

Walter Barbosa Guedes

Modelagem de bateria de Lítio-íon e estudo comparativo entre os métodos de estimação de estado de carga para veículos elétricos

Campina Grande, Brasil

Março de 2024

Walter Barbosa Guedes

**Modelagem de bateria de Lítio-íon e estudo
comparativo entre os métodos de estimação de estado
de carga para veículos elétricos**

Dissertação submetida à Coordenação de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

Universidade Federal de Campina Grande - UFCG
Centro de Engenharia Elétrica e Informática - CEEI
Departamento de Engenharia Elétrica - DEE
Coordenação de Pós-Graduação em Engenharia Elétrica - CGEE

Orientadores:

Jaidilson Jó da Silva

Angelo Perkusich

Campina Grande, Brasil

Março de 2024

G924m

Guedes, Walter Barbosa.

Modelagem de bateria de lítio-íon e estudo comparativo entre os métodos de estimação de estado de carga para veículos elétricos / Walter Barbosa Guedes. – Campina Grande, 2024.

88 f. : il. color.

Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2024.

"Orientação: Prof. Dr. Jaidilson Jó da Silva, Prof. Dr. Angelo Perkusich".

Referências.

1. Baterias de Lítio-íon. 2. Baterias de Íons de Lítio. 3. Estado de Carga (SOC). 4. Battery Management System (BMS). I. Silva, Jaidilson Jó da. II. Perkusich, Angelo. III. Título.

CDU 621.355(043)

Modelagem de bateria de Lítio-íon e estudo comparativo entre os métodos de estimação de estado de carga para veículos elétricos

WALTER BARBOSA GUEDES

DISSERTAÇÃO APROVADA EM 06/03/2024

JAIDILSON JO DA
SILVA:03072579407

Assinado de forma digital por
JAIDILSON JO DA SILVA:03072579407

JAIDILSON JÓ DA SILVA, D.Sc., UFCG
Orientador(a)

Digitally signed by

ANGELO

PERKUSICH:00954091817

Date: 2024.03.22 10:56:52


ANGELO PERKUSICH, D.Sc., UFCG
Orientador(a)

Documento assinado digitalmente

gov.br

ALEXANDRE CUNHA OLIVEIRA

Data: 26/03/2024 20:46:56-0300

Verifique em <https://validar.iti.gov.br>

ALEXANDRE CUNHA OLIVEIRA, D.Sc., UFCG
Examinador(a)



Assinado de forma digital por
KYLLER COSTA

GORGONIO:90002989468

Dados: 2024.03.27 11:24:18 -03'00'

KYLLER COSTA GORGÔNIO, Dr, UFCG
Examinador(a)

CAMPINA GRANDE - PB

Agradecimentos

Agradeço, primeiramente, a Deus, força motriz para tocar todos os projetos em minha vida buscando a prosperidade e a paz eterna.

Aos meus orientadores, o professor Jaidilson Jó, por todo suporte, disponibilidade e contribuição na realização deste trabalho, e a Angelo Perkusich, pela contribuição na pesquisa.

À UFCG, instituição que me proporcionou o aprendizado sobre diversas áreas do conhecimento, que me ajudou a crescer pessoalmente e profissionalmente, além de proporcionar amizades no decorrer dos anos de vínculo.

À minha família, suporte em todos os momentos, em especial a minha esposa, Fernanda Lais, pelo companheirismo e suporte na realização deste trabalho.

Aos meus amigos que me deram suporte no desenvolvimentos deste trabalho, em especial a Caio Gomes, que contuiu com diversas sugestões.

"O sonho é que leva a gente para a frente"
Ariano Suassuna

Resumo

Neste trabalho é abordado a representação das baterias de íons de lítio por meio de circuitos elétricos equivalentes, detalhando a forma de obter os parâmetros do circuito por meio de ferramentas computacionais. Também são apresentadas análises de metodologias de estimação de estado de carga de uma bateria de *Lithium Nickel Manganese Cobalt* (NMC) de um veículo elétrico comercial. O método de estimação *Coulomb counting* estima o estado de carga da bateria baseado na integral da corrente elétrica no tempo, apesar de ser simples, por ser de malha aberta, possui um erro acumulativo. As metodologias baseadas nos filtros de Kalman proporcionam precisão à estimação de estado de carga devido a sua capacidade de realizar ajustes na estimação a partir da covariância do sistema. Por fim, o método *machine learning* proporciona automatização do processo de estimação do estado de carga de baterias de lítio a partir do histórico de dados. As metodologias foram comparadas entre si em termos de precisão, acuracidade por meio de ferramentas da MathWorks e da linguagem de programação Python.

Palavras-chave: Bateria de íons de lítio, Estado de Carga (SoC), *Battery management System* (BMS), Filtro de Kalman, *Machine Learning*.

Abstract

This work addresses the representation of lithium-ion batteries through equivalent electrical circuits, detailing how to obtain the parameters using computational tools. Analysis of methodologies for estimating the state of charge of a *Lithium Nickel Manganese Cobalt* (NMC) battery of an electric commercial vehicle is also presented. The *Coulomb counting* estimation method estimates the battery's state of charge based on the integral of the electric current over time, despite being simple, as it is open loop, it has an accumulative error. Methodologies based on Kalman filters provide precision in the state of charge estimation due to their ability to adjust the estimation based on the system covariance. Finally, the machine learning method provides automation of estimating the state of charge of lithium batteries based on historical data. The methodologies were compared with each other regarding precision and accuracy using MathWorks tools and the Python programming language.

Keywords: Lithium-ion batteries, State of Charge, Battery Management System (BMS), Kalman Filter, Machine Learning.

Lista de tabelas

Tabela 1 – Principais características das células de íons de lítio comercializadas atualmente.	13
Tabela 2 – Principais aplicações de LIBs de acordo com a tecnologia	13
Tabela 3 – Detalhes da célula comercial <i>pouch</i> LGX N2.1 60AH da LG Chem . . .	57
Tabela 4 – Performance das estimações de SoC	75
Tabela 5 – Matriz de Pugh para Métodos de Estimação de SoC em Baterias de Lítio	78

Lista de ilustrações

Figura 1 – Representação da LIB do Audi e-tron 2019.	5
Figura 2 – Representação da curva do SOH de uma célula de NMC.	8
Figura 3 – Curva OCV em função da temperatura de uma célula de íons de lítio.	9
Figura 4 – Foto da célula comercial LGX N2.1 60AH da LG Chem.	9
Figura 5 – Representação da estrutura da célula de LIBs.	11
Figura 6 – Representação das químicas consolidadas no mercado de LIBs.	12
Figura 7 – Principais técnicas de estimação de SoC.	19
Figura 8 – Modelo de geração de dados de descarga pulsada	21
Figura 9 – Dados de descarga pulsada	21
Figura 10 – Identificação dos pulsos de corrente	22
Figura 11 – Curva de aproximação R_0 e E_m	22
Figura 12 – Simulação para definição do número de ramos RC do ECM	23
Figura 13 – Bloco de determinação dos parâmetros dos circuitos equivalentes	24
Figura 14 – Representação de parâmetros estimados correspondentes à uma célula de lítio.	25
Figura 15 – Diagrama do circuito de primeira ordem.	26
Figura 16 – Diagrama do circuito de segunda ordem.	27
Figura 17 – Diagrama do circuito de terceira ordem.	29
Figura 18 – Bloco estimador de SoC utilizando Coulomb Counting.	31
Figura 19 – Bloco estimador de SoC utilizando EKF.	37
Figura 20 – Representação de uma bateria na estimação de SoC utilizando EKF.	37
Figura 21 – Divisão da Inteligência Artificial	39
Figura 22 – Representação de uma dimensão de uma árvore de decisão	40
Figura 23 – Representação da aproximação de uma curva senoidal por meio de DTs	41
Figura 24 – Representação das etapas da estimação de SoC por meio de árvores de decisão.	42
Figura 25 – Representação do diagrama SVM na estimação de SoC de bateria de Li-ion.	44
Figura 26 – Representação de tipos de dados de SVM.	47
Figura 27 – Representação da estrutura de RNA utilizada na estimação de SoC de LIBs	49

Figura 28	– Representação da tensão e corrente elétrica do veículo e-tron em um ciclo de trabalho.	56
Figura 29	– Valores das resistências obtidos da bateria.	58
Figura 30	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de novembro de 2019.	59
Figura 31	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de dezembro de 2019.	59
Figura 32	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de janeiro de 2020.	59
Figura 33	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de junho de 2020.	60
Figura 34	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de julho de 2020.	60
Figura 35	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de agosto de 2020.	60
Figura 36	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de setembro de 2020.	61
Figura 37	– Estimação do SoC por meio de <i>Coulomb Counting</i> com dados do mês de outubro de 2020.	61
Figura 38	– Estimação do SoC por meio de EKF utilizando dados do mês de novembro de 2019.	62
Figura 39	– Estimação do SoC por meio de EKF utilizando dados do mês de dezembro de 2019.	62
Figura 40	– Estimação do SoC por meio de EKF utilizando dados do mês de janeiro de 2020.	62
Figura 41	– Estimação do SoC por meio de EKF utilizando dados do mês de junho de 2020.	63
Figura 42	– Estimação do SoC por meio de EKF utilizando dados do mês de julho de 2020.	63
Figura 43	– Estimação do SoC por meio de EKF utilizando dados do mês de agosto de 2020.	63
Figura 44	– Estimação do SoC por meio de EKF utilizando dados do mês de setembro de 2020.	64
Figura 45	– Estimação do SoC por meio de EKF utilizando dados do mês de outubro de 2020.	64
Figura 46	– Estimação do SoC por meio de DT com dados do mês de novembro de 2019.	65

Figura 47 –Estimação do SoC por meio de DT com dados do mês de dezembro de 2019.	65
Figura 48 –Estimação do SoC por meio de DT com dados do mês de janeiro de 2020.	66
Figura 49 –Estimação do SoC por meio de DT com dados do mês de junho de 2020.	66
Figura 50 –Estimação do SoC por meio de DT utilizando dados do mês de julho de 2020.	66
Figura 51 –Estimação do SoC por meio de DT utilizando dados do mês de agosto de 2020.	67
Figura 52 –Estimação do SoC por meio de DT utilizando dados do mês de setembro de 2020.	67
Figura 53 –Estimação do SoC por meio de DT utilizando dados do mês de outubro de 2020.	67
Figura 54 –Estimação do SoC por meio de RNA com dados do mês de novembro de 2019.	68
Figura 55 –Estimação do SoC por meio de RNA com dados do mês de dezembro de 2019.	69
Figura 56 –Estimação do SoC por meio de RNA com dados do mês de janeiro de 2020.	69
Figura 57 –Estimação do SoC por meio de RNA com dados do mês de junho de 2020.	69
Figura 58 –Estimação do SoC por meio de RNA com dados do mês de julho de 2020.	70
Figura 59 –Estimação do SoC por meio de RNA com dados do mês de agosto de 2020.	70
Figura 60 –Estimação do SoC por meio de RNA com dados do mês de setembro de 2020.	70
Figura 61 –Estimação do SoC por meio de RNA com dados do mês de outubro de 2020.	71
Figura 62 –Estimação do SoC por meio de SVM com dados do mês de novembro de 2019.	72
Figura 63 –Estimação do SoC por meio de SVM com dados do mês de dezembro de 2019.	72
Figura 64 –Estimação do SoC por meio de SVM com dados do mês de janeiro de 2020.	72
Figura 65 –Estimação do SoC por meio de SVM com dados do mês de junho de 2020.	73
Figura 66 –Estimação do SoC por meio de SVM com dados do mês de julho de 2020.	73
Figura 67 –Estimação do SoC por meio de SVM com dados do mês de agosto de 2020.	73

Figura 68 –Estimação do SoC por meio de SVM com dados do mês de setembro de 2020.	74
Figura 69 –Estimação do SoC por meio de SVM com dados do mês de outubro de 2020.	74

Lista de abreviaturas e siglas

AM	<i>Aprendizado de máquina</i>
BEV	<i>Battery Electrical Vehicle</i>
BMS	<i>Battery Management System</i>
DoD	<i>Depth of Discharge</i>
ECM	<i>Equivalent Circuit Model</i>
EoL	<i>End of Life</i>
EKF	<i>Extended Kalman Filter</i>
KF	<i>Kalman Filter</i>
LIB	<i>Lithium-ion battery</i>
Li-ion	<i>Lithium-ion</i>
LFP	<i>Lithium Iron Phosphaten</i>
LNCA	<i>Lithium Nickel Cobalt Aluminum Oxide</i>
LNMC	<i>Lithium Nickel Manganese Cobalt Oxide</i>
MLP	<i>Multilayer Perceptron</i>
ML	<i>Machine Learning</i>
OCV	<i>Open Circuit Voltage</i>
RNA	Rede Neural Artificial
SoC	<i>State of Charge</i>
SoH	<i>State of Health</i>
SVM	<i>Support Vector Machine</i>
VCU	<i>Vehicle Control Unit</i>

Sumário

1	Introdução	1
1.1	Objetivos	3
1.2	Organização do Trabalho	3
2	Baterias de íons de lítio	5
2.1	Introdução	5
2.2	Principais terminologias e definições envolvendo LIBs	6
2.3	Relação da OCV com outros fatores	7
2.4	Fenômenos internos das células	9
2.5	Tecnologias adotadas nas células de íons de lítio	12
2.6	Sistema de gerenciamento da bateria	13
2.6.1	Função de balanceamento das células	15
2.7	Funcionamento das LIBs	15
2.8	Carregamento das LIBs	16
2.9	Segurança, longevidade, performance e integração	16
3	Modelagem e estimação de SoC de baterias de íons de lítio	18
3.1	Introdução	18
3.2	Estimação de parâmetros do circuito equivalente	19
3.2.1	Carregamento e pré-processamento dos dados	20
3.2.2	Determinação do número de pares RC	23
3.2.3	Estimação dos parâmetros	24
3.2.4	Definição dos valores para cada parâmetro em função do SoC	24
3.3	Modelagem de baterias	24
3.3.1	Modelo RC de primeira ordem de uma bateria	26
3.3.2	Modelo RC de segunda ordem de uma bateria	27
3.3.3	Modelo RC de terceira ordem de uma bateria	28
3.4	Método <i>Coulomb Counting</i> aplicado na estimação de SoC	30
3.5	Filtros de Kalman aplicados na previsão de sistemas dinâmicos	32
3.6	Filtros de Kalman estendido aplicados na estimação de SoC de LIBs	34
4	<i>Machine learning</i>	38
4.1	Introdução	38
4.2	Sistemas supervisionados	40

4.2.1	Árvore de decisão (DT)	40
4.2.2	<i>Support Vector Machine</i> - SVM	42
4.2.2.1	Hiperplano separador	45
4.2.2.2	Hiperplano de margem máxima	45
4.2.2.3	Margem suave	46
4.2.2.4	Kernel	48
4.3	Redes Neurais Artificiais	49
4.4	Aprendizado de máquina utilizando <i>Python</i>	51
4.4.1	<i>Scikit-learn</i>	51
4.4.2	<i>Pandas</i>	52
4.4.3	<i>NumPy</i>	53
4.4.4	<i>Matplotlib</i>	53
4.4.5	<i>Tensorflow</i>	53
5	Resultados e análises	55
5.1	Dados de entrada das simulações	55
5.1.1	Modelagem da bateria do e-tron	57
5.2	Simulações de modelos por meio de <i>Coulomb Counting</i>	58
5.3	Simulações de modelos por meio de filtros de Kalman Extendido	61
5.4	Simulações de modelos utilizando ML	64
5.4.1	Simulações utilizando árvores de decisão	65
5.4.2	Simulações utilizando RNA	68
5.4.3	Simulações utilizando SVM	71
5.5	Impacto do envelhecimento da bateria na estimação do SoC	75
5.6	Erros na estimação de SoC	75
5.7	Implementação prática dos algoritmos em BMS	76
5.8	Matriz de Pugh para avaliação dos métodos	77
6	Conclusões	79
	Referências	81

1 | Introdução

Os veículos elétricos a baterias (do inglês, *Battery Electric Vehicles* - BEVs) têm assumido cada vez mais uma parcela maior do mercado automotivo devido a fatores como potência instantânea do sistema tracionário e a sua capacidade de substituir veículos movidos a combustíveis fósseis. A disseminação de BEVs no mercado de transportes é uma solução atraente para diminuir a emissão de gases de efeito estufa e aumentar a eficiência energética dos veículos do setor automotivo. De acordo com o Global EV outlook 2018 (AGENCY, 2019), o mercado automobilístico mundial implantará com sucesso 117,6 milhões de BEVs nas estradas até 2030, o que contribuirá para reduzir 262 Mt de emissão de CO_2 (SHRIVASTAVA et al., 2019).

No BEV, há duas baterias, uma auxiliar, geralmente de chumbo ácido e com baixa capacidade, que fornece energia para as centrais elétricas de comunicação do veículo quando ele se encontra desligado, e outra, de íons de lítio, com alta capacidade que fornece energia, principalmente, para o sistema tracionária. A bateria de íons de lítio é a principal fonte de energia e, geralmente, é o componente mais caro e mais desafiador devido à sua complexidade, pois a autonomia do veículo é afetada diretamente pelo seu mau funcionamento, que na maioria das vezes, está associada a erros na estimação do estado de carga, limitações de potência disponibilizada devido à temperatura de operação elevada e envelhecimento da bateria (CHEN; FU; MI, 2013).

Baterias são sistemas que conseguem armazenar energia por meio de reações eletroquímicas. As baterias de íons de lítio (do inglês, *Lithium ion batteries* - LIBs) são atualmente usadas em uma ampla gama de aplicações além de veículos elétricos, incluindo eletrônicos portáteis e armazenamento elétrico em escala devido à sua densidade de energia/potência, custo decrescente e vida útil aceitável (RUAN et al., 2022).

As principais características das LIBs que viabilizam sua aplicação em BEVs são longa vida útil, carregamento rápido e alta densidade de energia (LIPU et al., 2018). Características como confiabilidade e segurança são essenciais para uma LIB, pois o sistema

de gerenciamento deve ser hábil para prever e controlar possíveis problemas (SULAIMAN et al., 2015). Devido às suas características, diferentes tecnologias de baterias à base de lítio foram amplamente estendidas nos últimos anos em todos os tipos de sistemas de armazenamento de energia (RAMADAN; BECHERIF; CLAUDE, 2017).

Apesar das LIBs possuírem ótimas características, a aplicação dessa tecnologia em larga escala no setor automotivo se intensificou apenas nas duas últimas décadas devido à complexidade do processo produtivo das células de lítio e ao alto custo de insumos, como lítio, manganês, cobalto e fosfato, que começaram a diminuir após os investimentos realizados estimularem a produção de veículos elétricos (MOHAMMADI; SAIF, 2023).

Atualmente, nos sistemas automotivos, as LIBs possuem tensões que variam aproximadamente entre 400 V e 1000 V. Essa definição do nível de tensão é uma escolha do desenvolvedor, mas normalmente se encontram veículos com tensão nominal de 400 V, 600 V e 800 V. Curiosamente, de acordo com a Comissão Econômica das Nações Unidas para a Europa (UNECE), quando a tensão de uma bateria ultrapassa um determinado limite, frequentemente em torno de 60 volts, ela é considerada de alta tensão. Essa classificação é feita com base em considerações de segurança e padrões regulatórios, pois sistemas de alta tensão requerem precauções especiais de manuseio para evitar riscos elétricos. Essa definição pode causar confusão, porque no Brasil, segundo a NR10, tensões entre 150 V e 1500 V DC são classificadas como baixa tensão. Entretanto, neste trabalho, será adotada a prática de nomear as LIBs de baterias de alta tensão, haja vista que estamos tratando de sistemas aplicados ao setor automotivo.

As químicas das baterias de íons de lítio são pouco tolerantes a condições abusivas continuamente, como sobrecarga, descarga excessiva e temperaturas elevadas. O risco de choque elétrico é inerente aos sistemas de alta tensão, bem como aos riscos térmicos associados aos sistemas de bateria (WEICKER, 2013). O envelhecimento da bateria é causado por vários fenômenos relacionados ao ciclo de operação e ao tempo de uso. Sua degradação intensifica-se com o alto índice de profundidade de descarga (do inglês, *depth of discharge* - DoD), com a alta frequência de ciclagem, com o seu funcionamento em temperaturas elevadas, entre outros fatores (SMITH et al., 2012). Nesse sentido, a abertura de mercado da eletrificação veicular, além de impulsionar a exploração de recursos minerais, também fomenta o desenvolvimento de *softwares* e *hardwares* para prover o gerenciamento de baterias. Além disso, a utilização de LIBs vai ao encontro das medidas ambientais do Acordo de Paris, que estão sendo tomadas conjuntamente pelos países participantes, e como veículos 100% elétricos não emitem CO_2 , contribuem de forma significativa para reduzir a elevação da temperatura do planeta que é impulsionada pela emissão de gases de efeito estufa.

Alguns parâmetros das LIBs, como tensão e temperatura, podem ser medidos diretamente a partir de sensores, enquanto outros parâmetros, como estado de carga e estado de saúde, precisam ser estimados por meio de algoritmos (SU et al., 2021). Essas estimações são muito importantes porque são cruciais para o adequado fornecimento de energia da bateria. Neste trabalho serão apresentadas formas de estimação do estado de carga de LIBs, comparando-as em termos de erros, e buscando gerar rotinas que consigam realizar essa atividade com facilidade, com o objetivo de proporcionar solidez nas estimações.

1.1 Objetivos

Neste trabalho, objetiva-se abordar a modelagem de baterias de íons de lítio por meio de circuitos elétricos equivalentes, destacando o processo de modelagem da bateria. Serão detalhadas as variáveis que influenciam no processo e os parâmetros que precisam ser considerados para que o modelo possa representar de forma fidedigna o comportamento real da bateria. Além disso, será realizado um estudo comparativo entre os métodos de estimação de SoC mais aplicados na literatura, com um enfoque crítico na análise dos métodos existentes. O objetivo é fornecer uma visão abrangente das diferentes abordagens existentes. Neste trabalho também serão desenvolvidas metodologias automáticas de estimação de SoC, começando por abordagens mais simples e abrangendo métodos mais complexos posteriormente. Serão utilizados dados de ciclagem de campo de bateria de um veículo elétrico comercial disponibilizados na literatura, evitando a dependência exclusiva de dados de laboratório. A inovação neste trabalho está na utilização de técnicas de aprendizado de máquina para a estimação de SoC. Será avaliado o impacto da implementação de cada tipo de metodologia, proporcionando *insights* sobre a eficácia e eficiência das abordagens propostas. Finalmente, para consolidar o trabalho, será realizada uma comparação entre o SoC estimado e o SoC de referência disponibilizado na literatura. Isso será feito para os ciclos de trabalho dos 8 meses de coleta de dados realizados em 2019 e 2020, proporcionando uma avaliação abrangente do desempenho das metodologias propostas em condições reais de operação. A escolha desses dados para treinamento deve-se ao fato desses dados serem o maior banco de dados de ciclos de trabalho de veículos elétricos encontrados na literatura até o presente momento.

1.2 Organização do Trabalho

No capítulo 2, realiza-se uma revisão bibliográfica sobre baterias de íons de lítio, métodos de estimação de SoC e aplicações de métodos matemáticos. Também realiza-se


uma abordagem dos circuitos elétricos equivalentes que podem representar dinamicamente as LIBs, e abordam-se todas as variáveis envolvidas no processo. No capítulo 3, apresenta-se a rotina de geração de parâmetros dos circuitos equivalentes que melhor representam a célula/bateria de íons de lítio, e abordam-se os métodos de estimação de SoC contagem coulombica e o filtro de Kalman estendido. No capítulo 4 abordam-se algumas metodologias de *machine learning* e suas aplicações na estimação de SoC de LIBs, também abordam-se detalhes de sua implementação utilizando Python. No capítulo 5, apresentam-se os dados utilizados como entrada nas simulações, assim como os resultados obtidos das simulações e realiza-se análise dos resultados obtidos. Por fim, no capítulo 6, apresentam-se as considerações finais do trabalho e possíveis trabalhos futuros que podem ser realizados a partir do que foi desenvolvido.

2 | Baterias de íons de lítio

2.1 Introdução

Uma LIB de um veículo elétrico é constituída por *pack* de módulos (conjunto de células interligadas em série e/ou paralelo), conectores, sistemas de resfriamento e aquecimento, cabos de distribuição de potência, cabos de comunicação e sensores, como pode ser observado na imagem da bateria do Audi e-tron ilustrado na Figura 1. Além desses itens, a bateria também possui um sistema de gerenciamento (*Battery Management System - BMS*) que geralmente fica em um local estratégico no veículo, de fácil acesso, para os casos em que ele precise ser acessado.

Figura 1 – Representação da LIB do Audi e-tron 2019.



Fonte: Adaptado de Audi (2019).

Na construção da bateria, uma etapa que exige bastante atenção é a alocação

das células nos módulos ou packs, pois pode haver danificação das células por meio de esmagamento ou prensamento, e com isso, o comprometimento do nível de isolamento mínimo requerido para o veículo, além de poder acarretar outros problemas como curtos-circuitos internos nas células.

As baterias são projetadas para se adequarem aos espaços disponíveis nos veículos e são dimensionadas para proporcionarem autonomias que atendam os requisitos dos projetos. O dimensionamento de uma LIB para um BEV se inicia a partir da estimativa de consumo energético do veículo, cuja principal carga é o motor elétrico. A partir da estimativa do consumo médio, calcula-se a quantidade de energia requerida da bateria para atingir a autonomia desejada do veículo. No desenvolvimento de uma LIB para um projeto automotivo, várias normas precisam ser seguidas para atender requisitos específicos das legislações vigentes. As baterias precisam possuir certificações para atender requisitos de segurança, como a ECE R100, que valida sua aplicabilidade para as mais diversas situações rotineiras que os veículos são submetidos (KUNAKRON-ONG; RUANGJIRAKIT; JONGPRADIST, 2017).

Outro fator crítico no projeto de uma LIB é o peso, pois quanto maior for a energia da bateria, maior peso ela vai possuir e impactar a performance do veículo, pois mais energia será gasta para movimentar o veículo. Práticas adotadas quando se está projetando uma bateria é utilizar materiais leves no envólucro da bateria para otimizar sua densidade gravimétrica (ZACKRISSON; AVELLÁN; ORLENIUS, 2010).

As LIBs no veículo precisam possuir graus de proteção IP67 e IP6K9K que garantem proteção contra submersão e contra vapores pressurizados. As baterias precisam ficar em pontos estratégicos nos veículos para evitar que sejam danificadas por choques mecânicos durante as viagens realizadas, pois caso uma célula seja danificada, se sua substituição não for simples, toda a bateria precisa ser substituída devido a possíveis falhas de isolamento do veículo ou até mesmo comprometimento da estimação do SoC devido a células com baixo SoC, o que acaba onerando muito o usuário (ZHANG et al., 2018).

2.2 Principais terminologias e definições envolvendo LIBs

As LIBs são repletas de terminologias essenciais que são indispensáveis para um conhecimento abrangente do tema. Dentre essas terminologias, as principais são:

- Estado de Carga (do inglês, *State of Charge* - SoC) - Se refere à quantidade de energia que a bateria contém em relação à sua capacidade nominal (CHAOUÍ;

IBE-EKEOCHA, 2017).


- Estado de Saúde (do inglês, *State of Health* - SoH) - Expressa a proporção da capacidade da bateria fornecer energia em relação à sua condição inicial de operação. Esse nível de carga geralmente é afetado por certos fatores externos, como temperatura ambiente e idade da bateria (KIM, 2010).
- C-rate - Taxa que expressa a velocidade com que um sistema de armazenamento é carregado ou descarregado (SAXENA et al., 2019). 1C em uma bateria de X Ah implica em uma corrente de X A, o que significa que o sistema de armazenamento pode ser totalmente carregado ou descarregado no intervalo de uma hora. Para a mesma bateria 2C representa uma corrente de 2X A, dessa forma a bateria pode ser totalmente carregada ou descarregada em meia hora.
- Tensão de circuito aberto (do inglês, *Open Circuit Voltage* - OCV) - É a tensão que a bateria apresenta quando todas as células passam pelo período de relaxação após carga ou descarga. Um teste típico de OCV é realizado com correntes baixas em relação à capacidade de bateria, como por exemplo 1/20 C a 1/25 C, o que requer entre 20 a 25 horas (TIAN et al., 2021). A tensão de circuito aberto (OCV) das baterias é um parâmetro característico crucial que reflete muitos aspectos do desempenho de uma bateria, como capacidade, estado de carga (SOC) e estado de saúde. A OCV é mais amplamente utilizada para determinar o SOC quando a bateria funciona em um estado de esgotamento de carga. No entanto, a aplicação da OCV à estimativa do SOC pode ser difícil devido à necessidade de um longo tempo de descanso para relaxamento total (PEI; LU; ZHU, 2013).

O SOH tem um comportamento não linear no tempo. No início da vida da bateria ele é 100%, mas começa a decair assim que a bateria começa a ser utilizada, como pode ser observado na Figura 2. Os fornecedores de baterias, geralmente garantem o funcionamento da bateria para SOH de até 70%, pois abaixo desse valor, a capacidade de fornecimento de potência da célula deixa de ser constante e pode ter decaimentos abruptos, o que compromete o desempenho do veículo em uma ultrapassagem, por exemplo.

2.3 Relação da OCV com outros fatores

As relações da OCV com fatores internos e externos são de extrema importância para o entendimento do funcionamento da bateria e de como ela pode ser afetada. As duas principais influências sobre a OCV são variação de temperatura e o decaimento do SoH. O decaimento do SoH da bateria está atrelado diretamente ao aumento da resistência interna

Figura 2 – Representação da curva do SOH de uma célula de NMC.




Fonte: Jenu et al. (2022).

das células por meio de dendritos de lítio e pela degradação da interface de eletrólito sólido (do inglês, *solid electrolyte interphase* - SEI), que é a barreira criada entre o eletrólito sólido e o eletrodo negativo da bateria nas primeiras primeiras cargas. Dessa forma, com o envelhecimento da bateria, a curva OCV tende a cair em relação ao início da vida útil da bateria.

Efeitos térmicos provocam variação dinâmica na curva OCV, pois com a elevação da temperatura, a resistência interna da bateria diminui naturalmente porque os átomos se agitam internamente, necessitando de menos energia para migrarem, isso faz com que a OCV diminua com a elevação da temperatura, como pode ser observado na Figura 3, que representam testes performados em uma célula de NMC em diferentes temperaturas. O oposto é válido para temperaturas menores, as moléculas estão menos agitadas e necessitando de maior energia para poderem migrar entre os eletrodos.

Entretanto, mesmo a bateria sendo mais eficiente em temperaturas elevadas, essa condição é prejudicial, porque a SEI é sensível a elevação de temperatura e aumenta sua taxa de degradação interna. Outros fenômenos como contaminação interna ou danificação devido a choques mecânicos afetam a curva OCV e a sua vida útil que pode cair consideravelmente, porque a depender da forma com que o SoC é estimado, uma célula com problemas ser a referência inferior da estimativa. Por isso, essa dinamicidade da curva OCV deve ser levada em consideração para que os resultados obtidos a partir de modelagens possam ser representativos.

Figura 3 – Curva OCV em função da temperatura de uma célula de íons de lítio.



Fonte: Zhang et al. (2018)

2.4 Fenômenos internos das células

A célula de íons de lítio foi desenvolvida por uma equipe liderada por John Bannister Goodenough nos EUA. Comercialmente, a LIB foi lançada ao mercado pela Sony no início dos anos 90 em produtos eletrônicos de consumo, como câmeras e filmadoras. Uma célula de Li-ion, como a célula comercial *pouch* LGX N2.1 60AH da LG Chem, ilustrada na Figura 4, consiste nos seguintes componentes (WEICKER, 2013):

Figura 4 – Foto da célula comercial LGX N2.1 60AH da LG Chem.



Fonte: LG Chem (2021).


- Eletrodo positivo (muitas vezes referido como cátodo, embora o cátodo é, estritamente falando, o eletrodo onde ocorre a redução) - Geralmente formado por uma folha de alumínio, cuja função é proporcionar as reações de oxidação com acúmulo de elétrons e corrosão do eletrodo;

- Eletrodo negativo (frequentemente referido como ânodo) - Normalmente constituído por uma folha de cobre com uma cobertura de grafite, é onde ocorre as reações de redução, com deposição de metal na placa e consumo de elétrons;
- Eletrólito - Meio que fornece condutividade elétrica entre as partículas do material ativo e o coletor de corrente, bem como condutividade iônica entre o eletrólito e o material ativo;
- Separador - Filme de polímero poroso usado para separar os dois eletrodos enquanto fornece uma barreira através da qual os íons de lítio podem viajar. Os materiais mais utilizados são o polietileno e o polipropileno. O filme separador extremamente fino deve manter efetivamente o ânodo e o cátodo separados para evitar curtos-circuitos, proporcionando um caminho eficaz para os íons de lítio viajarem entre os eletrodos;
- Invólucro - Recipiente isolado geralmente constituído de material plástico cuja função é isolar a carcaça da célula, evitar perda de eletrólitos e contaminação. Deve ser durável o suficiente para proteger o conteúdo relativamente delicado da célula em condições adversas, como em impactos físicos e em variações extremas de temperaturas.

As substâncias adicionais nos materiais do eletrodo fornecem condutividade elétrica entre as partículas do material ativo e o coletor de corrente. Nas células que utilizam um eletrólito líquido, o eletrólito é geralmente composto por solventes orgânicos não aquosos contendo um sal de lítio dissolvido. Os materiais comuns para eletrólitos são carbonato de etileno (EC), carbonato de dietileno (DEC) e carbonato de dimetilo (DMC). O sal de lítio é, frequentemente, hexafluorofosfato de lítio (LiPF_6). Em contraste com os eletrólitos aquosos, que geralmente são soluções fortemente ácidas ou alcalinas, os eletrólitos de íons de lítio não são corrosivos, mas os solventes usados são altamente inflamáveis e têm uma pressão de vapor relativamente alta, levando a riscos de incêndio e explosão se as células forem ventiladas. A maioria das baterias de íon-lítio não são baterias do tipo úmido em que o interior do gabinete é inundado com eletrólito; a maior parte do eletrólito é absorvida no material ativo e no separador (WEICKER, 2013). Na Figura 5, pode-se observar uma estrutura típica de eletrólito, eletrodo e metal ativo.


A migração dos elétrons e íons de lítio desempenha um papel fundamental no processo de carga e descarga de uma LIB (ARMAND; TARASCON, 2008). Durante a descarga, que é o processo natural da bateria, os elétrons da superfície do eletrodo negativo migram pelo circuito externo para o eletrodo positivo, assim como os íons de lítio, mas estes se movimentam pelo eletrólito (ETACHERI et al., 2011). Durante esse fenômeno químico, a reação no eletrodo negativo pode ser descrita pela equação 2.1, e a reação no

Figura 5 – Representação da estrutura da célula de LIBs.



Fonte: Adaptado de Weicker (2013).

eletrodo positivo, após elétrons e átomos de lítio chegarem ao eletrodo positivo, pode ser representada pela equação 2.2:



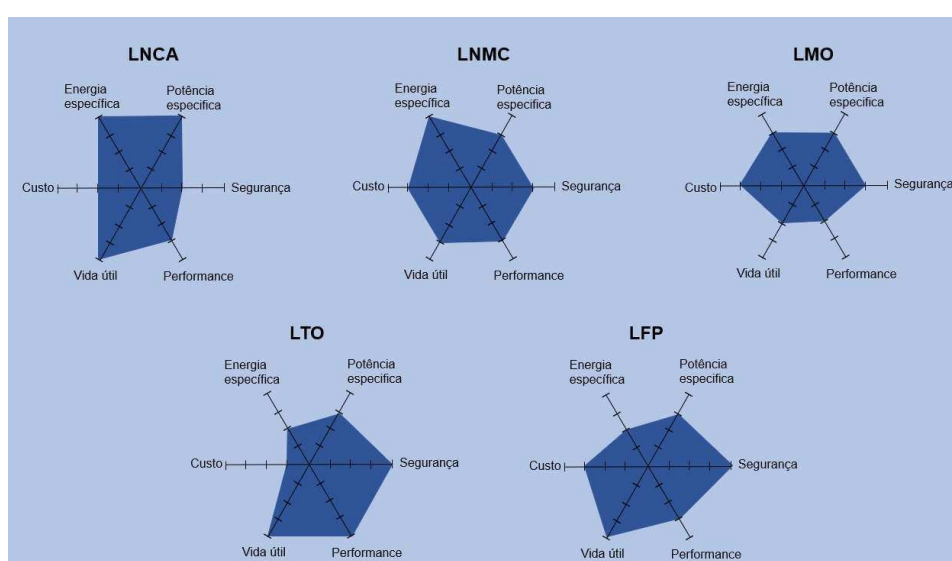
Durante o processo de carga, a corrente elétrica é aplicada à bateria, induzindo um fluxo de elétrons do eletrodo positivo para o eletrodo negativo (HU et al., 2017). Simultaneamente, íons de lítio são liberados do eletrodo positivo e migram através do eletrólito para o eletrodo negativo (GOODENOUGH; PARK, 2013). O eletrodo negativo geralmente consiste em grafite, que serve como um reservatório para os íons de lítio durante a carga.

A eficiência do processo de carga e descarga em uma bateria de íon de lítio está intrinsecamente ligada à capacidade dos materiais utilizados nos eletrodos e ao desempenho do eletrólito. Materiais de alta qualidade nos eletrodos e um eletrólito eficiente contribuem para uma maior eficiência energética e uma vida útil mais longa da bateria (SONG et al., 2019). A migração controlada dos íons de lítio é crítica para evitar problemas como a formação de dendritos de lítio, que são crescimentos de lítio metálico que podem causar curtos-circuitos internos e falhas na bateria. (LIN; LIU; CUI, 2017).

2.5 Tecnologias adotadas nas células de íons de lítio

Atualmente, as principais químicas utilizadas nas LIBs para BEVs são *Lithium Iron Phosphate* (LFP), *Lithium Nickel Manganese Cobalt Oxide* (NMC) e *Lithium Nickel Cobalt Aluminum Oxide* (NCA) (FICHTNER, 2022). Entretanto, diversas outras estão em desenvolvimento, com o objetivo de otimizar custos, densidade energética, quantidade de ciclos e em aumentar a segurança. Cada química possui características específicas, como pode ser observado na Figura 6.

Figura 6 – Representação das químicas consolidadas no mercado de LIBs.



Fonte: Adaptado de University (2022).

Baseado na Figura 6, é possível perceber que reunir todas as boas características de uma LIB em um único tipo de célula não é simples. Nesse sentido, projetam-se as baterias de acordo com as necessidades de projeto levando em consideração capacidade energética, segurança, potência específica, entre outros. Na Tabela 1, listam-se as principais características das principais tecnologias citadas nesse trabalho e na Tabela 2 listam-se as principais aplicações das baterias de íons de lítio.

A célula de MNC possui algumas topologias, como NMC111, NMC532 e NMC622, em que os números representam as proporções relativas de níquel (Ni), manganês (Mn) e cobalto (Co) no eletrodo positivo. A quantidade de lítio em uma bateria de íons de lítio é relativamente baixa, representando menos de 1% da massa total da bateria. A maior concentração de lítio na bateria está no cátodo, em uma célula NMC622, por exemplo, a quantidade de lítio varia entre 5-10% do peso total do cátodo. Entretanto, esses valores são estimativas, não há nenhuma normatização que assegure a quantidade desses componentes

Tabela 1 – Principais características das células de íons de lítio comercializadas atualmente.

Tecnologia	Tensão nominal	Tensão de operação	Densidade gravimétrica de energia	Densidade volumétrica de energia
LCO	3,6 V	3,0 - 4,2 V	150 - 240 Wh/kg	250 - 620 Wh/L
LMCO	3,7 V	3,0 - 4,2 V	100 - 150 Wh/kg	200 - 400 Wh/L
NMC	3,7 V	3,0 - 4,2 V	150 - 220 Wh/kg	400 - 700 Wh/L
LFP	3,3 V	2,5 - 3,65 V	90 - 150 Wh/kg	250 - 400 Wh/L
NCA	3,6 V	3,0 - 4,2 V	200 - 260 Wh/kg	450 - 650 Wh/L
LTO	2,4 V	1,5 - 2,85 V	35 - 90 Wh/kg	100 - 200 Wh/L

Fonte: Próprio autor.

Tabela 2 – Principais aplicações de LIBs de acordo com a tecnologia

Tecnologia	Aplicação
LCO	Notebooks - Câmeras digitais - Smartphones
LMCO	Ferramentas portáteis - UPS - Dispositivos médicos
NMC	Armazenamento de energia - Ferramentas portáteis - Veículos elétricos
LFP	Ferramentas portáteis - Veículos elétricos (ônibus, veículos de carga) - UPS - Armazenamento de energia de grande porte
NCA	Sistemas de armazenamento - Dispositivos médicos - Veículos elétricos
LTO	UPS - Veículos elétricos - Iluminação pública solar

Fonte: Adaptado de University (2024).

em cada bateria.

2.6 Sistema de gerenciamento da bateria

O Sistema de Gerenciamento de Baterias (do inglês, *Battery Management System* - BMS) é um elemento chave para garantir a utilização segura, confiável e eficiente da bateria em BEVs. O BMS não é usado apenas para controlar as condições de operação da bateria para prolongar sua vida útil e garantir sua operação segura, mas também para fornecer uma estimativa precisa do SoC e do SoH. O SoC não é mensurável diretamente, por isso, sua estimativa instantânea é um dos principais desafios do BMS para evitar sobrecarga e descargas excessivas. Além disso, o BMS é essencial em aplicações de BEVs para uma operação eficiente, em que enormes células de bateria são conectadas em configuração em série/paralelo para atender à alta potência e à tensão do veículo (RAMADAN; BECHERIF; CLAUDE, 2017). As principais atribuições de um BMS em uma LIB são:

- Estimar o SoC;

-
- Monitorar a corrente elétrica para garantir a proteção da bateria contra condições abusivas, além de utilizar o valor medido no cálculo do SoC;
 - Monitorar as tensões das células, dos módulos e tensão de saída da bateria. A estimação do SoC também leva em consideração as tensões das células;
 - Monitorar a temperatura: tem como principal objetivo garantir o funcionamento da bateria nos limites operacionais permitidos, garantindo a integridade e a durabilidade do sistema;
 - Garantir o balanceamento das células;
 - Conseguir comunicar com todas as células;
 - Realizar o controle térmico da bateria;
 - Realizar a proteção da bateria;
 - Gerenciar o carregamento da bateria;
 - Monitorar a bateria durante armazenamento.

O cálculo do SoC é uma função muito importante do BMS, pois fornece a carga restante apresentada dentro de uma célula de bateria (LIPU et al., 2019). Estimativas mais confiáveis e precisas do SoC, uma das principais tarefas do Sistema de Gerenciamento de Bateria (BMS), geralmente são esperadas em aplicações de alto nível, como automotivas (LIU et al., 2016).

A demanda pela estimação de SoC faz com que cada vez mais estudos sejam realizados para prover acurácia na modelagem de LIBs, porque para certos tipos de químicas, as estimativas de SoC conseguem ser representativas apenas por meio de circuitos elétricos equivalentes, que conseguem ter seus parâmetros estimados com precisão, para representarem os comportamentos dinâmicos das baterias.

A taxa de amostragem de corrente é uma variável importante da estimação de SoC, pois o tempo de amostra precisa ser suficiente para captar as mudanças do sinal da corrente elétrica do circuito. Grandes fabricantes de soluções de baterias utilizam taxas de amostragem de cerca de 0,01 s, pois é um período suficiente para observar com precisão a variação da corrente elétrica (CHARKHGARD; FARROKHI, 2010).

A bateria pode funcionar de duas formas, realizando seu próprio gerenciamento sem se comunicar com o veículo ou funcionando conjuntamente com o veículo. No modo *stand alone* o BMS gerencia as grandezas independentemente, sem se comunicar com o

veículo. Na operação integrada, há comunicação entre BMS e veículo, e o gerenciamento do conjunto é realizado na maioria das vezes pela *Vehicle Control Unit* (VCU), mas em ambos os casos, os limites operacionais da bateria são controlados similarmente.

2.6.1 Função de balanceamento das células

A função de balanceamento das células é estritamente importante porque o balanceamento está diretamente relacionado à autonomia do veículo. Assim como o SoH, o desbalanceamento afeta diretamente o quanto de energia a bateria pode suprir, porque em uma LIB, a energia disponível pelas células na faixa de tensão de desbalanceamento não consegue ser fornecida pela bateria para o veículo.

As topologias de balanceamento de células podem ser amplamente classificadas em duas categorias principais: balanceamento passivo (energia dissipativa) e ativo (energia não dissipativa). Os métodos de balanceamento passivo usam resistência para dissipar o excesso de energia das células sobrecarregadas da bateria, enquanto no método de balanceamento ativo, o excesso de energia é transferido para outra (s) célula (s) em vez de sua dissipação. Os sistemas de balanceamento passivo são normalmente baratos e fáceis de controlar, no entanto, apresentam baixa eficiência de balanceamento e problemas de gerenciamento térmico (SAMANTA; CHOWDHURI, 2021).

2.7 Funcionamento das LIBs

As LIBs funcionam associadas aos outros componentes do veículo. Enquanto o veículo está desligado, o BMS recebe fornecimento de energia da bateria auxiliar, que pode ser de 12 V ou 24 V, e que normalmente é de chumbo ácido, mas assim que o veículo é ligado ou colocado para carregar, os relés do sistema de alta tensão automotivo são fechados e a LIB passa a fornecer energia para todo o veículo, inclusive para a bateria auxiliar, que é carregada por meio dos conversores abaixadores de tensão, que convertem o nível de tensão DC da bateria para 12 V ou 24 V DC.

A partir das medições de tensão, corrente e temperatura, e das estimativas realizadas, o BMS habilita o fornecimento de energia para o veículo, assim como permite o carregamento da bateria por meio do fechamento de relés que energizam o circuito de alta tensão do veículo.

2.8 Carregamento das LIBs

O carregamento das baterias dos BEVs pode ser considerado um limitador de vendas de veículos elétricos comerciais devido ao grande valor de dinheiro que precisa ser investido nas estações de recarga. Os veículos de passeio têm baterias menores do que os veículos comerciais e não possuem demanda de disponibilidade alta porque podem ser carregadas durante a noite e madrugada, dessa forma, as baterias podem ser carregadas com carregadores de baixa potência que são mais baratos. Os veículos comerciais, geralmente, precisam ser carregados durante o seu funcionamento em um intervalo curto de tempo, então, para isso, emprega-se carregadores de alta potência, que chegam a custar algumas centenas de milhares de reais, o que pode chegar a representar facilmente cerca de 40% do valor do veículo (WASSILIADIS et al., 2021).

Baterias em desenvolvimento, como as de estado sólido, vão revolucionar as baterias no quesito carregamento, pois com essa nova tecnologia, o carregamento rápido (do inglês, *fast charging*), vai proporcionar recargas de oportunidade (carregamentos em alguns minutos durante entrada ou saída de passageiros do veículo ou enquanto o motorista vai ao banheiro) com alta capacidade de transferência de energia em poucos minutos. Para isso, o sistema elétrico de potência precisa se tornar mais robusto para ter capacidade de suprir altas demandas de potências em qualquer posto de carregamento (TEOH et al., 2018).

2.9 Segurança, longevidade, performance e integração

Ao se projetar uma LIB, deseja-se que ela seja segura, possua longa vida útil, boa performance e que seja de fácil integração com os outros sistemas. Essas características desafiadoras são difíceis de serem alcançadas porque demandam esforços no desenvolvimento e oneram o valor da bateria.

A segurança é um item muito prezado atualmente devido, principalmente, às legislações vigentes que impõe regras com o objetivo de prezar pela integridade dos usuários dos veículos. A norma geral que rege as regras sobre as mínimas condições para liberar uma LIB no mercado é a ECE R100, norma que impõe uma série de testes a serem realizados para garantir que a bateria pode ser submetida a diversas condições de operação sem haver nenhum problema. Além da ECE R100 ((ECE), 2022), os países estão normatizando seus setores de baterias com o objetivo de agregar segurança, impondo sistemas de supressão de incêndio para os compartimentos dos sistemas de baterias tracionárias dos veículos elétricos destinados ao transporte coletivo.

A longevidade da bateria está atrelada principalmente ao seu modo de uso e às suas condições de exposição. Quanto menor o C-rate RMS médio da bateria, menos ela

é exigida e maior é sua vida útil para as mesmas condições. A temperatura é o principal fator impactante da longevidade da bateria. Apesar do aumento da eficiência da bateria atrelada à elevação da temperatura, em altas temperaturas, as reações químicas dentro da bateria podem ocorrer mais rapidamente, levando a uma degradação mais rápida dos materiais ativos. Isso pode resultar em uma capacidade reduzida da bateria ao longo do tempo. Além disso, altas temperaturas aumentam a taxa de autodescarga da bateria, o que significa que ela pode descarregar rapidamente, mesmo quando não está em uso.

A performance das baterias de íons de lítio é crucial na aplicação automotiva. A bateria consegue fornecer a potência solicitada em qualquer ambiente natural do planeta, e até em ambientes controlados com temperaturas inferiores a 0° C, devido ao gerenciamento do sistema térmico da bateria e à estabilidade da tensão de descarga. Além disso, com seu ciclo de vida prolongado, e com altas C-rates de carregamento, aumenta a disponibilidade do veículo para o usuário.

A integração eficiente das baterias com os diversos sistemas do veículo proporcionam a otimização do desempenho e a maximização dos benefícios da tecnologia. A integração envolve toda a parte de comunicação entre baterias e sistemas. O BMS deve disponibilizar, na rede CAN, as mensagens de alertas e de falhas de forma eficiente para que as medidas sejam adotadas a fim de garantir o funcionamento seguro do veículo.

Em conclusão, as LIBs desempenham um papel fundamental nos BEVs. O entendimento aprofundado dos conceitos da bateria como o SoC, bem como a escolha criteriosa do tipo de bateria para a aplicação são essenciais no projeto de um veículo elétrico. No próximo capítulo serão abordados os meios necessários para se conseguir representar uma bateria por meio de circuitos elétricos equivalentes e algumas das metodologias utilizadas na estimação de SoC.

3 Modelagem e estimação de SoC de baterias de íons de lítio

Neste capítulo, apresentam-se metodologias amplamente utilizadas na literatura aplicadas na estimação de SoC de baterias de íons de lítio. Também se abordam as formas de representar uma bateria por meio de um circuito elétrico equivalente que proporciona o entendimento dinâmico da bateria. Por fim, detalha-se uma forma de como se obter os parâmetros desses circuitos.

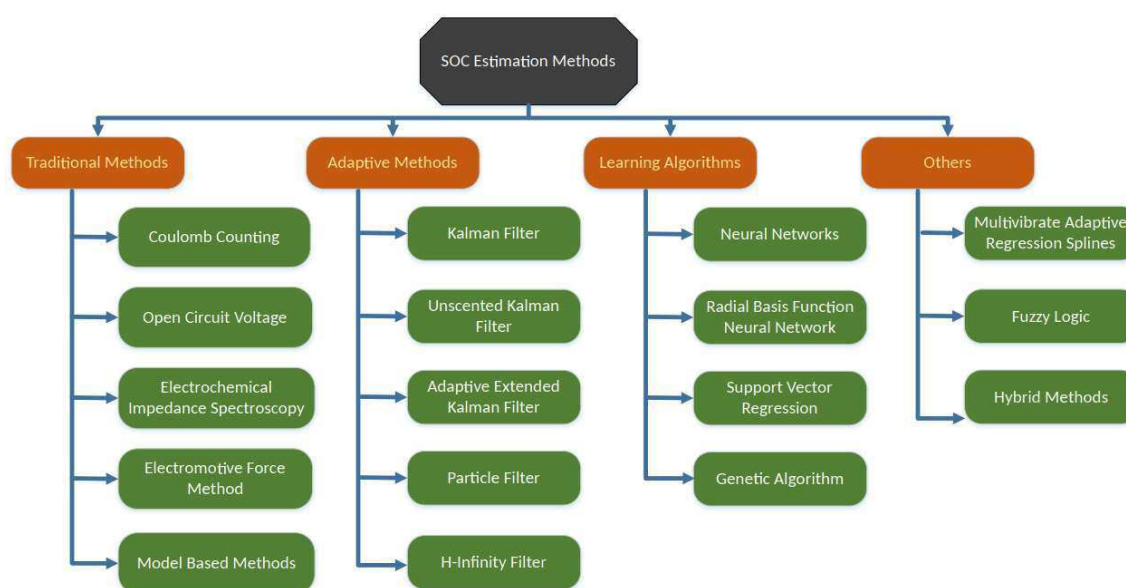
3.1 Introdução

A estimação do SoC pode ser realizada por diversas formas, levando em consideração energia carregada ou descarregada, por meio da relação entre tensão, SoC e temperatura de operação ou por meio de outros algoritmos desenvolvidos, exclusivamente, para essa aplicação. Algumas químicas, como a NMC e NCA, possuem a curva OCV versus SoC acentuada, o que proporciona facilidade na estimação fazendo uso da relação entre SoC e tensão. Entretanto, algumas químicas, como a LFP, não possuem essa relação quase linear, dessa forma, demandam-se mais esforços matemáticos para realizar a estimação do SoC desses tipos de baterias. A curva da tensão versus SoC, além de ser específica de acordo com o tipo de química utilizada, sofre alterações no decorrer da vida útil da bateria, pois fatores como o estado de saúde da bateria (*State of Health* - SoH) influenciam na sua performance.

Um método amplamente utilizado como base para estimar o SoC é a contagem coulômbica (do inglês, *Coulomb Counting*), abordagem que se resume a uma equação matemática que possui uma integral, levando em consideração algumas condições iniciais. No entanto, esse método possui algumas desvantagens em relação a outros métodos

existentes, como necessidade de inserir no modelo o SoC inicial, e acúmulo de erros de estimação devido ao fato de ser um método em malha aberta. Outros métodos que fazem uso de inteligência artificial, como o aprendizado de máquina, são capazes de simular a complicada dinâmica da bateria (LI et al., 2013). As principais metodologias aplicadas na estimação de SoC de LIBs podem ser observadas na Figura 7.

Figura 7 – Principais técnicas de estimação de SoC.



Fonte: Sidhu, Ronanki e Williamson (2019a).

A integração de várias abordagens individuais pode dar origem a um melhor desempenho. Filtro de Kalman estendido é usado para estimar a tensão de circuito aberto e, em seguida, o método de tensão de circuito aberto é usado para estimar o SoC (JUNPING; JINGANG; LEI, 2009). Atualmente, métodos de estimação *Coulomb Counting*, filtros de Kalman e *Machine Learning* possuem boa aplicabilidade nas medições e são aplicados em larga escala (CHARKHGARD; FARROKHI, 2010).

3.2 Estimação de parâmetros do circuito equivalente

A estimação de parâmetros do circuito equivalente, a depender do tipo de modelagem realizada, é uma das mais importantes atividades realizadas previamente à modelagem elétrica de bateria, pois os parâmetros do ECM são dados de entrada nas representações dos circuitos. Uma das formas de obter os parâmetros é por meio do Matlab, ambiente de programação e linguagem de programação de alto nível, por meio de quatro etapas que usam técnicas de otimização numérica para determinar o número de pares RC recomendados,

fornecer estimativas iniciais para os parâmetros do circuito do modelo da bateria e estimar os parâmetros para ajustar um modelo aos dados de descarga de pulso experimental. As 4 etapas são: carregamento e pré-processamento dos dados; determinação do número de pares RC do circuito equivalente; estimação de parâmetros e definição dos vetores das variáveis em função do SoC.

3.2.1 Carregamento e pré-processamento dos dados

Nesta etapa, inserem-se no Matlab os dados de entrada de tensão, corrente e temperatura da descarga pulsada que deve ser realizada na bateria com o SoC variando de 100% de SoC a 0% de SoC. Alguns requisitos devem ser adotados: temperatura constante, taxa de amostragem de no mínimo de 1 Hz, mudança no SOC para cada pulso não deve ser superior a 5%, e o tempo de relaxamento suficiente após cada pulso para garantir que a bateria se aproxime da tensão de estado estacionário (MathWorks®, 2022).

Esse fenômeno faz com que a tensão retorne ao estado estacionário de circuito aberto (OCV). Ocorre quando há um gradiente de íons de lítio através do eletrodo positivo, atingindo um estado de energia mínimo após uma carga ou descarga parcial.

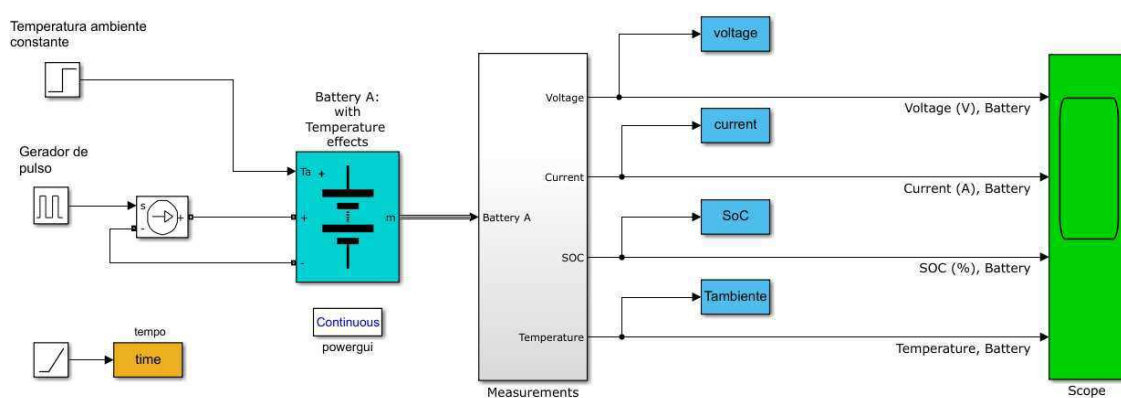
O relaxamento de tensão de circuito aberto em uma célula de Li-ion é um processo eletroquímico que ocorre após a interrupção da corrente elétrica, resultando na diminuição da tensão devido à queda na resistência interna. A tensão relaxa de volta para uma tensão de circuito aberto de estado estacionário (OCV). Este processo de relaxamento ocorre uma vez que há um gradiente de íons de lítio através do eletrodo positivo que atinge um estado mínimo de energia estado após um carga ou descarga parcial. Como a tensão é determinada pela concentração superficial de íons de lítio em um eletrodo, esse gradiente, através do eletrodo, se dispersa com o tempo e afeta a tensão nos terminais da bateria (THEUERKAUF; SWAN, 2022).

O reconhecimento da sequência de pulsos de corrente é realizado por meio da função *Battery.Pulse*, em que se carregam e processam os dados de descarga para a bateria em estudo, usando os comandos *Step1*, *Load and Preprocess Data*, na adaptação do *script* *Example_DischargePulseEstimation*. O modelo da bateria no Simulink em que se implementa essa função está ilustrado na Figura 8.

Os dados de caracterização de pulso incluem uma sequência de pulsos de descarga, seguidos por um período de relaxamento, como pode ser observado graficamente na Figura 9.

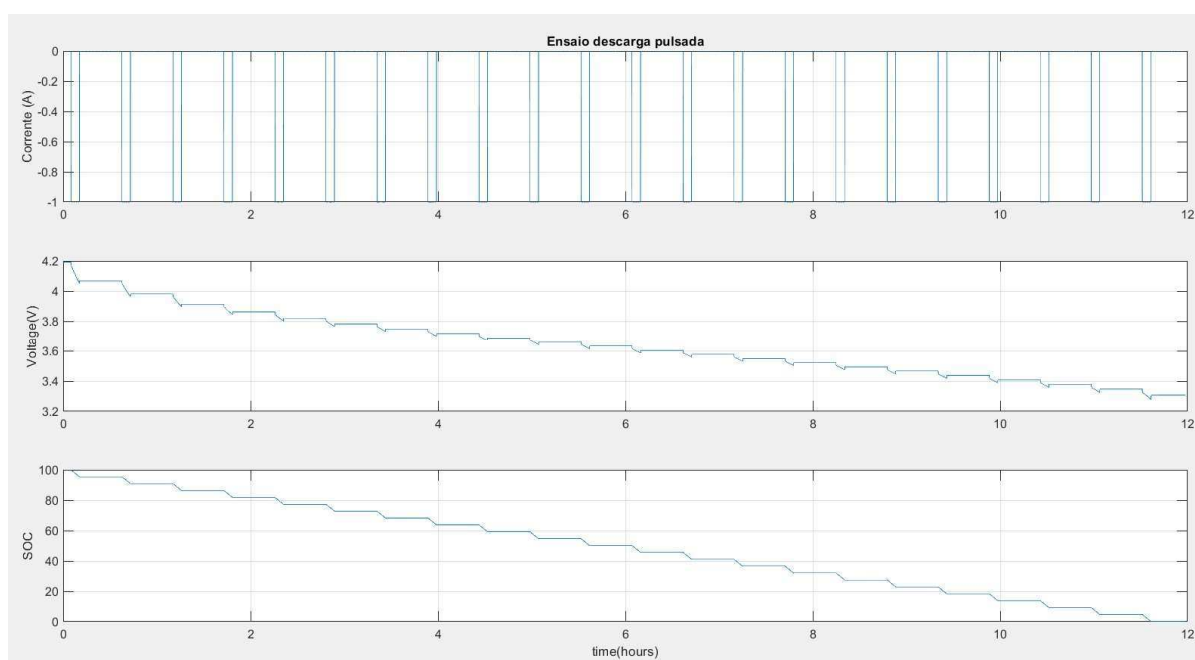
A identificação dos pulsos é um passo importante para a determinação dos parâmetros do modelo, tendo em vista que este processo identifica a porção da curva referente

Figura 8 – Modelo de geração de dados de descarga pulsada



Fonte: Próprio Autor.

Figura 9 – Dados de descarga pulsada

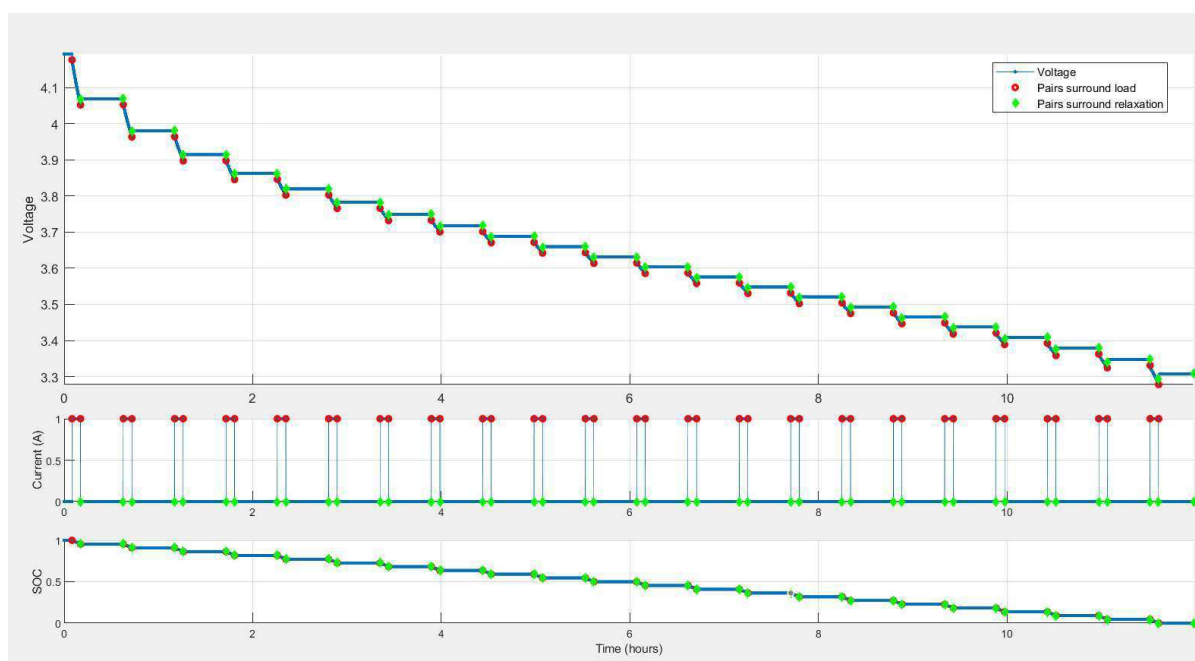


Fonte: Próprio Autor.


à variação instantânea da tensão, que diz respeito à resistência interna da bateria, e à porção referente às constantes de tempo do modelo (LI et al., 2019). A identificação dos pulsos pode ser observada na Figura 10.

A partir da geração de descarga pulsada, observam-se o pulso e o relaxamento referente à célula, como pode ser visualizado na Figura 11, que correspondem às estimativas iniciais para a tensão de circuito aberto (OCV) e resistência em série.

Figura 10 – Identificação dos pulsos de corrente



Fonte: Próprio Autor.

Figura 11 – Curva de aproximação R_0 e E_m 

Fonte: Próprio Autor.

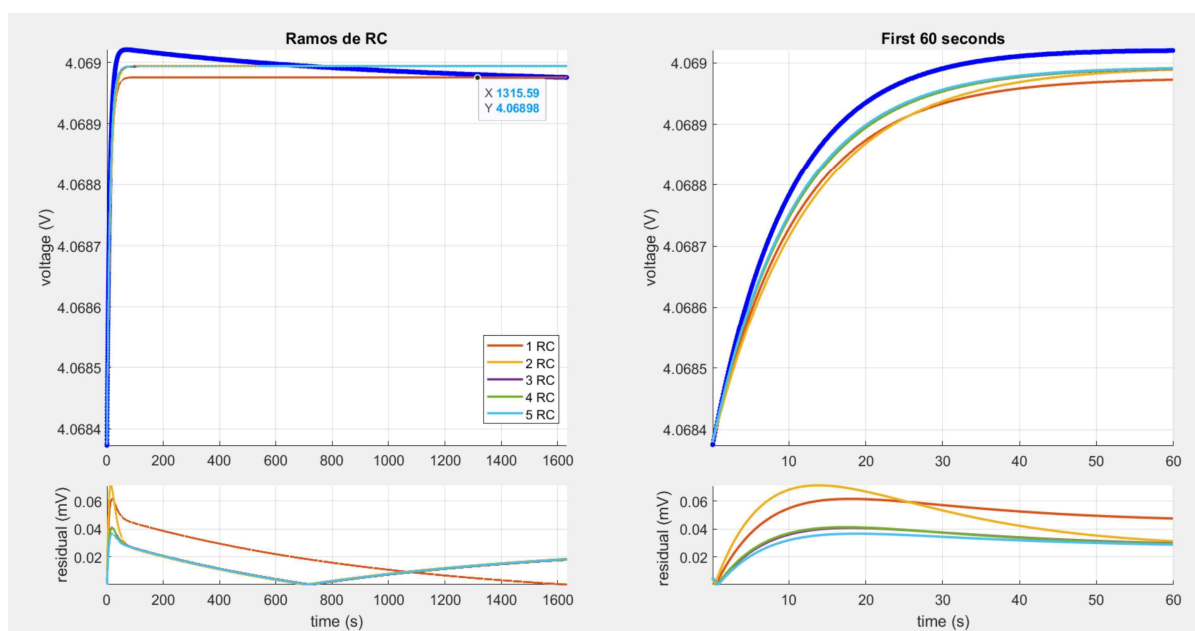
Em que $E_m(1)$ se refere à tensão de circuito aberto para o $SoC(1)$, $E_m(2)$ se refere à tensão de circuito aberto para o $SoC(2)$, $R_0(1)$ se refere à queda resistiva devido ao início do pulso de corrente entre o $SoC(1)$ e $SoC(2)$, $R_0(2)$ se refere à queda resistiva devido ao fim do pulso de corrente entre o $SoC(1)$ e $SoC(2)$, $R_{1,2,3}(1)$ e $C_{1,2,3}(1)$ são as variáveis relacionadas aos comportamentos transitórios das curvas de tensão.

A Figura 11 está estritamente relacionada com a resistência interna da bateria e com a quantidade de pares de RC. A resistência interna pode ser encontrada via lei de Ohm, mas a determinação dos valores dos parâmetros dos pares de RC demanda maiores esforços, pois circuitos equivalentes com dois pares RC ou mais, os parâmetros não podem ser obtidos por meio de análise gráfica, apenas por meio de análise numérica.

3.2.2 Determinação do número de pares RC

Após o reconhecimento dos pulsos da descarga pulsada por meio de funções, o Matlab plota curvas que representam as respostas do sistema para as opções de 1 a 5 pares de RC. A escolha da topologia do circuito equivalente é uma etapa importante no processo de modelagem, pois a quantidade de pares de RC usados no circuito elétrico equivalente influencia o comportamento dinâmico da bateria nas respostas transitórias. A automatização do processo de ajuste de curvas de equações de decaimento exponencial para cada período de relaxamento permite uma análise eficiente da dinâmica celular. Esta análise envolve a tentativa de ajustes usando de 1 a 5 constantes de tempo exponenciais, cada uma associada a pares RC no circuito, como pode ser observado na Figura 12.

Figura 12 – Simulação para definição do número de ramos RC do ECM



Fonte: Próprio Autor.

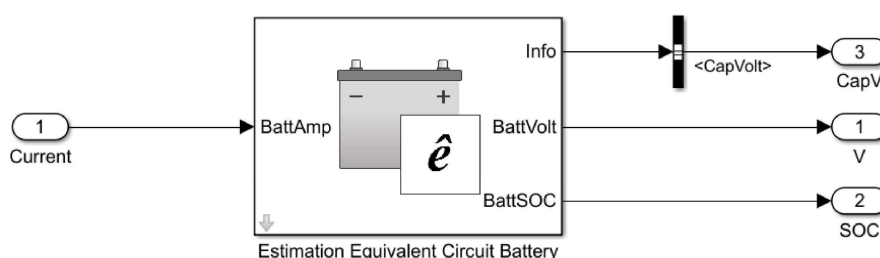
Observa-se no gráfico inferior direito da Figura 12 acima que as simulações que representam os ECMs de um e dois pares de RC possuem mais ruídos de aproximação do que todas as outras opções nos primeiros 60 segundos. Esse comportamento nos 60 segundos iniciais, que representa a dinâmica mais rápida, deve-se à predominância das constantes lentas do sistema devido ao extenso período de repouso. Entretanto, observa-se na posição inferior esquerda da Figura 12 que quando o número de pares de RC aumenta, a dinâmica mais lenta do sistema torna-se mais significativa.

3.2.3 Estimação dos parâmetros

A estimação dos parâmetros do modelo é a etapa 3 do algoritmo, na qual, inicialmente a tensão de circuito aberto E_m e a resistência em série R_0 são determinadas. Para isso, é necessário inspecionar a tensão imediatamente antes e após a corrente ser aplicada e removida no início e no fim de cada pulso. A técnica de estimação usa a tensão após o período de relaxação para estimar os parâmetros E_m e R_0 .

A partir dos dados gerados no Simulink pela simulação de descarga pulsada, gera-se um script no Matlab para inserir esses dados no bloco *Estimation Equivalent Circuit Battery*, ilustrado na Figura 13, para gerar os parâmetros do circuito equivalente.

Figura 13 – Bloco de determinação dos parâmetros dos circuitos equivalentes



Fonte: Próprio Autor.

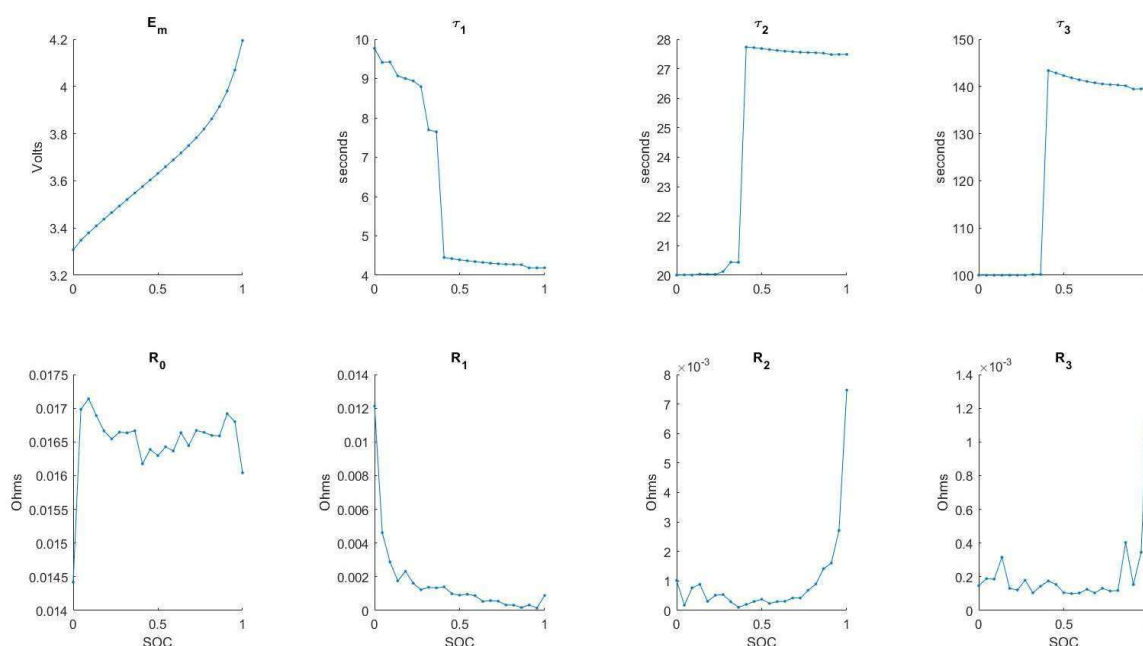
3.2.4 Definição dos valores para cada parâmetro em função do SoC

Os gráficos com os parâmetros do ECM obtidos da simulação podem ser observados na Figura 14. Observa-se que a resistência interna da bateria é menor para valores intermediários de SoC, o que é esperado devido à sua natureza elétrica, que tende a aumentar sua resistência interna quando todos os elétrons estão no eletrodo positivo ou quando todos estão no eletrodo negativo, quando a bateria está carregada e descarregada, respectivamente.

3.3 Modelagem de baterias

A modelagem de LIBs é um mecanismo utilizado para representar os comportamentos que as baterias apresentam quando submetidas a condições de operação, levando em consideração todas as variáveis que interferem em seu funcionamento. Para isso, realiza-se o levantamento e a análise de dados experimentais com o auxílio de modelos matemáticos,

Figura 14 – Representação de parâmetros estimados correspondentes à uma célula de lítio.



Fonte: Próprio Autor.

que servem de base para obtenção das representações dos sistemas. Nesta secção, detalha-se como obter circuitos elétricos equivalentes de LIBs.

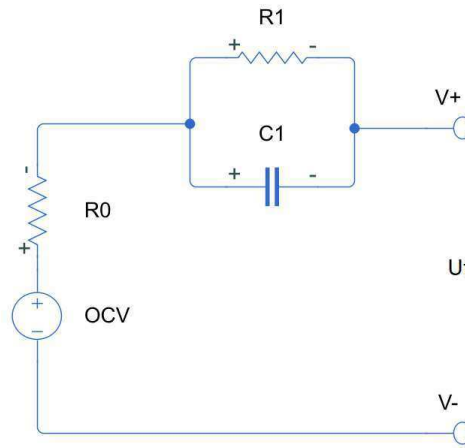
Para garantir a segurança e a robustez na utilização de LIBs, é necessário um modelo preciso, preferencialmente de baixa complexidade, para descrever as características dinâmicas e estáticas. A modelagem de LIBs desempenha um papel crucial na análise e controle de sistemas de energia de veículos elétricos. Os modelos de baterias de íons de lítio existentes se enquadram principalmente em três categorias: modelos eletroquímicos, modelos de caixa preta e modelos de circuito equivalente (HU et al., 2018).

O modelo de circuito equivalente de uma bateria consiste em uma fonte de tensão referente à OCV, um resistor interno e pares de resistência-capacitância (RC), que são capazes de descrever a relação elétrica entre as entradas (corrente, SOC e temperatura) e a tensão do terminal. Comparados aos modelos empíricos, os ECMs são muito mais fáceis para o entendimento das características elétricas da bateria. Além disso, devido à abundância de componentes do circuito e suas combinações, o ECM oferece ferramentas suficientes para a predição dos comportamentos reais das baterias, o que ajuda na acurácia do dimensionamento do projeto.

3.3.1 Modelo RC de primeira ordem de uma bateria

O modelo representado por uma fonte de tensão, uma resistência interna e um par de RC é o modelo de circuito equivalente mais simples e é selecionado para aproximar o desempenho elétrico da bateria como pode ser observado na Figura 15. Ao aplicar uma tensão ou corrente a um circuito que inclui uma bateria, o modelo RC de primeira ordem é usado para prever como a tensão ou corrente irá variar ao longo do tempo. A constante de tempo do circuito ($\tau = RC$) é um parâmetro importante que determina a velocidade com que a resposta transiente ocorre (Farag, 2013).

Figura 15 – Diagrama do circuito de primeira ordem.



Fonte: Próprio Autor.

As equações de espaço de estado que representam esse circuito estão detalhadas a seguir:

$$\begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} \end{bmatrix} * \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \end{bmatrix} + \begin{bmatrix} \frac{-\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \end{bmatrix} i(k) \quad (3.1)$$

$$y(k) = U_t(k) = \text{OCV}(\text{SoC}) - U_1(k) - R_0 \times i(k) \quad (3.2)$$

Onde,

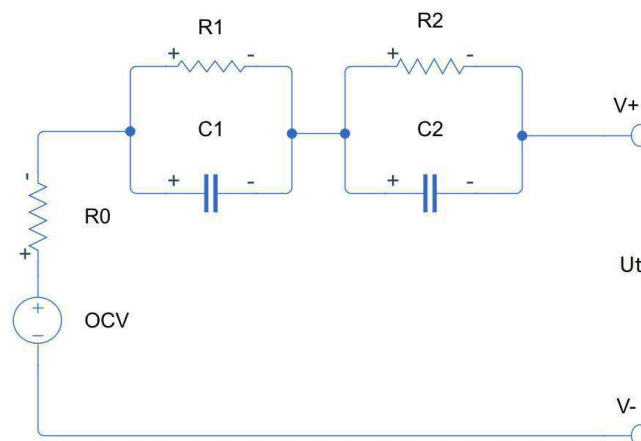
- SoC é o estado de carga da bateria;
- OCV é a tensão de circuito aberto;
- C é a capacidade nominal da bateria;

- R_0 é a resistência ôhmica da bateria;
- R_1C_1 se refere a dinâmica de polarização;
- U_1 é um estado que representa a tensão no capacitor C_1 ;
- SoC(k) e U_1 são os estados do sistema;
- $y(k)$ é a saída do sistema, a qual corresponde a tensão no terminal com a bateria conectada a uma carga;
- $i(k)$ é a corrente de entrada;
- $\eta_i = 13600 \times C_i$, sendo i um índice para representar a variação da capacidade em relação ao tempo;
- Δt é o período de amostragem.

3.3.2 Modelo RC de segunda ordem de uma bateria

O modelo de segunda ordem é ilustrado na Figura 16. O modelo é capaz de representar adequadamente o comportamento das constantes de tempo rápida (ramo R_1C_1) e lenta (ramo R_2C_2) para recuperação de tensão da bateria (Farag, 2013).

Figura 16 – Diagrama do circuito de segunda ordem.



Fonte: Próprio Autor.

Baseado nesse tipo de circuito é possível observar:

$$\begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \\ U_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_2 C_2} \end{bmatrix} * \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \\ U_2(k) \end{bmatrix} + \begin{bmatrix} \frac{-\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \end{bmatrix} i(k); \quad (3.3)$$

$$y(k) = U_t(k) = OCV(S_oC) - U_1(k) - U_2(k) - R_0 \times i(k) \quad (3.4)$$

Onde,

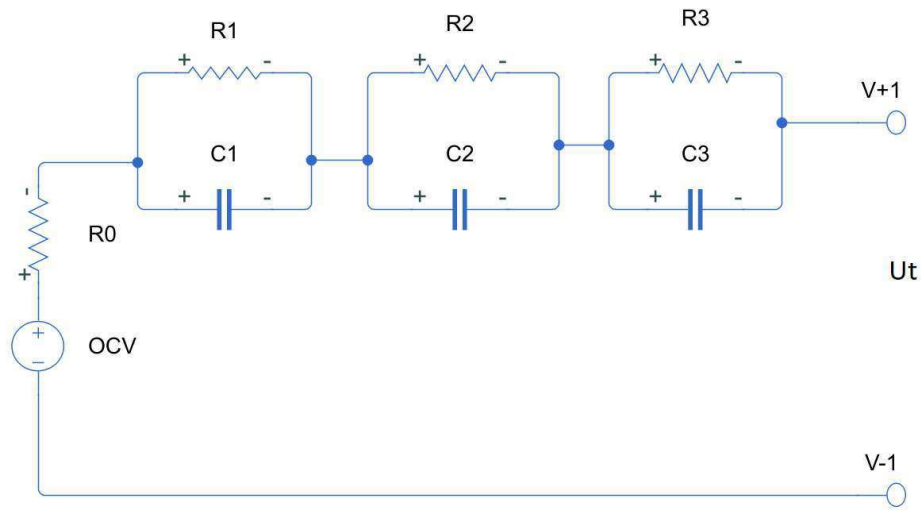
- SoC é o estado de carga da bateria;
- OCV é a tensão de circuito aberto;
- C é a capacidade nominal da bateria;
- R_0 é a resistência ôhmica da bateria;
- $R_1 C_1$ é referente à constante de tempo rápida de polarização e de dupla camada;
- $R_2 C_2$ é referente à constante de tempo lenta;
- U_1 e U_2 são estados que representam as tensões em volta dos capacitores C_1 e C_2 ;
- SoC (k), U_1 e U_2 são os estados do sistema;
- $y(k)$ é a saída do sistema, a qual corresponde a tensão no terminal com a bateria conectada a uma carga;
- $i(k)$ é a corrente de entrada;
- $\eta_i = \frac{1}{3600 \times C_i}$, sendo i um índice para representar a variação da capacidade em relação ao tempo;
- Δt é o período de amostragem.

3.3.3 Modelo RC de terceira ordem de uma bateria

O modelo de terceira ordem permite obter respostas de forma mais precisa do comportamento do sistema, como pode ser observado na Figura 17.

As equações de espaço de estado que representam esse circuito são:

Figura 17 – Diagrama do circuito de terceira ordem.



Fonte: Próprio Autor.

$$\begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \\ U_2(k+1) \\ U_3(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 \\ 0 & 0 & 0 & 1 - \frac{\Delta t}{R_3 C_3} \end{bmatrix} * \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \\ U_2(k) \\ U_3(k) \end{bmatrix} + \begin{bmatrix} \frac{-\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \\ \frac{\Delta t}{C_3} \end{bmatrix} i(k) \quad (3.5)$$

$$y(k) = U_t(k) = \text{OCV}(S \circ C) - U_1(k) - U_2(k) - U_3(k) - R_0 \times i(k) \quad (3.6)$$

Em que,

- SoC é o estado de carga da bateria;
- OCV é a tensão de circuito aberto;
- C é a capacidade nominal da bateria;
- R_0 é a resistência ôhmica da bateria;
- $R_1 C_1$ é referente à constante de tempo rápida de polarização e de dupla camada;
- $R_2 C_2$ é referente à constante de tempo lenta;
- $R_3 C_3$ é referente à constante de tempo mais lenta que o ramo anterior;

- U_1, U_2 e U_3 são estados que representam as tensões em volta dos capacitores C_1, C_2 e C_3 ;
- $\text{SoC}(k), U_1, U_2$ e U_3 são os estados do sistema;
- $y(k)$ é a saída do sistema, a qual corresponde a tensão no terminal com a bateria conectada a uma carga;
- $i(k)$ é a corrente de entrada;
- $\eta_i = \frac{1}{3600 \times c_i}$, sendo i um índice para representar a variação da capacidade em relação ao tempo;
- Δt é o período de amostragem.

A complexidade ao utilizar 1, 2 ou 3 pares de RC para representar uma LIB aumenta à medida que mais pares de RC são adicionados. Cada par de RC corresponde um circuito RC de primeira ordem, e a combinação de múltiplos pares de RC visa representar mais características do comportamento da bateria. A escolha adequada do modelo depende das características específicas da bateria, dos requisitos da aplicação e da disponibilidade de dados experimentais para identificar os parâmetros do modelo. Além disso, modelos mais complexos exigem maior esforço computacional e podem ser mais desafiadores de identificar corretamente. Portanto, é necessário encontrar um equilíbrio entre a complexidade do modelo e a utilidade prática para a finalidade desejada.

3.4 Método *Coulomb Counting* aplicado na estimação de SoC

O método *Coulomb Counting* é usualmente utilizado como base na estimação de SoC devido à sua simplicidade, pois se resume ao cálculo do SOC baseado no produto da corrente elétrica com o tempo. A metodologia leva em consideração o Ampère hora tanto da descarga como da recarga (Berecibar et al., 2016). Nessa metodologia, a partir da energia que entra e que sai da bateria, o algoritmo utilizado estima a capacidade e o SoC. No entanto, é um método de malha aberta e seu processo de estimação tende a se desviar dos valores originais devido ao efeito cumulativo dos erros de medição e ao cálculo pela função de integração. Além disso, é intrínseco ao método a necessidade de estimar o valor inicial do SOC, o que pode gerar mais problemas na estimação (SIDHU; RONANKI; WILLIAMSON, 2019b).

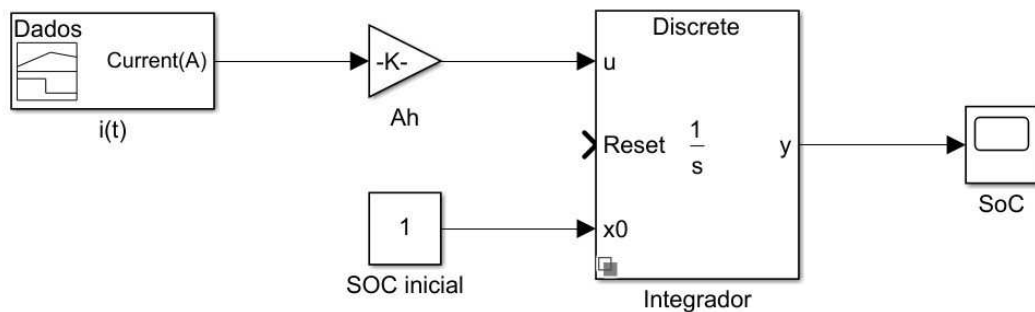
Além disso, essa metodologia possui limitações, pois a curva de correlação OCV-SoC não é prática para células que possuem histerese, uma vez que a célula da bateria leva muito tempo para atingir um OCV de estado estacionário após um pulso de corrente. O problema é agravado para as baterias LFP que também possuem uma curva de correlação OCV-SoC muito plana. Os modelos atuais de estimativa de SOC são incapazes de lidar com todas essas complicações. Um algoritmo mais robusto é necessário para estimar a carga total instantânea disponível para trabalho dentro de uma célula LFP (HURIA et al., 2013).

O modelo matemático da equação 3.7 explicita como o SoC é calculado, em que C_N é a capacidade nominal de uma bateria, $SoC(t_0)$ representa o SoC no tempo inicial t_0 , η é a eficiência de Coulomb e $I(t)$ é a corrente positiva na descarga e negativa na carga, com a corrente medida (Santos, 2019),

$$SoC(t) = SoC(t_0) - \frac{1}{C_N} \int_{t_0}^t \eta I(t) dt \quad (3.7)$$

A implementação do método pode ser realizada no Simulink por meio do bloco *SOC Estimator (Coulomb Counting)*. As variáveis de entrada são SoC inicial e corrente elétrica, e a variável de saída é o SoC estimado. O bloco está ilustrado na Figura 18.

Figura 18 – Bloco estimador de SoC utilizando Coulomb Counting.



Fonte: Próprio autor.

As entradas do sistema são corrente elétrica e o SoC inicial. Utilizou-se o bloco de ganho para converter os dados de corrente elétrica em Ampères-hora. O bloco integrador utiliza a carga que entra e que sai da bateria, e o SoC inicial para realizar a estimativa do SOC instantâneo na saída.

3.5 Filtros de Kalman aplicados na previsão de sistemas dinâmicos

O filtro de Kalman (do inglês, *Kalman Filter* - KF), desenvolvido por Rudolph E. Kalman, é uma metodologia que fornece um método eficiente ao longo do tempo para filtrar medições de entrada e saída do sistema para produzir uma estimativa inteligente do estado de um sistema linear. É de uso comum em muitos campos, incluindo rastreamento de alvos, navegação e comunicação (JUNPING; JINGANG; LEI, 2009). A representação mais simples dos modelos de espaço de estados podem ser expressos com equações da seguinte forma (TURNER, 2016):

$$x_k = A_{k-1}x_{k-1} + q_{k-1} \quad (3.8)$$

$$y_k = H_k x_k + r_k \quad (3.9)$$

Onde,

- $x_k \in \mathbb{R}^n$ é o estado do sistema no tempo k .
- $y_k \in \mathbb{R}^m$ é a medição no passo de tempo k .
- q_{k-1} é o ruído do processo no intervalo de tempo $k - 1$.
- r_k é a medição do ruído no intervalo de tempo k .
- A_{k-1} é a matriz de transição do modelo dinâmico.
- H_k é a medição do modelo da matriz.
- A distribuição a priori para o estado é $x_0 \sim N(m_0, P_0)$, em que os parâmetros m_0 e P_0 são definidos usando as informações conhecidas sobre o sistema em estudo.

O filtro de Kalman possui duas etapas: a etapa de previsão, em que o próximo estado do sistema é previsto a partir das medições anteriores, e a etapa de atualização, em que o estado atual do sistema é estimado considerando a medição naquela etapa de tempo (HARTIKAINEN; SOLIN; SÄRKKÄ, 2008)

- Previsão KF

$$m_k^- = A_{k-1}m_{k-1} \quad (3.10)$$

$$P_k^- = A_{k-1}P_{k-1}A_{k-1}^T + Q_{k-1} \quad (3.11)$$

- Correção KF

$$v_k = y_k - H_k m_k^- \quad (3.12)$$

$$S_k = H_k P_k^- H_k^T + R_k \quad (3.13)$$

$$K_k = P_k^- H_k^T S_k^- \quad (3.14)$$

$$m_k = m_k^- - K_k v_k \quad (3.15)$$

$$P_k = P_k^- - K_k S_k K_k^T \quad (3.16)$$

Em que:

- m_k^- e P_k^- são a média prevista e a covariância do estado, respectivamente, na etapa de tempo k antes de ver a medição.
- m_k e P_k são a média estimada e a covariância do estado, respectivamente, na etapa de tempo k depois de ver a medição.
- v_k é a inovação ou o resíduo de medição no intervalo de tempo k .
- S_k é a covariância de previsão de medição no intervalo de tempo k .
- K_k é o ganho do filtro, que informa quanto as previsões devem ser corrigidas no intervalo de tempo k .

Tratando-se da modelagem da estimação de SoC de LIBs em que a relação entre a tensão de circuito aberto e o SoC é não linear, realiza-se um processo de linearização que ocorre a cada passo de tempo para aproximar o sistema não linear de um sistema linear variável no tempo. Essa técnica, filtro de Kalman Extendido (do inglês, *Extended Kalman Filter* - EKF), herda a habilidade do do filtro de Kalman para estimar os melhores valores possíveis das entradas contendo ruído não medido. (TURNER, 2016).

3.6 Filtros de Kalman estendido aplicados na estimação de SoC de LIBs

O filtro de Kalman Estendido amplia o escopo do filtro de Kalman para problemas de filtragem de sistemas não lineares ao utilizar o princípio da linearização da função não linear que usa derivadas parciais e expansão em série de Taylor de primeira ordem, formando uma aproximação gaussiana para a distribuição conjunta do estado x e medições y (PLETT, 2004). A linearização permite propagar o estado e a covariância de estado em um formato aproximadamente linear e requer jacobianos da equação de estado e da equação de medição (CHENG et al., 2014). O modelo de filtragem utilizado no EKF é

$$x_{k+1} = f(x_k, u_k) + w_k \quad (3.17)$$

$$y_k = g(x_k, u_k) + r_k \quad (3.18)$$

Em que:

- $x_k \in \mathbb{R}^n$ é o vetor de estado do sistema no índice de tempo discreto k .
- $y_k \in \mathbb{R}^m$ é a medição do sistema.
- $w_k \sim N(0, Q_{k-1})$ é o ruído do processo.
- $r_k \sim N(0, R_k)$ é o ruído da medição.
- f é a função de modelo dinâmico.
- g é a função de modelo de medição.

A cada índice de tempo, $f(x_k, u_k)$ e $g(x_k, u_k)$ com a linearização por uma expansão da série Taylor de primeira ordem, o modelo pode ser reescrito como:

$$x_{k+1} = A_k \times x_k + B_k \times u_k + w_k \quad (3.19)$$

$$y_{k+1} = C_k \times x_k + D_k \times u_k + r_k \quad (3.20)$$

em que,

$$A_k = \frac{\partial [f(x_k, u_k)]}{\partial [x_k]} \quad (3.21)$$

$$B_k = \frac{\partial [f(x_k, u_k)]}{\partial [u_k]} \quad (3.22)$$

$$C_k = \frac{\partial [g(x_k, u_k)]}{\partial [x_k]} \quad (3.23)$$

$$D_k = \frac{\partial [g(x_k, u_k)]}{\partial [u_k]} \quad (3.24)$$

O espaço de estados do modelo do circuito equivalente ilustrado na Figura 17 é composto pelo SoC e pelas tensões nos pares de RC, e a entrada do modelo é a corrente i . Assim, o ECM dinâmico pode ser descrito no espaço de estados como resposta ao degrau da seguinte forma:

$$\begin{aligned} \begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \\ U_2(k+1) \\ U_3(k+1) \end{bmatrix} &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & e^{(-T_s/\tau_1)} & 0 & 0 \\ 0 & 0 & e^{(-T_s/\tau_2)} & 0 \\ 0 & 0 & 0 & e^{(-T_s/\tau_3)} \end{bmatrix} \\ * \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \\ U_2(k) \\ U_3(k) \end{bmatrix} &+ \begin{bmatrix} \frac{\eta T_s}{C_n} \\ R_1 \left(1 - e^{(-T_s/\tau_1)}\right) \\ R_2 \left(1 - e^{(-T_s/\tau_2)}\right) \\ R_3 \left(1 - e^{(-T_s/\tau_3)}\right) \end{bmatrix} I(k) + W_k \end{aligned} \quad (3.25)$$

$$y_k(k) = U_t = U_{oc}(\text{SoC}(k)) - U_3(k) - U_2(k) - U_1(k) - R_0 \times I(k) + V_k \quad (3.26)$$

Para obter as matrizes, deriva-se parcialmente em relação à tensão e à corrente:

$$A_k = \frac{\delta f}{\delta x} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & e^{(-T_s/\tau_1)} & 0 & 0 \\ 0 & 0 & e^{(-T_s/\tau_2)} & 0 \\ 0 & 0 & 0 & e^{(-T_s/\tau_3)} \end{bmatrix} \quad (3.27)$$

$$B_k = \frac{\delta f}{\delta u} = \begin{bmatrix} \frac{\eta T_s}{C_n} \\ R_1 \left(1 - e^{(-T_s/\tau_1)}\right) \\ R_2 \left(1 - e^{(-T_s/\tau_2)}\right) \\ R_3 \left(1 - e^{(-T_s/\tau_3)}\right) \end{bmatrix} \quad (3.28)$$

$$C_k = \frac{\delta g}{\delta x} = \begin{bmatrix} \delta U_{oc} \\ \delta \text{SoC} \end{bmatrix} \Big|_{\text{SoC}=\text{SoC}_{-1}} - 1 - 1 - 1 \quad (3.29)$$

$$D_k = \frac{\delta g}{\delta u} = [-R_0(k)] \quad (3.30)$$

O processo de previsão do EKF é dada por:

$$x_{k+1}^- = A_k \times x_k^+ + B_k \times I_t(k) \quad (3.31)$$

A propagação do erro de covariância é dado por:

$$P_{k+1}^- = A_k \times P_k^+ \times A_k^T + Q_k \quad (3.32)$$

Em que:

- $x_{k|k-1}$ é a estimativa a priori do estado no instante k ;
- $x_{k-1|k-1}$ é a função de transição de estado que modela a dinâmica do sistema;
- u_k é o vetor de entrada;
- $P_{k|k-1}$ é a covariância a priori do erro de estimativa;
- F_{k-1} é a matriz jacobiana da função de transição de estado;
- Q_{k-1} é a matriz de covariância do ruído do processo.

Na atualização, o cálculo do ganho é dado por:

$$K_k = P_{k+1}^- \times C_k^T \times [C_k \times P_{k+1}^- \times C_k^T + R_k]^{-1} \quad (3.33)$$

O erro é atualizado pela equação:

$$P_{k+1}^+ = P_{k+1}^- - K_k \times C_k \times P_{k+1}^- \quad (3.34)$$

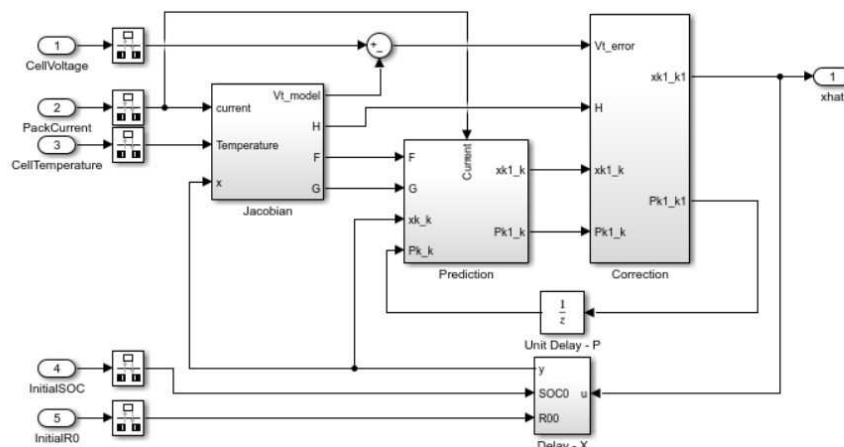
E a atualização do estado estimado é dada por:

$$x_{k+1}^+ = x_{k+1}^- + K_k \times [V(k) - U_t(k)] \quad (3.35)$$

A implementação do método EKF pode ser realizada no Simulink por meio do bloco *SoC Estimator (EKF)*, representado na Figura 19. As variáveis de entrada são SoC inicial e corrente elétrica, resistências e capacitâncias e a variável de saída é o SoC estimado. A partir desse bloco, implementou-se no Simulink a representação da bateria para inserir os

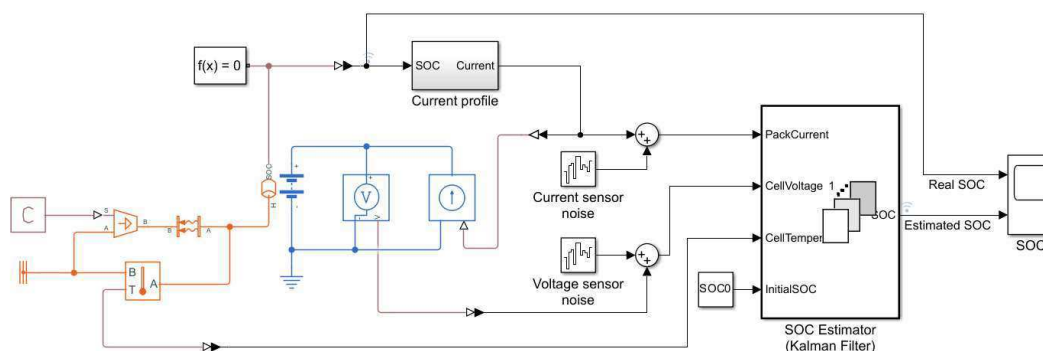
valores de entrada e realizar a estimação. A implementação completa no Simulink para a estimação de SoC por meio de EKF pode ser observada na Figura 20. A simulação foi realizada inserindo os valores iniciais dos estados e os dados da matriz de covariância inicial.

Figura 19 – Bloco estimador de SoC utilizando EKF.



Fonte: Próprio autor.

Figura 20 – Representação de uma bateria na estimação de SoC utilizando EKF.



Fonte: Próprio autor.

Concluindo, por meio de ferramentas computacionais e métodos matemáticos é possível realizar a modelagem de uma LIB por meio de circuitos elétricos equivalentes, em que seus parâmetros podem ser obtidos, dentre algumas formas, por meio de dados obtidos em ensaios de laboratório ou em condições reais de ciclos de trabalho. Utilizando o Matlab é possível implementar alguns métodos de estimação de SoC, como o *Coulomb Counting* e *Extended Kalman Filters* para realizar a estimação de SoC. No próximo capítulo será detalhado sobre como também pode-se realizar a estimação de SoC por meio de algumas metodologias de inteligência artificial utilizando *open source*.

4 | *Machine learning*

Exploram-se, neste capítulo, as características fundamentais de alguns algoritmos de *Machine learning* que podem ser aplicados na previsão de sistemas não lineares. Além disso, destacam-se as diferenças essenciais entre esses algoritmos, revelando os detalhes que os tornam aptos para a aplicação em metodologias voltadas para a estimação do SoC de LIBs.

4.1 Introdução

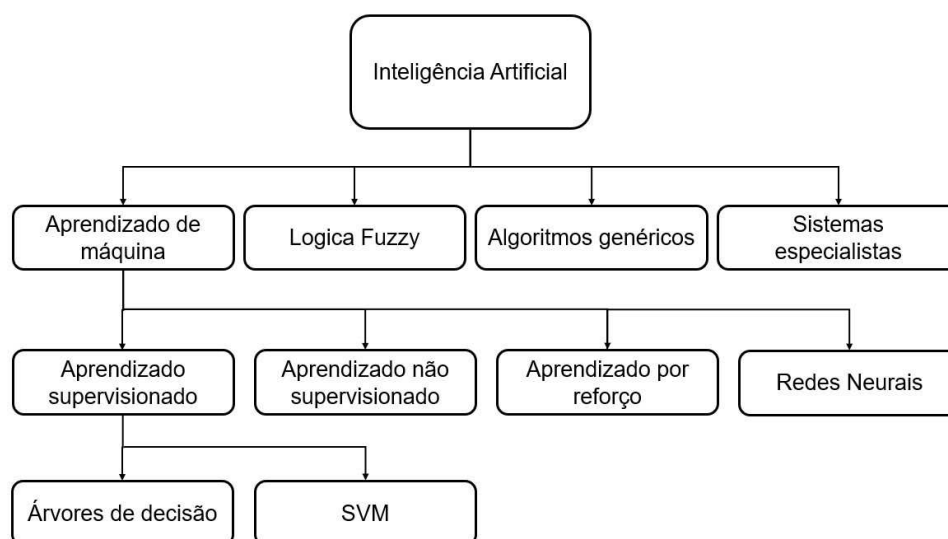
Recentemente, com o avanço do desenvolvimento da ciência e da tecnologia, alcançou-se a era da inteligência artificial. O reconhecimento e a classificação de objetos já desempenham papel importante no comércio eletrônico, na inteligência de negócios e em diversos setores como tecnologia, saúde, segurança e transporte. Muitas técnicas utilizando inteligência artificial são utilizadas em tarefas de estimação, reconhecimento e classificação de objetos e padrões (FENGXIN et al., 2017).

Inteligência artificial (do inglês, *Artificial Intelligence* - AI) é a simulação da inteligência humana por meio de máquinas. É uma área interdisciplinar que se concentra em criar sistemas e tecnologias que possam realizar tarefas que normalmente requerem inteligência humana, como tomar decisões, resolver problemas e reconhecer padrões. A AI pode ser implementada por diversas formas, entre elas, aprendizado de máquina (do inglês, *Machine Learning* - ML), processamento de linguagem natural, visão computacional e robótica. O objetivo da AI é desenvolver sistemas que possam ser autônomos ou ampliar a inteligência humana em tarefas específicas (TEJASWINI; SIVRAJ, 2020).

A AI pode ser dividida em grupos de algoritmos com base em sua aplicação e no tipo de tecnologia empregada, como ML, processamento de linguagem natural, sistemas especialistas, como pode ser observado na Figura 21.

ML é um ramo da inteligência artificial que apresenta boa aplicabilidade em

Figura 21 – Divisão da Inteligência Artificial



Fonte: Próprio Autor.

classificação, regressão e outras tarefas relacionadas a dados de alta dimensão. Com o objetivo de extrair conhecimento e obter percepções de grandes bancos de dados, o ML aprende com cálculos anteriores para produzir decisões e resultados confiáveis e repetíveis. Com o rápido ritmo de desenvolvimento de abordagens baseadas em dados que combinam a sabedoria de especialistas com poderosos modelos de ML, os cientistas estão começando a integrar a intuição humana na orientação da pesquisa científica (BARRETT; HARUNA, 2020). Não existe um tipo único de algoritmo que sirva para todos e que seja o melhor para resolver um problema. O tipo de algoritmo empregado depende do tipo de problema que se deseja resolver, do número de variáveis, do tipo de modelo que melhor se adequa a ele e assim por diante (MAHESH, 2020).

ML pode ser dividido em três metodologias: sistemas supervisionados, sistemas não supervisionados e aprendizado forçado (MAHESH, 2020). A aplicação de metodologias de sistemas supervisionados na estimação de SoC de LIBs pode ser realizada de forma acurada porque a metodologia é capaz de estimar as mudanças de SoC, devido aos carregamentos e aos descarregamentos, a partir de dados de entrada, e também conseguir interpretar o decaimento do SoC devido ao envelhecimento da bateria.

ML pode ser classificado com base na abordagem de aprendizado, com base na tarefa, com base na tecnologia e com base na aplicação. Tipos de métodos baseados na abordagem do aprendizado são sistemas supervisionados, sistemas não supervisionados e aprendizado forçado.

4.2 Sistemas supervisionados

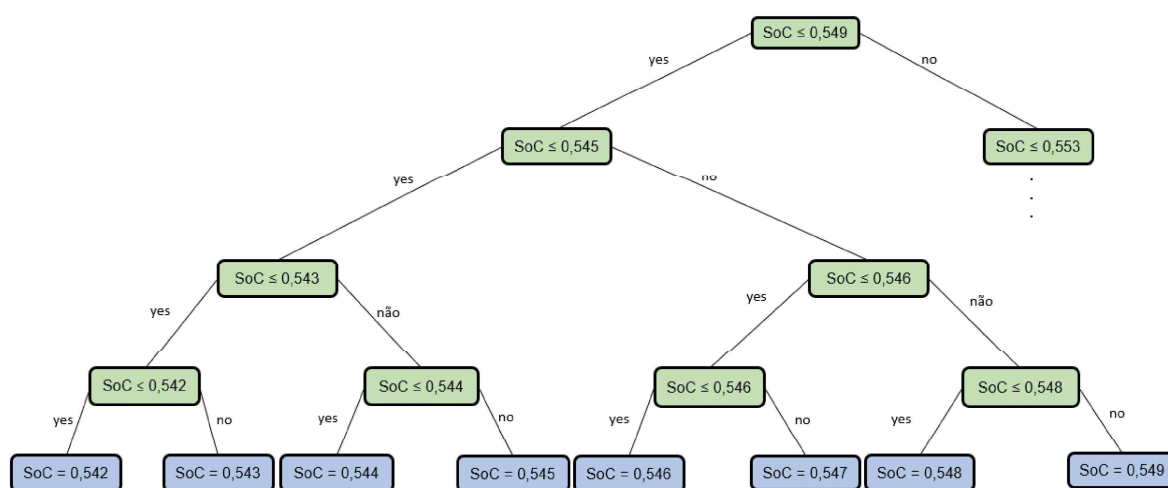
O aprendizado supervisionado é uma metodologia de ML que consegue aprender uma função que mapeia uma entrada para uma saída com base em pares de entrada-saída de exemplo. Ele infere uma função a partir de dados de treinamento rotulados que consistem em um conjunto de exemplos de treinamento. Os algoritmos de ML supervisionados são aqueles algoritmos que precisam de assistência externa. O conjunto de dados de entrada é dividido em conjunto de dados de treinamento e de teste (MAHESH, 2020).

Alguns algoritmos de predição de sistemas supervisionados que podem ser aplicados na estimação de SoC de LIBs são árvores de decisão (do inglês, *Decision Tree* - DT) e máquina de vetores de suporte (do inglês, *Support Vector Machine* - SVM).

4.2.1 Árvore de decisão (DT)

A metodologia de DT por meio de ML é um processo que envolve a construção de uma estrutura hierárquica multidimensional em forma de árvore para tomar decisões com base em características dos dados de entrada. A Figura 22 representa uma pequena parte de uma dimensão de uma DT, em que os blocos verdes representam nós de decisão e os blocos azuis, nós folhas.

Figura 22 – Representação de uma dimensão de uma árvore de decisão



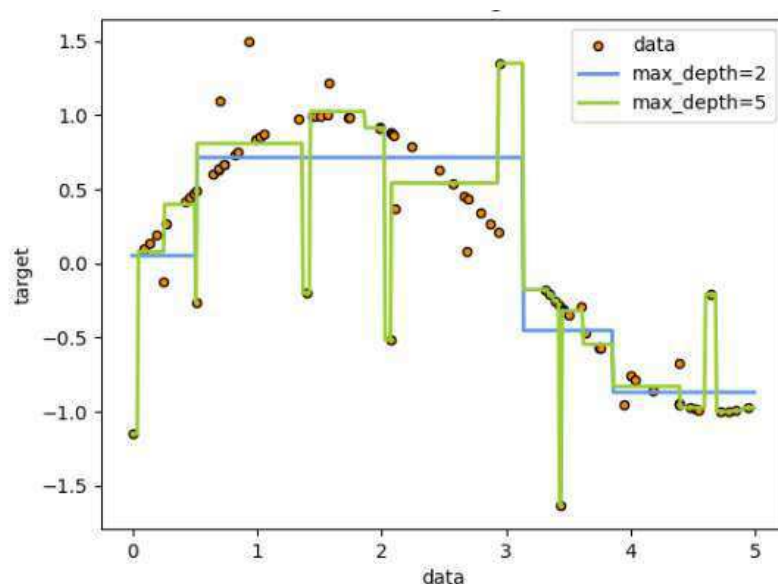
Fonte: Próprio autor

Trata-se de um modelo que não possui nenhuma estrutura de árvore prévia. A estrutura da árvore depende da complexidade dos dados de treinamento durante o estágio de aprendizado. A árvore de decisão é composta por dois tipos de nó: nó de decisão e nó

folha. Cada amostra de dados de treinamento é avaliada pelos nós de decisão e passada para diferentes nós, dependendo do valor das características da amostra (SIDHU; RONANKI; WILLIAMSON, 2019a). A estrutura de uma árvore de decisão é uma semelhante a um fluxograma em que cada nó interno representa um teste em um atributo, cada ramificação representa o resultado do teste e cada nó folha, um rótulo de classe (NIZAM et al., 2015).

As DTs aprendem com os dados para aproximar curvas por meio de conjuntos de regras de decisão baseado em funções lógicas do tipo *if-then-else*, como pode ser observado na aproximação da curva senoidal ilustrada na Figura 23. Quanto mais profunda a árvore, mais complexas as regras de decisão e mais adequado o modelo.

Figura 23 – Representação da aproximação de uma curva senoidal por meio de DTs



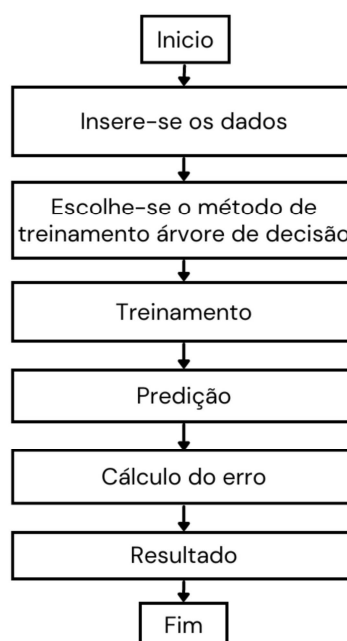
Fonte: scikit-learn (Acesso em 2023)

As principais vantagens dos métodos DTs são: simples de entender e interpretar, capaz de lidar com problemas de múltiplas saídas, requer pouca preparação de dados, possibilidade de validar um modelo usando testes estatísticos e apresenta bom desempenho (mesmo que suas suposições sejam um pouco violadas pelo modelo verdadeiro a partir do qual os dados foram gerados). A classificação das instâncias começa no nó raiz de uma árvore de decisão ou em qualquer outro algoritmo de classificação utilizado. Essas instâncias são classificadas com base em seus valores de recurso, que são as características ou atributos que descrevem cada instância (KOTSIANTIS et al., 2007). O objetivo é criar um modelo que preveja o valor de uma variável de destino aprendendo regras de decisão simples inferidas dos recursos de dados.

A implementação do método árvore de decisão pode ser realizado de diversas formas

utilizando linguagens de programação como *python*, C ou C++, por exemplo. Em *python*, essa implementação pode ser realizada por meio da biblioteca *scikit-learn*, que é uma biblioteca para aprendizado de máquina de código aberto. É possível implementar em *python* árvores de decisão por meio da classe *DecisionTreeRegressor*, que é uma classe capaz de realizar estimações por meio de regressão em um conjunto de dados. O fluxograma ilustrado na Figura 24 representa o passo a passo da execução do método.

Figura 24 – Representação das etapas da estimação de SoC por meio de árvores de decisão.



Fonte: Próprio Autor.

A biblioteca *scikit-learn* também disponibiliza a classe *RandonForest* para estimar estimação de sistemas não lineares. Essa classe é utilizada para criar modelos de florestas aleatórias, com o objetivo de encontrar a melhor quantidade de nós possíveis que possibilitem um resultado com menor erro possível na estimação. Por padrão, essas classes utilizam 70% dos dados para treinamento e 30% para teste, mas esses valores podem ser ajustados conforme necessidade de projeto. Caso se deseje maior acuracidade nas estimações, pode-se aumentar a proporcionalidade dos dados de treinamento para o sistema se tornar mais assertivo e possuir menor erro de estimação.

4.2.2 *Support Vector Machine - SVM*

Support Vector Machine (SVM) são sistemas de aprendizagem de máquina treinados com um algoritmo de otimização matemática, que são embasadas pela teoria do aprendizado

estatístico. O desenvolvimento dessa teoria iniciou-se em 1992 por B. Boser, I. Guyon e V. Vapnik ao desenvolverem um classificador de limite ideal, formando o primeiro protótipo de SVM (GUO et al., 2014). Essa metodologia destaca-se por possuir sólida fundamentação teórica e por poder alcançar alto desempenho em aplicações práticas. Trata-se de uma entidade matemática, um algoritmo para maximizar uma função matemática específica em relação a uma determinada coleção de dados (NOBLE, 2006a).

A teoria de aprendizagem de SVM identifica precisamente os fatores que devem ser considerados para a aprendizagem ser bem sucedida e construir modelos complexos. O treinamento de SVM envolve a otimização de uma função quadrática convexa, que é um problema de otimização matemática. SVM envolve poucos parâmetros livres que precisam ser ajustados pelo usuário e não há uma dependência, pelos menos de uma forma explícita, na dimensão do espaço de entrada do problema, o que sugere que SVM pode ser útil em problemas com um grande número de entradas. Outro destaque é que a arquitetura de SVM não é encontrada por experimentação. Essa técnica pode ser aplicada ao reconhecimento de padrões (estimar funções indicadores), de regressão (estimar funções de valores reais) e de extração de características (Santos, 2019).

Para o adequado funcionamento da SVM, princípios devem ser seguidos na obtenção de classificadores e estimadores com boa generalização, como a capacidade de prever corretamente a classe de novos dados do mesmo domínio em que o aprendizado ocorreu (LORENA; CARVALHO, 2007). Essa metodologia funciona com base no princípio do cálculo de margem, desenhando margens entre as classes. As margens são traçadas de forma que a distância entre a margem e as classes seja máxima e, portanto, minimizando o erro de classificação (MAHESH, 2020).

Em SVM, as classes se referem ao tipos de rótulos ou categorias em que as amostras podem apresentar, elas variam de acordo com o tipo de problema, e apresentam diferentes níveis de complexidade. Nos casos mais simples, como os de classificação binária, as classes são representadas por zeros e uns, mas em casos mais complexos, a SVM lida eficientemente com problemas não linearmente separáveis de alta dimensão (CRISTIANINI; SHAW-TAYLOR, 2000).

Nas SVMs, as margens se referem à distância entre a linha/plano separador e os dados de treinamento/teste de cada classe. Os vetores de suporte são os pontos mais próximos do hiperplano separador. O cálculo da margem é realizado a partir da distância perpendicular do hiperplano aos vetores de suporte (LORENA; CARVALHO, 2007). O SVM busca definir um hiperplano separador que maximize as margens, com o objetivo de garantir a maior distância possível entre o hiperplano e os pontos dos dados.

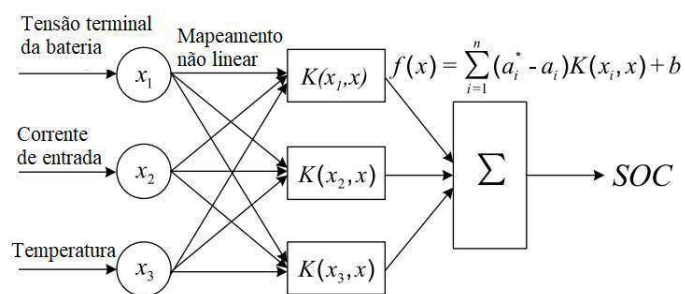
O SVM faz uso de uma função de kernel para mapear dados em um espaço de alta

dimensão, onde uma linha pode ser usada para ajustar os pontos de dados. A função de perda do SVM permite que o modelo tenha um erro aceitável para os dados de treinamento (LIU et al., 2022a). A ideia é a implementação de um método de regressão, *Support Vector Regression*, que encontra os parâmetros ótimos para fazer o desvio total de toda a amostra (TIAN; LI; LI, 2021).

O diferencial da aplicação de SVM pode ser observado na solução de problemas de sistemas não linearmente separáveis, utilizando-se uma técnica chamada de *kernel trick*, que é uma forma de calcular o produto interno entre os vetores no espaço de características, mapeando-os em um espaço de maior dimensão (ZHANG et al., 2019). Para isso, calcula-se o produto interno entre os vetores no espaço de características, transformado-o sem a necessidade de calcular explicitamente as novas coordenadas. O produto interno resultante é equivalente ao produto interno no espaço de características original, mas os dados foram implicitamente mapeados para um espaço de maior dimensionalidade.

SVM pode ser aplicado à previsão SoC de LIBs, com quatro parâmetros de características externas da bateria - tensão terminal, corrente de descarga, temperatura da bateria e o SoC de entrada - usadas como entradas para construir um modelo de máquina vetorial de suporte. Por meio de SVM, o problema de previsão SoC é transformado em um problema de regressão não linear (LI et al., 2020). O diagrama representado na Figura 25 apresenta o modelo de previsão de SoC por meio de SVM.

Figura 25 – Representação do diagrama SVM na estimação de SoC de bateria de Li-ion.



Fonte: Adaptado de Li et al. (2020).

Em que, x_i é o vetor de suporte alvo, $K(x_i, x)$ é a função kernel. A função do kernel pode inserir dados de baixa dimensão no espaço de alta dimensão.

As ideias básicas por trás do algoritmo SVM podem ser compreendidas sem a necessidade de se aprofundar em equações matemáticas. Para compreender a essência do método SVM, é preciso compreender quatro conceitos básicos: (i) o hiperplano de separação, (ii) o hiperplano de margem máxima, (iii) a margem suave e (iv) o hiperplano

de margem máxima (NOBLE, 2006b).

4.2.2.1 Hiperplano separador

O hiperplano é uma generalização do conceito de um plano para espaços de dimensões superiores. Em SVM, um hiperplano é usado como uma fronteira de decisão que separa dados de diferentes classes em um espaço multidimensional, com o objetivo de encontrar o hiperplano ótimo que maximiza as margens entre as classes (NOBLE, 2006b).

Em SVMs, o hiperplano é um subespaço de uma dimensão inferior aos espaços de amostras, em sistemas de duas dimensões, o hiperplano é uma linha; em sistemas de três dimensões, o hiperplano é um plano; em sistemas de 4 dimensões, é definido como hiperplano. Sua função é ser fronteira de decisão entre as classes.

A classificação é realizada com base em qual hiperplano o conjunto de dados está. A capacidade do SVM em encontrar esse hiperplano ótimo torna-o eficaz em problemas de classificação, especialmente quando os dados não são linearmente separáveis. Métodos como o truque do kernel são usados para lidar com casos em que um hiperplano linear não é suficiente. Os hiperplanos são parametrizados por um vetor (w), e uma constante (b), expressa na equação:

$$\mathbf{w} \cdot \mathbf{x} - b = 0 \quad (4.1)$$

Em que w é de fato o vetor ortogonal ao hiperplano, dado tal hiperplano (w, b) que separa os dados. A equação de um hiperplano é apresentada na Equação 4.2, em que $w \cdot x$ é o produto escalar entre os vetores w e x , $w \in X$ é o vetor normal ao hiperplano descrito, $\frac{e}{\|w\|}$ corresponde à distância do hiperplano em relação à origem, com $b \in \mathbb{R}$.

$$f(x) = \mathbf{w} \cdot \mathbf{x} + b \quad (4.2)$$

Em que $f(x)$ é a função de decisão, w é o vetor de pesos, x é o vetor de características do dado e b é o termo de polarização.

4.2.2.2 Hiperplano de margem máxima

A função de regressão por meio de SVM utilizada para estimar o SoC é dada por (LORENA; CARVALHO, 2007):

$$L(y_{\text{true}}, y_{\text{pred}}) = \max(0, |y_{\text{true}} - y_{\text{pred}}| - \varepsilon) \quad (4.3)$$

e a otimização da regressão é expressa por:

$$\text{Minimizar } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N L(y_i, f(\mathbf{x}_i)) \quad (4.4)$$

O hiperplano de margem máxima é um dos problemas mais simples de SVMs lineares, em que as classes estão em um sistema bidimensional e apenas uma linha precisa ser traçada para separar essas amostras, como ilustrado na Figura 25. Nesses casos, as SVMs lineares com margens rígidas definem fronteiras lineares a partir de dados linearmente separáveis. Seja T um conjunto de treinamento com n dados $x_i \in X$ e seus respectivos rótulos $y_i \in Y$, em que X constitui o espaço dos dados e $Y = \{-1, +1\}$. T é linearmente separável se for possível separar os dados das classes $+1$ e -1 por um hiperplano (LORENA; CARVALHO, 2007).

O conceito de tratar os objetos a serem classificados como pontos em um espaço de alta dimensão e de encontrar uma linha que os separe não é exclusivo do SVM. O SVM, entretanto, é diferente de outros classificadores baseados em hiperplanos em virtude de como o hiperplano é selecionado (NOBLE, 2006b).

Na definição da distância do hiperplano de separação ao vetor de expressão mais próximo como a margem do hiperplano, o SVM seleciona a margem máxima que separa o hiperplano. A seleção deste hiperplano específico maximiza a capacidade do SVM de prever a classificação correta de novas amostras.

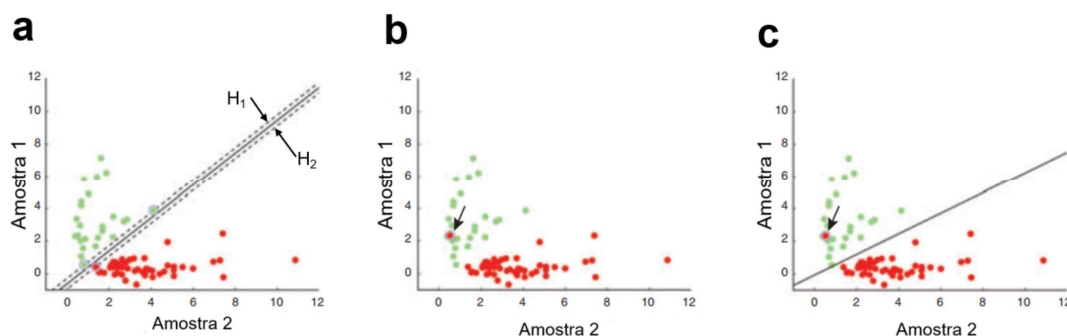
Este teorema é, em muitos aspectos, a chave para o sucesso de um SVM. Algumas observações são pertinentes sobre esse processo. Primeiro, o teorema assume que os dados utilizados para treinar e testar o SVM são extraídos da mesma distribuição para garantir um bom desempenho de generalização. Isso é razoável, uma vez que não podemos esperar, por exemplo, que um SVM treinado em dados de microarranjos seja capaz de classificar dados de espectrometria de massa. Mais relevante ainda, não pode-se esperar que o SVM tenha um bom desempenho se as amostras do conjunto de dados de treinamento foram preparadas usando um protocolo diferente das amostras utilizadas para a realização dos testes. Por outro lado, o teorema não assume que os dois conjuntos de dados foram extraídos de uma classe particular de distribuições. Por exemplo, um SVM não assume que os valores dos dados de treinamento seguem uma distribuição normal (NOBLE, 2006b).

4.2.2.3 Margem suave

Até agora, presumimos que os dados podem ser separados por meio de uma linha reta e que existem dois hiperplanos separadores, H_1 e H_2 , sem dados entre eles, como pode ser observado no item a da Figura 26. É claro que muitos conjuntos de dados reais

não podem ser separados de forma tão clara, em vez disso, eles se parecem com o item b da Figura 26, onde o conjunto de dados contém um “erro”.

Figura 26 – Representação de tipos de dados de SVM.



Fonte: Adaptado de Noble (2006b).

Intuitivamente, seria interessante que o SVM fosse capaz de lidar com erros nos dados, permitindo que alguns perfis de expressão anômalos caíssem no “lado errado” do hiperplano de separação. Para lidar com casos como estes, o algoritmo SVM deve ser modificado adicionando uma ‘margem suave’. Essencialmente, isso permite que alguns pontos de dados atravessem a margem do hiperplano de separação sem afetar o resultado final. O item c da Figura 26 apresenta a solução de margem suave para o problema do item a. O único valor discrepante reside no mesmo lado da linha com membros da classe oposta. É claro que não se deseja que o SVM permita muitos erros de classificação. Conseqüentemente, a introdução da margem suave exige a introdução de um parâmetro especificado pelo usuário que controla, aproximadamente, quantos exemplos podem violar o hiperplano de separação e até onde eles podem atravessar a linha. A definição deste parâmetro é complicada pelo fato de que ainda se objetiva tentar obter uma grande margem em relação aos exemplos corretamente classificados. Conseqüentemente, o parâmetro de margem suave especifica uma compensação entre as violações do hiperplano e o tamanho da margem (NOBLE, 2006b).

Em situações reais, é difícil encontrar aplicações cujos dados sejam linearmente separáveis. Isso se deve a diversos fatores, entre eles a presença de ruídos e *outliers* (valores que se diferenciam drasticamente da normalidade das amostras e que podem causar anormalidade nos resultados) nos dados ou à própria natureza do problema, que pode ser não linear. Para o entendimento dos sistemas não lineares, as SVMs lineares de margens rígidas são estendidas para lidar com conjuntos de treinamento mais gerais. Isso é feito com a introdução de variáveis de folga η_i , para todo $i = 1, \dots, n$. Essas variáveis relaxam as restrições impostas ao problema de otimização. A inequação do SVM é dada por:

$$y_i(w \cdot x_i + b) > 1 - \xi_i, \quad \xi_i > 0, \quad \forall i = 1, \dots, n \quad (4.5)$$

Em que y_i é o rótulo da classe do ponto de dados i , $w \cdot x_i + b$ é o produto escalar entre o vetor de pesos, w é o vetor de características, x_i mais o termo de polarização b e ξ_i é a variável de folga associada ao ponto de dados i . Esta inequação é uma restrição do problema de otimização quadrática do SVM. A aplicação desse procedimento suaviza as margens do classificador linear, permitindo que alguns dados permaneçam entre os hiperplanos H_1 e H_2 que ocorram alguns erros de classificação. Por esse motivo, as SVMs obtidas neste caso também podem ser referenciadas como SVMs com margens suaves.

4.2.2.4 Kernel

As técnicas SVMs evoluíram muito nos últimos anos, dando origem a um novo tipo de máquinas de aprendizagem que utilizam o conceito central de SVMs por meio de uma poderosa ferramenta, o kernel, utilizada em uma série de tarefas de aprendizagem. As máquinas kernel fornecem uma estrutura modular que pode ser adaptada a diferentes tarefas e domínios usando diferentes funções do kernel como lineares, polinomiais, sigmóides ou radiais, juntamente com o algoritmo base (ANTÓN et al., 2013).

Os Kernels são funções matemáticas que possibilitam o mapeamento dos dados originais para espaços de características de maior dimensão, em que a separação entre as classes é facilitada, especialmente em situações em que a separação linear não é viável no espaço original (SMITS; JORDAAN, 2002).

Em essência, a função kernel, $K(\mathbf{x}_i, \mathbf{x}_j)$, é um artifício matemático que permite ao SVM realizar uma classificação “bidimensional” de um conjunto de dados originalmente unidimensional. Em geral, uma função kernel projeta dados de um espaço de baixa dimensão para um espaço de dimensão superior encontrando fronteiras de decisão mais complexas (NOBLE, 2006b). Um Kernel é uma função que recebe dois pontos x_i e x_j do espaço de entradas e computa o produto escalar desses dados no espaço de característica (HERBRICH, 2001):

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (4.6)$$


Em resumo, o truque do kernel permite a aplicação eficiente de funções de mapeamento para espaços de características de alta dimensão, melhorando a eficiência de algoritmos que dependem apenas dos produtos escalares nesses espaços. O kernel é a medida da similaridade ou sobreposição entre os pontos \mathbf{x}_i e \mathbf{x}_j no espaço de características elevado.

4.3 Redes Neurais Artificiais

Uma das técnicas de Aprendizado de Máquina que tem tido sucesso em resolver muitos problemas são as Redes Neurais Artificiais (RNA). RNA são modelos matemáticos que se inspiram nas estruturas neurais biológicas e que têm a capacidade computacional adquirida por meio de aprendizado. O processamento da informação em RNA é feito nos neurônios artificiais, conhecidos como neurônio McCulloch e Pitts (ou modelo MCP) (LUDERMIR, 2021).

A arquitetura básica de uma RNA é dividida em 3 camadas: camada de entrada, camada oculta e camada de saída, como pode ser observado na Figura 27. A camada de entrada é a primeira camada de uma rede neural artificial que recebe as informações de entrada nas formas mais variadas, como textos, números, áudio e imagem. Após a camada de entrada, os dados são direcionados para uma ou várias camadas ocultas, onde são executados vários tipos de cálculos e reconhecimento de padrões desses dados. Cada camada oculta analisa o resultado da camada anterior, processa-o mais um pouco e o encaminha para a próxima camada. Na camada de saída obtêm-se os cálculos realizados nas camadas ocultas (FREITAS; HORA, 2020).

Figura 27 – Representação da estrutura de RNA utilizada na estimação de SoC de LIBs



Fonte: Adaptado de Li et al. (2020).

RNA é um grupo de múltiplos perceptrons (neurônios matemáticos) em cada camada que são processadas apenas na direção direta. Eles passam informações em uma direção, através de vários nós de entrada, até que cheguem ao nó de saída. A rede pode ou não ter camadas de nós ocultas, tornando seu funcionamento mais interpretável e possui as vantagens de armazenar informações em toda a rede e possuir tolerância à falhas (DENG; YU, 2014).

A camada de saída fornece o resultado final de todos os dados processados pela rede neural artificial. Ela pode ter um ou vários nós. Por exemplo, se tivermos um problema de classificação binária (sim/não), a camada de saída terá um nó de saída, o que fornecerá o

resultado como 1 ou 0. Porém, se tivermos um problema de classificação de várias classes, a camada de saída poderá ter mais de um nó de saída.

A arquitetura da rede é uma parte importante de seu design, e o número e tipo de camadas, bem como o número de neurônios em cada camada, podem afetar o desempenho da rede. Além disso, as camadas ocultas podem ser adicionadas ou removidas para melhorar o desempenho da rede (LECUN; BENGIO; HINTON, 2015).

Os três principais tipos de RNA são *feedforward*, *backpropagation* e convolucionais. Em uma rede *feedforward*, cada camada se conecta à próxima camada, mas o processamento de dados é unidirecional do nó de entrada para o nó de saída, não há caminho de volta (RUELA, 2012). Dentre os principais tipos de redes *feedforward*, destaca-se o *multilayer perceptron* (MLP). Redes MLP consistem de uma única camada de nós de saída, que são alimentados diretamente por uma camada de entrada através de um conjunto de pesos. Redes MLP consistem em múltiplas camadas: uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Cada camada possui nós e cada nó está totalmente interligado por pesos com todos os nós da camada subsequente (TISSOT; CAMARGO; POZO, 2012).

O método *backpropagation* é um procedimento de aprendizagem para redes *feedforward* MLP. Basicamente o procedimento de aprendizagem utiliza vetores que mapeiam um conjunto de entradas para um conjunto de saídas. O aprendizado é realizado por ajuste iterativo dos pesos da rede para minimizar as diferenças entre a saída atual e a saída desejada (TISSOT; CAMARGO; POZO, 2012).

Na RNA, cada nó tem um palpite sobre o próximo nó do caminho. Ele verifica se o palpite estava correto. Os nós atribuem valores mais altos aos caminhos que levam a palpites mais precisos e valores de peso mais baixo para os caminhos do nó que levam a palpites incorretos. Para o próximo ponto de dados, os nós fazem uma nova previsão usando caminhos de peso mais alto e, em seguida, repetem a etapa 1.

Métodos de estimação de SoC de baterias de Li-ion baseados em RNA têm sido utilizados na estimação do SoC, bem como na estimativa de parâmetros de corrente e temperatura. Esses métodos podem ser aplicados nas baterias comerciais utilizadas atualmente e apresentam um excelente desempenho nesse tipo de aplicação não linear (LIU et al., 2022b).

No entanto, a estimativa de SoC por Redes Neurais Artificiais é extremamente dependente de um conjunto de dados robusto o suficiente para representar possíveis condições de operação. No caso em que as condições de operação do sistema diferem do conjunto de dados de treinamento, a rede neural artificial geralmente apresenta erros

relevantes. A lógica difusa, por outro lado, depende da arquitetura construída por um especialista humano naquele domínio específico. Se a arquitetura não possui uma vasta base de conhecimento sobre o domínio do problema, o sistema tende a apresentar erros.

O método RNA considera características de comportamento não lineares e melhora gradualmente a precisão por meio dos dados coletados. Ele só precisa de dados de bateria em vez de depender de modelos de bateria e estruturas eletroquímicas. Tem sido amplamente utilizado para estimar o status da bateria recentemente (SUN; TSAI, 2022).

A implementação de RNA na estimação de SoC de LIBs pode ser realizada de algumas formas utilizando ferramentas computacionais como matlab e linguagens de programação. A aplicação de *Machine learning* na estimação do SoC de baterias de Li-ion consiste em três etapas: pré-processamento de dados, treinamento e estimativa.

4.4 Aprendizado de máquina utilizando *Python*

Python é uma linguagem de programação de alto nível com grande capacidade de processamento de dados e com alta capacidade de aprendizado. Trata-se de uma linguagem interpretada e seus recursos podem ser utilizados por meio de diversas bibliotecas que podem ser empregadas em diversos tipos de aplicações, como para resolver problemas matemáticos, para resolver problemas de interpretação gráfica, assim como na classificação e estimação. Sua execução pode ser feita em qualquer ambiente que possua interpretador instalado ou até mesmo online (TRAN et al., 2022).

Para realizar as simulações em *Python*, pode-se utilizar a biblioteca *scikit-learn*, pois oferece recursos eficientes no suporte ao aprendizado supervisionado. Essa biblioteca é baseada na interação com outras bibliotecas *Python*, numéricas e científicas, como *Pandas*, *NumPy*, *Matplotlib* e *Tensorflow*.

4.4.1 *Scikit-learn*

Scikit-learn, popularmente chamado de *sklearn*, é o pacote de aprendizado de máquina mais abrangente e de código aberto em *Python*. Beneficiando-se da ampla gama de aplicabilidade do *Python*, essa biblioteca se torna um pacote cada vez mais popular para aplicações relacionadas ao aprendizado de máquina. O *sklearn* possui muitos recursos que o diferenciam entre os softwares de aprendizado de máquina. A primeira é a cobertura abrangente dos métodos de aprendizado de máquina. Existe um procedimento de revisão da comunidade para identificar e decidir quais métodos de aprendizado de máquina devem ser incluídos no pacote *sklearn*. Tal mecanismo garante um equilíbrio entre a ampla cobertura e a seletividade dos métodos de aprendizado de máquina contidos no

pacote. A segunda é que a implementação do algoritmo dos métodos de aprendizado de máquina no *sklearn* é otimizada para eficiência computacional. Apesar de Python ser uma linguagem de programação interpretada, a maioria dos métodos de aprendizado de máquina no *sklearn* foram baseados em bibliotecas binárias compiladas que foram originalmente programadas em Fortran, C ou C++. Essas implementações baseadas em binário melhoram significativamente a eficiência da computação. A terceira é que o *sklearn* tem forte suporte da comunidade para documentação, rastreamento de bugs e garantia de qualidade. Por último, mas não menos importante, o *sklearn* impõe uma convenção unificada de dados de entrada/saída e possui um procedimento fixo de ajuste de modelo, tornando a mudança de um método para outro quase sem esforço. Em resumo, o *sklearn* inclui uma coleção de métodos de aprendizado de máquina implementados de forma eficiente e é bem documentado e mantido pela comunidade (KRAMER; KRAMER, 2016).

O pacote *Scikit-learn* cobre quatro tópicos principais relacionados ao aprendizado de máquina. Eles são transformação de dados, aprendizagem supervisionada, aprendizagem não supervisionada e avaliação e seleção de modelos (KRAMER, 2016).

O *Scikit-learn* possui muitos recursos, como análise de algoritmos de aprendizado supervisionado: partindo de modelos lineares generalizados (por exemplo, regressão linear), SVM, árvores de decisão e métodos baseados no teorema de Bayes, realiza diversos exames; validação cruzada: Existem vários métodos para verificar a precisão de modelos supervisionados em dados não vistos usando esta biblioteca; algoritmos de aprendizado não supervisionado: há uma grande variedade de algoritmos de aprendizado de máquina, começando com agrupamento, análise de fator, análise de componente principal e redes neurais não supervisionadas; extração de recursos: ferramentas desta biblioteca são capazes de extrair recursos de imagens e texto. (MODESTI, 2020).

4.4.2 *Pandas*

Pandas, é uma biblioteca de software escrita para a linguagem de programação *Python* para manipulação e análise de dados. Em particular, oferece estruturas de dados e operações para manipular tabelas numéricas e séries temporais (PANDAS, 2018). O *Pandas* disponibiliza estruturas de dados e ferramentas para tratar algoritmos que foram idealizados para facilitar o processo de tratamento e análise de informações utilizando a linguagem *Python*. No caso de bibliotecas de análise como *scikit-learn*, o *Pandas* também estará atuante no fornecimento de informações (MODESTI, 2020).

4.4.3 *NumPy*

NumPy, é uma biblioteca *Python* que é usada principalmente para realizar cálculos em matrizes multidimensionais. O *NumPy* fornece um grande conjunto de funções e operações de biblioteca que ajudam os programadores a executar facilmente diversos cálculos numéricos (NUMPY, 2019).

O pacote fornece um objeto de matriz multidimensional de alto desempenho e ferramentas para trabalhar com essas matrizes. É o pacote fundamental para computação científica com *Python*. Além de seus usos científicos óbvios, o *NumPy* também pode ser usado como um contêiner multidimensional eficiente de dados genéricos (MODESTI, 2020).

Matriz em *NumPy* é uma tabela de elementos (geralmente números), todos do mesmo tipo, indexados por uma lista de inteiros positivos. Em *NumPy*, o número de dimensões da matriz é chamado de classificação da matriz (NUMPY, 2019). Podem ser criadas matrizes utilizando a biblioteca *NumPy* de várias maneiras, como por exemplo a partir de listas dados. O tipo de matriz resultante é deduzido do tipo dos elementos nas sequências. Porém para apresentar o resultado de funções e operações entre matrizes é preciso seguir regras e neste contexto utiliza-se a ferramenta *Tensorflow* (NUMPY, 2019).

4.4.4 *Matplotlib*

Matplotlib é uma biblioteca de funções gráficas de visualização de dados em *Python* que possibilita a criação de gráficos estáticos, interativos e dinâmicos com qualidade de publicação. É um dos meios de visualizações de dados mais usadas em bibliotecas de *Python*. *Matplotlib* é uma biblioteca gráfica para pacote de visualização de dados em *Python* que abrange como um aspecto integral na pilha de ciência de dados *Python* e é facilmente suportada com *NumPy*, *Pandas* e outras bibliotecas relevantes (SIAL; RASHDI; KHAN, 2021).

4.4.5 *Tensorflow*

Tensorflow (TF) é uma biblioteca de computação numérica especializada para aprendizado profundo. É a ferramenta preferida por vários pesquisadores de aprendizagem profunda e profissionais da indústria para desenvolver modelos e arquiteturas de aprendizagem profunda, bem como para servir modelos aprendidos em servidores de produção e produtos de software (CHEMALI et al., 2018).

Tensorflow é uma biblioteca de software de código aberto para computação numérica usando grafos computacionais. Foi originalmente desenvolvido pelo Google Brain Team na organização de pesquisa Machine Intelligence do Google para aprendizado de máquina e

pesquisa de redes neurais profundas (*Deep Learning*). Mas esta biblioteca é abrangente o suficiente para ser aplicada em uma grande variedade de outros domínios também. Foi disponibilizada como open-source em 2015 e alcançou a versão 1.0 em 2017, com um desenvolvimento e adoção incrivelmente rápidos e muitos colaboradores externos. O *TensorFlow* vem se tornando a biblioteca padrão para desenvolvimento em aprendizagem profunda e outras aplicações de AI (MODESTI, 2020)

Com o avanço na área de redes neurais e ML houve também um aprimoramento de *frameworks* (abstração que une códigos comuns entre softwares) e interface de programação de aplicação (*Application Programming Interface* – API) que implementam redes cada vez mais complexas de aprendizado em um nível superior de programação, exigindo menos código e menos conhecimento para a implementação de algoritmos preditivos, por exemplo (TENSORFLOW, 2019).

A ferramenta explorada neste trabalho foi o *TensorFlow*, uma API de código aberto em *Python* da Google (TENSORFLOW, 2019). A mesma já apresenta as principais ferramentas de redes neurais (LSTM, manipulação de dados) implementadas, sendo chamadas por meio de funções prontas, além de criar códigos portáteis entre diferentes sistemas (MODESTI, 2020).

Em suma, a exploração do aprendizado de máquina por meio de sistemas supervisionados e por meio de RNA proporciona uma visão abrangente da aplicação dessas metodologias na estimação de sistemas não lineares, como na estimação de SoC de baterias de lítio. Mediante a utilização de ferramentas como *Scikit-learn*, *Pandas*, *NumPy*, *Matplotlib* e *Tensorflow*, destaca-se a importância da utilização de bibliotecas para facilitar o desenvolvimento de modelos. No próximo capítulo, realizaremos uma introdução dos dados utilizamos como *input* nas simulações e serão apresentados os resultados das estimativas de cada método a fim de avaliar qualitativamente as metodologias.

5 | Resultados e análises

Neste capítulo, são apresentados os dados de entrada utilizados nas simulações de estimações de SoC, os resultados obtidos das simulações utilizando todas metodologias de estimacão de SoC estudadas nesse trabalho, e compara-os levando em consideracão o erro médio absoluto (do inglês, *Mean Absolute Error* - MAE) e a raiz do erro médio quadrático (do inglês, *Root Mean Square Error* - RMSE) encontrados entre os dados de entrada e os estimados. Estimou-se o SoC referente a ciclos de trabalho de todos os meses de coleta de dados, que correspondem a novembro e dezembro de 2019 e a janeiro, junho, julho, agosto, setembro e outubro de 2020.

5.1 Dados de entrada das simulações

Neste trabalho, utilizou-se como entrada, dados disponibilizados pela Universidade de Stanford (POZZATO et al., 2023) em parceria com a Volkswagen. Os dados foram coletados pelo BMS do veículo Audi e-tron, um SUV elétrico de tamanho médio, via rede CAN com amostragem de aproximadamente 10 ms. O objetivo do estudo foi entender o comportamento do SoH da bateria para poder desenvolver algoritmos de estimacão e previsão, pois os algoritmos de estimativa de SoH, assim como algoritmos de estimativa de SoC, são projetados e treinados a partir de dados coletados em laboratório durante o ciclo de células sob condições de carga e temperaturas predefinidas. A metodologia desenvolvida foi diferente das usuais, uma vez que utilizou-se dados de campo e o SoH foi avaliado por meio de indicadores de desempenho online na forma de resistência durante a condução e na forma de impedância durante o carregamento. A análise realizada mostra que a temperatura depende da sazonalidade e afeta fortemente os indicadores, além de revelar a fragilidade dos dados coletados em testes laboratoriais a temperatura constante no desenvolvimento de estimadores robustos de SoH.


Os dados fornecidos referem-se a dados de ciclos de trabalho coletados entre novembro de 2019 e outubro de 2020, com cerca de 3750 horas de duração. Foram

fornecidos dados de tensão, corrente, temperatura e SoC durante as cargas (modo de carregamento) e descargas (modo de condução) da bateria do veículo elétrico.

Dentre as 3750 horas de dados, destaca-se que 91% desse período refere-se a períodos ociosos (*idle time*), nos quais o veículo encontrava-se parado. Adicionalmente, em 7% do tempo o veículo estava em carregamento e em 2% o veículo encontrava-se no modo de condução. Os dados são cíclicos, iniciando com carregamento do veículo, na sequência descarregamento, e assim continuam. Os 9% do tempo com o veículo funcionando, excluindo o tempo ocioso, representam 337,5 horas, dentre as quais, 59,7 horas foram utilizadas como dados de entrada para cada método de estimação de SoC por meio de ML. As 59,7 horas se referem a 8 ciclos de recarga da bateria e 8 ciclos de descarga. A justificativa para escolha dessas quase 60 horas específicas é devido a maior continuidade nos dados, pois durante a coleta de dados, o veículo não funcionou continuamente até o SoC ficar próximo de zero, pois houveram várias pausas. Dessa forma, foram escolhidas as amostras que possuem mais informações em menos tempo.

Um trecho do perfil de corrente elétrica e tensão versus tempo pode ser observado na Figura 28. Observa-se que a corrente elétrica fornecida pela bateria ultrapassa 800 A na descarga e -500 A na regeneração, o que representam C-rates de 3,3C e 2C, respectivamente. Arelado aos picos de corrente, há deltas de tensão momentâneos associados devido às resistências internas da bateria.

Figura 28 – Representação da tensão e corrente elétrica do veículo e-tron em um ciclo de trabalho.



Fonte: Próprio Autor.

A bateria do e-tron, ilustrada na Figura 1, possui NCA no seu eletrodo positivo, com energia de 95 kWh, composta por 36 módulos conectados em série, cada módulo contém 12 células que possuem capacidade nominal de 60 Ah com uma topologia elétrica 4P3S (3 conjuntos em série com 4 células em paralelo, cada). A tensão nominal da bateria é 396 V. As características da célula dessa bateria estão detalhadas na Tabela 3.

Tabela 3 – Detalhes da célula comercial *pouch* LGX N2.1 60AH da LG Chem

Especificações	Valores
Fabricante	LG Chem
Modelo	LGX N2.1
Capacidade nominal da célula	60 Ah
Tensão nominal	3,67
Energia nominal	209,907 Wh
Dimensões	16,5X100X330 mm
Volume	0,5445 L
Peso	820 g
Densidade volumétrica	403 Wh/L
Densidade gravimétrica	268 Wh/kg
Química	NMC 622

Fonte: Próprio autor.

Devido à relação não linear entre a OCV e a temperatura, é racional supor que deve existir uma curva OCV para cada temperatura, entretanto, essa observação pode ser dispensada no nosso caso porque o banco de dados utilizado nesse trabalho é extenso e leva em consideração todas as possíveis temperaturas que a bateria pode estar submetida, pois o sistema de resfriamento da bateria trabalha para manter a temperatura da bateria fixa na melhor condição de operação.

Diferentes temperaturas ambientes podem ser consideradas perturbações do sistema, mas assim como essa variável, a influência da temperatura devido a corrente elétrica da condição de operação da bateria também influencia na manutenção da temperatura. Essas variações são levadas em conta pelo sistema de resfriamento que tenta otimizar seu consumo energético e ao mesmo tempo resfriar a bateria da forma mais eficiente.

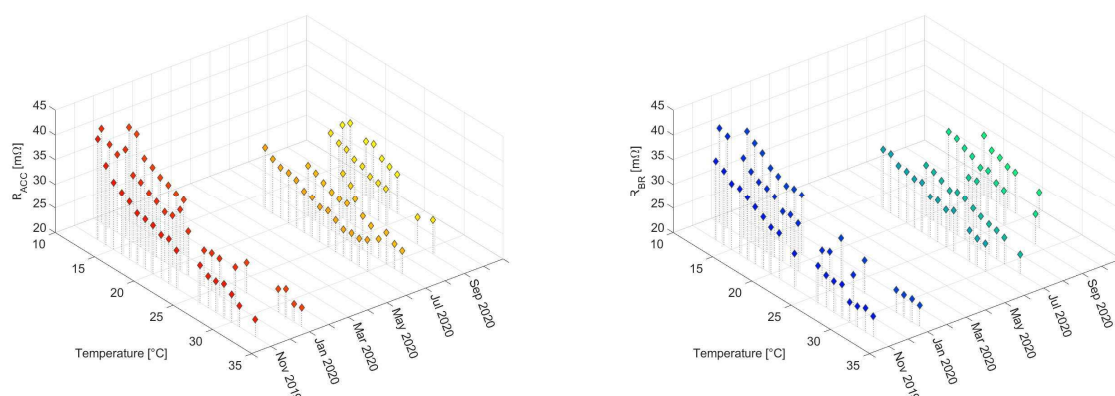
5.1.1 Modelagem da bateria do e-tron

Conforme detalhado no capítulo 3, as 4 etapas para estimação dos parâmetros do circuito equivalente são: carregamento e pré-processamento dos dados; determinação do número de pares RC do circuito equivalente; estimação dos parâmetros e definição dos parâmetros de bloco de bateria de circuito equivalente. Esses passos ajudam a determinar os valores de R_0 e R_1 da bateria.

Nos dados disponibilizados pela universidade de Stanford, o decaimento da tensão nos pulsos de corrente nos momentos de aceleração do veículo foram analisados para estimação dos valores da resistência interna e da resistência do par de RC do sistema. Os valores obtidos ao longo do período de teste podem ser observados na Figura 29. R_{ACC} , à esquerda, é a resistência interna da bateria e R_{BR} , à direita, do par RC do circuito elétrico

equivalente.

Figura 29 – Valores das resistências obtidos da bateria.



Fonte: Editado de Pozzato et al. (2023).

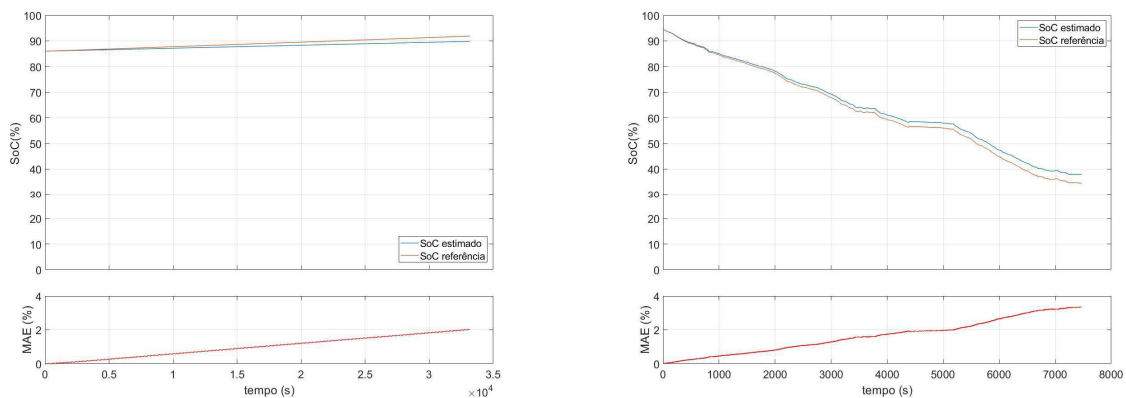
Devido a simplicidade dos usos dos dados disponibilizados, optou-se por utilizar um ECM com um par de RC para modelar a bateria do e-tron. Essa escolha implica na análise da relação direta entre os pulsos de corrente e a resposta característica de um circuito com comportamento capacitivo, pois para uso do ECM com mais de um par de RC seria necessário realizar uma análise matemática mais profunda, porque não consegue-se distinguir as influências de cada par de RC na curva da resposta ao degrau. Dessa forma, inseriu-se esses dados no Matlab para simulação do método EKF.

Teoricamente, baseado na seção 2.9, seria necessário um ECM para cada valor de temperatura da bateria, haja vista que a sazonalidade impacta diretamente no valor da temperatura ambiente, entretanto, para fins de análise e de simplificação do modelo, verificou-se a média móvel das resistências em função da temperatura para definir os parâmetros no ECM.

5.2 Simulações de modelos por meio de *Coulomb Counting*


Os resultados obtidos utilizando o método de estimação *Coulomb Counting* considerando a taxa de amostragem de 0,01 s, podem ser observados nas Figuras 30, 31, 32, 33, 34, 35, 36 e 37 para os modos de condução e de carregamento. À esquerda de cada figura está representado as estimações para o modo de carregamento, e à direita, as estimações para o modo de condução do veículo, essa distribuição deve-se ao sequenciamento do descarregamento após o carregamento do veículo. Na parte inferior de cada imagem observa-se o erro médio absoluto entre o SoC referência e o SoC estimado.

Figura 30 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de novembro de 2019.




Fonte: Próprio autor.

Figura 31 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de dezembro de 2019.



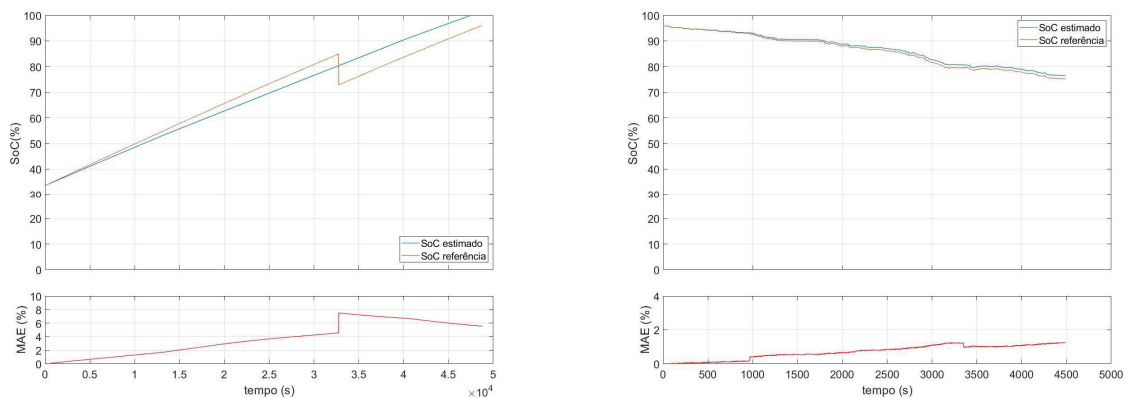
Fonte: Próprio autor.

Figura 32 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de janeiro de 2020.




Fonte: Próprio autor.

Figura 33 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de junho de 2020.



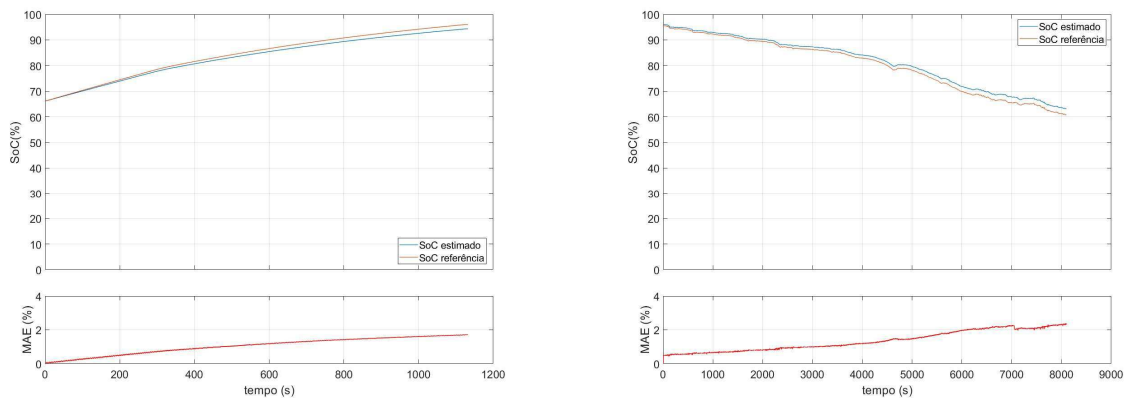
Fonte: Próprio autor.

Figura 34 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de julho de 2020.




Fonte: Próprio autor.

Figura 35 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de agosto de 2020.



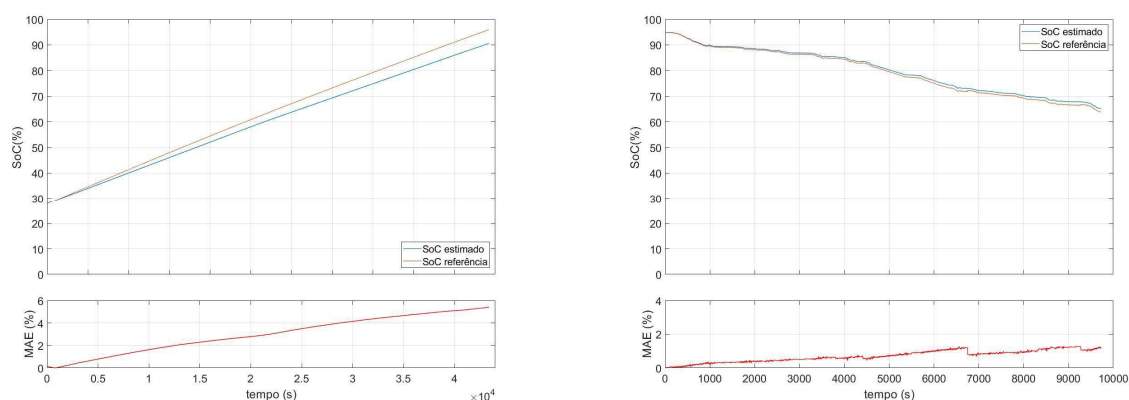
Fonte: Próprio autor.

Figura 36 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de setembro de 2020.



Fonte: Próprio autor.

Figura 37 – Estimação do SoC por meio de *Coulomb Counting* com dados do mês de outubro de 2020.



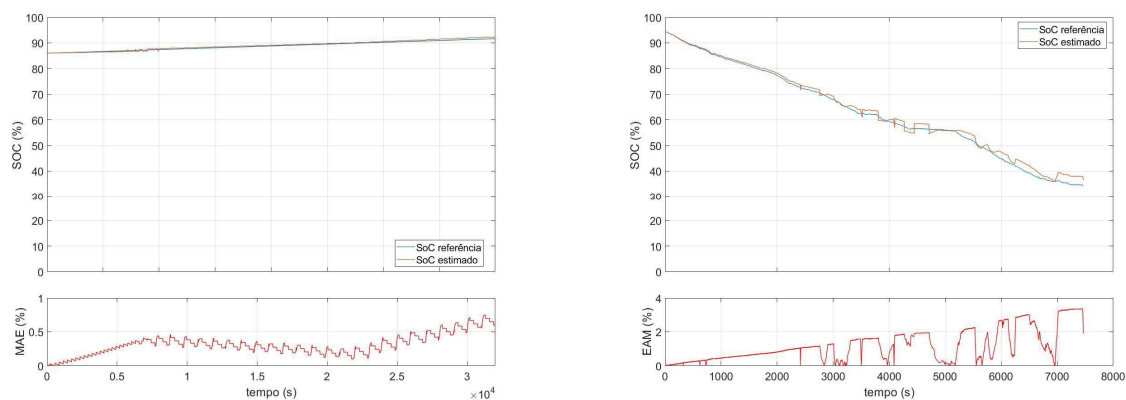
Fonte: Próprio autor.

A partir das simulações, observa-se o acúmulo do erro entre o SoC referência e SoC estimados ao longo dos ciclos de operação do veículo. Após as 59,7 horas de operação, o erro acumulado é de +17,7% em relação ao SoC referência. Erros de estimação dessa magnitude são inaceitáveis devido à imprecisão apresentada, pois um erro de 1% em um sistema de malha aberta já causa problemas.

5.3 Simulações de modelos por meio de filtros de Kalman Extendido

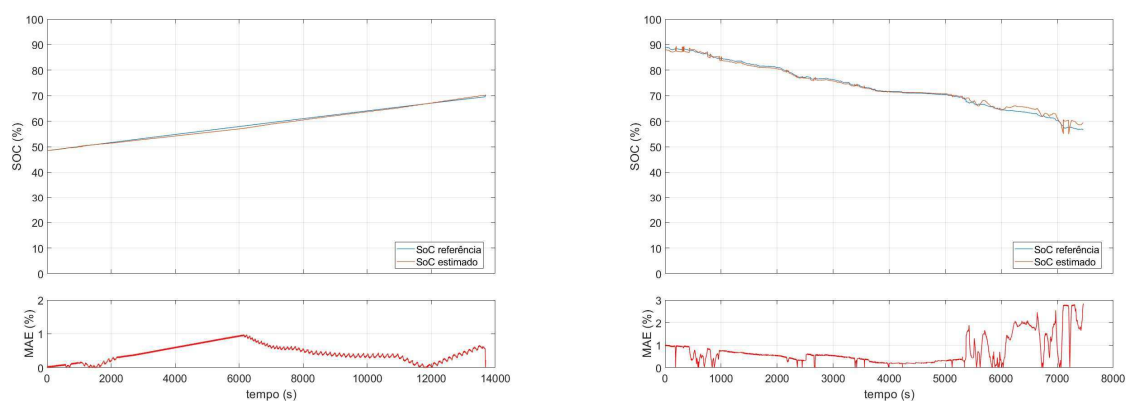
As estimações de SoC realizadas por meio da metodologia de EKF foram realizadas no Simulink por meio do bloco ilustrado na Figura 20, cujos resultados podem ser observados nas Figuras 38, 39, 40, 41, 42, 43, 44 e 45 para as simulações referentes aos oito meses de coleta de dados.

Figura 38 – Estimação do SoC por meio de EKF utilizando dados do mês de novembro de 2019.



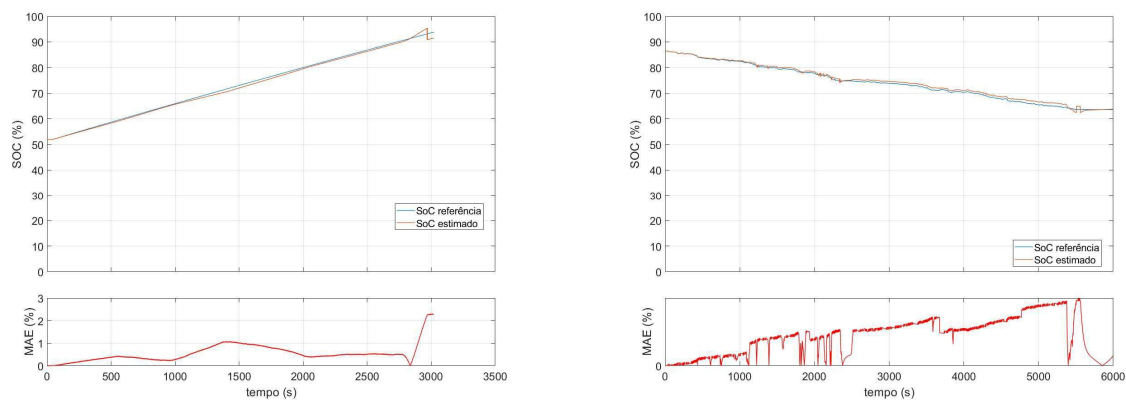
Fonte: Próprio autor.

Figura 39 – Estimação do SoC por meio de EKF utilizando dados do mês de dezembro de 2019.



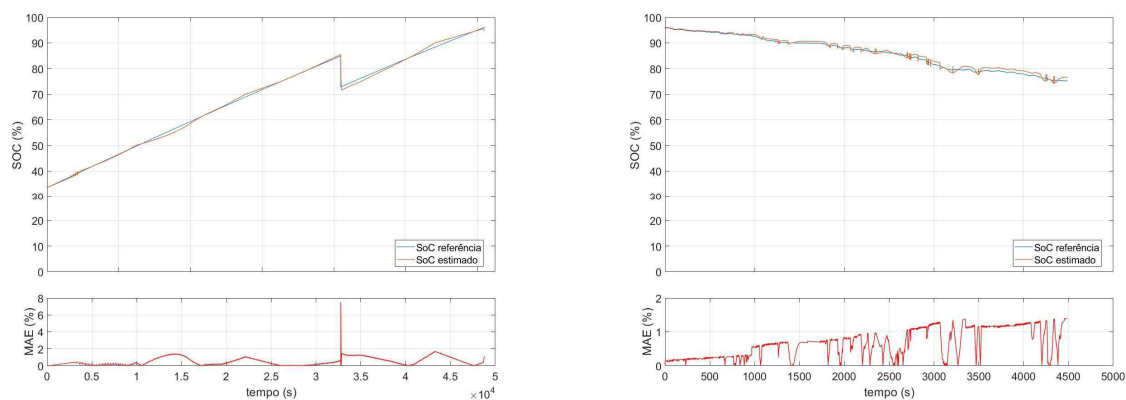
Fonte: Próprio autor.

Figura 40 – Estimação do SoC por meio de EKF utilizando dados do mês de janeiro de 2020.



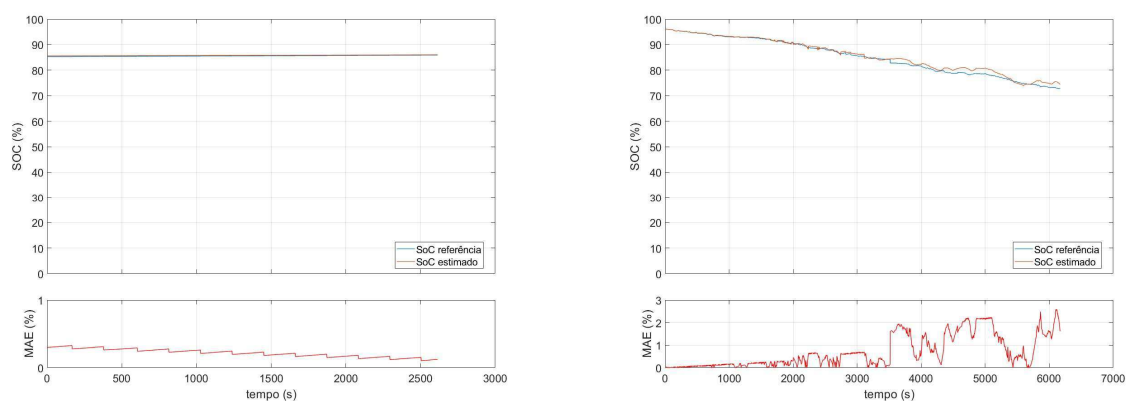
Fonte: Próprio autor.

Figura 41 – Estimação do SoC por meio de EKF utilizando dados do mês de junho de 2020.



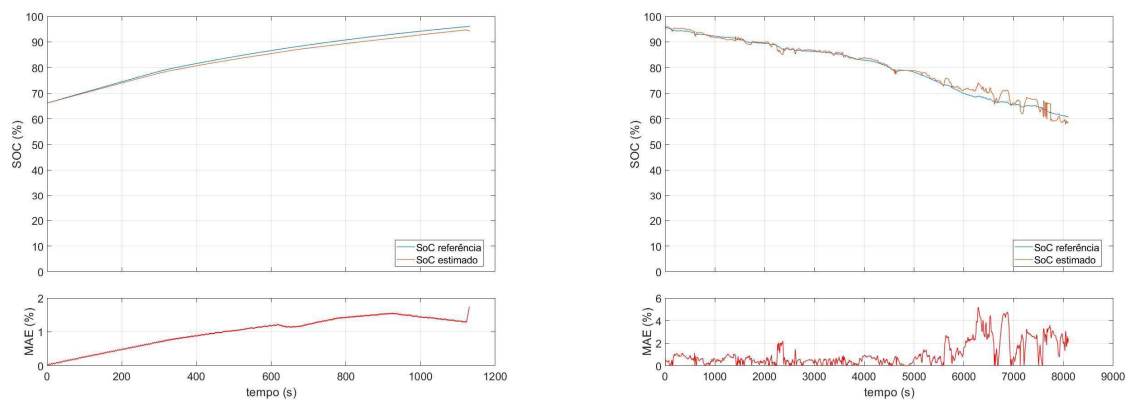
Fonte: Próprio autor.

Figura 42 – Estimação do SoC por meio de EKF utilizando dados do mês de julho de 2020.



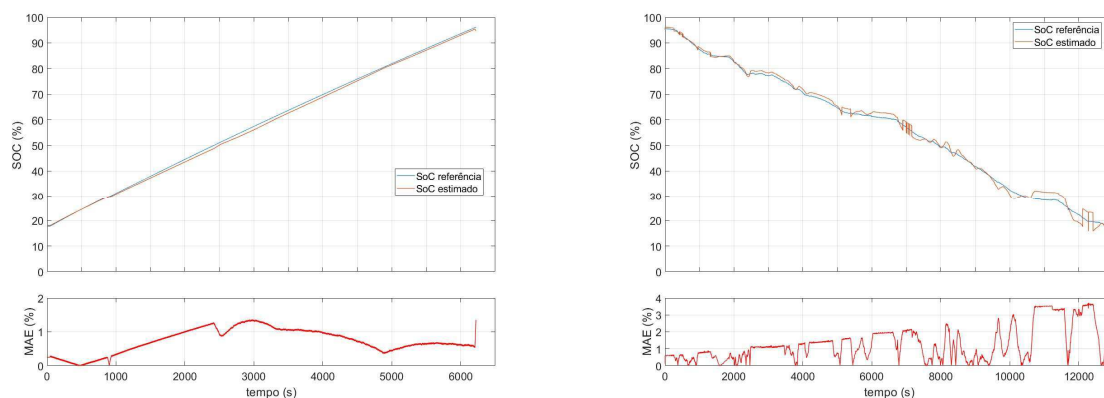
Fonte: Próprio autor.

Figura 43 – Estimação do SoC por meio de EKF utilizando dados do mês de agosto de 2020.



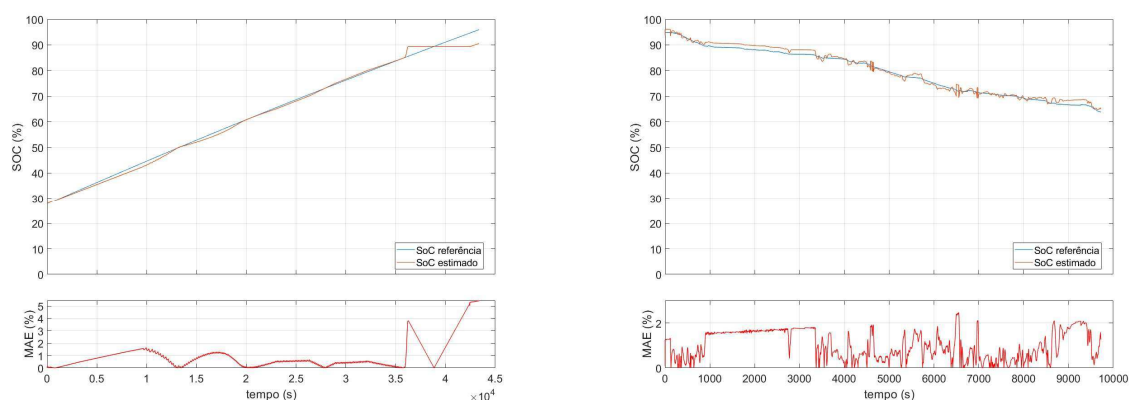
Fonte: Próprio autor.

Figura 44 – Estimação do SoC por meio de EKF utilizando dados do mês de setembro de 2020.



Fonte: Próprio autor.

Figura 45 – Estimação do SoC por meio de EKF utilizando dados do mês de outubro de 2020.



Fonte: Próprio autor.

Utilizou-se SoC inicial de 90% na simulação do modo de condução para observar se a estimação convergia para o valor real e qual seria o tempo necessário para isso. A simulação convergiu em poucos minutos utilizando uma taxa de amostragem de 0,01 s. Os MSA e RMSE obtidos foram 1,30% e 1,55%, respectivamente.

5.4 Simulações de modelos utilizando ML


Para a realização das simulações por meio de *machine learning* utilizando as metodologias DT, RNA e SVM, utilizou-se códigos em Python por meio do compilador *Visual Studio Code* para obter os resultados. Por padrão, utilizou-se 70% dos dados de entrada para treinamento e 30% dos dados de entrada para teste. Os ciclos de trabalho em formatos de arquivos excel com extensão csv foram importados para o compilador com

os dados de tempo, temperatura, corrente, tensão e SoC referência.

5.4.1 Simulações utilizando árvores de decisão


Os resultados obtidos para a estimação de SoC para o *driving mode* e para o *charging mode* por meio de DT podem ser observados nas Figuras 46, 47, 48, 49, 50, 51, 52 e 53. À esquerda de cada figura está representado as estimações para o modo de carregamento, e à direita as estimações para o modo de condução, essa distribuição deve-se ao sequenciamento do descarregamento após o carregamento do veículo. Na parte inferior de cada imagem observa-se o erro médio absoluto entre o SoC referência e o SoC estimado. Nas simulações foram utilizadas algumas dezenas de milhares de folhas de decisão e também algumas dezenas de milhares de ramos nas árvores de decisão. Essas quantidades não são predefinidas, porque o método verifica qual a melhor combinação de ramos e folhas que resultam em um menor erro absoluto.

Figura 46 – Estimação do SoC por meio de DT com dados do mês de novembro de 2019.




Fonte: Proprio autor.

Figura 47 – Estimação do SoC por meio de DT com dados do mês de dezembro de 2019.




Fonte: Proprio autor.

Figura 48 – Estimação do SoC por meio de DT com dados do mês de janeiro de 2020.



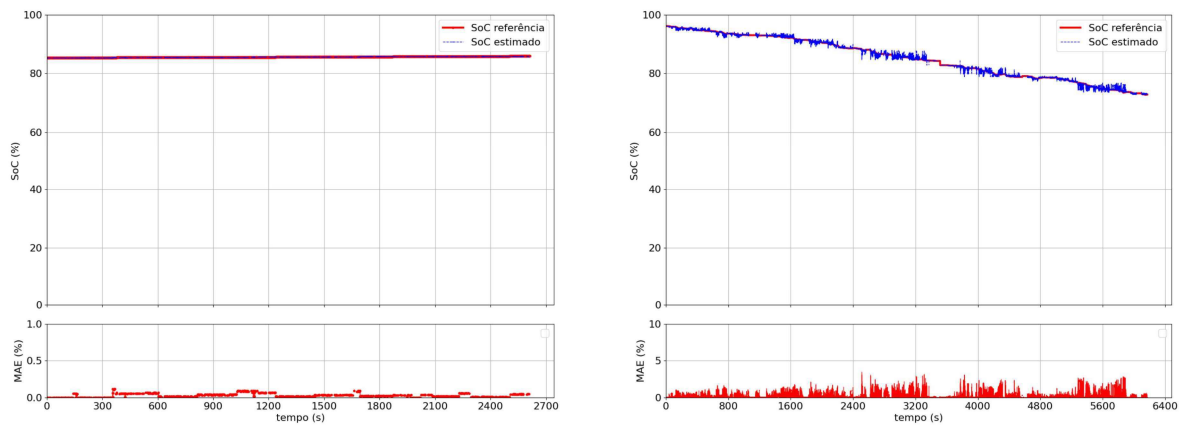
Fonte: Proprio autor.

Figura 49 – Estimação do SoC por meio de DT com dados do mês de junho de 2020.




Fonte: Proprio autor.

Figura 50 – Estimação do SoC por meio de DT utilizando dados do mês de julho de 2020.




Fonte: Proprio autor.

Figura 51 – Estimação do SoC por meio de DT utilizando dados do mês de agosto de 2020.




Fonte: Proprio autor.

Figura 52 – Estimação do SoC por meio de DT utilizando dados do mês de setembro de 2020.



Fonte: Proprio autor.

Figura 53 – Estimação do SoC por meio de DT utilizando dados do mês de outubro de 2020.




Fonte: Proprio autor.

A metodologia demonstra robustez na estimação, uma vez que os valores estimados se distanciam muito pouco dos valores de referência. Os MAEs obtidos entre valores referência e valores estimados foram 0,56% de 0,13% para os modos de carregamento e de condução, respectivamente. Observa-se que os maiores erros absolutos obtidos na simulação são referentes aos afundamentos de tensão no momento em que houve elevação abrupta da corrente elétrica em momentos que o motorista acelerou o veículo. Entretanto, a metodologia não está se adaptando às mudanças abruptas de temperatura entre os últimos instantes de funcionamento e os instantes em que o veículo é ligado, fazendo com que haja erros absolutos transitórios relativamente altos, mas isso pode ser corrigido de algumas formas via código.

5.4.2 Simulações utilizando RNA


As simulações de RNA foram realizadas utilizando a metodologia *Feedforward*, que é o tipo mais comum de rede neural. A arquitetura específica do modelo é formada por quatro camadas: camada de entrada, camada de saída e duas camadas ocultas. A primeira camada oculta tem 64 unidades (neurônios) e usa a função de ativação ReLU. A segunda camada oculta possui 32 unidades e também utiliza a função de ativação ReLU. Os resultados obtidos para a estimação de SoC para os modos de condução e carregamento por meio de RNA podem ser observados nas Figuras 54, 55, 56, 57, 58, 59, 60 e 61. À esquerda de cada figura está representado as estimções para o modo de carregamento, e à direita as estimções para o modo de condução, essa distribuição deve-se ao sequenciamento do descarregamento após o carregamento do veículo. Na parte inferior de cada imagem observa-se o erro médio absoluto entre o SoC referência e o SoC estimado.

Figura 54 – Estimação do SoC por meio de RNA com dados do mês de novembro de 2019.




Fonte: Proprio autor.

Figura 55 – Estimação do SoC por meio de RNA com dados do mês de dezembro de 2019.




Fonte: Proprio autor.

Figura 56 – Estimação do SoC por meio de RNA com dados do mês de janeiro de 2020.




Fonte: Proprio autor.

Figura 57 – Estimação do SoC por meio de RNA com dados do mês de junho de 2020.




Fonte: Proprio autor.

Figura 58 – Estimação do SoC por meio de RNA com dados do mês de julho de 2020.




Fonte: Proprio autor.

Figura 59 – Estimação do SoC por meio de RNA com dados do mês de agosto de 2020.




Fonte: Proprio autor.

Figura 60 – Estimação do SoC por meio de RNA com dados do mês de setembro de 2020.



Fonte: Proprio autor.

Figura 61 – Estimação do SoC por meio de RNA com dados do mês de outubro de 2020.



Fonte: Proprio autor.

Observa-se que nas simulações por meio de RNA, os erros de estimação de SoC obtidos foram pequenos comparados ao SoC referência, apenas na simulação do mês de agosto houveram erros maiores que 1%, como pode ser observado na Figura 59. Essa variação do erro na estimação do mês de agosto tem como causa as pausas do veículo durante a coleta de dados, que fazia com que a temperatura da bateria baixasse, e a não total adaptabilidade do método para contornar essa situação quando o veículo era inicializado com temperatura diferente antes de ser desligado.


Pode-se observar que a curva do SoC estimado é praticamente a mesma do SoC referência. A média dos MAEs obtidos para os modos de carregamento e condução e dos RMSE também para os modos de carregamento e condução foram 0,20%, 0,07%, 0,30% e 0,08%, respectivamente.

5.4.3 Simulações utilizando SVM

Nessa metodologia, a divisão dos dados de entrada entre treino e teste é uma etapa crítica. Conforme já mencionado, 70% dos dados de entrada são utilizados para treino e os outros 30% dos dados são utilizados para teste. O treinamento do modelo é realizado por meio da biblioteca *sklearn* por meio do objeto do tipo SVR (do inglês, *significa Support Vector Regressor*), que utiliza SVM para atividade de regressão.

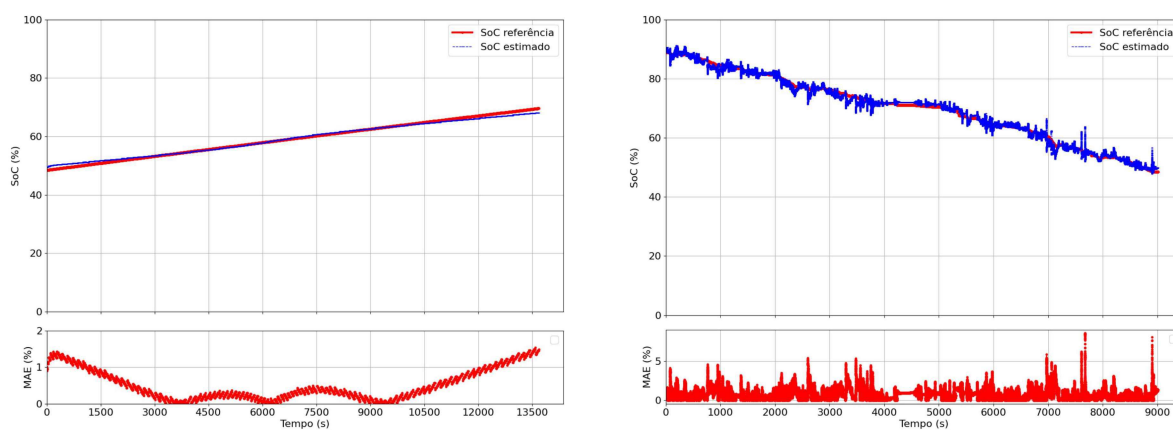
Os resultados obtidos para a estimação de SoC para os modos de condução e carregamento por meio de SVM podem ser observados nas Figuras 62, 63, 64, 65, 67, 68 e 69. À esquerda de cada figura está representado as estimativas para o modo de carregamento, e à direita as estimativas para o modo de condução, essa distribuição deve-se ao sequenciamento do descarregamento após o carregamento do veículo. Na parte inferior de cada imagem observa-se o erro médio absoluto entre o SoC referência e o SoC estimado.

Figura 62 – Estimação do SoC por meio de SVM com dados do mês de novembro de 2019.




Fonte: Proprio autor.

Figura 63 – Estimação do SoC por meio de SVM com dados do mês de dezembro de 2019.




Fonte: Proprio autor.

Figura 64 – Estimação do SoC por meio de SVM com dados do mês de janeiro de 2020.



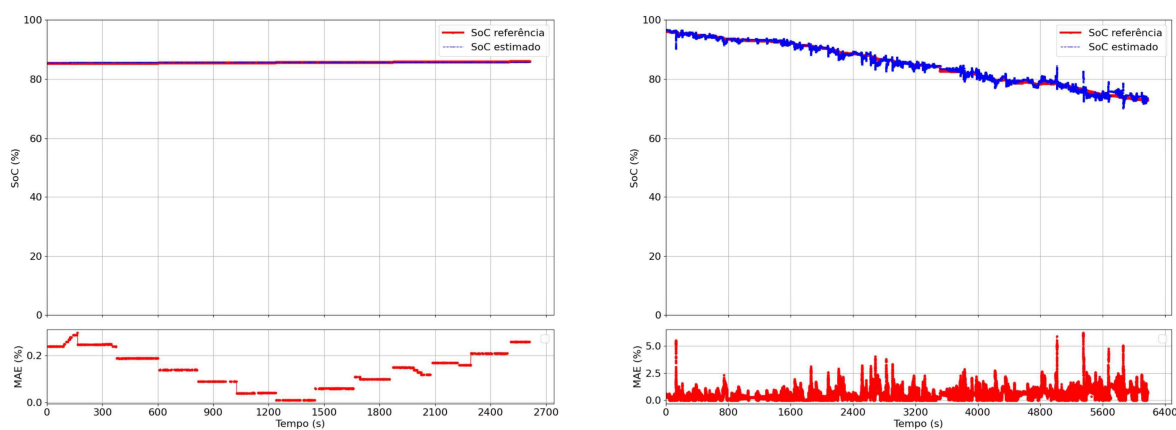
Fonte: Proprio autor.

Figura 65 – Estimação do SoC por meio de SVM com dados do mês de junho de 2020.




Fonte: Proprio autor.

Figura 66 – Estimação do SoC por meio de SVM com dados do mês de julho de 2020.



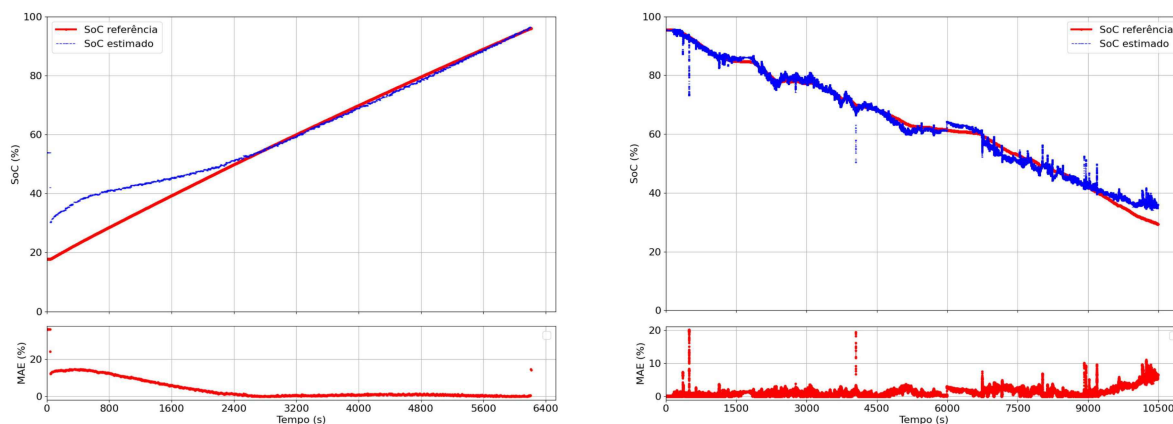
Fonte: Proprio autor.

Figura 67 – Estimação do SoC por meio de SVM com dados do mês de agosto de 2020.




Fonte: Proprio autor.

Figura 68 – Estimação do SoC por meio de SVM com dados do mês de setembro de 2020.



Fonte: Proprio autor.

Figura 69 – Estimação do SoC por meio de SVM com dados do mês de outubro de 2020.



Fonte: Proprio autor.

Baseado nos resultados obtidos para SVM, o MAE médio obtido para o modo de carregamento foi de 1,83% e 0,74% para o modo de condução. O RMSE médio obtido para o modo de carregamento foi de 2,70% e 1,06% para o modo de condução. Observa-se que a metodologia SVM não é tão eficaz quanto outras metodologias de ML. Observa-se também que o SoC inicial nas estimações apresentaram erros consideráveis devido diferentes temperaturas de inicialização. A metodologia teve muita dificuldade em estabilizar os valores estimados, fenômeno esse que se deve ao períodos em que o veículo não estava ligado e teve grande mudança da temperatura da bateria.

5.5 Impacto do envelhecimento da bateria na estimação do SoC

O mudança do SoH impacta no cálculo do SoC ao longo do tempo. A partir do princípio que a capacidade de retenção de carga da bateria cai no decorrer do tempo, é racional imaginar que o maior impacto ocorre na autonomia do veículo, porque a potência demandada pelo sistema tracionário permanece a mesma e a bateria consegue suprir. Dessa forma, a autonomia do veículo cai diretamente proporcional com o decaimento do SoH, e para a leitura do SoC ser correta, é preciso realizar uma calibração da energia da bateria. Por exemplo, em uma bateria de 100 kWh de energia com o SoH de 100%, quando o SoH cair para 90%, a energia da bateria referente a 100% de SoC passará a ser 90 kWh. Essa calibração é de extrema importância para que a predição da autonomia do veículo seja feita corretamente.

Para adaptar os modelos levando em consideração o decaimento do SoH, para os métodos CC e EKF é necessário criar funções que representem o SoH em função do tempo de uso, da energia total descarregada e da temperatura média da bateria durante seu funcionamento. Com isso, adicionando essa função no modelo, é possível realizar a análise do SoC ao longo da vida da bateria. Em relação aos métodos de ML usados para realizar as estimativas, o que precisa ser feito é adicionar a variável SoH nos dados de entrada dos modelos, pois a partir do banco de dados dessa variável o modelo se ajusta na realização das estimativas.

5.6 Erros na estimação de SoC

As médias dos erros médios absolutos e das raízes dos erros médios quadráticos obtidos nas estimativas podem ser visualizados na Tabela 4.

Tabela 4 – Performance das estimativas de SoC

Método	Charging		Driving	
	MAE (%)	RMSE (%)	MAE (%)	RMSE (%)
CC	2,0128	2,2457	1,2764	1,5153
EKF	0,5572	0,6710	0,9319	1,1904
DT	0,5556	0,0755	0,1318	0,2947
RNA	0,1980	0,3023	0,0687	0,0857
SVM	1,8306	2,7026	0,7398	1,0569

Fonte: Próprio autor.

Baseado dos valores obtido dos erros, observa-se que o método CC não tem precisão suficiente para ser utilizado sozinho, pois ao longo da simulação das 59,7 horas, a diferença

entre o SoC estimado e o SoC referência foi 17,7%. Os menores erros obtidos nas estimações são referentes aos métodos DT e RNA.

5.7 Implementação prática dos algoritmos em BMS

A implementação dos métodos de estimação de SoC em BMS pode ser realizada de diversas maneiras de acordo com o nível de investimento que pode ser realizado no projeto, pois quanto maior a capacidade de processamento, maior é o investimento a ser realizado.

As implementações dos métodos CC e EKF pode ser realizadas por meio de algumas plataformas:

- Série CompactDAQ ou CompactRIO da National Instruments, que oferecem alta precisão e taxa de amostragem suficiente para aquisição de dados em tempo real.
- Microcontroladores como Raspberry Pi, ou BeagleBone Black, que podem ser usadas para aplicações de controle em tempo real com taxas de amostragem adequadas para estimativa de SoC de baterias.
- Existem também placas de desenvolvimento específicas para aplicações de controle em tempo real que podem ser compatíveis com o Simulink Desktop Real-Time

As implementações dos métodos de *Machine learning* pode ser realizadas por meio de algumas plataformas:

- NVIDIA Jetson TX2: Suporta Python e é capaz de executar códigos mais complexos, incluindo modelos de aprendizado de máquina e processamento de arquivos CSV.
- NVIDIA Jetson Nano: Semelhante ao Jetson TX2, o Nano é projetado para aplicações de aprendizado de máquina e suporta Python.
- Raspberry Pi (Raspberry Pi 4 Model B): Suporta Python e pode ser usado para processar arquivos CSV.
- BeagleBone (BeagleBone Black): É compatível com Python e pode processar arquivos CSV.
- STM32 Discovery (STM32F4 Discovery Board): Normalmente, o STM32 é programado em C/C++. Python não é nativamente suportado, mas existem projetos que exploram a execução de Python em microcontroladores STM32.

- Zynq UltraScale+ MPSoC (Xilinx): Pode executar Python em sistemas operacionais incorporados, como o PetaLinux. Python pode ser usado para processamento de arquivos CSV.
- Altera DE10-Nano (Intel/Altera): Assim como o Zynq, a DE10-Nano pode executar Python em sistemas operacionais embarcados. Pode ser usado para processar arquivos CSV.

5.8 Matriz de Pugh para avaliação dos métodos

Com o intuito de avaliar esses erros, foi feito uma análise por meio da Matriz de Pugh (CERVONE, 2009), também conhecida como Matriz de Decisão, que é uma metodologia utilizada na avaliação e comparação por meio de critérios classificatórios. Para avaliar os resultados obtidos referentes às 5 metodologias de estimação de SoC, os critérios da avaliação foram acurácia, complexidade computacional e adaptabilidade.

A acurácia refere-se à proximidade entre os valores estimados e os valores referência. Em métodos de estimação de SoC a acurácia é crítica no processo devido ao grau de precisão que as estimações precisam ter. A complexidade computacional refere-se ao poder de processamento computacional necessário para executar as simulações, levando em consideração tempo de processamento e memória envolvidos no processo. A relevância da complexidade computacional é alta porque trata-se de uma aplicação em tempo real. A adaptabilidade refere-se à capacidade do sistema de entender as mudanças do que ocorrem devido aos fenômenos do processo e se adaptarem à essa dinamicidade.

Para realizar esta avaliação utilizou-se a seguinte escala de 5 pontos:

- 0: igual a, para $RMSE < 0,1\%$;
- -1: ligeiramente pior que, para $0,1\% \leq RMSE < 0,5\%$;
- -2: pior que, para $0,5\% \leq RMSE < 1\%$;
- -3: muito pior que, para $1\% \leq RMSE < 2\%$;
- -4: extremamente pior que, para $RMSE \geq 2\%$.

A classificação das estimações por meio da Matriz de Pugh, na qual os dados de entrada de SoC foram utilizados como referência pode ser observada na Tabela 5.

Tabela 5 – Matriz de Pugh para Métodos de Estimação de SoC em Baterias de Lítio

Crítérios / Métodos	CC	EKF	DT	RNA	SVM
Acurácia	-5	-2	-1	-1	-3
Complexidade Computacional	-2	-3	-4	-4	-4
Adaptabilidade	-5	-4	-1	-1	-2
Total das Pontuações	-12	-9	-6	-6	-9

Fonte: Próprio autor.

A análise da Matriz de Pugh proporciona percepções interessantes sobre os métodos de estimação de SoC de baterias de lítio. Baseado nos resultados, observa-se que os métodos DT e RNA possuem as melhores performances na estimação de SoC para a bateria do veículo e-tron modelo 2019. No capítulo seguinte serão realizadas as conclusões finais acerca deste trabalho.

6 | Conclusões

Neste trabalho, foram apresentados os resultados referentes às estimações de SoC utilizando contagem coulombica, filtros de Kalman estendido, Árvores de Decisão, Redes Neurais Artificiais e Máquinas de Vetores de Suporte. Para a contagem coulombica, os resultados obtidos possuem um erro médio acumulado superior a 17%, o que impacta negativamente o gerenciamento de um BMS, porque o erro acumulado ao longo dos ciclos implica no desbalanceamento da bateria. Em contrapartida, esse modelo apresenta baixa complexidade computacional para execução.

Nas estimações com a metodologia EKF foram obtidos resultados melhores que os obtidos por meio da contagem coulombica, mas mesmo assim, percebe-se pelos gráficos bastante variações abruptas nas estimções. Essas variações nas estimções de SoC devem-se ao problema de adaptabilidade do modelo, pois nos ciclos de trabalho, nos momentos em que altas correntes eram transitoriamente fornecidas pela bateria, haviam variações abruptas da tensão, que são um problema para o modelo, porque provoca um aumento do erro de estimação, e a correção da estimação por meio da mudança do valor do ganho de Kalman não ocorria de forma instantânea.

Nas simulações utilizando métodos de aprendizado de máquina, foram obtidos erros de estimação relativamente baixos, inferiores a 1% para as metodologias DT e RNA. Esses dois métodos apresentaram boa adaptabilidade para as variações abruptas de corrente e tensão. Apenas na simulação do ciclo de trabalho referente a janeiro de 2020, o método RNA apresentou erros de estimação maiores, comparados às outras estimções, por causa da diferença de temperatura entre os momentos que o veículo era desligado, com a bateria quente, e ligado, após algumas horas com a bateria mais fria, com variações de temperatura de até 18°C. Em contrapartida, as simulações por meio de SVM apresentaram muita variação no SoC estimado, como pode ser observado nos gráficos. Os erros obtidos ficaram acima de 1%. A metodologia demonstrou não ser tão eficiente comparada com DT e RNA.

Os resultados obtidos possuem implicações significativas no contexto prático de estimação de SoC de baterias de íons de lítio, pois observou-se que dados de condições reais de ciclos de trabalho podem ser usados com satisfação no treinamento de métodos de inteligência artificial. Observou-se que os métodos árvore de decisão de redes neurais artificiais apresentaram as menores médias de erro absoluto e raiz quadrada da média dos erros quadráticos para os cenários de carregamento e de condução do veículo. Essas consistentes performances sugerem que os métodos DT e RNA podem ser escolhas promissoras para aplicações práticas que demandam precisão na estimativa de SoC. No entanto, é crucial considerar a complexidade computacional de cada método, bem como sua adaptabilidade a diferentes condições operacionais. A seleção do método mais adequado deve ser orientada não apenas pela acurácia, mas também por fatores práticos e operacionais.

Importante ressaltar que os resultados das estimações de SoC apresentados no capítulo anterior não foram refinados para se aproximarem ainda mais do SoC referência. Todos se tratam de metodologias padrão de implementação, sem maiores artifícios computacionais para reduzir o erro absoluto de estimação. Esse melhoramento dos resultados pode ser realizado criando condições lógicas para evitar a variação do SoC estimado em condições reais, como o exemplo de a bateria fornecer corrente elétrica para o veículo, e mesmo assim, o SoC aumentar. Além disso, nas simulações de aprendizado de máquina foram utilizados 70% dos dados para treinamento e 30% de dados para teste, esses valores podem ser ajustados para se tentar obter menores erros de estimação. Essas melhorias podem ser realizadas em trabalhos futuros assim como a realização da implementação prática em *hardware* para controlar LIBs.

Em conclusão, é fundamental reconhecer que cada método possui suas próprias vantagens e limitações, e a escolha do método mais apropriado deve ser guiada pelas necessidades específicas da aplicação. Este estudo contribui não apenas para o entendimento da performance relativa desses métodos, mas também destaca a importância de considerar fatores práticos ao implementar soluções de estimação de SoC em sistemas de armazenamento de energia. Essas descobertas fornecem uma base sólida para futuras pesquisas e desenvolvimentos práticos no campo da gestão de baterias, visando aprimorar a eficiência e a confiabilidade dos sistemas de armazenamento de energia alimentados por baterias de íon de lítio.

Referências

- AGENCY, I. *Global EV Outlook 2019*. [S.l.]: IEA London, UK, 2019. Citado na página 1.
- ANTÓN, J. Á. et al. Battery state-of-charge estimator using the svm technique. *Applied Mathematical Modelling*, Elsevier, v. 37, n. 9, p. 6244–6253, 2013. Citado na página 48.
- ARMAND, M.; TARASCON, J.-M. Building better batteries. *nature*, Nature Publishing Group UK London, v. 451, n. 7179, p. 652–657, 2008. Citado na página 10.
- BARRETT, D. H.; HARUNA, A. Artificial intelligence and machine learning for targeted energy storage solutions. *Current Opinion in Electrochemistry*, v. 21, p. 160–166, 2020. ISSN 2451-9103. Energy Storage Energy Transformation. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2451910320300272>>. Citado na página 39.
- Berecibar, M. et al. Critical review of state of health estimation methods of li-ion batteries for real applications. *Renewable and Sustainable Energy Reviews*, v. 56, 2016. Citado na página 30.
- CERVONE, H. F. Applied digital library project management: Using pugh matrix analysis in complex decision-making situations. *OCLC Systems & Services: International digital library perspectives*, Emerald Group Publishing Limited, v. 25, n. 4, p. 228–232, 2009. Citado na página 77.
- CHAOUI, H.; IBE-EKEOCHA, C. C. State of charge and state of health estimation for lithium batteries using recurrent neural networks. *IEEE Transactions on Vehicular Technology*, v. 66, n. 10, p. 8773–8783, 2017. Citado na página 7.
- CHARKHGARD, M.; FARROKHI, M. State-of-charge estimation for lithium-ion batteries using neural networks and ekf. *IEEE Transactions on Industrial Electronics*, v. 57, n. 12, p. 4178–4187, 2010. Citado 2 vezes nas páginas 14 e 19.
- CHEMALI, E. et al. State-of-charge estimation of li-ion batteries using deep neural networks: A machine learning approach. *Journal of Power Sources*, Elsevier, v. 400, p. 242–255, 2018. Citado na página 53.
- CHEN, Z.; FU, Y.; MI, C. C. State of charge estimation of lithium-ion batteries in electric drive vehicles using extended kalman filtering. *IEEE Transactions on Vehicular Technology*, v. 62, n. 3, p. 1020–1030, 2013. Citado na página 1.
- CHENG, Z. et al. Estimation of state of charge for lithium-ion battery based on finite difference extended kalman filter. *Journal of Applied Mathematics*, v. 2014, 04 2014. Citado na página 34.
- CRISTIANINI, N.; SHAWE-TAYLOR, J. *An introduction to support vector machines and other kernel-based learning methods*. [S.l.]: Cambridge university press, 2000. Citado na página 43.

DENG, L.; YU, D. *Deep Learning: Methods and Applications*. [S.l.: s.n.], 2014. Citado na página 49.

(ECE), E. C. for E. *Regulation No. 100 - Uniform Provisions Concerning the Approval of Vehicles with Regard to the Electric Safety of Components and Systems*. 2022. Última versão acessada em 03/02/2023. Disponível em: <<https://unece.org/transport/documents/2022/03/standards/regulation-no-100-rev3>>. Citado na página 16.

ETACHERI, V. et al. Challenges in the development of advanced li-ion batteries: a review. *Energy & Environmental Science*, Royal Society of Chemistry, v. 4, n. 9, p. 3243–3262, 2011. Citado na página 10.

Farag, M. S. M. *Lithium-ion batteries: Modelling and state of charge estimation*. Master Thesis. Dissertação (Mestrado) — McMaster University, 10 2013. Citado 2 vezes nas páginas 26 e 27.

FENGXIN, L. et al. A novel approach to cloth classification through deep neural networks. *International Conference on Security, Pattern Analysis, and Cybernetics (SPAC)*, p. 368–371, 2017. Citado na página 38.

FICHTNER, M. Recent research and progress in batteries for electric vehicles. *Batteries & Supercaps*, Wiley Online Library, v. 5, n. 2, p. e202100224, 2022. Citado na página 12.

FREITAS, C.; HORA, H. Inteligência artificial na análise de vida útil de baterias. *CONFICT - V CONPG*, Instituto de Estudos Avançados da Universidade de São Paulo, n. Campos dos Goytacazes. Anais eletrônicos, 2020. Citado na página 49.

GOODENOUGH, J. B.; PARK, K.-S. The li-ion rechargeable battery: a perspective. *Journal of the American Chemical Society*, ACS Publications, v. 135, n. 4, p. 1167–1176, 2013. Citado na página 11.

GUO, G. F. et al. Soc estimation for li-ion battery using svm based on particle swarm optimization. *Advanced Materials Research*, Trans Tech Publ, v. 1051, p. 1004–1008, 2014. Citado na página 43.

HARTIKAINEN, J.; SOLIN, A.; SÄRKKÄ, S. Optimal filtering with kalman filters and smoothers—a manual for matlab toolbox ekf/ukf. *Biomedical Engineering*, p. 1–57, 2008. Citado na página 32.

HERBRICH, R. *Learning kernel classifiers: theory and algorithms*. [S.l.]: MIT press, 2001. Citado na página 48.

HU, M. et al. Lithium-ion battery modeling and parameter identification based on fractional theory. *Energy*, v. 165, p. 153–163, 2018. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544218318656>>. Citado na página 25.

HU, X. et al. Technological developments in batteries: A survey of principal roles, types, and management needs. *IEEE Power and Energy Magazine*, v. 15, n. 5, p. 20–31, 2017. Citado na página 11.

- HURIA, T. et al. Simplified extended kalman filter observer for soc estimation of commercial power-oriented lfp lithium battery cells. In: . [S.l.: s.n.], 2013. Citado na página 31.
- JENU, S. et al. State of health estimation of cycle aged large format lithium-ion cells based on partial charging. *Journal of Energy Storage*, v. 46, p. 103855, 2022. ISSN 2352-152X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352152X21015243>>. Citado na página 8.
- JUNPING, W.; JINGANG, G.; LEI, D. An adaptive kalman filtering based state of charge combined estimator for electric vehicle battery pack. *Energy Conversion and Management*, v. 50, n. 12, p. 3182–3186, 2009. ISSN 0196-8904. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0196890409003240>>. Citado 2 vezes nas páginas 19 e 32.
- KIM, I.-S. A technique for estimating the state of health of lithium batteries through a dual-sliding-mode observer. *IEEE Transactions on Power Electronics*, v. 25, n. 4, p. 1013–1022, 2010. Citado na página 7.
- KOTSIANTIS, S. B. et al. Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, Amsterdam, v. 160, n. 1, p. 3–24, 2007. Citado na página 41.
- KRAMER, O. Scikit-learn. In: _____. *Machine Learning for Evolution Strategies*. Cham: Springer International Publishing, 2016. p. 45–53. ISBN 978-3-319-33383-0. Citado na página 52.
- KRAMER, O.; KRAMER, O. Scikit-learn. *Machine learning for evolution strategies*, Springer, p. 45–53, 2016. Citado na página 52.
- KUNAKRON-ONG, P.; RUANGJIRAKIT, K.; JONGPRADIST, P. Design and analysis of electric bus structure in compliance with ece safety regulations. In: *2017 2nd IEEE International Conference on Intelligent Transportation Engineering (ICITE)*. [S.l.: s.n.], 2017. p. 25–29. Citado na página 6.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015. Citado na página 50.
- LI, J. et al. A comparative study of state of charge estimation algorithms for lifepo4 batteries used in electric vehicles. *Journal of Power Sources*, v. 230, p. 244–250, 2013. ISSN 0378-7753. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378775312019039>>. Citado na página 19.
- LI, R. et al. State of charge prediction algorithm of lithium-ion battery based on pso-svr cross validation. *IEEE Access*, v. 8, p. 10234–10242, 2020. Citado 2 vezes nas páginas 44 e 49.
- LI, S. et al. Lithium-ion battery modeling based on big data. *Energy Procedia*, v. 159, p. 168–173, 2019. ISSN 1876-6102. Renewable Energy Integration with Mini/Microgrid. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1876610218313419>>. Citado na página 21.

LIN, D.; LIU, Y.; CUI, Y. Reviving the lithium metal anode for high-energy batteries. *Nature nanotechnology*, Nature Publishing Group UK London, v. 12, n. 3, p. 194–206, 2017. Citado na página 11.

LIPU, M. H. et al. A review of state of health and remaining useful life estimation methods for lithium-ion battery in electric vehicles: Challenges and recommendations. *Journal of Cleaner Production*, v. 205, p. 115–133, 2018. ISSN 0959-6526. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0959652618327793>>. Citado na página 1.

LIPU, M. H. et al. Lithium-ion battery state of charge estimation method using optimized deep recurrent neural network algorithm. In: *2019 IEEE Industry Applications Society Annual Meeting*. [S.l.: s.n.], 2019. p. 1–9. Citado na página 14.

LIU, C. et al. A new method of modeling and state of charge estimation of the battery. *Journal of Power Sources*, v. 320, p. 1–12, 2016. ISSN 0378-7753. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378775316302804>>. Citado na página 14.

LIU, X. et al. Bayesian information criterion based data-driven state of charge estimation for lithium-ion battery. *Journal of Energy Storage*, v. 55, p. 105669, 2022. ISSN 2352-152X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352152X22016577>>. Citado na página 44.

LIU, Y. et al. A review of lithium-ion battery state of charge estimation based on deep learning: Directions for improvement and future trends. *Journal of Energy Storage*, v. 52, p. 104664, 2022. ISSN 2352-152X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352152X22006776>>. Citado na página 50.

LORENA, A. C.; CARVALHO, A. C. P. L. F. de. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, Dec. 2007. Disponível em: <https://seer.ufrgs.br/index.php/rita/article/view/rita_v14_n2_p43-67>. Citado 3 vezes nas páginas 43, 45 e 46.

LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *Estudos Avançados*, Instituto de Estudos Avançados da Universidade de São Paulo, v. 35, n. Estud. av., 2021 35(101), Jan 2021. ISSN 0103-4B8r3B4p7yhRXuBWLqsQ546WR43cqQwrbXMDFnBi6vSJBeif8tPW85a7r7DM961Jvk4hdryZoByEp8GC8HzsqJpRN4FxGM935101.007. Citado na página 49.

MAHESH, B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], v. 9, p. 381–386, 2020. Citado 3 vezes nas páginas 39, 40 e 43.

MathWorks®. *Generate Parameter Data for Equivalent Circuit Battery Block*. 2022. Disponível em: <https://www.mathworks.com/help/autoblks/ug/generate-parameter-data-for-estimations-circuit-battery-block.html>, Acesso em: 07 de agosto 2022. Citado na página 20.

MODESTI, P. H. d. *Método baseado em inteligência artificial para previsão do prazo de entrega de tarefas em estações de manufatura*. Dissertação (Dissertação de Mestrado), Curitiba, 2020. Citado 3 vezes nas páginas 52, 53 e 54.

MOHAMMADI, F.; SAIF, M. A comprehensive overview of electric vehicle batteries market. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, v. 3, p. 100127, 2023. ISSN 2772-6711. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2772671123000220>>. Citado na página 2.

NIZAM, M. et al. Decision tree for state of charge (soc) prediction of lifepo4 battery. In: *Proceedings of the Joint International Conference on Electric Vehicular Technology and Industrial, Mechanical, Electrical and Chemical Engineering (ICEVT IMECE)*. [S.l.: s.n.], 2015. p. 359–361. Citado na página 41.

NOBLE, W. S. What is a support vector machine? *Nature biotechnology*, Nature Publishing Group UK London, v. 24, n. 12, p. 1565–1567, 2006. Citado na página 43.

NOBLE, W. S. What is a support vector machine? *Nature Biotechnology*, v. 24, n. 12, p. 1565–1567, 2006. ISSN 1546-1696. Disponível em: <<https://doi.org/10.1038/nbt1206-1565>>. Citado 4 vezes nas páginas 45, 46, 47 e 48.

PEI, L.; LU, R.; ZHU, C. Relaxation model of the open-circuit voltage for state-of-charge estimation in lithium-ion batteries. *Electrical Systems in Transportation, IET*, v. 3, p. 112–117, 12 2013. Citado na página 7.

PLETT, G. L. Extended kalman filtering for battery management systems of lipb-based hev battery packs: Part 3. state and parameter estimation. *Journal of Power Sources*, v. 134, n. 2, p. 277–292, 2004. ISSN 0378-7753. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378775304003611>>. Citado na página 34.

POZZATO, G. et al. Analysis and key findings from real-world electric vehicle field data. *Joule*, v. 7, n. 9, p. 2035–2053, 2023. ISSN 2542-4351. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2542435123003161>>. Citado 2 vezes nas páginas 55 e 58.

RAMADAN, H.; BECHERIF, M.; CLAUDE, F. Extended kalman filter for accurate state of charge estimation of lithium-based batteries: a comparative analysis. *International Journal of Hydrogen Energy*, v. 42, n. 48, p. 29033–29046, 2017. ISSN 0360-3199. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360319917331312>>. Citado 2 vezes nas páginas 2 e 13.

RUAN, H. et al. Generalised diagnostic framework for rapid battery degradation quantification with deep learning. *Energy and AI*, v. 9, p. 100158, 2022. ISSN 2666-5468. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666546822000192>>. Citado na página 1.

RUELA, A. S. Redes neurais feedforward e backpropagation. *UFOP (http://www.decom.ufop.br/imobilis/wpcontent/uploads/2012/06/03_Feedforward-e-Backpropagation.pdf)(Acedido em 3 05 2014)*, 2012. Citado na página 50.

SAMANTA, A.; CHOWDHURI, S. Active cell balancing of lithium-ion battery pack using dual dc-dc converter and auxiliary lead-acid battery. *Journal of Energy Storage*, v. 33, p. 102109, 2021. ISSN 2352-152X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352152X20319393>>. Citado na página 15.

Santos, R. M. S. *Estimação do Estado de Carga de Baterias de Lítio-íon em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman*. Dissertação (Mestrado) — Universidade Federal da Paraíba, 6 2019. Citado 2 vezes nas páginas 31 e 43.

SAXENA, S. et al. Accelerated degradation model for c-rate loading of lithium-ion batteries. *International Journal of Electrical Power Energy Systems*, v. 107, p. 438–445, 2019. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061518301212>>. Citado na página 7.

SCIKIT-LEARN. Acesso em 2023. Disponível em: <<https://scikit-learn.org/stable/modules/tree.html>>. Citado na página 41.

SHRIVASTAVA, P. et al. Overview of model-based online state-of-charge estimation using kalman filter family for lithium-ion batteries. *Renewable and Sustainable Energy Reviews*, v. 113, p. 109233, 2019. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032119304332>>. Citado na página 1.

SIAL, A. H.; RASHDI, S. Y. S.; KHAN, A. H. Comparative analysis of data visualization libraries matplotlib and seaborn in python. *International Journal*, v. 10, n. 1, 2021. Citado na página 53.

SIDHU, M. S.; RONANKI, D.; WILLIAMSON, S. State of charge estimation of lithium-ion batteries using hybrid machine learning technique. In: *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*. [S.l.: s.n.], 2019. v. 1, p. 2732–2737. Citado 2 vezes nas páginas 19 e 41.

SIDHU, M. S.; RONANKI, D.; WILLIAMSON, S. State of charge estimation of lithium-ion batteries using hybrid machine learning technique. In: *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*. [S.l.: s.n.], 2019. v. 1, p. 2732–2737. Citado na página 30.

SMITH, K. et al. Comparison of plug-in hybrid electric vehicle battery life across geographies and drive-cycles. *SAE Technical Papers*, 04 2012. Citado na página 2.

SMITS, G. F.; JORDAAN, E. M. Improved svm regression using mixtures of kernels. In: IEEE. *Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No. 02CH37290)*. [S.l.], 2002. v. 3, p. 2785–2790. Citado na página 48.

SONG, Y. et al. High-efficiency self-charging smart bracelet for portable electronics. *Nano Energy*, Elsevier, v. 55, p. 29–36, 2019. Citado na página 11.

SU, L. et al. Cycle life prediction of lithium-ion batteries based on data-driven methods. *eTransportation*, v. 10, p. 100137, 2021. ISSN 2590-1168. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S2590116821000357>>. Citado na página 3.

SULAIMAN, N. et al. A review on energy management system for fuel cell hybrid electric vehicle: Issues and challenges. *Renewable and Sustainable Energy Reviews*, v. 52, p. 802–814, 2015. ISSN 1364-0321. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1364032115007790>>. Citado na página 2.

SUN, T.-W.; TSAI, T.-H. A battery management system using interleaved pulse charging with charge and temperature balancing based on narx network. *IEEE Transactions on Circuits and Systems I: Regular Papers*, v. 69, n. 4, p. 1811–1819, 2022. Citado na página 51.

TEJASWINI, P.; SIVRAJ, P. Artificial intelligence based state of charge estimation of li-ion battery for ev applications. In: IEEE. *2020 5th international conference on communication and electronics systems (icces)*. [S.l.], 2020. p. 1356–1361. Citado na página 38.

TEOH, T. et al. Decarbonisation of urban freight transport using electric vehicles and opportunity charging. *Sustainability*, MDPI, v. 10, n. 9, p. 3258, 2018. Citado na página 16.

THEUERKAUF, D.; SWAN, L. Characteristics of open circuit voltage relaxation in lithium-ion batteries for the purpose of state of charge and state of health analysis. *Batteries*, v. 8, n. 8, 2022. ISSN 2313-0105. Disponível em: <<https://www.mdpi.com/2313-0105/8/8/77>>. Citado na página 20.

TIAN, H.; LI, A.; LI, X. Soc estimation of lithium-ion batteries for electric vehicles based on multimode ensemble svr. *Journal of Power Electronics*, v. 9, p. 2093–4718, 2021. Citado na página 44.

TIAN, J. et al. Electrode ageing estimation and open circuit voltage reconstruction for lithium ion batteries. *Energy Storage Materials*, v. 37, p. 283–295, 2021. ISSN 2405-8297. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405829721000611>>. Citado na página 7.

TISSOT, H.; CAMARGO, L.; POZO, A. Treinamento de redes neurais feedforward: comparativo dos algoritmos backpropagation e differential evolution. In: . [S.l.: s.n.], 2012. Citado na página 50.

TRAN, M.-K. et al. Python-based scikit-learn machine learning models for thermal and electrical performance prediction of high-capacity lithium-ion battery. *International Journal of Energy Research*, Wiley Online Library, v. 46, n. 2, p. 786–794, 2022. Citado na página 51.

TURNER, J. 3. simplified extended kalman filter observer for soc estimation of commercial power-oriented lfp lithium battery cells (2013-01-1544). In: _____. *Progress in Modeling and Simulation of Batteries*. [S.l.: s.n.], 2016. p. 19–28. Citado 2 vezes nas páginas 32 e 33.

University, B. *Is Li-ion the Solution for the Electric Vehicle?* 2022. Disponível em: <https://batteryuniversity.com/article/is-li-ion-the-solution-for-the-electric-vehicle>, Acesso em: 23 de julho 2022. Citado na página 12.

UNIVERSITY, B. *Summary Table of Lithium-based Batteries*. 2024. Acesso em: 03 de fevereiro de 2024. Disponível em: <https://batteryuniversity.com/article/bu-216-summary-table-of-lithium-based-batteries>>. Citado na página 13.

WASSILIADIS, N. et al. Review of fast charging strategies for lithium-ion battery systems and their applicability for battery electric vehicles. *Journal of Energy Storage*, v. 44, p. 103306, 2021. ISSN 2352-152X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352152X21009981>>. Citado na página 16.

WEICKER, P. *A systems approach to lithium-ion battery management*. [S.l.]: Artech house, 2013. Citado 4 vezes nas páginas 2, 9, 10 e 11.

ZACKRISSON, M.; AVELLÁN, L.; ORLENIUS, J. Life cycle assessment of lithium-ion batteries for plug-in hybrid electric vehicles – critical issues. *Journal of Cleaner Production*, v. 18, n. 15, p. 1519–1529, 2010. ISSN 0959-6526. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652610002167>>. Citado na página 6.

ZHANG, J. et al. An overview on thermal safety issues of lithium-ion batteries for electric vehicle application. *IEEE Access*, v. 6, p. 23848–23863, 2018. Citado na página 6.

ZHANG, L. et al. A sparse least squares support vector machine used for soc estimation of li-ion batteries. *IFAC-PapersOnLine*, v. 52, n. 11, p. 256–261, 2019. ISSN 2405-8963. 5th IFAC Conference on Intelligent Control and Automation Sciences ICONS 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2405896319307827>>. Citado na página 44.

ZHANG, R. et al. A study on the open circuit voltage and state of charge characterization of high capacity lithium-ion battery under different temperature. *Energies*, MDPI, v. 11, n. 9, p. 2408, 2018. Citado na página 9.