefas T e medida de desempenho P , se seu desempenho em tarefas em T , como medido por P , melhora com a experiência E ."

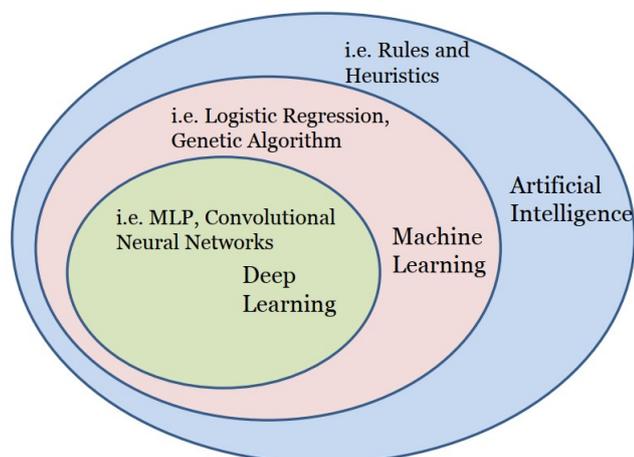
Com o intuito de exemplificar o conceito acima suponha que um algoritmo de aprendizado seja utilizado para dirigir um veículo. A classe de tarefas (T) será dirigir em estradas de várias vias usando sensores de proximidade e câmeras, a medição da performance (P) do algoritmo corresponde a distância média percorrida antes de um erro (conforme julgamento de um humano) e por fim a experiência acumulada no treinamento (E) será uma sequência de imagens e comandos são armazenados ao observar as escolhas de um motorista humano.

2.4.5.2 Aprendizado Profundo (Deep Learning)

A aprendizagem profunda (Deep Learning) é um tipo de abordagem de IA e uma sub-área de aprendizado em máquina (Machine Learning), ela caracteriza as técnicas que possibilitam o aprendizado das máquinas com o acúmulo de experiência. Genericamente, os algoritmos de aprendizado profundo e aprendizado em máquina assimilam subsistemas simples e produzem uma base de conhecimento para compreender e representar sistemas

complexos. A seguir a Figura 7 mostra o arranjo organizacional de aprendizado profundo e aprendizado em máquina no escopo da inteligência artificial.

Figura 7 – Diagrama de Venn em IA



Fonte: Adaptado de [25]

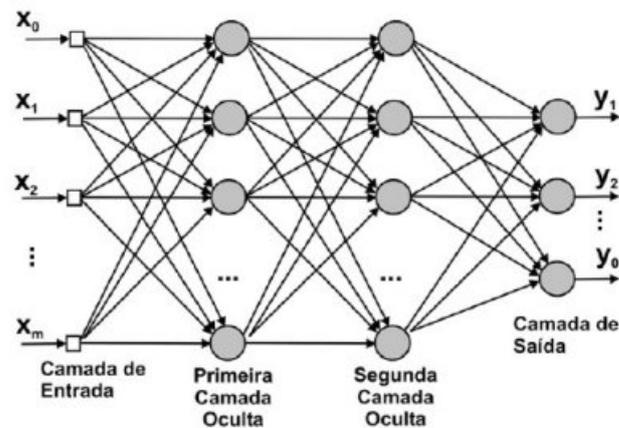
Os algoritmos de aprendizado podem executar diferentes tipos de tarefas, sendo as tarefas mais frequentemente usadas a classificação e regressão. Na tarefa de classificação, a máquina analisa um vetor de entrada e de acordo com suas características, determina a classe a que pertence o vetor analisado. Já na tarefa de regressão, o algoritmo realiza estimativas numéricas com base em dados do vetor de entrada.

Com a evolução do poder computacional tornando o hardware mais rápido e uma quantidade de dados produzidos sendo demasiadamente grande, as arquiteturas das redes foram cada vez mais melhoradas, bem como pesquisas mais aprofundadas foram desenvolvidas resultando na criação de arquiteturas, todos estes avanços possibilitaram aos pesquisadores aumentar o desempenho dos algoritmos e diversificar ainda mais sua gama de aplicações.

2.4.5.3 Redes Neurais

O trabalho em redes neurais artificiais, usualmente denominadas "redes neurais", tem sido motivado desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional [26]. O cérebro é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo [26]. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos (p.ex., reconhecimento de padrões, percepção e controle motor) com alta velocidade de processamento digital.

Figura 8 – Diagrama de uma RNA básica



A Figura 8 mostra a estrutura básica de uma rede neural com as camadas de entrada e saída, assim como duas camadas ocultas. Em geral, uma rede neural é uma máquina desenvolvida com o intuito de aperfeiçoar a forma como o cérebro realiza uma tarefa em particular, a rede geralmente é executada por meio de componentes eletrônicos ou simulada via programação em ambiente digital. Segundo [26], defini-se como rede neural:

"Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:"

- *O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
- *O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*

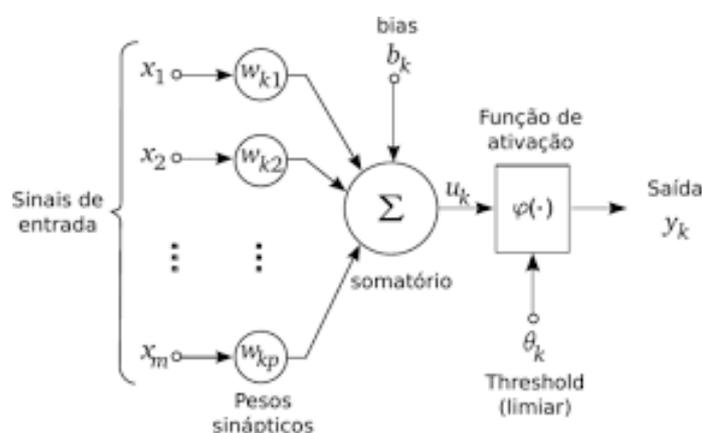
O procedimento usado no processo de aprendizagem é usualmente denominado algoritmo de aprendizagem, cuja atribuição é alterar os pesos sinápticos da rede de maneira sistemática para aproximar a saída dos targets. [26]

A alteração dos pesos sinápticos é o método convencional para o projeto de redes neurais. Esta abordagem é próxima da teoria dos filtros adaptativos lineares, que já está bem estabelecida e foi aplicada com sucesso em diversas áreas (Widrow e Stearns, 1985; HAYKIN, 1996). Porém, para uma rede neural também é possível modificar sua própria topologia, o que é motivado pelo fato de os neurônios no cérebro humano poderem morrer e que novas conexões sinápticas possam crescer. [26]

Modelo do neurônio

Os neurônios constituem uma unidade de processamento de informação essencial na execução de uma rede neural [26]. O diagrama de blocos na Figura 9 descreve o modelo de um neurônio, servindo de base para todas as redes neurais. Observando-se essa figura é possível identificar três elementos básicos do modelo:

Figura 9 – Modelo de Neurônio



Fonte: Adaptado de Haykin (2001)

- Um conjunto de sinapses, onde cada uma é determinada por um peso. Especialmente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} , é importante salientar a maneira com que são escritos os índices do peso sináptico. O primeiro índice refere-se ao neurônio observado, e o segundo está atrelado ao terminal de entrada da sinapse do peso em questão. Distintivamente de uma sinapse cerebral, o peso sináptico poderá estar contido em um intervalo onde existem valores negativos e positivos [26].
- Um somador para somar os sinais de entrada, ponderados pelas devidas sinapses do neurônio, as operações aqui descritas formam uma combinação linear [26].
- Uma função de ativação para limitar a amplitude de saída de cada neurônio. A função de ativação também é denominada função restritiva, já que restringe o intervalo permissível de amplitude do sinal de saída para um valor finito. Particularmente, o intervalo normalizado de amplitude de saída de um neurônio é expresso como um intervalo unitário fechado $[0,1]$ ou, de forma alternativa, $[-1,1]$ [26].

O modelo do neurônio exibido na Figura 9 também inclui uma variável externa bias, denotada por b_k . O bias (polarização) tem o efeito de ampliar ou reduzir a entrada função de ativação, dependendo se o valor é positivo ou negativo, respectivamente [26].

O modelo representado na Figura 9 também pode ser expresso em termos matemáticos, dado um neurônio k pode-se representá-lo por meio da Equação 2.5.

$$y_k(x) = \varphi(v) \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (2.5)$$

Onde $x_1, x_2, x_3, \dots, x_n$, são os sinais de entrada, $w_{k_1}, w_{k_2}, w_{k_3}, \dots, w_{k_m}$ representam os pesos sinápticos do neurônio k , b_k é o bias; φ é a função de ativação e y_k é o sinal de saída do neurônio.

Funções de Ativação

A função de ativação, que corresponde ao termo $\varphi(v)$, determina a saída de um neurônio nas condições do campo local induzido v . Dentre as funções de ativação existentes, será abordada apenas a função Sigmoide que é longe o método mais comum de função de ativação utilizada na construção de redes neurais artificiais [26]. Ela é definida como uma função estritamente crescente que demonstra um equilíbrio adequado entre comportamento linear e não-linear. Um exemplo de função sigmoide é a função logística, definida por:

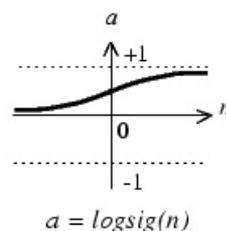
$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (2.6)$$

Onde a é o parâmetro de inclinação da função sigmoide. Desta maneira variando o parâmetro a , é possível obter funções sigmóides com inclinações diferentes. Quando a tende ao infinito, a função sigmoide passa a ter o comportamento da função limite. Enquanto a função limite atribui apenas os valores 0 ou 1, uma função sigmoide assume infinitos valores no intervalo de 0 até 1. Vale a pena ressaltar que a função sigmoide é derivável, característica que não é válida para a função limite [26].

As funções de ativação determinadas nas equações anteriores se estendem em um intervalo de 0 até 1. Em casos particulares, é desejável que a função de ativação estenda-se a região negativa (-1 até 1).

Particularmente, neste trabalho foi utilizado uma função de ativação sigmoide específica usualmente denominada logsig, cujo comportamento é ilustrado na Figura 10.

Figura 10 – Comportamento da função logsig



Fonte: Adaptado de MathWorks Matlab

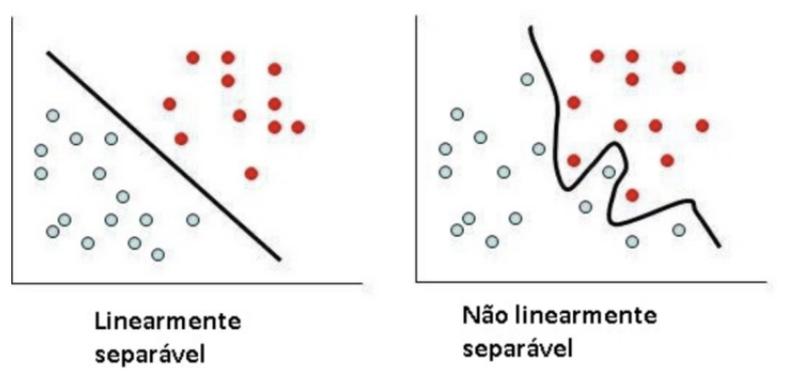
Além disso, em termos matemáticos esse comportamento é representado pela equação a seguir:

$$\text{logsig}(n) = \frac{1}{1 + \exp(-n)} \quad (2.7)$$

Backpropagation

As estruturas de redes neurais atuais, utilizam algoritmos para o reconhecimento de padrões entre eles podemos destacar o Kohonen, Perceptron Adaline, Backpropagation e entre outros, cada qual com suas especialidades. O objetivo primário do backpropagation é otimizar os pesos para que a rede neural possa aprender a mapear corretamente as entradas para as saídas. Além disso, uma particularidade que o destaca dos demais é o fato de que ele executa o reconhecimento através de múltiplas camadas e soluciona problemas não linearmente separáveis que alguns algoritmos não conseguem resolver. De forma sucinta, uma questão "não-linearmente separável" é aquele no qual não podemos desassociar duas classes diferentes no eixo cartesiano bidimensional apenas traçando uma reta. Uma representação do conceito apresentado acima segue na Figura 11.

Figura 11 – Representação de problemas não-linearmente separáveis



Adaptado de IA Brasil, 2019

Analisando a Figura 11 é perceptível que há uma dificuldade em separar com uma reta os termo padronizados no gráfico não linearmente separável, isso demonstra que existindo uma necessidade de diferenciar os objetos de coloração azul dos objetos de cor vermelhos, alguns algoritmos não serão capazes de fazer essa distinção e conseqüentemente não conseguirão resolver o problema.

Levenberg-Marquadt (LM)

Segundo [27], enquanto o Back-Propagation padrão funciona através da decida do gradiente como método de aproximação do mínimo da função de erro, o algoritmo de LM utiliza um meio de aproximação chamado método de Newton. Essa aproximação é obtida por meio da modificação do método de Gauss-Newton inserindo o parâmetro μ , segundo a

equação abaixo:

$$\Delta x = [J^T(x)J(x) + \mu I]^{-1} J^T(x)e(x) \quad (2.8)$$

onde I corresponde a matriz identidade, $e(x)$ o erro e J a matriz Jacobiana. O parâmetro μ é multiplicado por um fator β sempre que um passo resultar em uma elevação da função de erro, que deseja-se reduzir ao mínimo possível. No momento em que um passo resultar na diminuição da função genérica $V(x)$, μ é dividido pelo fator β . Neste caso, se houver uma convergência para o mínimo da função, μ é pequeno e a expressão aproxima-se do método de Newton, no caso de não haver convergência, o método se aproximará da decida do gradiente. O parâmetro μ trabalha como um fator de estabilização do treinamento, ela funciona ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência.

2.4.5.4 Redes Neurais Recorrentes

As redes neurais recorrentes são redes com um ou mais laços de realimentação, sendo essa realimentação podendo ser classificada como global ou local. Em uma rede de múltiplas camadas, a aplicação de realimentação global pode assumir uma variedade de formas. Um exemplo delas é a realimentação dos neurônios de saída para a camada de entrada, outro exemplo de realimentação global é dos neurônios ocultos da rede para a camada de entrada. Quando este tipo de rede possui em sua composição uma ou mais camadas ocultas, as possíveis formas de realimentação global se expandem ainda mais. Portanto, as redes recorrentes têm uma gama ampla de arquiteturas que podem ser implementadas. Em resumo, existem dois modos de utilização para as redes recorrentes:

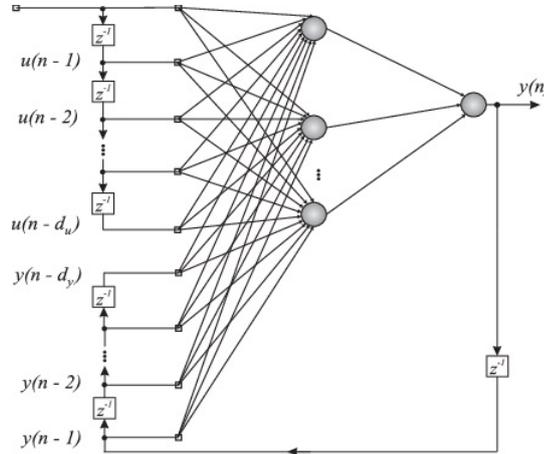
- Memórias associativas;
- Redes para mapeamento de entrada-saída;

O vetor de entrada de uma rede de mapeamento é estruturado em um vetor de saída, assim para esta aplicação, uma rede recorrente responde temporariamente a um sinal de entrada aplicado externamente. Portanto, pode-se denominar as redes recorrentes como redes recorrentes dirigidas dinamicamente. Além disso, a utilização da realimentação possibilita que as redes recorrentes alcancem representações do estado, o que as torna modelos pertinentes a aplicações diversas como previsão não-linear e modelagem, equalização adaptativa de canais de comunicação, processamento de voz, controle de instalações industriais e diagnósticos de motores. Um ponto importantíssimo a ser destacado é o potencial de reduzir significativamente as exigências de memória, quando emprega-se a realimentação global [26].

A delineação arquitetural de uma rede recorrente assume diversos contornos diferentes. As redes recorrentes dispõem de algumas características importantes, elas incorporam

um perceptron de múltiplas camadas estático ou partes dele. Elas também exploram a capacidade de mapeamento não linear do perceptron de múltiplas camadas.

Figura 12 – Modelo representativo da NARX



Adaptado de [26]

Particularmente neste trabalho, foi implementado um modelo de rede neural recorrente específico chamado NARX (Rede auto regressiva não-linear com entradas externas). A Figura 12 mostra um exemplo de arquitetura de rede recorrente NARX, singularmente, este tipo de rede tem uma capacidade própria de simular autômatos de estados finitos [26].

A rede auto regressiva não-linear com entradas exógenas utiliza um modelo fundamentado em um modelo ARX linear, que é comumente usado em séries temporais, o modelo NARX pode ser expresso pela equação 2.9.

$$y(t) = f(y(t-1), y(t-3), y(t-3), \dots, y(t-n_y), u(t-1), u(t-3), u(t-3), \dots, u(t-n_u)) \quad (2.9)$$

Conforme apresentado na definição 2.9, o valor atual $y(t)$ do sinal de saída da rede NARX pode ser dependente de valores anteriores do sinal de saída, bem como de valores anteriores de um sinal de entrada independente (exógeno), ou seja um valor proveniente de uma entrada externa. Outra forma de implementar um modelo NARX é aplicando uma rede neural feedforward para aproximar a função f que também pode ser incrementada com um modelo ARX vetorial, em que a entrada e a saída podem ser multidimensionais [28].

2.5 Estado da Arte

2.5.1 Algoritmos para SoC

Em [29], foi abordado um modelo de rede neural chamada LSTM para aprendizado profundo que é bastante aplicada na área de classificação de imagens, reconhecimento de

voz, detecção de objetos, regressão linear e entre outras aplicações. As redes LSTM são classificadas como recorrentes, pois possuem uma interconexão interna de realimentação possibilitando o uso para prever dados de sequência. Em paralelo, esse modelo tem a vantagem de memorizar os resultados calculados em instantes anteriores considerando-os na determinação da saída.

Complementarmente, o artigo [29] ainda mostra que para este tipo de rede é necessário desconsiderar a variável temperatura mesmo ela sendo um fator de grande influência nas baterias. Devido a temperatura variar pouco em um período específico, bem como o fato dela não ser consistente ao longo da superfície da bateria foram as razões de sua desconsideração. Contudo, para representar seus efeito sobre a bateria, verificou-se que a mudança de temperatura no desempenho da bateria refletia na capacidade. Assim, a capacidade foi considerada como um parâmetro de entrada para refletir o efeito térmico sobre a bateria. Além disso, outro ponto importante abordado foi considerar o envelhecimento da bateria através do cálculo das resistências e capacitâncias que representam-na.

No artigo [30], um algoritmo genético BSA foi desenvolvido em conjunto com um modelo BPNN para melhorar a precisão, buscando o melhor valor de neurônios de camada oculta e taxa de aprendizado. O estudo foi conduzido utilizando dois diferentes perfis de carga em três temperaturas diferentes. O desempenho do modelo foi mensurado com base no erros RMSE, MAE e MAPE, e então comparado com outros modelos de redes recorrentes como RBFNN, GRNN e ELM para validação dos resultados. Neste modelo foi utilizado o algoritmo de treinamento LM e a função de ativação logsig, como entradas, foram utilizadas a tensão e temperatura da bateria, além da corrente.

Já em [31], inicialmente um modelo aprimorado de bateria foi desenvolvido usando uma rede FFNN. As estimativas de SoC foram executadas por meio de um modelo de rede FFNN trabalhando em conjunto com um algoritmo de EKF, para alimentar a rede FFNN foi empregado um estado de polarização e os resultados da rede aplicados no algoritmo EFK. Para o método de validação, foi realizada uma comparação entre o modelo proposto e duas referências, a primeira referência foi uma curva estimada por um circuito equivalente e a segunda foi uma curva estimada por um modelo FFNN.

No artigo [32], foi adotado o modelo comum de rede neural com tensão, corrente e temperatura como entradas. O modelo em apenas uma camada intermediária ou oculta com dez neurônios, na camada oculta foi aplicada a função de ativação sigmoide e na camada de saída a função de ativação linear. Como procedimento de validação, o artigo demonstra uma comparação entre o modelo com a rede e um sistema de medição com preditor de SoC.

Por fim, no artigo [33] também foi empregado um modelo de rede neural comum, porém como entradas da rede utilizaram Corrente, Tensão e a integral da corrente (Capacidade). A rede foi desenvolvida em Python e foi constituída de duas camadas ocultas

com sete neurônios cada, nas camadas ocultas foi usado uma função de ativação sigmoide e na camada de saída uma função linear.

Um fato interessante abordado nesta referência foi a normalização dos dados para alimentar a rede, os dados pré-processados contêm atributos com várias escalas, ou seja, o pacote de dados têm grandes diferenças numéricas de variável para variável. Portanto, esses dados devem ser escalonados para um espaço de dados conveniente, por exemplo de 0 a 1, para normalizar os dados de entrada foi utilizado a técnica Min-Max que é representada pela equação 2.10.

$$X_{new} = \left(\frac{X - X_{min}}{X_{max} - X_{min}} * (new_{max} - new_{min}) \right) + new_{min}; \quad (2.10)$$

2.5.2 Algoritmos para SoH

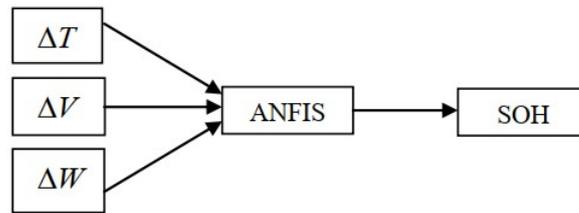
No artigo [34], foi empregado o algoritmo de aprendizado GRNN no qual, é capaz de simular o comportamento não linear da bateria para estimar o SoH. O GRNN é um algoritmo de aprendizado bastante avançado e tem uma estrutura de rede flexível, proporcionando ao pesquisador aplica-lá em várias situações de comportamento não linear. Além disso possui um alto grau de robustez e tolerância a falhas.

Ainda em [34], a rede neural utilizada pelo autor foi constituída de quatro camadas, sendo elas, a camada de entrada (Input Layer), a camada de modelo (Model Layer), a camada de somatórios (Summation Layer) e por fim a camada de saída (Output Layer). Com relação aos dados de treinamento da rede, o autor realizou vários ensaios de carga e descarga para cada bateria de um conjunto com a finalidade de obter a degradação delas. Desta forma o autor conseguiu observar entre um ensaio e outro a variação da curva de tensão, variação de tempo que a bateria alcançava determinados pontos de SoC e a variação da energia fornecida ou extraída da bateria.

Já em [35], foi aplicado uma rede neural probabilística para determinar o SoH. Uma PNN tem uma velocidade de aprendizado rápida porque os pesos da conexão da rede é definido apenas uma vez, os dados necessários da amostra de treinamento podem ser inseridos diretamente sem interação. O princípio básico do PNN começa a partir de um modelo de probabilidade, especificamente, classificadores Bayesianos e neste tipo de rede a estrutura é similar as utilizadas em back-propagation, porém as funções de ativação são substituídas por uma classe de funções, tal como funções exponenciais.

Em [1], foi proposto um método de estimativa de SoH abordando o modelo de aprendizado ANFIS. Esta estrutura de rede proporciona uma alta velocidade de treinamento e garante boa precisão nas estimativas, neste artigo também é proposto um modelo fundamentado em Fletcher-Reeves.

Figura 13 – Diagrama do algoritmo de [1]

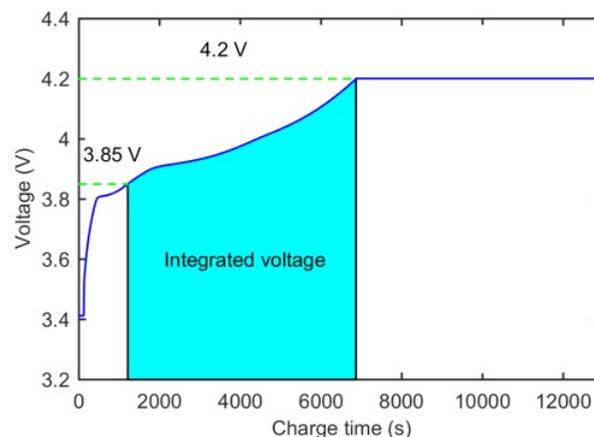


Adaptado de [1]

Assim como em [34], também foram avaliados como entradas da rede no procedimento de treinamento a variação da curva de tensão, variação de tempo que a bateria alcançava determinados pontos de SoC e a variação da energia fornecida ou extraída da bateria. A Figura 13 mostra um diagrama representativo do modelo proposto.

O artigo [36] abordou um ponto interessante bastante válido na estimativa do SoH, o comportamento da área sob a curva de tensão caracteriza bem a degradação da capacidade da bateria ao longo de sua vida útil (ver Figura 14). Observando-se os dados experimentais, notou-se que ao selecionar um intervalo confiável (região de comportamento praticamente linear ao longo da curva), a área correspondente a este intervalo deforma-se diminuindo de tamanho. O autor ainda trata de realizar cálculos de correlação entre a área e o SoH, sendo que o resultado validou a hipótese.

Figura 14 – Gráfico da área sob a curva de tensão



Adaptado de [36]

3 Algoritmos Propostos

A princípio, neste capítulo será dado um esclarecimento em relação ao conceito estabelecido para este trabalho fundamenta-se no desenvolvimento de dois algoritmos preditores para determinar o Estado de carga e o Estado de Saúde de uma bateria de Lítio-ion empregando técnicas de Machine Learning. Também serão abordadas considerações realizadas para a escolha das variáveis utilizadas como entradas das redes.

3.1 Panorama geral

O desenvolvimento dos algoritmos de previsão foi realizado utilizando a toolbox de Deep Learning do software de cálculos computacionais MATLAB® em conjunto com o banco de dados fornecido pela NASA.

O processo de concepção dos algoritmos dar-se basicamente por meio de três estágios: treinamento, validação e teste. O procedimento inicial é o treinamento, este estágio consiste em apresentar os dados a rede neural para que ocorra o processo de aprendizagem. No estágio de validação, as previsões da rede são comparados com dados reais ao fim de cada iteração de treino com o objetivo de gerar um erro e direcionar a rede para obter a melhor resposta as entradas. Por fim, o último estágio do processo de desenvolvimento de uma rede é o teste, nele é apresentado a rede um conjunto de dados novo, além do que é feita uma comparação entre a resposta da rede e a resposta esperada.

Figura 15 – Visão geral do algoritmo



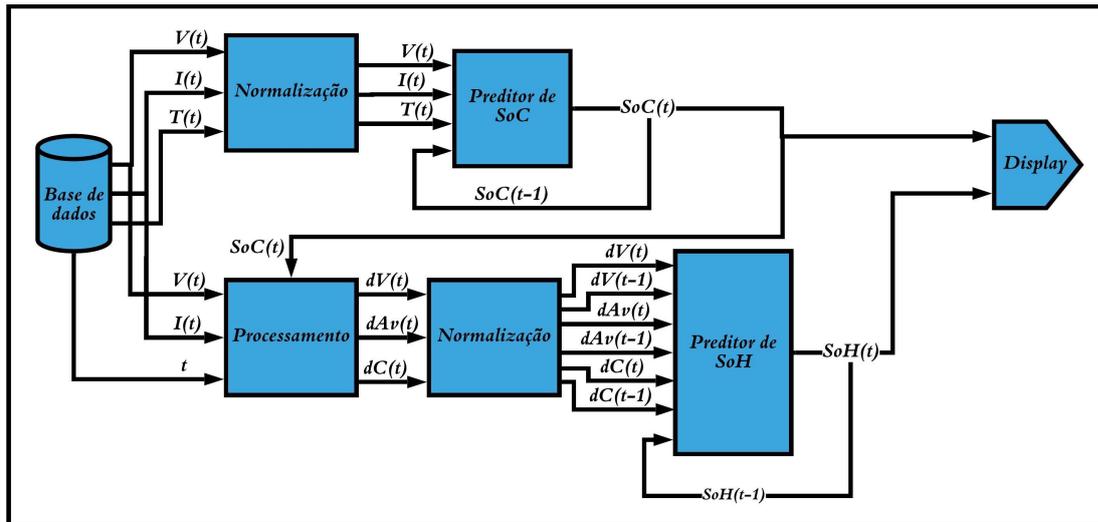
Fonte: elaborado pelo autor, 2019

Sinteticamente, o modelo proposto neste trabalho pode resumir-se a em um sistema representado na Figura 15, tendo como entradas as medições de tensão, corrente e temperatura ao longo do tempo. Como saídas do sistema são apresentados o Estado de Carga (SoC) e Estado de Saúde (SoH) de uma bateria.

3.2 Visão interna

Na Figura 16 apresenta-se o diagrama de blocos do modelo desenvolvido, nela observa-se as estruturas que serão melhor comentadas em subseções que estão dispostas mais a seguir.

Figura 16 – Diagrama interno de blocos do algoritmo



Fonte: elaborado pelo autor, 2019

Normalização

Em especial, deve-se destacar o processo de normalização presente na entrada dos blocos de previsão de estados. Afim de minimizar os problemas provenientes do uso de unidades e faixas de valores distintos entre os parâmetros, assim é necessário que os dados sejam normalizados, padronizados em uma mesma escala. O uso de redes neurais com funções de ativação sigmoideal exige que os dados que alimentam a rede sejam normalizados para valores pertencentes ao intervalo de 0 até 1. Devido a sua boa resposta em sistemas não lineares, as funções sigmoideais foram bastante utilizadas neste trabalho.

O processo de normalização foi executado utilizando o comando *normalize* configurado para normalizar os dados no modo *zscore*. Desta forma, o conjunto de dados de entrada da rede foram totalmente representados dentro do intervalo de -1 até 1. O método *zscore* utiliza a média μ e o desvio padrão σ de uma variável aleatória X para padronizar os dados mantendo as propriedades dos dados originais, em termos matemáticos a equação 3.1 define o método *zscore*.

$$z = \frac{(x - \mu)}{\sigma} \quad (3.1)$$

3.2.1 Base de Dados

Em uma tarefa específica, os dados ou conjuntos de exemplos dos quais um computador aprende são tão importantes quanto os próprios algoritmos de aprendizado. Dados suficientes permitirão que o algoritmo de aprendizagem garanta uma representação geral, embora isso seja difícil de avaliar, além de observar seu desempenho em relação aos dados de validação.

Nesta atividade, o modelo proposto foi desenvolvido utilizando como informações para treinamento e validação uma base de dados disponibilizados em um repositório online mantido pela National Aeronautics and Space Administration (NASA) [37]. O referido banco de dados foi concebido a partir de vários conjuntos de dados doados por várias universidades, agências ou empresas. Além disso, podem ser utilizados para o desenvolvimento de algoritmos de prognóstico principalmente por serem séries temporais construídas a partir de um estado nominal para um estado de falha.

Na construção do banco de dados, foram utilizadas vinte e oito baterias de Lítio-íon modelo 18650 (esse código de modelo, refere-se as dimensões da bateria utilizada), essa bateria geralmente é utilizada em dispositivos portáteis como notebooks, câmeras digitais e entre outros. Além disso, esse modelo de bateria pode ser utilizada na composição de bancos de baterias de veículos elétricos e até mesmo satélites. Na tabela 1 estão dispostas as características da bateria utilizada nos ensaios.

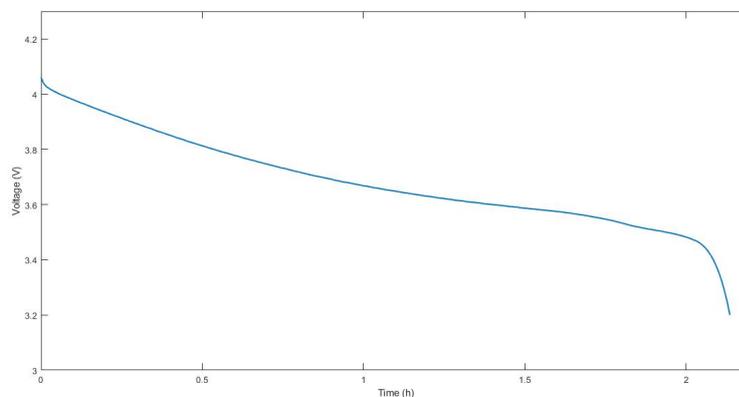
Tabela 1 – Especificações técnicas da bateria

Química	LMO
Tensão nominal	3,7 V
Tensão máxima	4.2 V
Tensão de cut-off	3.2 V
Capacidade nominal	2100 mAh
Impedância interna	48 m Ω
Número de ciclos	300
Geometria	Cilíndrica
Diâmetro	18.35 mm
Comprimento	65.10 mm
Massa	45.5 g

Os dados apresentados na tabela acima podem ser utilizados nos procedimentos de ensaios das baterias, como por exemplo, as tensões máxima e de cut-off podem ser utilizadas para setar valores de proteção para a bateria no ensaio. A capacidade nominal é bastante utilizada para observar o decaimento da vida útil da bateria, assim como o número de ciclos que neste caso é especificado pelo fabricante. A geometria da bateria corresponde ao formato como ela foi construída.

Em uma breve análise do banco de dados, observou-se que no conjunto de dados havia outliers, ou seja, alguns pontos atípicos nas curvas representando uma inconsistência no comportamento da variável em questão. Quando presente em uma série temporal, o fenômeno descrito anteriormente pode comprometer o modelo de previsão já que a confiabilidade dos dados no processo de aprendizagem da rede é indispensável. Em virtude disso, foi empregado um processo de tratamento no banco de dados para eliminar essas e outras incongruências detectadas, porém como este trabalho não é direcionado a este processo, assumiu-se que os dados não necessitaram de um processo de tratamento.

Figura 17 – Exemplo de um ensaio realizado em uma bateria

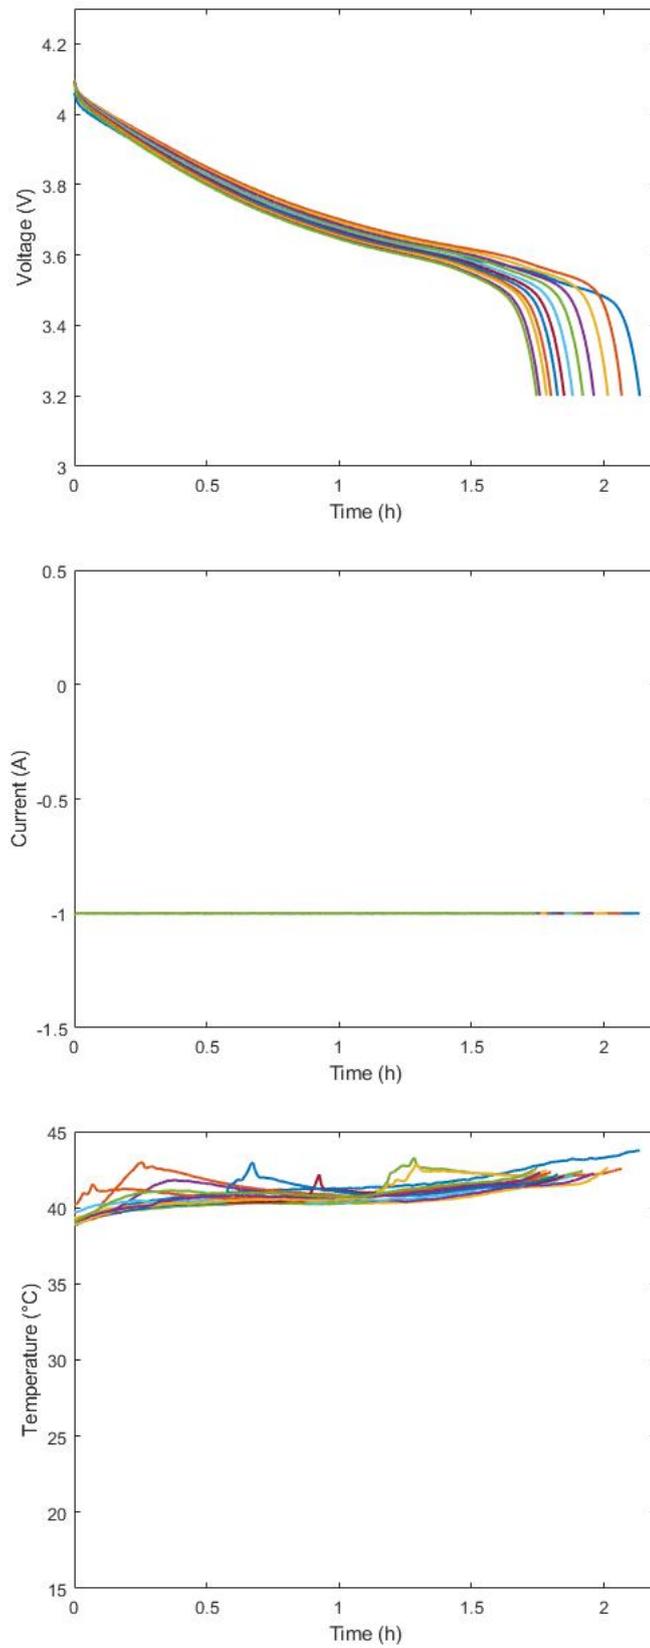


Fonte: elaborado pelo autor, 2019

A Figura 17 mostra uma curva de tensão característica de um ensaio contínuo de descarga, no qual a bateria foi submetida a uma descarga completa sem intervalos de repouso. O ensaio realizado demonstra o comportamento característico da química Lítio-íon, onde a curva de tensão tem em uma pequena faixa um comportamento praticamente exponencial, um trecho com comportamento um pouco linear na faixa intermediária e ao fim da curva um intervalo com comportamento similar a um degrau.

Vale destacar que a base de dados manipulada dispõe de uma ótima variedade de ensaios realizados nas baterias, por exemplo, ensaios com a bateria em estado de repouso, ensaios de carga e descarga contínua, testes de estresse dinâmico e entre outros tipos de ensaios. Para o desenvolvimento dos algoritmos neste trabalho, foram utilizados os ensaios de descarga contínua por prover uma boa consistência nos dados, a quantidade de ensaios realizados ser bastante satisfatória para o processo de treinamento e em um estudo mais detalhado a possibilidade de verificar a degradação da bateria ao longo do tempo. Em geral, as baterias foram submetidas a ensaios nos quais elas foram descarregadas da tensão máxima até alcançarem a tensão de cut-off, com período de amostragem de 10s e taxa de descarga de $0.47619C$.

Figura 18 – Ensaio da bateria 27



Fonte: elaborado pelo autor, 2019

Analisando a Figura 18 pode-se observar um comportamento característico da bateria, ao passo que o número de ensaios aumenta a curva de descarga deforma-se de maneira mais acelerada alcançando um ponto que torna-se praticamente inviável o emprego dessa bateria em alguma aplicação. Este comportamento será melhor abordado no desenvolvimento da seção do preditor de SoH da bateria.

3.2.2 Seleção de variáveis

No processo de seleção de variáveis, foram realizadas algumas considerações e utilizado o conhecimento teórico fundamentado pela revisão bibliográfica principalmente no desenvolvimento do preditor de SoH.

Preditor de SoC

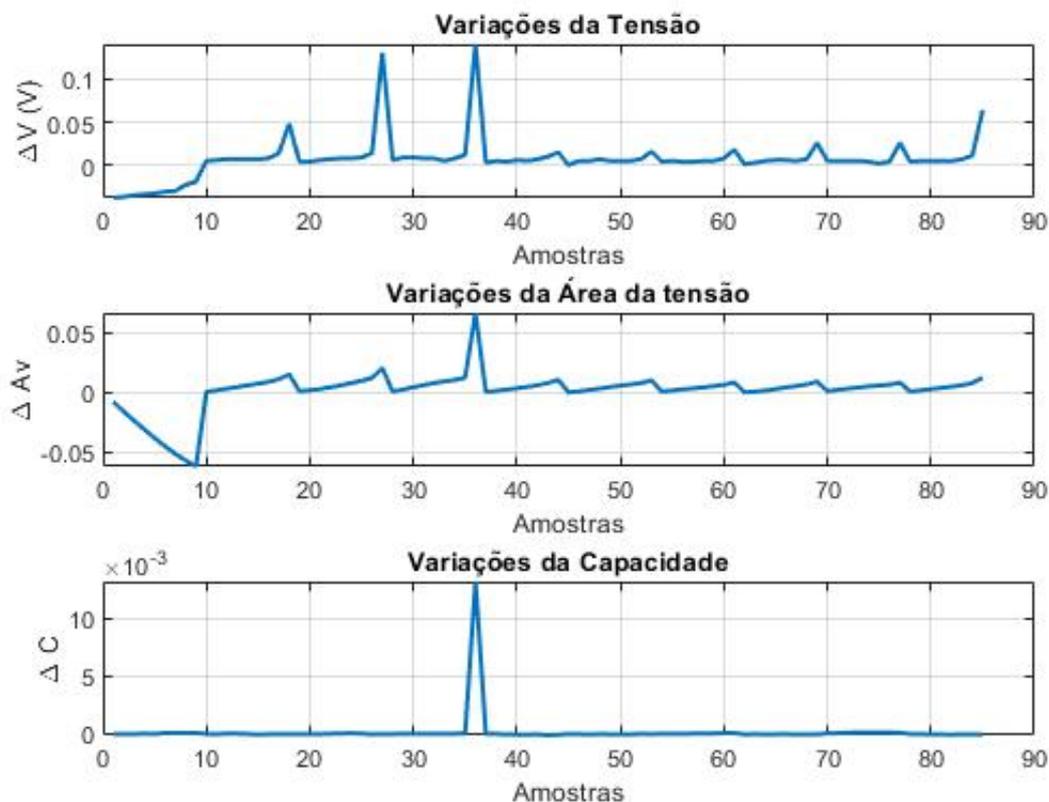
Na seleção das variáveis de entrada para o preditor de SoC, foram realizadas considerações teóricas embasadas no estudo de caso para o Estado de Carga. Assim, foram consideradas as principais grandezas que afetam o comportamento da bateria como corrente e temperatura.

A princípio, a tensão da bateria foi escolhida como entrada por representar o resultado de todo processo dinâmico interno da bateria. Já a corrente foi selecionada por ter uma relação direta com a carga disponível na bateria como visto na fundamentação teórica. Por fim, a temperatura também foi considerada por afetar o comportamento dinâmico interno da bateria, por exemplo, o aumento da temperatura provoca uma movimentação maior dos elétrons, causando uma perda mais rápida da massa ativa, que é formada pelas placas. Isso significa que a bateria está sofrendo descarregamento mais rápido.

Preditor de SoH

Como abordado na fundamentação teórica, o Estado de Saúde da bateria pode ser definido como o declínio da capacidade com o aumento do número de ciclos de uma bateria. Quando esse declínio atinge níveis onde a capacidade corresponde a menos de 80% da capacidade nominal, a bateria deve ser considerada em final de vida útil para aplicação em veículos elétricos ou híbridos. Por este motivo, a variação de capacidade entre ensaios também faz parte do vetor de entrada da rede NARX.

Figura 19 – Gráfico das variações



Fonte: elaborado pelo autor, 2019

Outra variável considerada como entrada da rede NARX foi a área sob a curva de tensão, observando o gráfico da Figura 18, percebe-se que a tendência da curva de tensão é diminuir sua área com o crescimento do número de ciclos. Em virtude desse comportamento, a área também foi considerada como entrada da rede. Além disso, pelo fato de selecionar pontos majoritariamente na região intermediária do gráfico de tensão onde possui um comportamento com uma semelhança ao de uma curva linear, os problemas originários de uma integração discreta são atenuados e com isso o erro neste vetor de entrada é diminuído. Assim como no preditor de SoC, no preditor de SoH foram consideradas as variações da tensão por serem resultado do processo dinâmico interno da bateria.

3.2.3 Preditor de Carga (SoC)

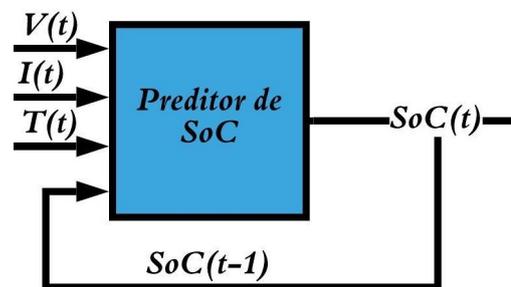
Em um primeiro momento, para o algoritmo de estimação de SoC cogitou-se a possibilidade de empregar um modelo de RNA Multilayer Perceptron, neste caso o feed-forward, em consequência da sua facilidade de implementação e velocidade de treinamento e validação. Entretanto, um problema bastante discutido foi a questão dinâmica de uma rede feedforward, dado que em um ambiente real poderá ocorrer situações que os dados

de entrada são totalmente diferentes dos dados aprendidos pela rede. Neste caso, a rede feedforward poderá ter um comportamento que não corresponde a resposta esperada. Assim sendo, afim de melhorar a resposta dinâmica do modelo proposto foi utilizada uma rede recorrente NARX para estimar o SoC, a seguir estão listadas as principais características da rede:

- Arquitetura: NARX;
- Número de camadas: 3;
- Número de neurônios: Este parâmetro foi variado dentro de um intervalo de 1 a 20, com o objetivo de encontrar a melhor configuração;
- Algoritmo de treinamento: Algoritmo de Levenberg-Marquadt (LM). Na concepção do modelo deste trabalho, empregou-se a *toolbox* NEURAL NETWORK TOOLBOX do MATLAB®(2019). O método de treinamento *Levenberg Marquadt* é denominado no *trainlm*, esse método de treinamento é um aperfeiçoamento do modelo tradicional *Backpropagation*. Afim de corrigir os pesos ao final de cada iteração, o algoritmo LM usa o erro médio quadrático para avaliar a divergência entre a saída e o valor desejável.

Na concepção do algoritmo da rede neural foram utilizadas as variáveis tensão, corrente e temperatura, além de um sinal de recorrência da saída, a Figura 20 demonstra a descrição realizada anteriormente. O processo de treinamento e validação da rede neural deu-se com 80% da população de baterias disponíveis, os outros 20% foram utilizados no processo de validação do algoritmo.

Figura 20 – Representação do Preditor de SoC



Fonte: elaborado pelo autor, 2019

O modelo mostrado na Figura 20 também pode ser representado pela equação 3.2.

$$SoC(t) = f(V(t), I(t), T(t), SoC(t - 1)) \quad (3.2)$$

3.2.4 Preditor de Saúde (SoH)

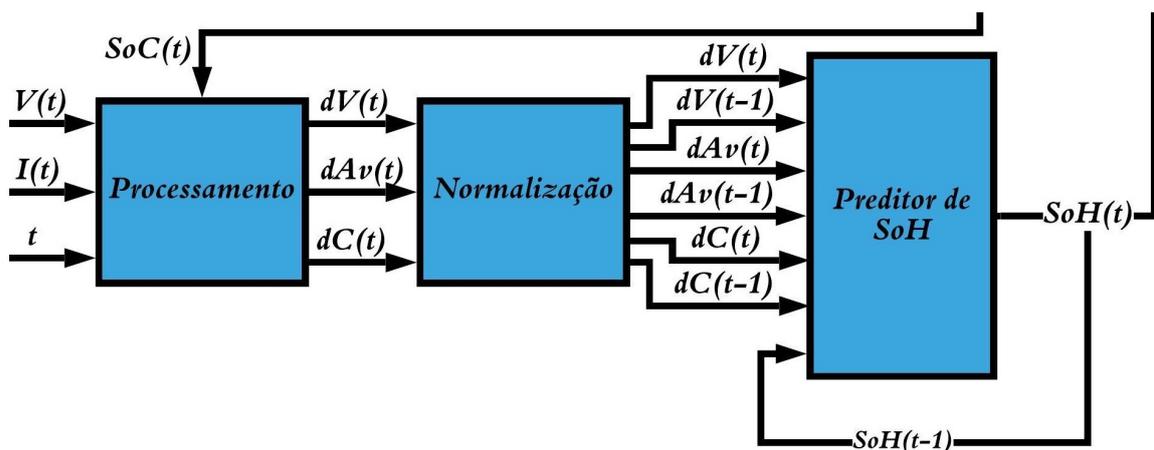
A idealização do algoritmo preditor de SoH deu-se a partir das mesmas bases do algoritmo preditor de SoC, em função da deficiência das redes feedforward em sistemas dinâmicos, o modelo de arquitetura de rede adotado como preditor de SoH também foi o NARX por proporcionar uma boa resposta em sistemas dinâmicos.

Analisando a Figura 21, observa-se uma representação do algoritmo desenvolvido como preditor de SoH e em especial pode-se destacar um bloco de processamento para gerar os vetores de entrada para treinamento e teste da rede. A rede NARX foi projetada com um atraso no vetor de entrada e um atraso de realimentação, pois foram realizados testes com outros atrasos e o que obteve melhor resultado do ponto de vista computacional, bem como de desempenho foi utilizando um atraso. A equação 3.3 também modela o preditor. A estrutura do preditor de SoH possui as seguintes características:

- Arquitetura: NARX;
- Número de Camadas: 3;
- Número de Neurônios: Este parâmetro foi variado entre o intervalo de 1 até 20 em cada camada. Desta forma, encontrou-se a melhor configuração.
- Algoritmo de treinamento: Levenberg-Marquadt(LM).

$$SoH(t) = f(dV(t), dV(t-1), dAv(t), dAv(t-1), dC(t), dC(t-1), SoH(t-1)) \quad (3.3)$$

Figura 21 – Representação do Preditor de SoH



Fonte: elaborado pelo autor, 2019

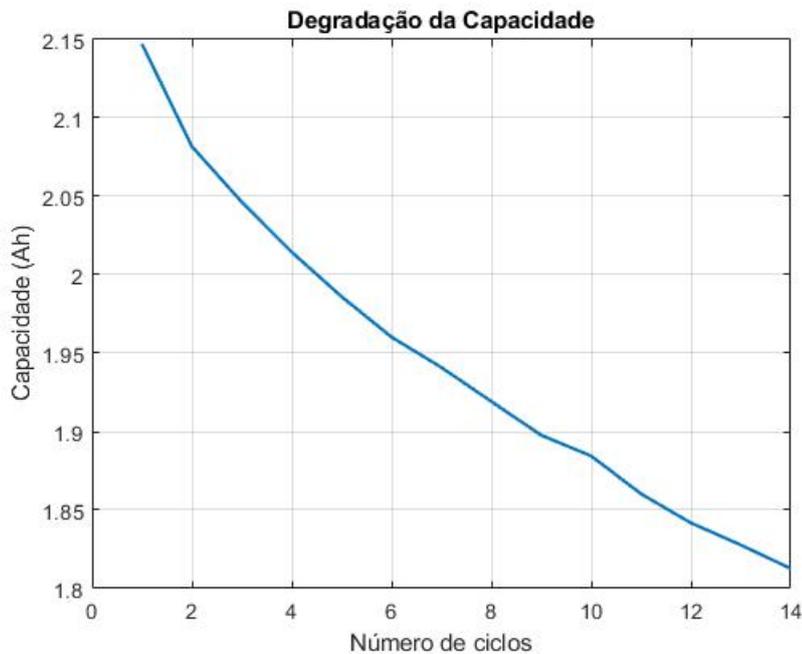
O bloco de processamento avalia o SoC para adquirir pontos nos vetores de tensão e corrente, a partir desses dados, são calculados a área sob a curva de tensão e a capacidade. Desta forma, os dados de tensão, área sob a curva de tensão e a capacidade são armazenados

e comparados com os dados adquiridos posteriormente. A faixa de SoC considerada nas aquisições está entre 90% e 20%, pois essa faixa corresponde a uma região na curva de tensão com comportamento mais estável.

Nos anexos deste trabalho, está presente a tabela 2 onde estão dispostos os valores de tensão organizados em "Ensaio versus SoC". Conforme descrito no parágrafo anterior os dados de um ensaios são comparados com o ensaio seguinte e desta maneira é gerado o vetor de variação de tensão ΔV . Os cálculos das variações da área da tensão ΔAv e da capacidade atual da bateria ΔC foram realizados de maneira similar ao da tensão. Ainda nos anexos está a tabela 3, apresentando alguns dos valores de variação de tensão calculados que foram utilizados no ensaio. Observando-a, temos os valores de transição entre um ensaio e outro classificados para cada estado de carga verificado.

Examinando a tabela 2 constata-se um comportamento característico do envelhecimento da bateria, ao passo que o número de ciclos aumenta, a bateria perde suas características como pode ser observado no declínio da tensão em um mesmo ponto de SoC entre um ensaio e outro. Outro comportamento específico da degradação é a atenuação da vida útil da bateria, verificada pela perda de dados a partir do ensaio 17 quando o SoC é 20%.

Figura 22 – Degradação da capacidade da bateria



Fonte: elaborado pelo autor, 2019

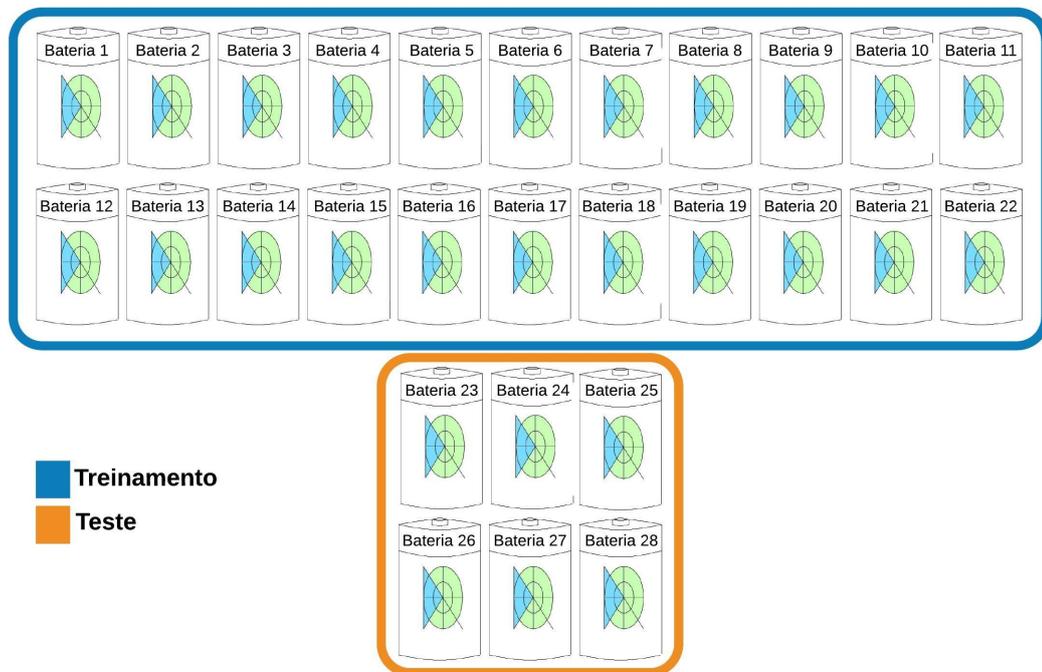
No gráfico da Figura 22 observa-se o comportamento da capacidade de uma bateria ao longo de sua vida útil, comprovando que as afirmações no parágrafo anterior.

4 Resultados

Neste capítulo, os resultados obtidos no estágio de teste dos preditores serão apresentados e comentados com mais detalhes considerando como base todo o desenvolvimento no capítulo anterior e as estruturas dos preditores de SoC e SoH.

Em uma breve revisão do que foi comentado nos capítulos anteriores, destaca-se que o banco de dados utilizado foi construído utilizando baterias de Lítio-íon 18650 com tensão nominal 3.6 V e capacidade nominal 2100 mAh. A base de dados em questão possui diversos tipos de ensaios como testes de estresse dinâmico, ensaios pulsados, ensaios contínuos de carga e descarga e entre outros. Os ensaios contínuos de descargas por apresentarem-se com uma quantidade satisfatória de ensaios para modelagem do preditor de SoH e consistência nos dados, devido a essas vantagens foram utilizados no processo de treinamento e teste das redes. Na Figura 23, observa-se as partições da base de dados utilizadas no processo de treinamento e no processo de teste do preditor do SoC. Para o caso do preditor do SoH foram usadas o conjunto de treinamento de baterias de 1 até 25, e para o teste as baterias 26 até 28.

Figura 23 – Diagrama da base de dados para o preditor SoC



Fonte: Elaborado pelo autor, 2019

Como métrica de avaliação dos preditores, foi utilizado o Erro Médio Relativo

Percentual (MAPE). O MAPE, de modo formal, significa o valor absoluto da diferença existente entre um valor de referência e um valor aproximado dividido pela magnitude do mesmo valor. Em resumo, esse método permite a você determinar o quão próximos estão os valores estimados e medidos em forma de porcentagem. Em termos matemáticos o MAPE pode ser representado da seguinte maneira:

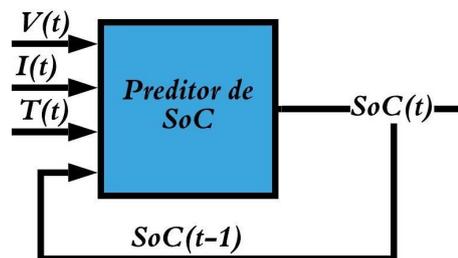
$$MAPE_{\%} = 100\% * \frac{1}{N} \sum_{k=1}^N \left| \frac{P_k - T_k}{P_k} \right| \quad (4.1)$$

Onde, N corresponde ao tamanho do conjunto de validação, P_k é o vetor de saída da rede (dados previstos) e T_k corresponde aos targets dos preditores. Ao fim da fase de treinamento de todas as redes, as melhores estruturas foram selecionadas considerando os menores valores de MAPE (Erro Relativo Absoluto Percentual) durante o processo de teste. A validação da arquitetura da rede está atrelada aos vetores de previsão para o conjunto de dados que não fazem parte do estágio de treinamento.

4.1 Preditor de SoC

Resumidamente, embasado na evolução da seção 3.2.3, o preditor de SoC foi desenvolvido empregando como entradas a tensão e a temperatura da bateria, assim como o nível de corrente utilizado no ensaio e um sinal atrasado de SoC. Durante o estágio de treinamento, foi executado um processo de varredura afim de encontrar a melhor configuração das camadas ocultas da rede NARX, tal varredura foi executada variando dentro de um intervalo de 1 até 20 a quantidade de neurônios que compõem as três camadas da rede, dessa forma foram obtidas 8000 redes neurais distintas.

Figura 24 – Diagrama do preditor de SoC



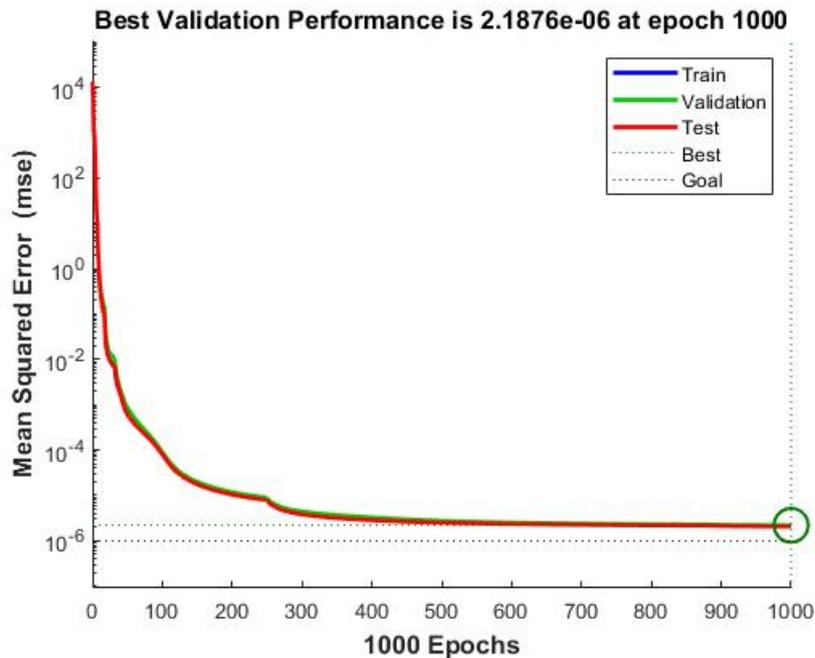
Fonte: Elaborado pelo autor, 2019

No processo de treinamento foram utilizados alguns parâmetros importantes como número de épocas setado para 1000, tempo máximo de treinamento 60s e meta de métrica para performance fixado em $1 * 10^{-6}$. As escolhas na configuração de treinamento apresentadas anteriormente, foram realizadas com base em testes de desempenho demonstrado pela rede no processo de treinamento. Na subseção posterior, serão apresentados os resultados do estágio de treinamento e teste.

4.1.1 Resultados do Preditor de SoC

Na Figura 25, observa-se o comportamento da desempenho da rede a medida que o número de iterações do processo de treinamento aumenta. Nesta etapa, o algoritmo de treinamento considerou como métrica de validação o Erro Médio Quadrático (MSE) para comparação entre as previsões da rede e os dados esperados.

Figura 25 – Gráfico da desempenho da rede

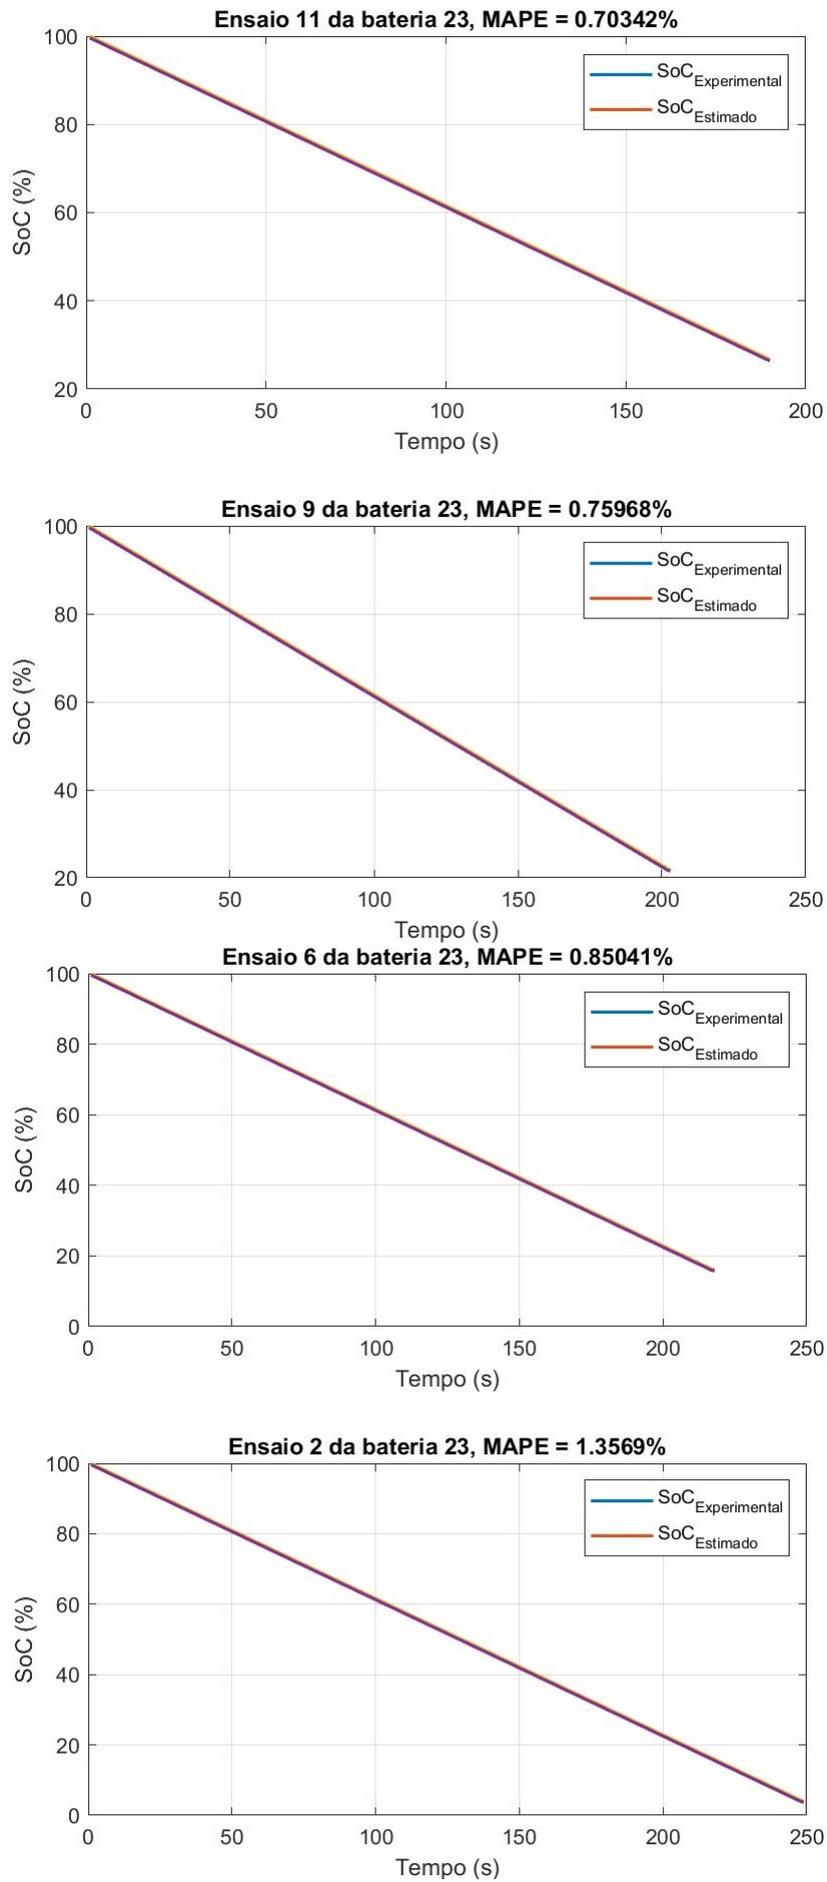


Fonte: Elaborado pelo autor, 2019

Uma vez realizado o treinamento de todas as redes, estas foram avaliadas por meio da partição da base de dados destinada aos testes. Assim, foi implementado um script para efetuar o processo de teste em cada rede e computar os respectivos valores do MAPE. Após selecionada a melhor rede NARX, foram utilizados vetores de ensaios aleatórios em uma mesma bateria para calcular os erros MAPE correspondentes e validar a rede.

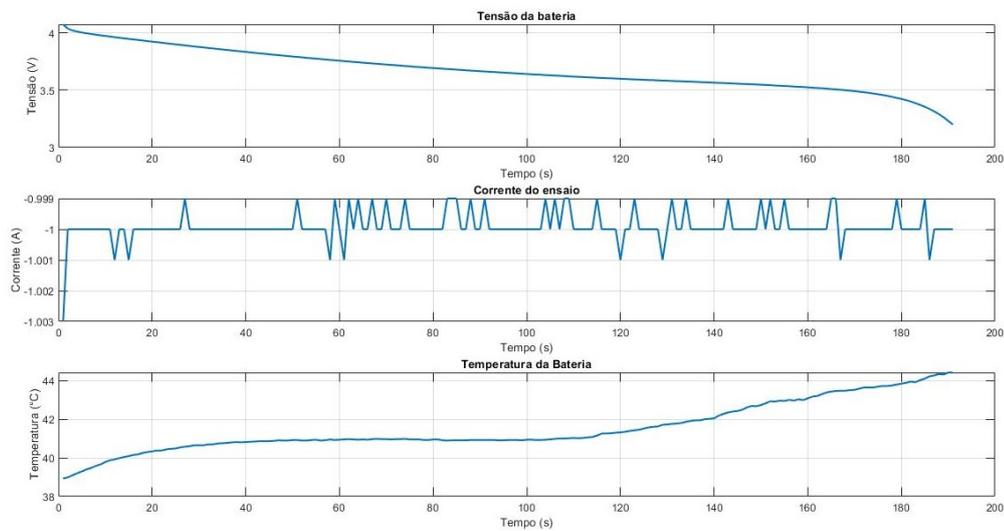
Por fim, com o processo de treinamento concluído, os testes foram executados tendo como resultados os gráficos apresentados da Figura 26, para a bateria 23 (pertencente ao conjunto de baterias usadas para o teste da RNA). Analisando-a, no título de todos os gráficos aparece o erro MAPE de referente a cada processo de teste juntamente com o ciclo da bateria. Em uma análise geral, verifica-se que o algoritmo adaptou-se bem a dinâmica do sistema como pode-se constatar pela observação dos gráficos. Além disso, observando que a curva termina em pontos diferentes do plano, pode-se afirmar fundamentado no desenvolvimento do capítulo 3 que esse efeito é o resultado do aumento do número de ciclos da bateria. Como resultado dos testes o erro MAPE médio dos ensaios 2, 6, 9 e 11, foi de 0.9176%.

Figura 26 – Resposta do Preditor de SoC



Como todos os ensaios que compõem a partição do banco de dados destinada a teste possuem as mesmas características, assim uma análise detalhada do primeiro ensaios pode ser feita sendo válida para os demais. Na Figura 27 são apresentados os vetores do ensaio utilizados no primeiro teste, a bateria foi submetida a uma taxa de descarga de $0.4762C$ sendo descarregada da tensão máxima até a tensão de cut-off. Outro fato importante é que mesmo estando em ambiente com temperatura controlada, a temperatura da bateria variou bruscamente partindo de aproximadamente $39^{\circ}C$ até pouco mais de $44^{\circ}C$.

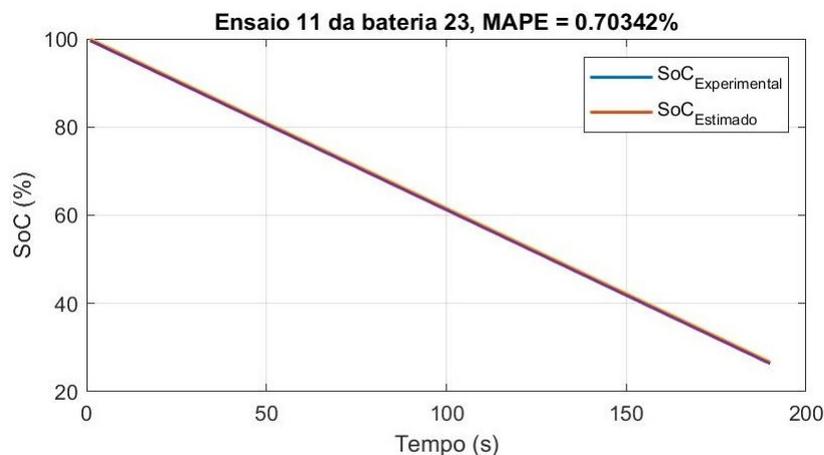
Figura 27 – Vetores de entrada da rede no primeiro teste



Fonte: Elaborado pelo autor, 2019

Dado o vetor de entrada exposto acima, foi obtido como resultado o gráfico apresentado pela Figura 28.

Figura 28 – Gráfico da melhor resposta

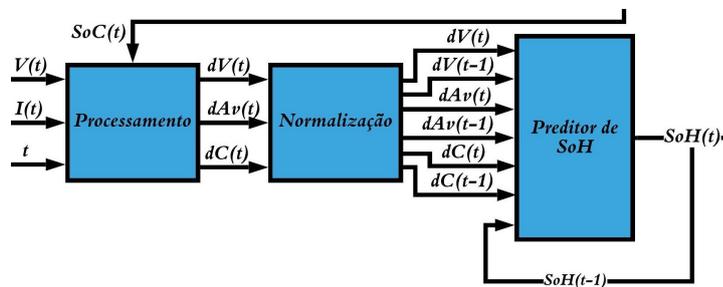


Fonte: Elaborado pelo autor, 2019

4.2 Preditor de SoH

Recapitulando tudo que foi apresentado na seção 3.2.4, o modelo de preditor elaborado teve como entradas as variações de tensão, área sob a curva de tensão e capacidade, do mesmo modo que um atraso de amostra desses sinais e do SoH também foram utilizados como demonstra a Figura 29. Assim como o ocorreu no desenvolvimento do preditor de SoC, no preditor de SoH também foi executado uma varredura ao longo do estágio de treinamento alterando o número de neurônios de cada camada da rede NARX. Dessa forma, o número de neurônios de cada camada variou ente 1 e 20 obtendo como resultados 8000 preditores distintos.

Figura 29 – Diagrama de blocos do Preditor de SoH



Fonte: Elaborado pelo autor, 2019

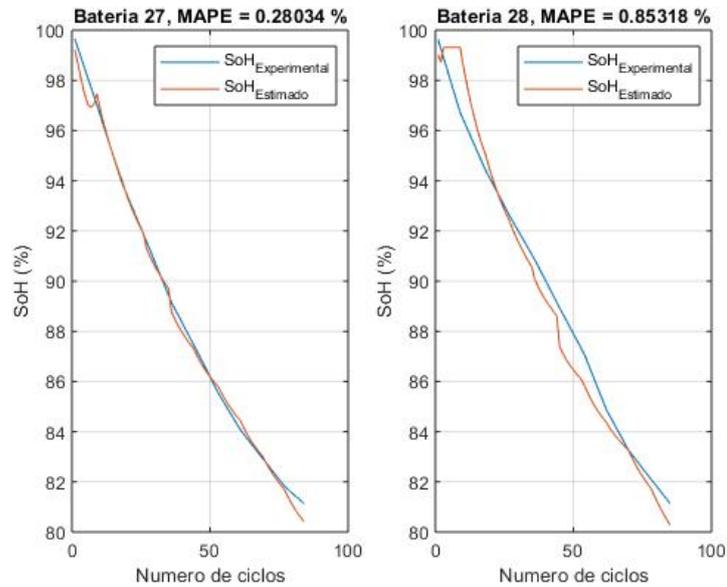
No processo de treinamento foram utilizados alguns parâmetros importantes como número de épocas setado para 1500, tempo máximo de treinamento 40s e meta de métrica para performance fixado em 1×10^{-3} . Na subseção posterior, serão apresentados os resultados do estágio de treinamento e teste.

4.2.1 Resultados do preditor de SoH

Seguindo o mesmo processo descrito na implementação do preditor de SoC, o procedimento de treinamento foi executado em todas as redes obtendo a estrutura com as redes treinadas. Após este estágio, foi realizada uma avaliação de cada rede com base na partição do banco de dados selecionada para teste. Com a seleção da rede NARX com melhor precisão, foram utilizados vetores da partição para teste para calcular os erros MAPE correspondentes e validar o algoritmo.

Com o processo de treinamento concluído, os testes de validação foram efetuados para as baterias pertencentes ao conjunto de testes (27 e 28), cujos resultados são apresentados na Figura 30. Observando a figura, o título de cada gráfico descreve a bateria utilizada e o erro MAPE obtido no teste, ainda verifica-se que houveram previsões com boa precisão mesmo que em certas regiões não houve uma semelhança esperada. O erro MAPE médio para estes resultados foi de 0.58%.

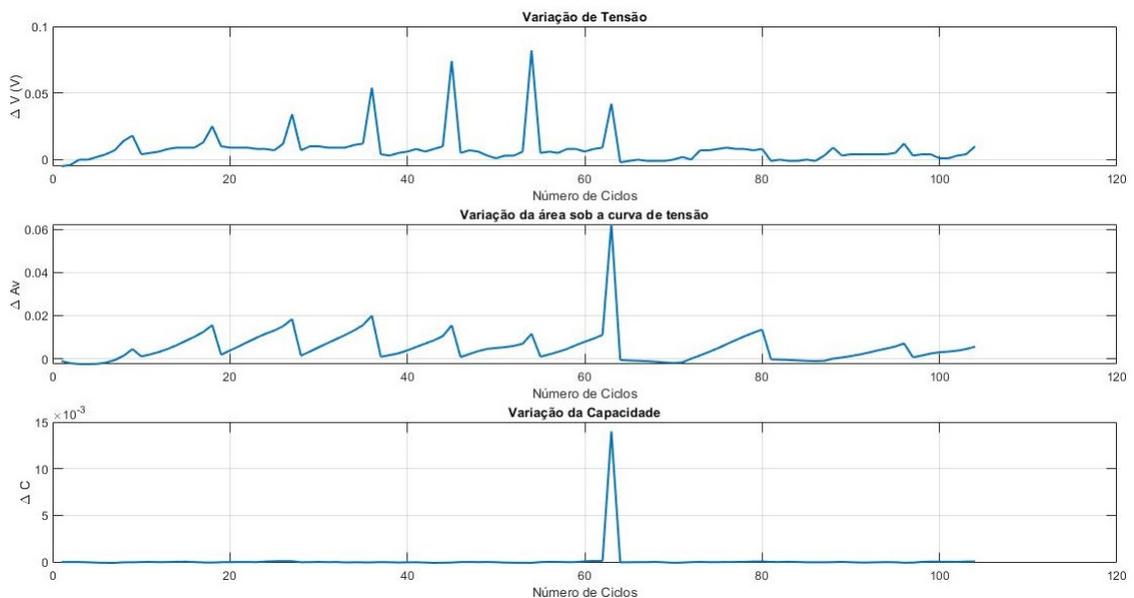
Figura 30 – Resposta do Preditor de SoH



Fonte: Elaborado pelo autor, 2019

Com a finalidade de exemplificar o processo de estimação do SoH, na Figura 31 se ilustram o conjunto de entradas para RNA referentes a bateria 27 (ΔV , ΔA e ΔC). Essas características dos sinais de entrada são similares para a partição de ensaios de baterias do mesmo modelo e com a mesma corrente de descarga.

Figura 31 – Trecho dos vetores de entrada da rede

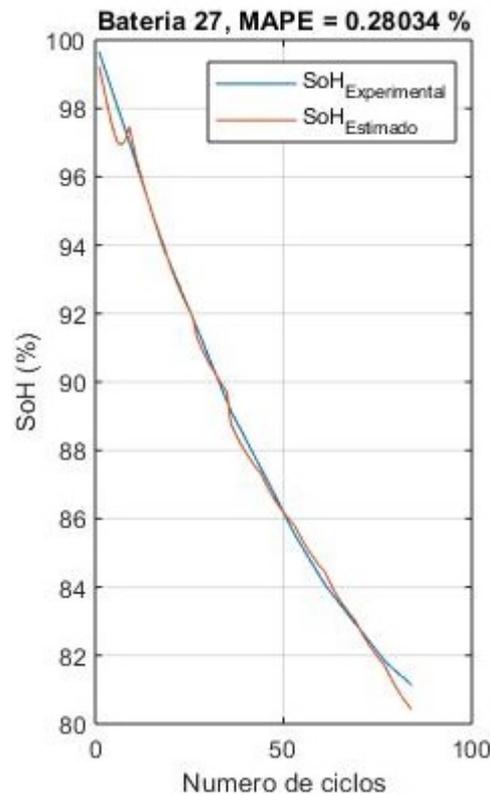


Fonte: Elaborado pelo autor, 2019

Como resultados da previsão com os dados do gráfico acima, foram obtidos os

gráficos da Figura 32.

Figura 32 – Trecho dos vetores de entrada da rede



Fonte: Elaborado pelo autor, 2019

Com base no desenvolvimento nas seções 4.1 e 4.2, mesmo com o comportamento dinâmico do sistema, observou-se que os preditores proporcionaram respostas esperadas diante dos vetores de entrada empregados. Ainda que com uma certa variação, os vetores de resposta dos preditores permaneceram dentro da faixa esperada principalmente em se tratando do preditor de SoC, que mostrou-se muito robusto respondendo com um erro máximo de 0.9176%. Com relação ao preditor de SoH, sua precisão garantiu bons resultados com um erro máximo de 0.58%. Entretanto, como ainda é uma área pouco estudada, esse preditor tem um potencial muito grande em sua evolução com trabalhos futuros tendo um estudo mais aprofundado para implementação de suas entradas ou na aplicação de redes profundas onde pode-se trabalhar melhor a arquitetura para proporcionar uma precisão maior.

5 Conclusão

Neste trabalho, foi apresentado um estudo de caso para o desenvolvimento de um modelo de previsão abordando técnicas de Machine Learning. O objetivo central deste trabalho foi desenvolver preditores para mensurar o Estado de Carga e o Estado de Saúde de uma bateria de Li-ion. A princípio, para construir um modelo robusto que adapte-se a dinâmica do sistema em questão, de forma que foram considerados tensão, corrente e temperatura no preditor de SoC e a variação de tensão, área sob a curva de tensão e capacidade entre um ciclo de ensaio e outro.

O modelo de rede neural empregado tanto no preditor de SoC quanto no preditor de SoH foi a NARX, principalmente pelo fato da rede comportar-se bem para entradas as quais ela não foi treinada. Com os dados obtidos de um repositório mantido pela NASA, após um processo de tratamento para eliminar possíveis *outliers* presentes na base de dados, foi possível extrair os vetores de entrada necessários para a implementação dos algoritmos.

No desenvolvimento do preditor de SoC foi necessário um esforço computacional para encontrar uma rede NARX robusta que conseguisse responder satisfatoriamente a dinâmica do sistema. Os resultados obtidos com o algoritmo desenvolvido foram bastante satisfatórios, resultando em um erro MAPE médio dos ensaios analisados de 0.9176%.

A concepção do modelo do preditor de SoH necessitou de um esforço computacional ainda maior na etapa de treinamento, para gerar os vetores de entradas abordados no desenvolvimento do capítulo 3, foi necessário realizar um processo de pré-tratamento dos dados originais. Desta forma, os vetores de variação foram construídos através da comparação entre os pontos adquiridos do ciclo atual e os pontos do ciclo posterior. O erro MAPE obtido na etapa de teste do preditor de SoH foi de 0.58%, porém alguns curtos trechos da curva não tiveram um comportamento esperado.

Sem dúvidas, a principal contribuição deste trabalho consiste em conseguir relacionar o comportamento característico da degradação da bateria através dos vetores de variação, com o Estado de Saúde utilizando como meio técnicas de Machine Learning.

Em trabalhos futuros, estes preditores podem ser aprimorados através estudos mais aprofundados na seleção de variáveis principalmente no preditor de SoH. Outro ponto que pode ser melhorado são as arquiteturas de redes, provavelmente a utilização de redes profundas como por exemplo, as LSTM que possibilitam ao projetista a vantagem da memória de curto e longo prazo para que sejam considerados na ponderação dos pesos na saída da redes. Além disso, as redes profundas proporcionam ao projetista uma vasta gama de possibilidade em relação sua arquitetura interna.

Referências

- 1 Guojin Ma et al. Estimation of li-ion battery soh using fletcher-reeves based anfis. In: *2015 IEEE 24th International Symposium on Industrial Electronics (ISIE)*. [S.l.: s.n.], 2015. p. 827–830. Citado 3 vezes nas páginas 11, 43 e 44.
- 2 WORLD ENERGY OUTLOOK. 2018. Citado na página 19.
- 3 UNITED NATIONS. Our common future: Report of the world commission on environment and development. p. p.54, 1987. Citado na página 19.
- 4 BLOOMBERG NEW ENERGY FINANCE. 2019. Disponível em: <<http://www.istoedinheiro.com.br/carros-eletricos-representarao-57-do-mercado-em-2040-projeta-bloomberg>>. Citado na página 19.
- 5 AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. 2018. Citado na página 20.
- 6 Dai, H. et al. 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, Oct 2019. Citado 2 vezes nas páginas 21 e 30.
- 7 HURIA T.,CERAOLO M.,GAZZARRI J.,JACKEY R. "Simplified Extended Kalman Filter Observer for SOC Estimation of Commercial Power-Oriented LFP Lithium Battery Cells". *SAE International*, 2013. Disponível em: <<https://doi.org/10.4271/2013-01-1544>>. Citado na página 21.
- 8 FOGAÇA, J. R. VARGAS. Bateria de chumbo dos automóveis. *Brasil Escola*, 2019. Disponível em: <<https://brasilecola.uol.com.br/quimica/bateria-chumbo-dos-automoveis>>. Citado na página 25.
- 9 BATTERY UNIVERSITY. Baterias a base de chumbo. *BATTERY UNIVERSITY*. Disponível em: <https://batteryuniversity.com/learn/article/lead_based_batteries>. Citado na página 26.
- 10 RAFAEL H. L. DA TRINDADE. "estudo das características de bterias recarregáveis possíveis de serem utilizadas no projeto satélite universitário, itasat". 2006. Citado 2 vezes nas páginas 26 e 28.
- 11 BATTERY UNIVERSITY. Baterias a base de níquel. *BATTERY UNIVERSITY*. Disponível em: <https://batteryuniversity.com/learn/article/nickel_based_batteries>. Citado na página 26.
- 12 BATTERY UNIVERSITY. Baterias de lithion-ion. *BATTERY UNIVERSITY*. Disponível em: <https://batteryuniversity.com/learn/article/lithium_based_batteries>. Citado na página 28.

- 13 MIT ELECTRIC VEHICLE TEAM. "A Guide Understanding Battery Specifications . *Massachusetts Institute of Technology*, 2008. Disponível em: <http://mit.edu/evt/summary_battery_specifications.pdf>. Citado na página 29.
- 14 CHEN Z., SUN H., DONG G., WEI J., WU J.,. "Particle filter-based state-of-charge estimation and remaining-dischargeable-time prediction method for lithium-ion batteries . *Journal of Power Sources*, v. 414, n. 10, p. 158–166, 2019. ISSN 0378-7753. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378775319300138>>. Citado na página 29.
- 15 MENG C., RICCO M., ACHARYA A. B., LUO G., SWIERCZYNSKI M., STROE D., TEODORESCU R. "Low-complexity online estimation for LiFePO₄ battery state of charge in electric vehicles . *Journal of Power Sources*, v. 395, n. 10, p. 280–288, 2018. ISSN 0378-7753. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378775318305664>>. Citado na página 29.
- 16 Zhou, J. et al. Battery state of health estimation using the generalized regression neural network. In: *2015 8th International Congress on Image and Signal Processing (CISP)*. [S.l.: s.n.], 2015. p. 1396–1400. Citado na página 29.
- 17 Shen, P. et al. 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, Jan 2018. ISSN 0018-9545. Citado 2 vezes nas páginas 29 e 32.
- 18 MOHAMMED, F. "Lithium-Ion Batteries: Modelling and State of Charge Estimation. . *McMaster University*, 2013. Citado 3 vezes nas páginas 29, 31 e 33.
- 19 M. GALEOTTI, C. GIAMMANCO, L. CINÀ, S. CORDINER, A. Di CARLO, . "Synthetic methods for the evaluation of the State of Health (SOH) of nickel-metal hydride (NiMH) batteries . *Energy Conversion and Management*, v. 92, p. 1–9, 2015. ISSN 0196-8904. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0196890414010796>>. Citado na página 30.
- 20 He, L.; Guo, D. An improved coulomb counting approach based on numerical iteration for soc estimation with real-time error correction ability. *IEEE Access*, v. 7, p. 74274–74282, 2019. Citado na página 31.
- 21 BACCOUNCHE I., JEMMALY S.; MLAYAH A., MANAI B., E. B. AMARA N. "Implementation of an Improved Coulomb-Counting Algorithm Based on a Piecewise SOC-OCV Relationship for SOC Estimation of Li-Ion Battery . *NASA/ADS*, 2018. Disponível em: <<https://arxiv.org/abs/1803.10654>>. Citado na página 31.
- 22 Xiong, R.; Mu, H. Accurate state of charge estimation for lithium-ion battery using dual unscented kalman filters. In: *2017 Chinese Automation Congress (CAC)*. [S.l.: s.n.], 2017. p. 5484–5487. Citado na página 33.

- 23 T. HURIA, M. CERAOLO, J. GAZZARRI, R. JACKY. "Simplified Extended Kalman Filter Observer for SOC Estimation of Commercial Power-Oriented LFP Lithium Battery Cells
. *SAE International*, 2013. Disponível em: <<https://doi.org/10.4271/2013-01-1544>>. Citado na página 33.
- 24 MICHELL, T. M. *Machine Learning*. [S.l.]: McGraw-Hill Science/Engineering/Math, 1997. Citado na página 34.
- 25 CHEMALI, E. "Intelligent State of Charge and State of Health Estimation Framework For Li-Ion Batteries in Electrified Vehicles Using Deep Learning Techniques
. *McMaster University*, 2018. Citado na página 35.
- 26 HAYKIN, S. *Neural Network: A comprehensive foundation*. [S.l.]: MacMillan Publishing Company, 1994. Citado 6 vezes nas páginas 35, 36, 37, 38, 40 e 41.
- 27 Hagan, M. T.; Menhaj, M. B. Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, v. 5, n. 6, p. 989–993, Nov 1994. Citado na página 39.
- 28 . "Design Time Series NARX Feedback Neural Networks
. *Mathworks Matlab*. Disponível em: <<https://www.mathworks.com/help/deeplearning/ug/design-time-series-narx-feedback-neural-networks.html>>. Citado na página 41.
- 29 ZHANG, Q. et al. State-of-charge estimation method of lithium-ion batteries based on long-short term memory network. *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, v. 208, p. 012001, dec 2018. Disponível em: <<https://doi.org/10.1088%2F1755-1315%2F208%2F1%2F012001>>. Citado 2 vezes nas páginas 41 e 42.
- 30 Hannan, M. A. et al. Neural network approach for estimating state of charge of lithium-ion battery using backtracking search algorithm. *IEEE Access*, v. 6, p. 10069–10079, 2018. Citado na página 42.
- 31 C. CHEN, R. XIONG, R. YANG, W. SHEN, F. SUN. "State-of-charge estimation of lithium-ion battery using an improved neural network model and extended Kalman filter
. *Journal of Cleaner Production*, v. 234, p. 1153–1164, 2019. ISSN 0959-6526. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0959652619322383>>. Citado na página 42.
- 32 Liu, F.; Liu, T.; Fu, Y. An improved soc estimation algorithm based on artificial neural network. In: *2015 8th International Symposium on Computational Intelligence and Design (ISCID)*. [S.l.: s.n.], 2015. v. 2, p. 152–155. Citado na página 42.
- 33 Chitnis, M. S.; Pandit, S. P.; Shaikh, M. N. Electric vehicle li-ion battery state of charge estimation using artificial neural network. In: *2018 International Conference on Inventive Research in Computing Applications (ICIRCA)*. [S.l.: s.n.], 2018. p. 992–995. Citado na página 42.
- 34 Zhou, J. et al. Battery state of health estimation using the generalized regression neural network. In: *2015 8th International Congress on Image and Signal Processing (CISP)*. [S.l.: s.n.], 2015. p. 1396–1400. Citado 2 vezes nas páginas 43 e 44.

-
- 35 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, May 2013. Citado na página 43.
- 36 Zhou, Y.; Huang, M.; Pecht, M. An online state of health estimation method for lithium-ion batteries based on integrated voltage. In: *2018 IEEE International Conference on Prognostics and Health Management (ICPHM)*. [S.l.: s.n.], 2018. p. 1–5. Citado na página 44.
- 37 NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. Disponível em: <<http://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository>>. Citado na página 47.

Anexos

Tabela com pontos adquiridos

Na Tabela 2 estão dispostos as tensões adquiridas para cálculo das variações entre os ensaios, a tabela está dividida em oito colunas onde as tensões foram selecionadas de acordo com o SoC da coluna correspondente. Em relação as linhas, a tabela está divididas em 48 linhas que correspondem ao ensaio que a tensão foi selecionada.

Tabela 2 – Tabela das tensões adquiridas

	SoC 90%	SoC 80%	SoC 70%	SoC 60%	SoC 50%	SoC 40%	SoC 30%	SoC 20%	SoC 10%
Ensaio 1	3,875	3,779	3,698	3,641	3,596	3,555	3,526	3,485	3,361
Ensaio 2	3,884	3,795	3,719	3,658	3,609	3,570	3,540	3,500	3,368
Ensaio 3	3,908	3,817	3,739	3,672	3,622	3,585	3,554	3,503	3,276
Ensaio 4	3,912	3,821	3,746	3,686	3,635	3,592	3,561	3,514	3,294
Ensaio 5	3,902	3,810	3,734	3,666	3,615	3,580	3,542	3,478	
Ensaio 6	3,901	3,808	3,733	3,672	3,623	3,585	3,548	3,487	3,200
Ensaio 7	3,909	3,814	3,738	3,674	3,622	3,582	3,544	3,456	
Ensaio 8	3,902	3,809	3,733	3,670	3,621	3,584	3,545	3,457	
Ensaio 9	3,905	3,809	3,732	3,671	3,621	3,583	3,539	3,413	
Ensaio 10	3,906	3,811	3,735	3,673	3,623	3,586	3,543	3,424	
Ensaio 11	3,908	3,811	3,733	3,670	3,621	3,583	3,532	3,353	
Ensaio 12	3,902	3,805	3,728	3,665	3,616	3,578	3,523	3,329	
Ensaio 13	3,897	3,798	3,719	3,654	3,606	3,566	3,500	3,261	
Ensaio 14	3,902	3,804	3,726	3,663	3,616	3,578	3,518	3,295	
Ensaio 15	3,889	3,789	3,711	3,648	3,600	3,557	3,475	3,200	
Ensaio 16	3,888	3,789	3,710	3,647	3,599	3,557	3,473	3,200	
Ensaio 17	3,882	3,781	3,703	3,639	3,591	3,545	3,443		
Ensaio 18	3,883	3,783	3,705	3,641	3,593	3,547	3,449		
Ensaio 19	3,870	3,769	3,690	3,625	3,578	3,524	3,393		
Ensaio 20	3,872	3,771	3,692	3,628	3,583	3,531	3,400		
Ensaio 21	3,865	3,762	3,682	3,619	3,573	3,511	3,358		
Ensaio 22	3,866	3,763	3,683	3,620	3,573	3,512	3,365		
Ensaio 23	3,860	3,756	3,678	3,615	3,566	3,494	3,326		
Ensaio 24	3,864	3,760	3,679	3,615	3,568	3,499	3,337		
Ensaio 25	3,851	3,747	3,669	3,610	3,563	3,491	3,339		
Ensaio 26	3,855	3,754	3,676	3,612	3,562	3,488	3,334		
Ensaio 27	3,843	3,739	3,660	3,599	3,546	3,458	3,282		
Ensaio 28	3,844	3,740	3,661	3,600	3,544	3,452	3,273		
Ensaio 29	3,834	3,729	3,651	3,590	3,530	3,429	3,237		
Ensaio 30	3,842	3,735	3,655	3,594	3,537	3,438	3,250		
Ensaio 31	3,827	3,723	3,646	3,586	3,524	3,413	3,208		
Ensaio 32	3,832	3,727	3,648	3,585	3,519	3,404	3,200		
Ensaio 33	3,814	3,707	3,627	3,566	3,490	3,359			
Ensaio 34	3,815	3,708	3,628	3,565	3,490	3,359			
Ensaio 35	3,811	3,705	3,627	3,566	3,490	3,358			
Ensaio 36	3,804	3,698	3,620	3,559	3,480	3,339			
Ensaio 37	3,789	3,682	3,604	3,538	3,443	3,290			
Ensaio 38	3,794	3,686	3,606	3,540	3,446	3,296			
Ensaio 39	3,791	3,682	3,603	3,536	3,438	3,272			
Ensaio 40	3,796	3,686	3,606	3,541	3,447	3,284			
Ensaio 41	3,790	3,679	3,600	3,530	3,432	3,252			
Ensaio 42	3,803	3,692	3,611	3,544	3,450	3,276			
Ensaio 43	3,816	3,705	3,625	3,562	3,483	3,342			
Ensaio 44	3,809	3,697	3,616	3,551	3,465	3,305			
Ensaio 45	3,775	3,661	3,582	3,506	3,383				
Ensaio 46	3,773	3,657	3,577	3,498	3,370				
Ensaio 47	3,750	3,634	3,552	3,456	3,293				
Ensaio 48	3,750	3,633	3,552	3,464	3,309				

Tabela com variações de tensão

A tabela 3 apresenta as variações de tensão calculadas a partir da tabela 2, as colunas correspondem ao SoC considerado na seleção dos pontos. As linhas, descritas como transição, correspondem a variação entre o ensaio atual e o ensaio posterior.

Tabela 3 – Tabela das variações calculadas

	SoC 90%	SoC 80%	SoC 70%	SoC 60%	SoC 50%	SoC 40%	SoC 30%	SoC 20%	SoC 10%
Transição 1	-0,0090	-0,0160	-0,0210	-0,0170	-0,0130	-0,0150	-0,0140	-0,0150	-0,0070
Transição 2	-0,0240	-0,0220	-0,0200	-0,0140	-0,0130	-0,0150	-0,0140	-0,0030	0,0920
Transição 3	-0,0040	-0,0040	-0,0070	-0,0140	-0,0130	-0,0070	-0,0070	-0,0110	-0,0180
Transição 4	0,0100	0,0110	0,0120	0,0200	0,0200	0,0120	0,0190	0,0360	0,094
Transição 5	0,0010	0,0020	0,0010	-0,0060	-0,0080	-0,0050	-0,0060	-0,0090	
Transição 6	-0,0080	-0,0060	-0,0050	-0,0020	0,0010	0,0030	0,0040	0,0310	
Transição 7	0,0070	0,0050	0,0050	0,0040	0,0010	-0,0020	-0,0010	-0,0010	
Transição 8	-0,0030	0,0000	0,0010	-0,0010	0,0000	0,0010	0,0060	0,0440	
Transição 9	-0,0010	-0,0020	-0,0030	-0,0020	-0,0020	-0,0030	-0,0040	-0,0110	
Transição 10	-0,0020	0,0000	0,0020	0,0030	0,0020	0,0030	0,0110	0,0710	
Transição 11	0,0060	0,0060	0,0050	0,0050	0,0050	0,0050	0,0090	0,0240	
Transição 12	0,0050	0,0070	0,0090	0,0110	0,0100	0,0120	0,0230	0,0680	
Transição 13	-0,0050	-0,0060	-0,0070	-0,0090	-0,0100	-0,0120	-0,0180	-0,0340	
Transição 14	0,0130	0,0150	0,0150	0,0150	0,0160	0,0210	0,0430	0,0950	
Transição 15	0,0010	0,0000	0,0010	0,0010	0,0010	0,0000	0,0020		
Transição 16	0,0060	0,0080	0,0070	0,0080	0,0080	0,0120	0,0300		
Transição 17	-0,0010	-0,0020	-0,0020	-0,0020	-0,0020	-0,0020	-0,0060		
Transição 18	0,0130	0,0140	0,0150	0,0160	0,0150	0,0230	0,0560		
Transição 19	-0,0020	-0,0020	-0,0020	-0,0030	-0,0050	-0,0070	-0,0070		
Transição 20	0,0070	0,0090	0,0100	0,0090	0,0100	0,0200	0,0420		
Transição 21	-0,0010	-0,0010	-0,0010	-0,0010	0,0000	-0,0010	-0,0070		
Transição 22	0,0060	0,0070	0,0050	0,0050	0,0070	0,0180	0,0390		
Transição 23	-0,0040	-0,0040	-0,0010	0,0000	-0,0020	-0,0050	-0,0110		
Transição 24	0,0130	0,0130	0,0100	0,0050	0,0050	0,0080	-0,0020		
Transição 25	-0,0040	-0,0070	-0,0070	-0,0020	0,0010	0,0030	0,0050		
Transição 26	0,0120	0,0150	0,0160	0,0130	0,0160	0,0300	0,0520		
Transição 27	-0,0010	-0,0010	-0,0010	-0,0010	0,0020	0,0060	0,0090		
Transição 28	0,0100	0,0110	0,0100	0,0100	0,0140	0,0230	0,0360		
Transição 29	-0,0080	-0,0060	-0,0040	-0,0040	-0,0070	-0,0090	-0,0130		
Transição 30	0,0150	0,0120	0,0090	0,0080	0,0130	0,0250	0,0420		
Transição 31	-0,0050	-0,0040	-0,0020	0,0010	0,0050	0,0090	0,0080		
Transição 32	0,0180	0,0200	0,0210	0,0190	0,0290	0,0450			
Transição 33	-0,0010	-0,0010	-0,0010	0,0010	0,0000	0,0000			
Transição 34	0,0040	0,0030	0,0010	-0,0010	0,0000	0,0010			
Transição 35	0,0070	0,0070	0,0070	0,0070	0,0100	0,0190			
Transição 36	0,0150	0,0160	0,0160	0,0210	0,0370	0,0490			
Transição 37	-0,0050	-0,0040	-0,0020	-0,0020	-0,0030	-0,0060			
Transição 38	0,0030	0,0040	0,0030	0,0040	0,0080	0,0240			
Transição 39	-0,0050	-0,0040	-0,0030	-0,0050	-0,0090	-0,0120			
Transição 40	0,0060	0,0070	0,0060	0,0080	0,0150	0,0320			
Transição 41	-0,0130	-0,0130	-0,0110	-0,0110	-0,0180	-0,0240			
Transição 42	-0,0130	-0,0130	-0,0140	-0,0180	-0,0330	-0,0660			
Transição 43	0,0070	0,0080	0,0090	0,0110	0,0180	0,0370			
Transição 44	0,0340	0,0360	0,0340	0,0450	0,0820				
Transição 45	0,0020	0,0040	0,0050	0,0080	0,0130				
Transição 46	0,0230	0,0230	0,0250	0,0420	0,0770				
Transição 47	0	0,008	0,002	0	0				