



**Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

**Identificação do Modelo Matemático e
Estimação do Estado de Carga de Baterias de
Íons de Lítio Utilizando um Filtro de Kalman
Estendido**

Camilo Andrés Villarraga Solís

**DISSERTAÇÃO DE MESTRADO
PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS MECATRÔNICOS**

Brasília
2025

**Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

**Identificação do Modelo Matemático e
Estimação do Estado de Carga de Baterias de
Íons de Lítio Utilizando um Filtro de Kalman
Estendido**

Camilo Andrés Villarraga Solís

Dissertação de Mestrado submetida ao Departamento de Engenharia Mecânica da Universidade Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre

Orientador: Prof. Dr. Renato Vilela Lopes

Brasília
2025

V12i Villarraga Solís, Camilo Andrés.
Identificação do Modelo Matemático e Estimação do Estado de Carga de Baterias de Íons de Lítio Utilizando um Filtro de Kalman Estendido / Camilo Andrés Villarraga Solís; orientador Renato Vilela Lopes. -- Brasília, 2025.
124 p.

Dissertação de Mestrado (Programa de Pós-Graduação em Sistemas Mecatrônicos) -- Universidade de Brasília, 2025.

1. Sistema de gestão de baterias. 2. Estado de Carga. 3. Modelo de Circuito Equivalente. 4. Filtro de Kalman Extendido. I. Vilela Lopes, Renato, orient. II. Título

Referência

SOLIS, CAMILO ANDRES VILLARRAGA (2025). Identificação do Modelo Matemático e Estimação do Estado de Carga de Baterias de Íons de Lítio Utilizando um Filtro de Kalman Estendido. Dissertação de mestrado em sistemas mecatrônicos, Publicação 03/2025, Programa de Pós-Graduação, ENM/FT/UnB, Universidade de Brasília, Brasília, DF, Brasil.

Cessão de Direitos

AUTOR: Camilo Andrés Villarraga Solís

TÍTULO: Identificação do Modelo Matemático e Estimação do Estado de Carga de Baterias de Íons de Lítio Utilizando um Filtro de Kalman Estendido.

GRAU: Mestre

ANO: 2025

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito da autora.



Camilo Andrés Villarraga Solís
222107760@aluno.unb.br
Depto. de Engenharia Mecânica (ENM) - FT
Universidade de Brasília (UnB)
Brasília - DF - Brasil

**Universidade de Brasília
Faculdade de Tecnologia
Departamento de Engenharia Mecânica**

**Identificação do Modelo Matemático e Estimação do
Estado de Carga de Baterias de Íons de Lítio Utilizando
um Filtro de Kalman Estendido**

Camilo Andrés Villarraga Solís

Dissertação de Mestrado submetida ao Departamento de Engenharia Mecânica da Universidade Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre

Trabalho aprovado. Brasília, 25 de Março de 2025:

Prof. Dr. Renato Vilela Lopes, UnB/FGA
Orientador

Prof. Dr. Evandro Teixeira, UnB/FGA
Examinador interno

Dra. Cynthia Thamires, USP/EESC
Examinador externo

Brasília
2025

Dedico este trabalho a Deus, minha luz e guia em cada passo; à minha mãe e minha irmã, pelo seu amor incondicional e apoio constante; ao meu apoio inabalável, A.D.I.B, por sua paciência, compreensão e incentivo.

Agradecimentos

Agradeço, em primeiro lugar, a Deus, por me conceder força e perseverança para alcançar esta importante conquista em minha vida.

À minha família, minha maior fonte de inspiração. Sou imensamente grato pelo amor incondicional, pela paciência, pelo incentivo constante e por acreditarem em mim, mesmo nos momentos mais desafiadores. Cada palavra de apoio, cada gesto de carinho e cada sacrifício foram essenciais para que eu chegasse até aqui. Obrigado.

À Angie Daniela Ibarra Benavides, cujo apoio inestimável foi fundamental ao longo desta jornada. Foi ela quem me apresentou a valiosa oportunidade de realizar este mestrado, acreditando no meu potencial e incentivando-me a dar esse grande passo. Sua orientação e ajuda incansável não apenas facilitaram minha adaptação acadêmica e pessoal, mas também tornaram essa experiência muito mais enriquecedora. Sou imensamente grato por sua motivação constante, pelas palavras de encorajamento nos momentos difíceis e pelo apoio incondicional que me permitiu seguir em frente com confiança e determinação.

Expresso minha profunda gratidão ao Dr. Renato Vilela Lopes por sua orientação e apoio ao longo deste processo, assim como a todos os professores e membros do grupo de pesquisa, cujo conhecimento e colaboração foram fundamentais para o meu desenvolvimento acadêmico e profissional.

Aos meus colegas de laboratório, que compartilharam comigo essa jornada de aprendizado, desafios e crescimento. O convívio diário, as discussões acadêmicas, a troca de ideias e o apoio mútuo tornaram o ambiente de pesquisa mais enriquecedor e motivador. Agradeço pela camaradagem, pelas colaborações e pelas incontáveis horas dedicadas ao desenvolvimento de projetos e experimentos.

À Universidade de Brasília (UnB), por me proporcionar a oportunidade de obter este tão esperado título, e aos seus diretores, pelo compromisso e dedicação em manter esta instituição entre as melhores do país.

Reconheço, com gratidão, o governo do Brasil por seu compromisso com a educação, possibilitando que inúmeros estudantes, tanto nacionais quanto internacionais, tenham acesso a esse bem inestimável: o conhecimento.

À Fundação de Desenvolvimento da Pesquisa – Fundep, Rota 2030 - Linha V, Projeto No. 27192.03.01/2022.01-00, pelo apoio financeiro concedido por meio da bolsa de estudos, que transformou este sonho em realidade.

Por fim, meu mais sincero agradecimento a todas as pessoas e instituições que, de alguma forma, contribuíram para a realização desta conquista.

Resumo

Este trabalho desenvolve e implementa um método otimizado para a estimativa do estado de carga (*SoC*) de baterias de íon-lítio por meio de um Filtro de Kalman Estendido (*EKF*). A precisão na estimativa do *SoC* é um fator determinante para a eficiência e segurança dos sistemas de gerenciamento de baterias (*BMS*), especialmente em aplicações de mobilidade elétrica e armazenamento de energia renovável. No entanto, a efetividade do *EKF* depende diretamente da correta parametrização de suas matrizes de covariância, que influenciam sua capacidade de filtragem e correção de erros. Nesse contexto, propõe-se um processo de otimização das matrizes de covariância (Q_k , R_k e P), permitindo um ajuste dinâmico em função do *SoC* e reduzindo o impacto das incertezas do modelo e das medições. A otimização baseia-se na minimização do erro quadrático médio (*RMSE*) da tensão terminal e do *SoC* dentro da função objetivo, aplicando uma abordagem de ponderação que prioriza a precisão na estimativa do *SoC*. Os resultados obtidos demonstram que o *EKF* otimizado reduz significativamente o *RMSE* em diversas condições operacionais. Em um teste de validação com um *SoC* inicial de 100%, obteve-se um *RMSE* de 0,809%; em outro teste com um *SoC* inicial de 60%, o *RMSE* foi de 0,368%. Além disso, em testes com o perfil de corrente *HPPC*, utilizados para a caracterização da bateria, o *RMSE* atingiu 1,266%, validando a estimativa em cenários com tempos de simulação prolongados. Essas validações foram realizadas a uma temperatura ambiente de 20 °C, evidenciando a estabilidade e a precisão do método otimizado em condições operacionais padrão. Os testes foram realizados em diferentes temperaturas (-5, 0, 10, 20, 30, 40 e 50 °C), demonstrando que o *EKF* mantém sua estabilidade e precisão em uma ampla faixa térmica. Evidenciou-se que o ajuste das matrizes de covariância permite que o filtro corrija eficazmente erros iniciais na estimativa do *SoC*, reduzindo discrepâncias iniciais de até 10% para valores inferiores a 2,5%. Os resultados obtidos demonstram que a otimização das matrizes de covariância não apenas melhora a precisão do *EKF*, mas também reduz o custo computacional ao permitir o armazenamento dos valores ótimos em tabelas de consulta (*LUT*). Isso facilita sua implementação em sistemas embarcados, promovendo um monitoramento mais confiável do *SoC* em aplicações industriais e comerciais. Por fim, este trabalho contribui para o avanço do conhecimento na gestão de baterias, fornecendo um marco metodológico robusto que pode servir de base para futuras pesquisas e aplicações em sistemas de energia sustentável.

Palavras-chave: Sistema de gestão de baterias. Estado de Carga. Modelo de Circuito Equivalente. Filtro de Kalman Estendido.

Abstract

This work develops and implements an optimized method for estimating the state of charge (SoC) of lithium-ion batteries using an Extended Kalman Filter (EKF). The accuracy of SoC estimation is a crucial factor for the efficiency and safety of battery management systems (BMS), particularly in electric mobility and renewable energy storage applications. However, the effectiveness of the EKF directly depends on the proper parameterization of its covariance matrices, which influence its filtering and error correction capabilities. In this context, an optimization process for the covariance matrices (Q_k , R_k e P) is proposed, enabling a dynamic adjustment based on the SoC and reducing the impact of model and measurement uncertainties. The optimization is based on minimizing the root mean square error (RMSE) of the terminal voltage and SoC within the objective function, applying a weighting approach that prioritizes SoC estimation accuracy. The results show that the optimized EKF significantly reduces the RMSE under various operating conditions. In a validation test with an initial SoC of 100%, an RMSE of 0.809% was obtained; in another test with an initial SoC of 60%, the RMSE was 0.368%. Additionally, in tests using the HPPC current profile, commonly used for battery characterization, the RMSE reached 1.266%, validating the estimation in scenarios with extended simulation times. These validations were conducted at an ambient temperature of 20°C, demonstrating the stability and accuracy of the optimized method under standard operating conditions. Tests were performed at different temperatures (-5, 0, 10, 20, 30, 40, and 50°C), showing that the EKF maintains its stability and accuracy across a wide thermal range. It was observed that adjusting the covariance matrices allows the filter to effectively correct initial errors in the SoC estimation, reducing initial discrepancies of up to 10% to values below 2.5%. The results indicate that optimizing the covariance matrices not only enhances EKF accuracy but also reduces computational cost by enabling the storage of optimal values in lookup tables (LUT). This facilitates implementation in embedded systems, promoting more reliable SoC monitoring in industrial and commercial applications. Ultimately, this work contributes to advancing knowledge in battery management by providing a robust methodological framework that can serve as a foundation for future research and applications in sustainable energy systems.

Keywords: Battery management system. State of Charge. Equivalent Circuit Model. Extended Kalman Filter.

Lista de ilustrações

Figura 1 – Estrutura da Dissertação: Organização dos capítulos em ordem crescente de complexidade.	23
Figura 2 – Movimento dos Li^+ : Equilíbrio dos electrões durante os ciclos de carga e descarga de uma LIB. Adaptado de [40].	26
Figura 3 – Balanceamento ativo e passivo e comportamento energético de células de bateria desequilibradas.	29
Figura 4 – Relação de descarga não linear entre OCV e o SoC de uma LIB 18650 a uma temperatura de 30 °C.	35
Figura 5 – Modelo da célula com tensão de saída constante. Adaptado de [13]. . . .	40
Figura 6 – ECM da ESR. Adaptado de [13].	42
Figura 7 – Tensão de difusão: Resposta ao pulso de descarga. Adaptada de Plett [13].	43
Figura 8 – ECM da inclusão da tensão de difusão (V1). Adaptado de [13].	44
Figura 9 – ECM com três ramificações RC. Adaptado de [13]	47
Figura 10 – Esquema da bancada experimental.	56
Figura 11 – Painel principal de controle dos testes no MATLAB <i>Simulink</i>	58
Figura 12 – Implementação da estimativa e controle da corrente no MATLAB <i>Simulink</i>	59
Figura 13 – Implementação da estimativa do SoC pelo método de Coulomb Counting no MATLAB <i>Simulink</i>	59
Figura 14 – Implementação da estimativa da temperatura da bateria no MATLAB <i>Simulink</i>	60
Figura 15 – Implementação do cálculo da capacidade da célula no MATLAB <i>Simulink</i>	60
Figura 16 – Placa NI SCB-68A de aquisição de dados da <i>National Instruments</i>	62
Figura 17 – Sistema de comutação e Diagrama de carga programável.	63
Figura 18 – Incubadora refrigerada com alternância de temperatura da <i>SolidSteel</i> . .	64
Figura 19 – Fonte de alimentação MPL3305 da Minipa.	65
Figura 20 – Estrutura dos métodos utilizados para o desenvolvimento desta pesquisa.	67
Figura 21 – Tela principal da <i>Toolbox</i> , onde são configuradas as ramificações RC a serem identificadas. Adaptada de [109]	70
Figura 22 – Segmentação dos pulsos. Adaptado de [18].	71
Figura 23 – Elemento <i>Battery (Table-Based)</i> do MATLAB- <i>Simulink</i>	73
Figura 24 – Diagrama de conexões com a bateria simulada.	73
Figura 25 – Modelo <i>Simulink</i> desenvolvido para a validação do modelo.	74
Figura 26 – Perfis de correntes para validação.	75
Figura 27 – Modelo <i>Simulink</i> desenvolvido para a estimativa de SoC por meio do método CC.	76

Figura 28 – Perfis de corrente aplicando diferentes tipos de erros no sensor a uma temperatura de 20°C.	82
Figura 29 – Resultados do experimento de identificação da capacidade da célula em uma temperatura ambiente constante de 20 °C.	85
Figura 30 – Resultado do teste de caracterização de <i>HPPC</i> da célula em uma temperatura constante de 20 °C.	87
Figura 31 – Comparação entre a saída real do sistema e a saída identificada pela <i>Toolbox Battery Modeling</i> correspondente a uma temperatura de 20 °C .	88
Figura 32 – Comparação entre a saída real do sistema e a saída identificada pela <i>Toolbox Sae</i> [18] correspondente a uma temperatura de 20 °C.	89
Figura 33 – Caracterização da não linearidade da célula em diferentes temperaturas.	90
Figura 34 – Avaliação das saídas de tensão dos modelos identificados: ModelTX ($FIT = 92,5\%$) e ModelSE ($FIT = 87,8\%$) a uma temperatura de 20 °C.	91
Figura 35 – Resultado do teste para a validação do modelo correspondente a um SoC_{t0} de 100%, temperatura constante de 20 °C.	94
Figura 36 – Resultado do teste para a validação do modelo correspondente a um SoC_{t0} de 60%, temperatura constante de 20 °C.	95
Figura 37 – Resultados da validação considerando os melhores desempenhos experimentais para diferentes condições do SoC inicial (SoC_{t0}).	96
Figura 38 – Resultado do método de contagem de Coulomb para estimativa do SoC em temperatura de 20 °C.	97
Figura 39 – Resultados da estimativa de SoC em que a função objetiva do processo de otimização considera um peso de 95 % para o erro do SoC a uma temperatura de 20 °C.	99
Figura 40 – Resultados da estimativa com o perfil de corrente <i>HPPC</i> a uma temperatura de 20 °C.	100
Figura 41 – Resultados da estimativa com o perfil de corrente SoC_{t0} é de 100% a uma temperatura de 20 °C.	101
Figura 42 – Resultados da estimativa com o perfil de corrente SoC_{t0} de 60% em temperatura de 20 °C.	102
Figura 43 – Estimativa do <i>EKF</i> em relação a um erro do tipo <i>Bias</i> em uma temperatura de 20 °C.	104
Figura 44 – Estimativa do <i>EKF</i> em relação a um ruído gaussiano em uma temperatura de 20 °C.	105
Figura 45 – Estimativa do <i>EKF</i> em relação ao erro inicial no SoC em uma temperatura de 20 °C.	105

Lista de tabelas

Tabela 1 – Terminologia referente às baterias com as especificações técnicas, nomenclatura e a sua definição [41] [42] [43].	26
Tabela 2 – Tendências atuais para a estimativa do SoC em EV com LIB (E_{max} : Erro máximo).	32
Tabela 3 – Fases do EKF com a representação matemática correspondente.	36
Tabela 4 – Revisão da literatura com as respectivas contribuições a serem levadas em conta no presente estudo.	51
Tabela 5 – Características da bateria utilizada (LPF : Fosfato de Ferro-Lítio).	65
Tabela 6 – Temperaturas consideradas na pesquisa em relação à capacidade identificada na célula.	86
Tabela 7 – Resultados da identificação dos parâmetros do modelo ECM usando a <i>Toolbox Battery Modeling</i> em uma temperatura de 20 °C.	89
Tabela 8 – Tabela de comparação dos dois modelos identificados, denominados ModelTX e ModelSE	92
Tabela 9 – Tabela de comparação referente ao comportamento do ModelTX em seus dois tempos de amostragem diferentes.	93
Tabela 10 – Resultados da validação do modelo em relação aos dois perfis de corrente diferentes em que o SoC_{t_0} é diferente.	97
Tabela 11 – Valores das matrizes de covariância P , Q_k e R_k utilizadas no EKF para uma temperatura de 20 °C.	100
Tabela 12 – Estimativa do SoC nos diferentes perfis de corrente em que os resultados são expressos em RMSE a 20 °C.	103
Tabela 13 – Resultados em termos de $RMSE$ da estimativa de SoC e saída de tensão em as diferentes temperaturas.	103
Tabela 14 – Resultados da estimativa do SoC com o EKF nos diferentes cenários de validação para o teste em que SoC_{t_0} é 100% a uma temperatura de 20 °C.	106
Tabela 15 – Resultados da estimativa do SoC com o EKF nos diferentes cenários de validação para o teste em que SoC_{t_0} é 60% a uma temperatura de 20 °C.	106
Tabela 16 – Resultados da estimativa do SoC com o EKF em cada célula do pack de baterias com tempo de execução de 342,224 s.	107

Lista de abreviaturas e siglas

<i>BMS</i>	Sistema de gestão de baterias (do inglês, <i>Battery Management System</i>)	17
<i>BoL</i>	Início da vida (do inglês, <i>Beginning of Life</i>)	30
<i>CC</i>	Contagem de coulomb (do inglês, <i>Coulomb Counting</i>)	18
<i>CC</i>	Corrente constante (do inglês, <i>Constant Current</i>)	65
<i>Cv</i>	Tensão constante (do inglês, <i>Constant Voltage</i>)	65
<i>DFN</i>	<i>Doyle-Fuller-Newman</i>	38
<i>DoD</i>	Profundidade de descarga (do inglês, <i>Depth of Discharge</i>)	27
<i>ECM</i>	Modelo de circuito equivalente (do inglês, <i>Equivalent Circuit Model</i>)	19
<i>EKF</i>	Filtro de Kalman estendido (do inglês, <i>Extended Kalman Filter</i>)	18
<i>EoL</i>	Fim da vida (do inglês, <i>End of Life</i>)	30
<i>ESR</i>	Resistência em série equivalente do inglês, <i>Equivalent series resistance</i>	42
<i>EV</i>	Veículos eléctricos (do inglês, <i>Electric Vehicles</i>)	17
<i>FIT</i>	Falha no tempo (do inglês, <i>Failure in time</i>)	49
<i>HEV</i>	Veículos eléctricos híbridos (do inglês, <i>Hybrid Electric Vehicles</i>)	17
<i>HPPC</i>	Caracterização híbrida de potência por pulsos (do inglês, <i>Hybrid Pulse Power Characterization</i>)	37
<i>KG</i>	Ganho de Kalman (do inglês, <i>Kalman Gain</i>)	79
<i>LIB</i>	Baterias de íon de lítio (do inglês, <i>Lithium-ion Batteries</i>)	17
<i>LUT</i>	Tabela de consulta (<i>Look-up Table</i>)	19
<i>NTC</i>	Coefficiente de temperatura negativo (do inglês, <i>Negative temperature coefficient</i>)	63
<i>OCV</i>	Tensão de circuito Aberto (do inglês, <i>Open-circuit voltage</i>)	18
<i>PFI</i>	Interface de função programável do inglês, <i>Programmable Function Interface</i>	61
<i>RMSE</i>	Erro médio quadrático (do inglês, <i>Root Mean Squared Error</i>)	80
<i>SDRT</i>	<i>Simulink Desktop Real-Time</i>	57
<i>SoC</i>	Estado de carga (do inglês, <i>State of Charge</i>)	17
<i>SoF</i>	Estado de Funcionalidade (do inglês, <i>Functionality Status</i>)	17
<i>SoH</i>	Estado de saúde (do inglês, <i>State of Health</i>)	17
<i>UEKF</i>	Filtro de Kalman Unscented (do inglês, <i>Unscented Kalman Filter</i>)	18
<i>VAF</i>	Variação explicada (do inglês, <i>Variance Accounted For</i>)	49
<i>IA</i>	Inteligência artificial	18

Lista de símbolos

Ω	Ohms	42
η	Eficiência de carga ou eficiência de Coulomb	33
τ	constantes de tempo	71
$^{\circ}\text{C}$	Graus celsius	35
A	Matriz de transferência	77
B	Matriz de entrada do sistema	77
C	Matriz de observação	77
D	Matriz de realimentação	77
E_{nom}	Energia nominal	27
E_{max}	Erro máximo	32
$h(\text{SoC}, t)$	Histerese dinâmica	46
$h(t)$	Histerese em função do tempo	46
$i(t)$	Corrente instantânea medida	33
i_{max}	Corrente máxima de descarga (do inglês, Maximum Discharge Current)...	27
i_c	Corrente de carga	34
i_d	Corrente de descarga	34
I_{test}	Corrente do teste	69
$M(\text{SoC}, \dot{\text{SoC}})$	Função de polarização máxima do SoC	46
N_{cycle}	Ciclo de vida (do inglês, Life Cycle)	27
P	Matriz de covariância de erro do estado inicial	78
P_{dis}	Potência dissipada	43
P_{demanda}	Potência demandada pelo sistema	31
P_{max}	Máxima potência que a bateria pode fornecer	31
Q	Capacidade de carga total	40
Q_k	Matriz de covariância do ruído do processo	78
R_k	Matriz de covariância do ruído de medição	79
SoC	Estado da carga no instante de tempo t	33
SoC_{t_0}	Estado inicial da carga	33
t	Tempo do teste	69
t_c	Tempo de carga	34
t_d	Tempo de descarga	34
u_k	Entrada de controle	78
V_{test}	Tensão do teste	69
W	Watts	31
Li^+	Íons de Lítio	25
$\#$	Número de ciclos de vida	27
LPF	Fosfato de Ferro-Lítio (do inglês, Lithium Iron Phosphate)	65
NiMH	Hidreto metálico de níquel (do inglês, <i>Níquel-hidreto metálico</i>)	17
A	Ampere	27
Ah	Ampere-hora	26
C	Taxa de descarga	26
Cn	Capacidade nominal	26
Em	Tensão de circuito aberto nas <i>toolbox</i> de identificação do modelo	71
K	Kelvin	63

LiFePO4	Lítio Ferro Fosfato	33
mAh	miliAmperes-hora	40
ms	Milisegundos	57
P	Potência instantânea que a bateria pode fornecer.	31
R0	Resistência interna da célula.	42
RC	Resistor-capacitor	44
T	Temperatura	72
V	voltios ou volts	26
V(t)	Tensão terminal da célula	40
V1	Tensão de difusão	43
V _{cut-off}	Tensão de corte	26
V _{esta}	Variação de tensão em estado estacionário	45
VH	Tensão de histerese total	47
Vh	Tensão de histerese linear	46
VS	Tensão de histerese instantânea	47
Wh	Watts-hora	27

Sumário

1	INTRODUÇÃO	17
1.1	Motivação	19
1.2	Contribuições e objetivos	20
1.2.1	Objetivo geral	21
1.2.2	Objetivos específicos	21
1.3	Estrutura da dissertação	23
2	FUNDAMENTAÇÃO TEÓRICA	24
2.1	Relevância e contribuições das baterias na era atual	24
2.2	Funcionamento e fenômenos internos das baterias	25
2.2.1	Terminologias referentes às baterias	26
2.3	Sistema de gerenciamento da bateria (BMS)	27
2.3.1	Balanceamento das células	28
2.3.2	Estado de saúde (SoH)	29
2.3.3	Estado de Funcionalidade	30
2.3.4	Estado da carga (SoC)	31
2.4	Métodos para estimação do SoC	32
2.4.1	Tabela de Consulta (LUT)	33
2.4.2	Coulomb Counting (CC)	33
2.4.3	Tensão de circuito aberto (OCV)	34
2.4.4	Método baseado em filtro kalman estendido (EKF)	35
2.5	Caracterização híbrida de potência por pulsos	36
2.6	Modelagem da bateria	37
2.6.1	Modelos empíricos	38
2.6.2	Modelos eletroquímicos	38
2.6.3	Modelos baseados em aprendizado de máquina	39
2.6.4	Modelos híbridos	39
2.6.5	Modelo de Circuito Equivalente (ECM)	39
2.7	Validação de modelo	48
2.7.1	Testes de ajuste FIT	49
2.7.2	Métrica VAF	49
2.7.3	Estado da arte e resultados da literatura sobre a estimativa do SoC nas LIB associado ao BMS adaptativo	50
3	MATERIAIS E MÉTODOS	56
3.1	Materiais	56

3.1.1	Sistema computacional para aquisição de dados e controle de testes no MATLAB <i>Simulink</i>	57
3.1.2	Placa de aquisição de dados NI SCB-68A da <i>National Instruments</i>	61
3.1.3	Sistema de comutação	62
3.1.4	Monitoramento de temperatura	63
3.1.5	Incubadora refrigerada com alternância de temperatura	63
3.1.6	Fonte de alimentação	64
3.1.7	Células usadas nos experimentos	65
3.1.8	<i>Toolbox Battery Modeling</i> de MATLAB	66
3.2	Métodos	66
3.2.1	Caracterização da célula	68
3.2.2	Identificação do sistema	69
3.2.3	Validação do modelo implementado	72
3.2.4	Estimativa do SoC pelo método do CC	75
3.2.5	Modelo matemático representado em espaço de estados	77
3.2.6	Implementação do <i>EKF</i>	78
3.2.7	Validação do <i>EKF</i>	81
4	RESULTADOS	84
4.1	Caraterização da célula	84
4.2	Identificação dos parâmetros do <i>ECM</i>	87
4.3	Validação do modelo	93
4.4	Estimativa do SoC pelo método CC	97
4.5	Implementação do <i>EKF</i>	98
4.5.1	Validação do <i>EKF</i>	103
5	CONCLUSÕES	108
	REFERÊNCIAS	112

1 Introdução

No cenário atual, onde o desenvolvimento de tecnologias para reduzir a poluição atmosférica, os gases de efeito estufa e melhorar o armazenamento de energia de forma eficiente é prioridade, as baterias assumem um papel indispensável, especialmente nos setores de veículos elétricos (*EV* do inglês, *Electric Vehicles*), veículos elétricos híbridos (*HEV* do inglês, *Hybrid Electric Vehicles*) e no armazenamento de energia de fontes renováveis [1]. Dessa forma, elas ganharam uma relevância significativa devido à sua alta eficiência e densidade energética, tornando-se uma fonte de energia confiável.

Embora as baterias não gerem energia, elas desempenham um papel essencial no armazenamento e fornecimento de energia de forma eficiente [2]. Elas são compostas por duas ou mais células e utilizam reações químicas durante os processos de carga e descarga, um processo conhecido como oxirredução [3]. Existem diversas tecnologias de baterias disponíveis comercialmente, que se diferenciam pela capacidade de armazenamento, tolerância à descarga profunda e perfil de carga necessário [4]. Devido a isso, as baterias mais adotadas são as de íon-lítio (*LIB* do inglês, *Lithium-ion Batteries*), chumbo-ácido e níquel-hidreto metálico (*NiMH* do inglês, *Nickel-Metal Hydride*).

As *LIB* são um dos dispositivos de armazenamento de energia mais promissores devido às tecnologias que possuem, por exemplo, peso leve, alta densidade de energia e alta potência específica [5]. No desenvolvimento dessas tecnologias, muitos fabricantes têm se concentrado em desenvolver estratégias para prolongar os ciclos de vida, aumentar a densidade de energia e potência, ao mesmo tempo garantindo a segurança e estabilidade das baterias [6]. De acordo com *Ultimate Bimmer Service* [7] e Winter [8], para contribuir para a proteção das baterias, são necessários certos cuidados, como evitar sobrecarga, descargas profundas e operar em temperaturas elevadas.

Para contribuir para a prolongação da vida útil das baterias e equilibrar a distribuição energética em cada uma das células que as compõem, é necessário implementar um sistema de gestão de baterias, conhecido como *BMS* (do inglês, *Battery Management System*). Este sistema assume uma importância crucial ao garantir a segurança, longevidade e desempenho ideal das baterias, além de controlar de forma otimizada sua carga e descarga [9]. O *BMS* realiza medições diretas de tensão, corrente e temperatura utilizando sensores, ao mesmo tempo em que é capaz de estimar grandezas que não podem ser medidas diretamente, como o estado de saúde (*SoH* do inglês, *State of Health*), o estado de funcionalidade (*SoF* do inglês, *Functionality Status*) e o estado de carga (*SoC* do inglês, *State of Charge*) [10].

O *SoC* é definido como a relação entre a quantidade de carga disponível armazenada em um determinado instante de tempo e a carga máxima (ou nominal) que pode ser contida na bateria. Trata-se de uma medida crucial para o desempenho e a utilização das baterias. Contudo, diferentemente de grandezas como tensão e corrente, o *SoC* não pode ser medido diretamente por meio de um sensor, sendo necessário estimá-lo utilizando algoritmos baseados em modelos matemáticos ou dados experimentais. Os autores Purwadi [11] e Xing [12] destacam que essa estimativa apresenta desafios significativos, especialmente em aplicações práticas e do mundo real, devido à complexidade dos fatores que afetam o comportamento das baterias. A dificuldade reside na natureza indireta das técnicas de medição, somada à influência de diversos fatores que afetam o comportamento da bateria, como condições externas e a complexidade do comportamento eletroquímico. Além disso, o uso de algoritmos de estimação que combinam diferentes técnicas e modelos matemáticos acrescenta uma camada adicional de complexidade. Portanto, a estimativa precisa em tempo real do *SoC* tem gerado um interesse significativo entre pesquisadores como, Santos [3], Hui [9], Xing [12], Plett [13], Silva [14], Zhang [15] e Wu [16], os quais têm dedicado esforços significativos para avanços neste campo de estudo.

Atualmente, diversas estratégias têm sido desenvolvidas para enfrentar o desafio da estimação do *SoC* em baterias. Essas estratégias podem ser classificadas em métodos diretos, abordagens baseadas em modelos matemáticos e técnicas de inteligência artificial (IA). Os métodos diretos, como a contagem de Coulomb (*CC* do inglês, *Coulomb Counting*) e a medição da tensão em circuito aberto (*OCV* do inglês, *Open-circuit voltage*), apresentam a vantagem de serem relativamente simples, mas sofrem com limitações, como a acumulação de erro e a necessidade de períodos de repouso prolongados para medições precisas [17] [3]. Já as abordagens baseadas em modelos matemáticos utilizam equações dinâmicas para descrever o comportamento da bateria [13] [18] [19] [20], permitindo maior precisão na estimação do *SoC*. Dentro dessa categoria, destacam-se os estimadores de estados, como o Filtro de Kalman Estendido (*EKF* do inglês, *Extended Kalman Filter*) [21] [22] [23] e o Filtro de Kalman Unscented (*UKF* do inglês, *Unscented Kalman Filter*) [15] [24] [25] [26], amplamente empregados em *BMS* devido à sua capacidade de fornecer estimativas robustas e em tempo real. Por fim, técnicas baseadas em IA, incluindo redes neurais artificiais e aprendizado de máquina, têm ganhado relevância por sua habilidade em lidar com sistemas complexos e não lineares, oferecendo uma alternativa promissora para a estimação do *SoC* [26].

Dentre essas abordagens, os métodos baseados em modelos matemáticos, especialmente aqueles que empregam estimadores de estado, destacam-se pela combinação entre precisão, robustez e viabilidade computacional [19]. Em particular, o modelo de circuito equivalente (*ECM* do inglês, *Equivalent Circuit Model*) tem sido amplamente utilizado na literatura por apresentar um equilíbrio entre simplicidade e representatividade da dinâmica

da bateria [27]. O *ECM* permite a identificação de parâmetros da bateria com base em dados experimentais e pode ser integrado a algoritmos de estimação, como o *EKF*, para melhorar a precisão das estimativas de *SoC*. Essa abordagem oferece vantagens significativas em comparação aos métodos diretos e às técnicas de *IA*, pois combina fundamentos físicos bem estabelecidos com a capacidade de adaptação a diferentes condições operacionais.

Reconhecendo a importância de estimar o *SoC* com o menor erro possível, especialmente em aplicações veiculares, este trabalho se concentra na modelagem da bateria e em sua validação, além da implementação de um algoritmo baseado no *EKF* para melhorar a precisão da estimação. A qualidade dessa estimativa é crucial para determinar corretamente a autonomia de um *EV* e para otimizar funções como a prevenção de riscos nas baterias devido a excessos de temperatura, carga ou descarga [28]. A eficácia do *EKF* depende diretamente da definição adequada das matrizes de covariância, que influenciam a precisão da estimação ao caracterizar os níveis de incerteza do modelo e das medições. Neste trabalho, é proposto um método que propõe um processo de otimização *offline* das matrizes de covariância, permitindo identificar os valores ideais para diferentes temperaturas. Os resultados obtidos são armazenados em tabelas de consulta (*LUT* do inglês, *Look-up Table*), o que reduz significativamente o custo computacional em comparação com abordagens tradicionais que assumem matrizes de covariância fixas [29] [30] [31].

Além disso, este trabalho faz parte de um projeto de maior escala que envolve a colaboração entre diversas universidades e empresas no Brasil. O objetivo principal desse projeto é o desenvolvimento e implementação de um *BMS* adaptável para um veículo elétrico leve, garantindo maior eficiência, segurança e longevidade das baterias. No contexto desse projeto, nossa contribuição está focada na construção de um algoritmo de estimação do *SoC*, utilizando métodos inovadores que permitam ao *BMS* adaptar-se às variações das condições operacionais. A escolha de técnicas avançadas, como o *EKF* para a estimação do *SoC* se justifica pela necessidade de um *BMS* flexível e preciso, capaz de otimizar o desempenho das baterias em um ambiente veicular real.

1.1 Motivação

Em um mundo onde a transição para fontes de energia mais limpas e sustentáveis é imperativa, as *LIB* emergiram como pilares tecnológicos no desenvolvimento de *EV*, *HEV* e sistemas de armazenamento para energias renováveis. Sua capacidade de armazenar energia com alta densidade e eficiência as torna componentes essenciais para enfrentar os desafios globais relacionados à redução das emissões de gases de efeito estufa e à mitigação das mudanças climáticas.

No entanto, o desempenho ideal e a segurança dessas baterias dependem, em grande parte, de sua gestão adequada, na qual a estimativa eficiente do *SoC* desempenha um papel

significativo. Esse parâmetro, que reflete a quantidade de energia disponível na bateria, é crucial para prever a autonomia dos *EV* e evitar riscos associados ao uso inadequado, como sobrecarga, descarga profunda ou temperaturas extremas. Os métodos tradicionais para estimar o *SoC*, como o método de *CC* ou a medição do *OCV*, apresentam limitações significativas em termos de precisão e aplicabilidade em tempo real, especialmente em condições operacionais dinâmicas.

O uso de estratégias avançadas, como o *EKF*, representa uma oportunidade para superar essas limitações, oferecendo uma estimativa mais precisa e confiável ao levar em conta a dinâmica complexa das baterias. No entanto, a eficácia deste filtro depende diretamente da qualidade dos modelos matemáticos utilizados e da calibração adequada de seus parâmetros, como as matrizes de covariância, o que representa um desafio técnico significativo.

Esta pesquisa surge da necessidade de desenvolver soluções eficientes e robustas para a estimativa do *SoC*, considerando as variações nas condições ambientais, especialmente a temperatura. Com esse objetivo, foi implementado um *EKF* otimizado, no qual as matrizes de covariância são previamente identificadas por meio de um processo de otimização. Os valores resultantes são organizados em uma *LUT*, que permite acessar rapidamente os parâmetros otimizados conforme a condição térmica. Essa abordagem contribui para a redução do custo computacional e viabiliza a implementação do algoritmo em sistemas embarcados voltados para aplicações práticas.

Adicionalmente, este trabalho aborda um desafio técnico relevante, com potencial para contribuir com o avanço do conhecimento na gestão de baterias, apoiando a transição para sistemas de energia mais sustentáveis e confiáveis. A combinação de modelagem, experimentação e otimização nesta pesquisa oferece uma abordagem integral que pode servir de base para futuros desenvolvimentos tecnológicos na área de gerenciamento de baterias.

1.2 Contribuições e objetivos

Este trabalho busca contribuir de maneira significativa para o campo da estimativa do *SoC*, apresentando um método estruturado e detalhado que abrange os processos essenciais para obter uma estimativa robusta e confiável. Inicialmente, são realizados testes de corrente pulsada para caracterizar a resposta dinâmica da bateria em diferentes condições operacionais. Em seguida, procede-se à identificação de um modelo *ECM* que represente fielmente o comportamento real da bateria, considerando suas características dinâmicas. Após a definição do modelo, realiza-se sua validação por meio da comparação entre os resultados simulados e os dados experimentais, assegurando sua precisão. Finalmente, o método de estimativa de *SoC* é otimizado, ajustando as matrizes de covariância para maximizar a precisão do *EKF*. Embora este estudo se concentre exclusivamente no *EKF*, os resultados

obtidos demonstram um desempenho notável, consolidando-se como uma contribuição relevante para a literatura da área.

Uma das principais contribuições desta pesquisa é a implementação de um processo de otimização focado na identificação dos valores ideais para as matrizes de covariância (Q_k , P e R_k), elementos essenciais para o funcionamento do *EKF*. Como apontado por autores como Plett [13], Silva [14] e Khanum [30], a precisão deste filtro depende fortemente dessas matrizes, uma vez que refletem as incertezas associadas tanto ao modelo quanto às medições. Incorporar esse processo na estimativa do *SoC* confere ao filtro características adaptativas, aumentando sua robustez e confiabilidade diante de variações nas condições operacionais.

Além disso, este trabalho também aborda de forma abrangente os aspectos fundamentais do processo de estimativa, incluindo a realização de testes de caracterização para obter parâmetros-chave da bateria, a identificação do *ECM* por meio de técnicas de ajuste e a validação do modelo com dados experimentais utilizando simulações no MATLAB-Simulink. Esses passos garantem o desenvolvimento de um algoritmo eficiente e preciso, proporcionando não apenas uma solução prática para a estimativa do *SoC* com *EKF*, mas também um guia sistemático que pode servir como referência para futuras pesquisas na área.

1.2.1 Objetivo geral

Desenvolver um algoritmo para a estimativa do *SoC* em *LIB*, utilizando o *EKF* com um método de otimização para identificar os valores ideais das matrizes de covariância em diferentes temperaturas. A abordagem proposta visa melhorar a precisão e a confiabilidade da estimativa, reduzindo erros acumulativos e aumentando a robustez do algoritmo diante de variações operacionais, tornando sua implementação viável para aplicações em *BMS*.

1.2.2 Objetivos específicos

- Realizar testes de corrente pulsada (*HPPC*) em laboratório para obter dados experimentais que permitam identificar o comportamento da bateria sob diferentes condições de operação.
- Estimar os parâmetros do *ECM*, incluindo resistências internas, capacitâncias e *OCV*, a partir dos dados obtidos nos testes de caracterização da bateria. A estimativa desses parâmetros é realizada por meio de um processo de otimização.
- Validar o *ECM* por meio de simulações realizadas no MATLAB-Simulink, avaliando a eficiência do modelo em replicar o comportamento real da bateria.
- Implementar a estimativa do *SoC* utilizando o método de *CC* como referência para comparar o desempenho com outras técnicas de estimativa.

- Desenvolver e implementar um *EKF*, que, por meio de um processo de otimização baseado na função *Fmincon* do MATLAB, identifique os valores ideais das matrizes de covariância para uma estimativa do *SoC* precisa e robusta. A função objetivo do processo de otimização baseia-se na minimização do erro quadrático médio (*RMSE*) entre as estimativas do *EKF* e os dados reais.
- Validar o *EKF* implementando cenários que simulam condições reais de operação, avaliando seu desempenho e sua robustez em relação às variações de medição da bateria.

1.3 Estrutura da dissertação

A presente dissertação está organizada em seis capítulos, estruturados de forma a abordar gradualmente os aspectos necessários para o desenvolvimento e validação do algoritmo de estimação do *SoC*. Cada capítulo está interligado, formando uma sequência lógica que vai desde a fundamentação teórica até as conclusões e projeções futuras.

A Figura 1 apresenta a organização dos capítulos, disposta de menor para maior complexidade, destacando as principais etapas abordadas neste trabalho: revisão bibliográfica, pesquisa científica com os resultados obtidos e, por fim, as limitações e projeções relacionadas à pesquisa desenvolvida.




Figura 1 – Estrutura da Dissertação: Organização dos capítulos em ordem crescente de complexidade.

2 Fundamentação teórica

Neste capítulo, apresentam-se os fundamentos teóricos que sustentam o desenvolvimento desta pesquisa, proporcionando o contexto necessário para compreender os aspectos essenciais relacionados às *LIB*, seus fenômenos internos e os conceitos-chave associados ao design e implementação de um *BMS*. Dada a crescente relevância dessas baterias em aplicações críticas, como *EV* e armazenamento de energias renováveis, é fundamental estabelecer uma base sólida que abranja tanto a caracterização das baterias quanto os métodos de estimativa do *SoC*.

Foram abordados aspectos técnicos que incluem a descrição dos fenômenos eletroquímicos internos, as terminologias mais relevantes para o gerenciamento de baterias e os princípios subjacentes à estimativa do *SoC*. Entre os métodos discutidos, destacam-se a integração da corrente por meio da técnica *CC*, o uso da tensão de *OCV* e a implementação do *EKF*, que constitui o principal enfoque deste trabalho.

2.1 Relevância e contribuições das baterias na era atual

A implementação das baterias gera inúmeros benefícios em setores como o automotivo e o armazenamento de fontes renováveis. No setor automotivo, o surgimento de *EV* e *HEV* impulsionados por *LIB* tem contribuído para a redução significativa da poluição ambiental em comparação com os veículos de combustão interna, já que os primeiros não emitem gases de efeito estufa [32]. Estudos indicam que, ao longo de seu ciclo de vida, os *EV* podem apresentar uma emissão de carbono menor do que os tradicionais [32] [33]. Além disso, as baterias apresentam alta eficiência, permitindo um armazenamento e uma utilização mais eficaz da energia. Elas convertem uma maior porcentagem da energia proveniente da rede em movimento, minimizando perdas na forma de calor [34] [35].

No setor das energias renováveis, o uso de baterias proporciona estabilidade e confiabilidade à rede, atuando como um amortecedor que oferece serviços auxiliares, como a regulação de frequência e a resposta à demanda, as quais são vitais para o funcionamento eficiente das redes elétricas modernas [34] [36]. Além da aplicação da chamada segunda vida das baterias, que consiste em utilizar as baterias usadas como fontes de armazenamento secundárias em residências e empresas, o que prolonga sua vida útil em mais 10 a 15 anos. Essa reutilização pode reduzir significativamente a demanda por novas baterias e diminuir o impacto ambiental geral associado à sua produção [33] [36]. Entretanto, essa reutilização não é viável no caso dos combustíveis fósseis.

2.2 Funcionamento e fenômenos internos das baterias

Uma bateria é definida como uma ou mais células eletroquímicas (unidade básica que armazena e libera energia) em contato elétrico, capazes de converter energia química em energia elétrica através de reações eletroquímicas [37] [38]. Existem dois tipos de baterias, as baterias primárias e as baterias secundárias. As baterias primárias são desenvolvidas para armazenar energia elétrica até o seu esgotamento, momento em que devem ser descartadas. Por outro lado, as baterias secundárias, também conhecidas como recarregáveis, têm a capacidade de restaurar sua energia original aplicando uma corrente elétrica em direção oposta ao fluxo de corrente durante a descarga, o que permite seu uso repetido [8].

As baterias de íon-lítio são compostas por dois eletrodos (ânodo e cátodo), um eletrólito, um separador e um coletor de corrente, formando um sistema altamente eficiente para o armazenamento e a conversão de energia. A Figura 2 apresenta a estrutura fundamental de uma célula de *LIB*, destacando os componentes essenciais responsáveis pelo transporte e armazenamento de carga. Durante os ciclos de carga e descarga, ocorrem diversos processos eletroquímicos que influenciam diretamente a dinâmica da bateria, afetando seu desempenho e vida útil. Esses fenômenos são influenciados por fatores externos, como temperatura, regime de operação e tempo de uso, além de características intrínsecas da bateria, como o *SoC*, o *SoH* e o *SoF* [3].

Os fenômenos internos das baterias envolvem diversos processos eletroquímicos e mudanças físicas que ocorrem durante seu funcionamento, sendo fundamentais para determinar sua eficiência, dinâmica e características de desempenho. Durante a descarga de uma *LIB*, ocorre uma reação eletroquímica em que o ânodo se oxida, liberando elétrons e íons de lítio (Li^+) para o eletrólito, enquanto o cátodo se reduz, aceitando esses elétrons e íons. Durante a carga, esse processo é invertido, com os Li^+ se movendo do cátodo para o ânodo. O transporte dos Li^+ por meio do eletrólito, que pode ser líquido, em gel ou sólido, dependendo do tipo de bateria, é essencial para manter o equilíbrio de carga e viabilizar as reações eletroquímicas [39].

A transferência de carga, representada pela passagem de elétrons entre os eletrodos e o eletrólito, afeta diretamente a eficiência e o desempenho das células. A resistência interna, determinada pela condutividade dos eletrodos e do eletrólito, pode resultar em perdas de energia levando à dissipação de calor no funcionamento da bateria. Além disso, a temperatura exerce um papel crucial, pois temperaturas elevadas podem acelerar as reações e o processo de degradação, enquanto temperaturas baixas tendem a retardar essas reações e reduzir a capacidade da bateria [8]. Esses processos são cruciais para o desempenho, a eficiência e a longevidade das *LIB* recarregáveis, especialmente em aplicações como os *EV* [39].




Figura 2 – Movimento dos Li^+ : Equilíbrio dos electrões durante os ciclos de carga e descarga de uma LIB. Adaptado de [40].

2.2.1 Terminologias referentes às baterias

Ao longo do documento, são abordados termos técnicos essenciais que descrevem as particularidades das baterias. Para facilitar a compreensão desses termos, a Tabela 1 apresenta os respectivos conceitos.

Tabela 1 – Terminologia referente às baterias com as especificações técnicas, nomenclatura e a sua definição [41] [42] [43].

Especificações técnicas	Nomenclatura	Unidade	Definição
Tensão nominal	V_{nom}	V	Tensão de referência da bateria, também considerada como a tensão “normal” da bateria. É medida entre os terminais da bateria quando uma carga é aplicada
Tensão de corte	$V_{cut-off}$	V	A tensão mínima permitida. Essa tensão é a tensão que geralmente define o estado “sem carga” da bateria.
Taxa de descarga	C	Ah	A taxa de descarga de uma bateria, expressa como C , indica quão rápido ela carrega ou descarrega em relação à sua capacidade máxima. 1C significa que a bateria é descarregada completamente em 1 hora.
Capacidade nominal	C_n	Ah	A quantidade total de ampere-hora disponível quando a bateria é descarregada a uma determinada corrente de descarga

Continuação da Tabela 1.

			(especificada como C_{rate}) desde 100% do SoC até a tensão de corte.
Energia nominal	E_{nom}	Wh	A quantidade total de watts-hora disponível quando a bateria é descarregada a uma determinada C_{rate} desde 100% do SoC a $V_{\text{cut-off}}$.
Ciclo de vida	N_{cycle}	#	A quantidade de ciclos de carga e descarga que a bateria pode experimentar antes de deixar de cumprir com critérios de desempenho específicos. O ciclo de vida é calculado para condições específicas de carga e descarga.
Corrente máxima de descarga contínua	i_{max}	A	A corrente máxima de descarga contínua de uma bateria é o limite estabelecido pelo fabricante para evitar danos ou diminuição da capacidade devido a taxas de descarga excessivas.
Profundidade de descarga	DoD	%	A profundidade de descarga (DoD do inglês, Depth of Discharge) representa a porcentagem da capacidade total da bateria que foi utilizada em relação à sua capacidade máxima. Quando a descarga atinge ou ultrapassa 80% do DoD , ela é classificada como uma descarga profunda.

2.3 Sistema de gerenciamento da bateria (*BMS*)

O *BMS*, sendo um sistema eletrônico integrado, é projetado para a supervisão, gestão e otimização do desempenho de um pacote de baterias recarregáveis, garantindo sua segurança. Este componente é amplamente utilizado em veículos, sistemas de alimentação ininterrupta e dispositivos portáteis de uso diário [44]. Seu funcionamento consiste em medir grandezas como corrente, tensão e temperatura em cada bateria. Essas medições são analisadas para garantir a segurança e a confiabilidade do sistema. Entre suas principais funções destacam-se [45].

- Proteção de segurança: O *BMS* garante a segurança do pacote de baterias e de seu operador ao detectar condições de funcionamento irregulares, como sobrecarga, DoD ,

sobrecorrente e temperaturas extremas. O sistema desconecta as baterias da carga, quando é necessário, para prevenir danos ou situações de risco.

- Capacidade de estimação: Mede parâmetros críticos como as tensões de cada célula, a temperatura dos módulos e a corrente do pacote de baterias. Esses dados são essenciais para estimar outros parâmetros que incluem o *SoC*, *SoF*, *SoH* e realizar o balanceamento das células.
- Gestão do desempenho: Calcula os limites energéticos disponíveis no pacote de baterias, garantindo um funcionamento dentro de parâmetros seguros e eficientes. Além disso, gerencia as condições térmicas das células para prolongar sua vida útil.
- Comunicação: Fornece informações ao usuário sobre o estado das baterias e qualquer evento atípico, realizando diagnósticos.

Em geral, o *BMS* desempenha uma função fundamental para garantir a confiabilidade, a segurança e a durabilidade dos sistemas de bateria, especialmente em aplicações que usam *LIB*. Conforme mencionado acima, o *BMS* é capaz de estimar os principais parâmetros, como *SoC*, *SoF* e *SoH*, além de realizar o balanceamento das células. Para contextualizar a relevância desses parâmetros na operação do *BMS*, seus principais características e funções são detalhados a continuação.

2.3.1 Balanceamento das células

As baterias modernas possuem capacidades impressionantes de armazenamento de energia, mas as tensões e capacidades de corrente de cada célula individual são relativamente limitadas [46]. Para atender aos requisitos de tensão e corrente necessários em diversas aplicações, utiliza-se uma configuração na qual as células de lítio são conectadas em série e em paralelo [47]. No entanto, fatores como a não uniformidade de temperatura e as discrepâncias de carga entre as células podem afetar significativamente o desempenho e a durabilidade das baterias. Esses fatores resultam em operações desiguais que podem levar a problemas sérios, como redução da vida útil da bateria e queda no desempenho geral do sistema [48] [49]. Por isso, é crucial implementar estratégias de balanceamento entre as células, assegurando que todas operem de forma uniforme. Isso evita que as células mais fracas limitem a corrente de carga e descarga do sistema, promovendo maior eficiência e confiabilidade [46] [49] [50].

O *BMS* é responsável por realizar a equalização das cargas entre as células quando a tensão de qualquer uma delas começa a apresentar uma diferença significativa. Esse processo é utilizado para balancear as tensões entre as células de uma bateria, além de ser vital para garantir o uso eficiente e seguro das baterias e prolongar sua vida útil. [50]. Dessa maneira, o balanceamento das células pode ser abordado a partir de três estratégias

principais, equalização baseada na uniformidade da tensão, no equilíbrio do *SoC* ou na estimativa da capacidade restante [49].

O balanceamento das células nos *BMS* pode ser realizado de duas maneiras principais. O balanceamento ativo, também chamado de não dissipativo, redistribui a energia entre as células para igualar seu *SoC*. Esse processo é realizado por meio de componentes sofisticados, como transformadores, indutores ou capacitores, para transferir energia das células de maior tensão para as de menor tensão (Figura 3a). O outro método, conhecido como balanceamento passivo ou dissipativo, consiste na descarga do excesso de carga das células que atingiram uma tensão mais alta. Isso é normalmente realizado utilizando resistores que desviam a corrente das células de maior tensão (Figura 3b), de modo que as células de menor tensão podem continuar a se carregar [51] [52]. Para uma melhor compreensão desse processo de balanceamento, é apresentada a Figura 3.




Figura 3 – Balanceamento ativo e passivo e comportamento energético de células de bateria desequilibradas.

2.3.2 Estado de saúde (*SoH*)

Este parâmetro fornece uma avaliação da condição geral e do desempenho das baterias em relação às suas especificações originais. Reflete a capacidade da bateria de armazenar e fornecer energia em comparação com quando era nova [49], desde o início da vida útil (*BoL* do inglês, *Beginning of Life*) até o fim da vida útil (*EoL* do inglês, *End of Life*) [43]. O *SoH* pode ser expresso como a porcentagem da capacidade atual da bateria em relação à sua

capacidade nominal original. Por exemplo, se uma bateria com capacidade inicial de 100 Ah, após meses de uso, apresentar uma capacidade de 80 Ah, seu *SoH* seria de 80% [45].

Como destaca Plett [45], existem vários fatores principais que afetam o percentual de *SoH*, sendo um dos mais importantes a quantidade de ciclos de carga e descarga a que a bateria é submetida. Pois cada ciclo contribui para o desgaste e a degradação da bateria. A temperatura também desempenha um papel fundamental, o uso das baterias em temperaturas extremas acelera sua degradação e afeta significativamente o *SoH*, da mesma forma, as baixas temperaturas podem reduzir seu desempenho. Outro fator relevante é o uso inadequado das baterias, incluindo sobrecarga e profundidade de descarga. Reduzir a exposição das baterias a essas condições pode ajudar a prevenir danos significativos.

À medida que a bateria envelhece, não só seu percentual de *SoH* diminui, mas também sua resistência interna aumenta, o que pode afetar seu desempenho. Considerando que uma maior resistência interna pode resultar em menor eficiência e no aumento da geração de calor durante a carga e a descarga [45].

2.3.3 Estado de Funcionalidade

O Estado de Funcionalidade (*SoF*) é um parâmetro que representa a relação entre a potência demandada pela carga e a potência armazenada na bateria. Ele indica a capacidade da bateria de suprir a demanda de potência da carga em um determinado instante de tempo, considerando limitações operacionais e condições de uso. Um *SoF* elevado sugere que a bateria é capaz de atender à demanda energética do sistema com eficiência, enquanto um *SoF* reduzido pode indicar que a bateria está próxima de seus limites operacionais [53]. Este parâmetro é especialmente relevante em aplicações onde o fornecimento de energia deve ser preciso e confiável, como nos *EV*, onde a bateria deve atender tanto à demanda de potência do sistema de propulsão quanto aos sistemas auxiliares e de conforto, como o ar condicionado, entre outros [49]. Portanto, o *SoF* é crucial para garantir que a bateria possa fornecer energia suficiente aos diferentes sistemas.

O monitoramento do *SoF* é crucial para garantir operações seguras e eficientes, pois um *SoF* baixo pode indicar que a bateria não está em condições de atender às demandas do sistema, o que poderia resultar em falhas ou em uma experiência insatisfatória para o usuário [14]. Existem vários fatores que influenciam significativamente o comportamento do *SoF*, como a impedância da bateria, que afeta diretamente sua capacidade de fornecer energia rapidamente, junto com o *SoC*, que impacta a capacidade de entrega de energia. Além disso, as temperaturas externas podem afetar o desempenho da bateria e, consequentemente, o *SoF* [45].

O *SoF* pode ser calculado por meio da Equação 2.1, que relaciona a potência que a bateria pode fornecer com a potência demandada. Sendo que o resultado pode ser representado

da seguinte forma, para $P = P_{max}$, então $SoF=1$; indicando que a bateria está operando na capacidade máxima. Para $P = P_{demanda}$, então $SoF=0$; o que significa que só pode fornecer exatamente a potência exigida. Para $P < P_{demanda}$, então SoF seria negativo; indicando que a bateria não pode atender à demanda de energia. E finalmente, com $0 < SoF < 1$; possibilita que a bateria forneça mais energia do que está sendo exigido, mas sem atingir sua capacidade máxima. Essa formulação torna possível avaliar o desempenho da bateria em tempo real e otimizar seu uso em sistemas elétricos [49].

$$SoF = \frac{P - P_{demanda}}{P_{max} - P_{demanda}} \quad . \quad (2.1)$$

Onde P , é a potência $[W]$ que a bateria pode suportar; $P_{demanda}$, é a potência demandada pelo sistema $[W]$; e P_{max} , é a máxima potência que a bateria pode fornecer $[W]$.

2.3.4 Estado da carga (SoC)

O SoC é um parâmetro fundamental que indica o nível de carga atual de uma bateria em relação à sua capacidade total, funcionando de maneira análoga aos indicadores de combustível em veículos movidos por combustíveis fósseis [54]. Geralmente expresso como uma porcentagem, o SoC varia de 0% (descarga completa) até 100% (bateria totalmente carregada). Sua relevância nos sistemas de *BMS* tornou-se cada vez mais evidente nas últimas décadas, devido ao papel essencial que desempenha na gestão eficiente e segura das baterias [55].

A estimativa precisa do SoC não apenas desempenha um papel central na gestão de energia, evitando sobrecarga ou descarga excessiva que possam comprometer a funcionalidade e a longevidade do sistema, mas também está diretamente ligada à segurança operacional. Além disso, operar a bateria fora dos limites recomendados pode resultar em condições perigosas, como a fuga térmica, colocando em risco a integridade do sistema. Portanto, o monitoramento contínuo e preciso do SoC é indispensável para garantir a confiabilidade, a eficiência e a sustentabilidade dos sistemas de baterias [45].

A estimativa deste parâmetro é um dos principais desafios para o funcionamento bem-sucedido dos *EV*, já que é um parâmetro que não pode ser observado diretamente devido às características não lineares, ao envelhecimento das células, à variabilidade da temperatura, às reações eletroquímicas e aos ciclos de carga e descarga [56]. Por isso, este parâmetro deve ser estimado utilizando diversos métodos atualmente disponíveis, como a medição da tensão, a integração da corrente, a espectroscopia de impedância e métodos baseados em estimadores como o filtro de Kalman e suas variações [45].

2.4 Métodos para estimação do SoC

Existem diversos métodos, cada um com suas vantagens e limitações, que variam de acordo com a complexidade do sistema e a precisão desejada. Esta subseção explora as principais abordagens utilizadas para a estimação do *SoC*, discutindo seus princípios, aplicações e limitações.

A estimativa do *SoC* pode ser realizada por diferentes métodos, cada um com fundamentos específicos e variações em precisão e erro máximo. A Tabela 2 apresenta uma comparação das principais abordagens utilizadas na literatura para a estimação do *SoC* em *LIB* aplicadas a *EV*. Os métodos estão organizados de acordo com os fundamentos utilizados, incluindo *LUT*, integração da corrente e algoritmos baseados em filtros. Além disso, a tabela informa o erro máximo E_{max} associado a cada método, permitindo avaliar e comparar o desempenho relativo de cada abordagem.

Tabela 2 – Tendências atuais para a estimativa do *SoC* em *EV* com *LIB* (E_{max} : Erro máximo).

Fundamentos utilizados	Método	E_{max} [%]	
<i>LUT</i>	<i>OCV</i>	1,20	[57]
	Impedância	1,40	[58]
Ampere-hora integral	Integral da corrente	4,00	[59]
Filtros	Linear Kalman	2,00	[60]
	Kalman estendido	1,40	[61]
	Kalman adaptativo	2,00	[62]
	Ponto Sigma Kalman	1,20	[63]
	<i>Unscented Kalman</i>	0,12	[15]
	Kalman adaptativo <i>unscented</i>	0,10	[64]
	Diferença central Kalman	1,40	[65]
	Kalman cubatura	2,70	[66]
	Partícula	0,86	[67]
	Partícula <i>Unscented</i>	0,90	[68]
	Partícula de cubatura	1,10	[68]
Observador	<i>Luenberger</i>	0,88	[69]
	<i>Sliding mode</i>	2,00	[70]
	Integral proporcional	2,50	[71]
	H-infinito	3,36	[72]
Baseado em dados	Algoritmo genético	2,98	[73]
	Máquinas de vetor de suporte	6,00	[74]
	Rede neural	3,80	[75]

Adaptado de [76].

2.4.1 Tabela de Consulta (*LUT*)

As *LUT* são ferramentas fundamentais para a estimativa do *SoC*, especialmente em aplicações onde precisão e rapidez são prioridades, essas tabelas estabelecem uma correlação direta entre as medições de tensão e os níveis do *SoC*, permitindo que os *BMS* realizem estimativas rápidas e confiáveis do *SoC* atual [31]. Por exemplo, ao medir a tensão de uma célula, consulta-se a *LUT* para identificar o percentual do *SoC* correspondente, facilitando decisões críticas relacionadas aos processos de carga e descarga.

Essa abordagem é particularmente eficaz em *LIB* e Lítio Ferro Fosfato (LiFePO_4), pois essas tecnologias apresentam variações significativas de tensão em função do *SoC* [77]. A implementação de tabelas de consulta de tensão não apenas otimiza o desempenho operacional das baterias, mas também prolonga sua vida útil ao evitar descargas profundas e garantir que os níveis de carga permaneçam dentro de faixas ideais [31].

Além disso, as *LUT* não se limitam a serem ferramentas práticas para a estimativa do *SoC*, elas podem ser integradas a algoritmos avançados, como o *KF*, para aprimorar ainda mais a precisão das estimativas. Essa integração possibilita a combinação de dados históricos com medições em tempo real, resultando em uma solução robusta, eficiente e adaptativa para a gestão avançada de baterias em diversas aplicações [78].

2.4.2 Coulomb Counting (*CC*)

O método de *CC* é amplamente utilizado para a estimativa do *SoC* devido à sua implementação simples e direta. Ele se baseia na integração da corrente que entra e sai da bateria ao longo do tempo, assumindo que a variação do *SoC* é proporcional à quantidade de carga transferida. Essa abordagem é expressa matematicamente pela Equação 2.2.

No entanto, apesar de sua simplicidade, o método apresenta limitações significativas. Pequenos erros de medição nos sensores de corrente são acumulados ao longo do tempo, resultando em um desvio progressivo na estimativa do *SoC*. Esse erro tende a se amplificar em períodos prolongados de operação, especialmente na ausência de um mecanismo de correção, como calibração periódica ou fusão com outras técnicas de estimativa. Dessa forma, embora seja um método eficiente em curto prazo, sua precisão pode ser comprometida em aplicações de longa duração.

$$SoC(t) = SoC_{t_0} - \frac{1}{C_n} \int_{t_0}^t \eta i(t) dt \quad . \quad (2.2)$$

Onde $SoC(t)$, é o *SoC* no instante de tempo t ; SoC_{t_0} , é o estado inicial da carga; C_n , capacidade nominal da bateria; $i(t)$, corrente medida no instante t ; e η , eficiência de Coulomb. O valor inicial SoC_{t_0} pode ser determinado por meio de métodos como a medição do *OCV* ou por meio de uma abordagem de estimativa de estados, como o *EKF* [79]. A capacidade

nominal da bateria pode ser calculada por meio de experimentos de laboratório nos quais a célula é carregada e descarregada completamente, ou pode ser fornecido pelo fabricante [80]. E finalmente, η relaciona a carga total extraída da bateria com a carga total introduzida durante um ciclo completo, varia durante os processos de carga e descarga devido a fatores como o *SoH*, a temperatura e a corrente aplicada. Sendo calculada através da Equação 2.3.

$$\eta = \frac{\int_0^{t_d} i_d dt}{\int_0^{t_c} i_c dt} . \quad (2.3)$$

Onde i_d , é a corrente de descarga; i_c , é a corrente de carga; t_d , é o tempo de descarga; e t_c é o tempo de carga. Para a simplificação dos cálculos, o parâmetro n geralmente assume um valor de 1 durante a descarga e um valor de 0,998 durante a carga [3].

2.4.3 Tensão de circuito aberto (OCV)

A *OCV* é um parâmetro fundamental para caracterizar células eletroquímicas, como as *LIB*, sendo definida como a tensão medida entre os terminais da célula quando o equilíbrio termodinâmico é atingido, ou seja, quando não há fluxo de corrente e as reações químicas internas cessaram. Entretanto, identificar se uma célula está em equilíbrio não é um processo simples, já que esse estado requer um período prolongado de repouso [81]. Por essa razão, na prática, a medição da *OCV* é realizada após um tempo significativo de estabilização, permitindo uma estimativa precisa da capacidade restante da bateria.

O uso da *OCV* é amplamente reconhecido como um método simples para estimar o *SoC*, devido à relação existente entre esses dois parâmetros. No entanto, essa relação é não linear, o que significa que mudanças no *SoC* não resultam em variações proporcionais no *OCV*, como pode ser visto na Figura 4. A natureza não linear da curva *SoC-OCV* torna inviável uma estimativa direta baseada exclusivamente na *OCV*. Além disso, o tempo requerido para atingir o equilíbrio termodinâmico limita a aplicação desse método em situações específicas, como quando a bateria está em repouso, como ocorre em veículos estacionados [81] [82].

Dado que o método baseado na *OCV* apresenta limitações, como a necessidade de períodos prolongados de estabilização e sua dependência de condições ideais, ele é frequentemente combinado com técnicas complementares, como o método de *CC*. Enquanto a *OCV* fornece uma visão instantânea do estado da célula em condições de repouso, o *CC* monitora os fluxos de carga e descarga ao longo do tempo, mitigando erros acumulativos. A combinação desses métodos melhora significativamente a precisão na estimativa do *SoC*, especialmente em cenários dinâmicos onde não é viável aguardar a estabilização da *OCV* [83].

Apesar de ser um método confiável em circunstâncias específicas, a forte dependência da *OCV* em relação ao tempo de repouso e a variabilidade da sua relação com o *SoC* ao




Figura 4 – Relação de descarga não linear entre OCV e o SoC de uma LIB 18650 a uma temperatura de $30\text{ }^{\circ}\text{C}$.

longo do ciclo de vida da bateria, representam desafios significativos para sua aplicação em sistemas de gestão de baterias. Essas limitações ressaltam a importância de integrá-lo a estratégias avançadas que considerem as dinâmicas complexas das baterias durante sua operação [83].

2.4.4 Método baseado em filtro kalman estendido (EKF)

O Filtro de Kalman (KF) é um algoritmo recursivo de estimação de estados utilizado amplamente em sistemas lineares dinâmicos. Ele combina medições possivelmente ruidosas com um modelo preditivo para fornecer uma estimativa otimizada do estado do sistema ao longo do tempo. No entanto, sua aplicação em sistemas não lineares é limitada, pois o KF assume que a dinâmica do sistema pode ser representada por equações lineares.

Para lidar com essa limitação, foi desenvolvido o EKF , uma variante do KF projetada especificamente para estimar estados em sistemas não lineares. Isso o torna uma ferramenta poderosa e amplamente utilizada para a estimação de estados em sistemas complexos, como a estimativa do SoC em baterias [21] [84]. Baseado em uma abordagem matemática, o EKF utiliza medições, como OCV e outras variáveis de estado, para estimar o SoC . Sua capacidade de linearizar sistemas não lineares em torno da estimativa atual o torna especialmente útil em aplicações como as LIB , onde a relação entre o OCV e o SoC não é linear [29].

Para lidar com a não linearidade, o EKF emprega a expansão da série de Taylor em torno da estimativa atual, utilizando as derivadas parciais das funções do processo e de medição [84]. O processo do EKF consiste em duas fases fundamentais, predição e correção, conforme apresentado na Tabela 3. Na fase de predição, os estados e a covariância do erro são projetados para frente, utilizando o modelo de transição de estado e considerando o ruído do processo. Posteriormente, na fase de correção, calcula-se o ganho de Kalman para

ajustar a estimativa com base nas novas medições, o que permite atualizar tanto a estimativa quanto a covariância do erro [30].

É importante destacar que a precisão do *EKF* depende significativamente da correta definição das matrizes de covariância do ruído, que representam as incertezas no modelo e nas medições. Essas matrizes, conhecidas como Q_k , P e R_k , são cruciais para garantir a estabilidade e a convergência do filtro [84]. Este filtro tem se mostrado altamente eficaz em diversas aplicações, incluindo a gestão de baterias em *EV*, onde melhora significativamente a precisão na estimativa do *SoC*, contribuindo para um melhor desempenho e confiabilidade do sistema [21] [29].

Tabela 3 – Fases do *EKF* com a representação matemática correspondente.

Fase	Equações
Previsão de estado	$\hat{x}_{k+1 k} = A\hat{x}_{k k} + Bu_k \quad . \quad (2.4)$
Previsão de covariância	$P_{k+1 k} = AP_{k k}A^T + Q_k \quad . \quad (2.5)$
Ganho de Kalman	$K_{k+1} = P_{k+1 k}C^T(CP_{k+1 k}C^T + R_{k+1})^{-1} \quad . \quad (2.6)$
Correção do estado	$\hat{x}_{k+1 k+1} = \hat{x}_{k+1 k} + K_{k+1}(z_{k+1} - C\hat{x}_{k+1 k}) \quad . \quad (2.7)$
Correção de covariância	$P_{k+1 k+1} = (I - K_{k+1}C)P_{k+1 k} \quad . \quad (2.8)$

Adaptado de [30].

2.5 Caracterização híbrida de potência por pulsos

O método *HPPC* (Caracterização híbrida de potência por pulsos do inglês, *Hybrid Pulse Power Characterization*) é amplamente utilizado para analisar o desempenho dinâmico, a capacidade disponível e a resistência interna das baterias sob diferentes condições de carga e descarga. Esse procedimento consiste na aplicação de uma série de pulsos de corrente de diferentes magnitudes e durações, seguidos por períodos de repouso, permitindo avaliar tanto a resposta transiente quanto a estabilização dos parâmetros da célula [85]. Os testes *HPPC* são procedimentos padronizados desenvolvidos para avaliar a capacidade de uma bateria de suportar ciclos de carga e descarga, sendo amplamente utilizados para caracterizar seu comportamento eletroquímico. A seguir é apresentado o procedimento padrão desses testes, detalhando as etapas necessárias para obter uma caracterização precisa dos parâmetros internos da célula [86].

1. Preparação da bateria: A bateria é completamente carregada e deixada em repouso

para estabilização.

2. Descarga: A bateria é descarregada com uma corrente específica, correspondente a uma porcentagem do *SoC*, registrando tanto a tensão quanto a corrente durante o processo. Em seguida, é deixada em repouso para permitir que alcance o equilíbrio eletroquímico e térmico. Vale ressaltar que, quanto maior o tempo de repouso, melhor será a captura da sua dinâmica.
3. Pulsos de carga e descarga: São aplicados pulsos de carga e descarga em níveis predefinidos, permitindo avaliar a resposta da bateria a diferentes intensidades.
4. Períodos de repouso: Após cada pulso, a bateria é deixada em repouso para alcançar o equilíbrio eletroquímico, registrando a *OCV*.
5. Registro e análise de dados: Durante cada período de repouso, a tensão é registrada para estabelecer a curva da *OCV*. Por fim, os dados obtidos são analisados para determinar a resistência interna e a capacidade utilizável, gerando as curvas características necessárias para avaliar o desempenho da bateria.

A principal vantagem do método *HPPC* reside na sua capacidade de fornecer informações detalhadas sobre a variação da impedância da bateria em função do *SoC* e da temperatura, possibilitando a extração de parâmetros fundamentais para a modelagem dos *BMS*. Esses dados são essenciais para o desenvolvimento de *ECM* e algoritmos de estimação do *SoC* e do *SoH*. Além disso, o método permite avaliar a eficiência energética da bateria ao longo do tempo, fornecendo subsídios para a otimização do seu desempenho em aplicações críticas, como *EV* e sistemas de armazenamento estacionário [85].

Outro aspecto relevante do *HPPC* é sua capacidade de detectar variações na resistência interna da bateria, um indicador-chave do envelhecimento da célula e de possíveis limitações na entrega de potência. Ao medir a resposta da bateria a diferentes perfis de corrente, o método permite identificar padrões de degradação, contribuindo para estratégias mais eficientes de manutenção e prolongamento da vida útil do sistema. Dessa forma, a caracterização híbrida de potência por pulsos se estabelece como uma ferramenta essencial tanto para a validação de modelos eletroquímicos quanto para o desenvolvimento de estratégias de controle avançadas em aplicações de alta demanda energética [86].

2.6 Modelagem da bateria

A modelagem matemática de baterias é uma ferramenta essencial para compreender, simular e otimizar seu comportamento sob diversas condições de operação. Esse enfoque é especialmente relevante em sistemas que dependem criticamente de baterias, como *EV*, sistemas de armazenamento de energia e dispositivos eletrônicos. Os modelos matemáticos não

apenas fornecem uma representação abstrata do funcionamento interno da bateria, mas também permitem prever variáveis chave como o *SoC*, a vida útil e os efeitos do envelhecimento [87].

Em aplicações práticas, a modelagem é indispensável para garantir a eficiência, segurança e durabilidade de sistemas alimentados por baterias. Esses modelos permitem antecipar e mitigar comportamentos perigosos relacionados a fenômenos térmicos ou elétricos, melhorando a segurança operacional [88]. Além disso, oferecem ferramentas para realizar simulações detalhadas, reduzindo significativamente a dependência de testes experimentais custosos e demorados [89].

O uso de modelos também desempenha um papel crucial no design e na otimização de sistemas *BMS*, permitindo avaliar o desempenho sob diferentes condições de operação e tomar decisões informadas para melhorar a funcionalidade do sistema e prolongar a vida útil das células [55] [90]. A seguir, são descritos diversos tipos de modelos matemáticos, cada um projetado para diferentes níveis de complexidade.

2.6.1 Modelos empíricos

Os modelos empíricos fundamentam-se na análise de dados experimentais obtidos a partir de testes, como curvas de descarga ou ciclos de carga e descarga. Esses modelos se destacam por sua simplicidade e facilidade de implementação, tornando-os particularmente adequados para aplicações onde não é necessário um entendimento detalhado dos processos internos da bateria. Através de equações simples, descrevem relações entre variáveis-chave, como capacidade, corrente e tensão. No entanto, sua principal limitação reside na falta de capacidade para generalizar, uma vez que dependem diretamente dos dados de entrada e não conseguem capturar adequadamente o comportamento dinâmico da bateria sob condições operativas variáveis [59].

2.6.2 Modelos eletroquímicos

Baseados em princípios físico-químicos, os modelos eletroquímicos descrevem os processos internos da bateria, como o transporte de íons e as reações químicas nos eletrodos. Eles oferecem um alto nível de detalhe ao representar fenômenos como a difusão de espécies químicas e as reações eletroquímicas que afetam o desempenho da bateria. Um exemplo notável é o modelo *Doyle-Fuller-Newman (DFN)*, que utiliza equações diferenciais para descrever o comportamento celular. Embora sejam altamente precisos, sua complexidade computacional os torna inadequados para aplicações em tempo real, sendo mais utilizados em simulações detalhadas e estudos avançados [91].

2.6.3 Modelos baseados em aprendizado de máquina

O aprendizado de máquina emergiu como uma ferramenta poderosa para modelagem de baterias devido à sua capacidade de capturar comportamentos não lineares e complexos a partir de grandes volumes de dados. Algoritmos como RN e métodos de regressão avançada podem prever variáveis-chave de desempenho com alta precisão. Sua principal vantagem está na adaptabilidade a diferentes condições operacionais. Contudo, esses modelos requerem grandes quantidades de dados para treinamento e têm interpretabilidade limitada, dificultando o entendimento físico dos fenômenos subjacentes [92].

2.6.4 Modelos híbridos

Os modelos híbridos combinam as vantagens de diferentes abordagens, como modelos de circuito equivalente e modelos eletroquímicos, para equilibrar precisão e eficiência computacional. Por exemplo, um modelo híbrido pode empregar um circuito equivalente para simulações em tempo real, complementado por componentes eletroquímicos que detalham fenômenos internos [93]. Essa flexibilidade permite ajustar o nível de complexidade de acordo com as necessidades específicas do sistema, tornando-os ideais para aplicações que exigem precisão e rapidez em ambientes dinâmicos [13].

2.6.5 Modelo de Circuito Equivalente (*ECM*)

O *ECM* representa a bateria como um conjunto de elementos elétricos passivos, como resistores e capacitores, que simulam suas características dinâmicas. Essa abordagem alcança um equilíbrio entre simplicidade e precisão, tornando-se uma opção ideal para sua integração em *BMS*. O modelo utiliza componentes análogos aos de um circuito elétrico para oferecer uma representação fenomenológica do comportamento da tensão da célula em resposta a diferentes estímulos de corrente [94].

É importante destacar que o propósito deste modelo não é detalhar a estrutura interna da célula, em vez disso, o modelo se concentra em descrever o comportamento da célula. Dado o conhecimento existente sobre o funcionamento dos elementos do circuito, essa abordagem permite compreender os processos internos e como a célula responde em diversas situações de uso [21]. Para a compreensão do *ECM*, opta-se por seguir o método proposto por Plett [13], onde é explicada a construção detalhada do modelo elemento por elemento.

OCV no ECM

Em uma célula de uma *LIB*, um dos comportamentos fundamentais está relacionado à sua capacidade de fornecer energia. Ao medir os terminais da célula, é registrada a tensão

entregue. Além disso, quando a célula está descarregada e em equilíbrio completo, a tensão da célula se torna bastante previsível. Portanto, no modelo, essa fonte de tensão é o *OCV*.

Esses comportamentos são considerados na primeira etapa do modelo da bateria, onde a tensão fornecida pela célula é tratada como uma fonte ideal. Embora essa abordagem geralmente seja simplificada e não leve em consideração fatores como o envelhecimento da célula ou a corrente de carga, ela fornece um ponto de partida para o desenvolvimento do modelo. O esquema deste modelo é representado na Figura 5. Onde no modelo, a tensão terminal da célula $V(t)$ é considerada constante, não dependendo da corrente de carga $i(t)$ nem do histórico de uso da célula.




Figura 5 – Modelo da célula com tensão de saída constante. Adaptado de [13].

Relação *SoC* - *OCV*

Para aprimorar o modelo, é crucial incorporar a relação entre a *OCV* e o *SoC*, reconhecendo que a tensão registrada em uma célula completamente carregada, em repouso e sem demanda de corrente, é geralmente superior à tensão observada quando a célula está descarregada. O *SoC* é definido como 100% ou 1,0 quando a célula está completamente carregada, e como 0% ou 0,0 quando está totalmente descarregada. Entre esses extremos, o *SoC* reflete estados intermediários que indicam a proporção da capacidade total disponível. Sendo que, a inclusão dessa relação no modelo permite capturar de forma mais realista as características dinâmicas da célula.

Para determinar o *SoC* de uma bateria, é fundamental ter informações sobre sua capacidade de carga total, onde essa capacidade refere-se à quantidade total de carga que pode ser extraída ao descarregar a célula, desde um nível de carga de 100% até atingir 0% de sua capacidade nominal, ou seja, de *SoC* = 100% até *SoC* = 0%. A capacidade de carga total é medida em unidades de *Ah* ou miliampere-hora (*mAh*) e é representada pelo símbolo Q . As variações no *SoC* podem ser descritas pela Equação 2.9.

$$\dot{SoC}(t) = \frac{-\eta(t)i(t)}{Q} . \quad (2.9)$$

O sinal positivo de $i(t)$ indica a descarga da célula, diminuindo assim o seu *SoC*,

enquanto uma corrente negativa representa a carga, aumentando o *SoC*. As unidades de $i(t)$ devem ser expressas em A e, para serem compatíveis com Q , são convertidas para ampere-segundo (Coulombs). Sendo que tanto o *SoC* quanto η são grandezas unidimensionais.

Para simplificar η , o valor é igual a 1 quando a corrente tem um sinal positivo (descarga) e é menor a 1 quando a corrente é negativa (carga). η varia em função do *SoC*, a velocidade de carga, a temperatura, e o estado eletroquímico interno da célula, o que complica a criação de um modelo preciso. No entanto, muitas vezes, a suposição de primeira ordem de que η é sempre igual a 1 fornece uma aproximação razoavelmente precisa para o modelo em geral.

Alteração do *SoC* ao longo do tempo

Por meio da integração da Equação 2.9, obtém-se uma equação consolidada que descreve a mudança no *SoC* durante um intervalo de tempo determinado. A seguir, é apresentado o modelo matemático tanto em tempo contínuo (Equação 2.10) quanto em tempo discreto (Equação 2.11). A análise em tempo discreto é especialmente relevante devido à sua aplicabilidade em microcontroladores econômicos, amplamente utilizados em *BMS*. Sendo $t_0 = k\Delta t$ e $t = [k + 1]\Delta t$.

$$SoC(t) = SoC(t_0) - \frac{1}{Q} \int_{t_0}^t \eta(t)i(t)dt \quad . \quad (2.10)$$

$$SoC[k + 1] = SoC[k] - \frac{\Delta t}{Q} \eta[k]i[k] \quad . \quad (2.11)$$

Dependência entre *OCV* e *SoC*

Ao compilar o modelo matemático para a estimativa do *SoC*, reconhece-se que a *OCV* de uma célula é função do seu *SoC* e que essa relação, por sua vez, depende da temperatura interna da célula e da profundidade de descarga (*DoD*). Essa relação é visualizada na Figura 4, elaborada para uma temperatura ambiente de 30°C. Essa correspondência é comumente expressa em termos da *DoD* da célula. A *DoD*, que representa a inversa do *SoC*, pode ser expressa tanto como uma fração (Equação 2.12) quanto em *Ah* (Equação 2.13).

$$DoD = 1 - SoC(t) \quad . \quad (2.12)$$

$$DoD = Q(1 - SoC(t)) \quad . \quad (2.13)$$

Resistência em série equivalente

Ao incorporar a dependência do *SoC* e da temperatura na relação com a *OCV*, o modelo matemático torna-se mais complexo, porém mais preciso, proporcionando uma

estimativa mais confiável. A fonte, inicialmente formulada como uma tensão ideal, é agora substituída por uma tensão controlada que depende de fatores adicionais, conforme indicado anteriormente, e é expressa matematicamente como $OCV(SoC(t))$. Os valores da OCV para uma célula são determinados empiricamente em vários pontos do SoC por meio de procedimentos de laboratório detalhado no capítulo 3, na seção de caracterização da bateria 3.2.1.

A partir deste ponto, iniciam-se as adições de elementos que enriquecerão o modelo atual com características dinâmicas. Essas dinâmicas são o resultado dos eventos que ocorrem quando a célula é submetida a uma corrente de entrada que varia com o tempo. Neste contexto, o modelo descreve como a tensão terminal da célula diminui abaixo da OCV durante a descarga e aumenta acima da OCV quando a célula está em processo de carga. Este fenômeno pode ser explicado, em parte, pela introdução de uma resistência em série equivalente (*ESR* do inglês, *Equivalent series resistance*) ($R0$) [Ω] com a fonte de tensão controlada.




Figura 6 – ECM da ESR. Adaptado de [13].

Neste ponto, no modelo revisado a equação do SoC permanece inalterada, mas uma segunda equação é introduzida para detalhar o cálculo da tensão terminal (Equação 2.14 e Equação 2.15).

$$V(t) = OCV(SoC(t)) - i(t)R0 \quad . \quad (2.14)$$

$$V[k] = OCV(SoC[k]) - i[k]R0 \quad . \quad (2.15)$$

Na Equação 2.14 tem-se, que $V(t) > OCV(SoC(t))$ quando $i(t) < 0$ (durante a carga) e $V(t) < OCV(SoC(t))$ quando $i(t) > 0$ (durante a descarga). A presença de $R0$ no modelo implica que a potência é dissipada como calor devido à resistência interna da célula, resultando em uma η que não é perfeita. A potência dissipada por $R0$ é expressa como $P_{dis} = i^2(t)R0$. Isso indica que a resistência da célula geralmente é uma função do SoC

e sempre depende da temperatura interna da célula. A precisão das previsões do modelo melhora significativamente quando essas dependências em R_0 são consideradas e mantidas.

Tensão de difusão

Até o momento, com o modelo atual de *ECM*, foi possível capturar a polarização instantânea através do termo $i(t)R_0$, que corresponde ao comportamento observado durante o repouso inicial da célula, conforme evidenciado na Figura 7 no período de 0 a ± 5 min. Essa abordagem também explica a rápida queda da tensão ao aplicar corrente e a recuperação instantânea da tensão ao retirar a corrente (Figura 7, quando $5 < t < 20$ min). No entanto, é importante observar que as células apresentam um comportamento mais complexo, onde a polarização da tensão se desenvolve gradualmente ao longo do tempo conforme a corrente da célula é demandada (Figura 7, quando $t > 20$ min) e, posteriormente, diminui lentamente durante o período de repouso da célula.




Figura 7 – Tensão de difusão: Resposta ao pulso de descarga. Adaptada de Plett [13].

É desafiador avaliar com precisão o modelo atual, pois é necessário considerar comportamentos adicionais, como as flutuações constantes na tensão. Embora a tensão apresente variações contínuas, observa-se que o *SoC* da célula permanece constante na ausência de corrente. Esse fenômeno introduz uma dinâmica complexa que ainda não foi incorporada ao modelo, o que limita sua capacidade de representar completamente o comportamento da célula em condições reais. Como evidenciado na Figura 8, é introduzida uma tensão de difusão representada por V_1 para compensar essa deficiência.




Figura 8 – ECM da inclusão da tensão de difusão (V_1). Adaptado de [13].

Um exemplo ilustrativo ao qual Plett [13] faz referência para explicar esse fenômeno é o comportamento de uma lanterna quando sua carga está próxima de se esgotar. A lanterna começa a piscar constantemente, mas ao desligá-la e esperar alguns minutos para então ligá-la novamente, observa-se que o piscar desapareceu, apenas para reaparecer quando a tensão diminui novamente. Isso não significa necessariamente que a bateria foi recarregada, pelo contrário, o fenômeno apresentado nesse caso é a tensão que se recupera ligeiramente devido à gradual diminuição da polarização, um processo relacionado à difusão do lítio em uma célula de Li^+ . Essa tensão que muda lentamente é denominada tensão de difusão.

Esse efeito pode ser representado por um circuito que utiliza um ou mais subcircuitos RC em paralelo. Na Figura 8, a combinação de R_1 e C_1 desempenha esse papel. No modelo, a equação do SoC permanece inalterada, enquanto a equação da tensão é modificada para refletir a presença desse fenômeno de difusão de tensão (Equação 2.16 e Equação 2.17).

$$V(t) = OCV(SoC(t)) - V_{C1}(t) - V_{R0}(t) \quad . \quad (2.16)$$

$$V[k] = OCV(SoC[k]) - V_{C1}[k] - V_{R0}[k] \quad . \quad (2.17)$$

Dado que $i(t) = i_{R1}(t) + i_{C1}(t)$, então,

$$\frac{di_{R1}(t)}{dt} = -\frac{1}{R1C1}i_{R1}(t) + \frac{1}{R1C1}i(t) \quad . \quad (2.18)$$

$$i_{R1}[k+1] = \exp\left(-\frac{\Delta t}{R1C1}\right)i_{R1}[k] + \left(1 - \exp\left(-\frac{\Delta t}{R1C1}\right)\right)i[k] \quad . \quad (2.19)$$

Finalmente, observa-se que a resposta de V1 de uma célula geralmente depende tanto do *SoC* da célula quanto de sua temperatura interna. Se $R1$ e $C1$ forem modelados como funções de $SoC(t)$ e $T(t)$, as previsões do modelo podem ser aprimoradas.

Valores aproximados dos parâmetros $R0$, $R1$ e $C1$

Para determinar os valores aproximados dos parâmetros RC que descrevem a resposta das células, inicialmente submete-se a célula a um pulso de descarga a corrente constante. Posteriormente, a célula é deixada em repouso enquanto se registra sua resposta de tensão. Em seguida, elimina-se o pulso de corrente de descarga (Figura 7, $t = 20$ min), o que permite observar que a variação instantânea da tensão é igual ao produto da variação instantânea da corrente pela resistência $R0$ ($\Delta V_0 = R0\Delta i$). Isso se fundamenta no fato de que, no momento em que a corrente tende a zero, a tensão do capacitor não muda instantaneamente, e o *SoC* permanece constante. Desse jeito o valor de $R0$ pode ser evidenciado na Equação 2.20.

$$R0 = \left| \frac{\Delta V_0}{\Delta i} \right| . \quad (2.20)$$

No caso da variação de tensão em estado estacionário (Figura 7, $t = 60$ min), esta é definida como a soma dos resistores, multiplicada pela variação da corrente ao longo do tempo ($\Delta V_{esta} = (R0 + R1)\Delta i$). Se a tensão do capacitor tende a zero em estado estacionário, então $R1$ pode ser definido da seguinte forma (Equação 2.21).

$$R1 = \left| \frac{\Delta V_{\infty}}{\Delta i} \right| - R0 . \quad (2.21)$$

Finalmente, para determinar o valor de $C1$, assume-se que a resposta ao pulso (Figura 7, quando $7 < t < 20$ min) converge para um valor próximo ao estado estacionário em aproximadamente quatro constantes de tempo (t_c) do circuito RC ($4\tau = t_c$). Isso representa o tempo necessário para que o modelo alcance o estado estacionário, permitindo assim calcular o valor do capacitor de acordo com a Equação 2.22.

$$C1 \approx \frac{t_c}{4R1} . \quad (2.22)$$

Efeitos das tensões de histerese

O efeito de histerese no modelamento de baterias refere-se ao comportamento não linear e dependente da trajetória da tensão na bateria, particularmente durante os processos de carga e descarga. Esse fenômeno resulta de diferenças nas dinâmicas internas da bateria, o que gera uma discrepância entre as curvas de carga e descarga, mesmo quando o *SoC* é o mesmo. Ignorar o efeito de histerese em um modelo celular pode levar a estimativas incorretas do *SoC*, com erros que se tornam evidentes, especialmente em condições dinâmicas, como durante transições de corrente entre carga e descarga.

É importante ressaltar que, enquanto as tensões de difusão mudam com o tempo, as tensões de histerese dependem principalmente do *SoC*. A inclusão desse parâmetro no modelo permite observar que, ao deixar a célula em repouso, as tensões de difusão tendem a zero, no entanto, as tensões de histerese permanecem constantes. No comportamento de uma célula, podem ser identificados dois tipos de tensões de histerese:

- Histerese instantânea: Ocorre imediatamente após uma mudança de corrente, como ao alternar de descarga para carga.
- Histerese dependente do *SoC*: É um fenômeno gradual e linear que ocorre à medida que o *SoC* varia.

Para descrever a histerese dependente do *SoC*, é introduzido o termo $h(\text{SoC}, t)$, que representa a histerese dinâmica. A evolução dessa variável em função do tempo é modelada utilizando a Equação 2.23, que é derivada considerando a Equação 2.9.

$$\dot{h}(t) = -|\dot{\text{SoC}}(t)\gamma| h(t) + |\dot{\text{SoC}}(t)\gamma| M(\text{SoC}, \dot{\text{SoC}}) \quad . \quad (2.23)$$

Considerando que $h(t)$ representa a histerese em função do tempo e $M(\text{SoC}, \dot{\text{SoC}})$ descreve a função de polarização máxima devido à histerese, em função do *SoC* e de sua taxa de variação, é possível modelar o comportamento dinâmico da histerese.

No contexto de um sistema discreto, a histerese pode ser representada pela Equação 2.24. Para simplificar, assume-se que tanto $i(t)$ quanto $M(\text{SoC}, \dot{\text{SoC}})$ permanecem constantes durante o período de amostragem. Além disso, ao adotar uma representação básica, estabelece-se que $M(\text{SoC}, \dot{\text{SoC}}) = -M \text{sgn}(i[k])$, capturando assim a não linearidade inerente ao sistema.

$$h[k+1] = \exp\left(-\left|\frac{\eta[k]i[k]\gamma\Delta t}{Q}\right|\right) h[k] - \left(1 - \exp\left(-\left|\frac{\eta[k]i[k]\gamma\Delta t}{Q}\right|\right)\right) M \text{sgn}(i[k]) \quad . \quad (2.24)$$

Para finalmente obter a equação da tensão de histerese linear (Vh) (Equação 2.25),

$$Vh = Mh[k] \quad . \quad (2.25)$$

No caso da histerese instantânea, esta varia diretamente com o sinal da corrente. Esse comportamento pode ser expresso matematicamente e é evidenciado na Equação 2.26.

$$s[k] = \begin{cases} \text{sgn}(i[k]), & |i[k]| > 0 \\ s[k-1], & \text{Outros casos} \end{cases} \quad . \quad (2.26)$$

O valor final da tensão de histerese instantânea é obtido por meio da Equação 2.27, que incorpora a relação direta entre a histerese e o sinal da corrente aplicada.

$$V_s = M_0 s[k] \quad . \quad (2.27)$$

Após a definição de ambos os tipos de histerese presentes no sistema, a histerese total pode ser expressa como a soma da histerese linear e da histerese instantânea. Essa relação é definida pela Equação 2.28.

$$VH = M_0 s[k] + Mh[k] \quad . \quad (2.28)$$

Modelo RC de terceira ordem

O modelo de terceira ordem, ilustrado na Figura 9, incorpora múltiplos ramos RC que permitem uma representação mais precisa dos comportamentos dinâmicos das baterias em condições reais. Nesse modelo, o primeiro ramo RC captura o comportamento associado às constantes de tempo rápidas, enquanto os outros dois ramos representam as constantes de tempo lentas, abrangendo fenômenos mais prolongados ao longo do tempo. Essa estrutura melhora significativamente a capacidade do modelo de refletir a complexidade do comportamento dinâmico de uma bateria sob diversas condições de operação [3].

A inclusão de múltiplos ramos RC possibilita capturar efeitos transitórios e de longa duração com maior fidelidade, posicionando o modelo de terceira ordem como uma das representações mais próximas do comportamento real das baterias. No entanto, essa precisão vem acompanhada de um custo computacional consideravelmente maior. O aumento na ordem do sistema implica na adição de mais estados dinâmicos, o que se traduz em equações diferenciais adicionais e em uma maior complexidade nos cálculos [43], conforme observado na Equação 2.29.




Figura 9 – ECM com três ramificações RC. Adaptado de [13]

Esse modelo pode é representado na Equação 2.29,

$$\begin{bmatrix} SoC[k+1] \\ V_1[k+1] \\ V_2[k+1] \\ V_3[k+1] \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 \\ 0 & 0 & 0 & 1 - \frac{\Delta t}{R_3 C_3} \end{bmatrix} \begin{bmatrix} SoC[k] \\ V_1[k] \\ V_2[k] \\ V_3[k] \end{bmatrix} + \begin{bmatrix} -\frac{\eta \Delta t}{C_n} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \\ \frac{\Delta t}{C_3} \end{bmatrix} i[k] \quad (2.29)$$

A Equação 2.30, representa a equação de saída, e é dada por,

$$y[k] = V_t[k] = OCV(SoC) - V_1[k] - V_2[k] - V_3[k] - R_0 i[k] \quad (2.30)$$

Os termos da Equação 2.29 e da Equação 2.30 representam, C_n , a capacidade nominal da bateria; R_0 , a resistência ôhmica da bateria; $R_1 C_1$, referente à constante de tempo rápida de polarização e de dupla camada; $R_2 C_2$, referente à constante de tempo lenta; $R_3 C_3$, referente à constante de tempo mais lenta que o ramo anterior; V_1 , V_2 e V_3 , são estados que representam as tensões em volta dos capacitores C_1 , C_2 e C_3 ; $SoC[k]$, V_1 , V_2 e V_3 , são os estados do sistema; $y[k]$, é a saída do sistema, a qual corresponde à tensão no terminal com a bateria conectada a uma carga; $i[k]$, é a corrente de entrada; $\eta = \frac{1}{3600 \times C}$, sendo um índice para representar a variação da capacidade em relação ao tempo; Δt , é o período de amostragem.

Apesar de sua maior demanda computacional, o modelo de terceira ordem é amplamente utilizado em aplicações onde a precisão na simulação do comportamento dinâmico da bateria é crucial, como no design de sistemas avançados *BMS* e em estudos que exigem uma compreensão detalhada dos fenômenos internos. Sua capacidade de representar tanto respostas rápidas quanto lentas o torna uma ferramenta poderosa para a estimativa de parâmetros-chave, como o *SoC*, e para prever o desempenho da bateria sob diversas condições.

2.7 Validação de modelo

A validação de modelos é uma etapa crítica no desenvolvimento de representações matemáticas de baterias, pois garante que esses modelos capturem com precisão o comportamento real das baterias sob diversas condições de operação. Esse processo é particularmente importante em aplicações como os sistemas *BMS*, onde previsões precisas são essenciais para assegurar a segurança, a eficiência e a confiabilidade operacional.

Esta não apenas verifica se os modelos conseguem prever corretamente variáveis-chave, como o *SoC* e o envelhecimento, mas também identifica discrepâncias entre as

previsões e os dados experimentais. Isso proporciona um feedback valioso para o ajuste e a melhoria contínua dos modelos [95] [96]. Em setores como o automotivo e o aeroespacial, essa etapa também é fundamental para atender aos padrões regulatórios internacionais, garantindo desempenho e segurança adequados [97].

Para validar um modelo matemático de baterias, é comum utilizar testes específicos que avaliam tanto o ajuste das previsões quanto a capacidade do modelo de capturar a dinâmica do sistema. Entre esses testes, os mais relevantes para este trabalho são os de ajuste de falha no tempo (*FIT* do inglês, *Failure In time*) e de variação explicada (*VAF* do inglês, *Variance accounted for*).

2.7.1 Testes de ajuste *FIT*

Segundo Yogananda [97], os testes *FIT* avaliam a precisão das previsões do modelo em relação aos dados experimentais obtidos sob diversas condições operacionais. As saídas do modelo, como tensão, corrente e temperatura, são comparadas diretamente com as medições experimentais, permitindo quantificar a precisão do modelo por meio de uma métrica baseada na norma euclidiana dos erros, a Equação 2.31 é usada para o cálculo do ajuste *FIT*.

$$FIT = \left(1 - \frac{\|y - \hat{y}\|}{\|y - \bar{y}\|} \right) \times 100 \quad . \quad (2.31)$$

Onde y , é o vetor dos dados reais (saída real do sistema); $\hat{y}$, é o vetor das saídas estimadas pelo modelo; $\bar{y}$, é a média dos dados reais; $\|\cdot\|$, denota a norma 2 (euclidiana) do vetor. O resultado é expresso como uma porcentagem, onde um valor próximo a 100% indica uma excelente correspondência entre o modelo e os dados experimentais.

2.7.2 Métrica *VAF*

A métrica *VAF* mede a capacidade do modelo de capturar a variabilidade presente nos dados reais, sendo especialmente útil em sistemas dinâmicos. Este método oferece informações cruciais sobre a habilidade do modelo de refletir dinâmicas complexas, como os efeitos de envelhecimento e as variações ambientais, assegurando sua aplicabilidade ao longo do ciclo de vida da bateria [96] [98]. A Equação 2.32 é utilizada para calcular o *VAF*.

$$VAF = \left(1 - \frac{\text{var}(y[k] - \hat{y}[k])}{\text{var}(y[k])} \right) \times 100 \quad . \quad (2.32)$$

Onde $y[k]$, é o vetor das saídas reais do sistema; $\hat{y}[k]$, é o vetor das saídas estimadas pelo modelo; $\text{var}(\cdot)$, denota a variância dos dados.

Ambas as métricas são utilizadas para avaliar a precisão de modelos, mas com abordagens distintas. O FIT foca na norma euclidiana dos erros e na média dos dados, avaliando a proximidade geral entre o modelo e os dados medidos, enquanto o VAF mede especificamente a capacidade do modelo de explicar a variabilidade nos dados reais, sendo mais sensível às dinâmicas complexas e ao ruído. O uso combinado de FIT e VAF fornece uma avaliação abrangente da precisão e da aplicabilidade do modelo, destacando tanto o ajuste geral quanto a representação de dinâmicas mais complexas, garantindo a confiabilidade do modelo em simulações e aplicações práticas.

2.7.3 Estado da arte e resultados da literatura sobre a estimativa do SoC nas LIB associado ao BMS adaptativo

Para a elaboração deste artigo foi realizada uma revisão extensa da literatura científica relacionada à modelagem matemática e à estimativa do SoC em baterias de íon-lítio. A busca por informações foi conduzida em diversas bases de dados acadêmicas e repositórios científicos reconhecidos, tais como IEEE Xplore, ScienceDirect, SpringerLink, Scopus e Web of Science, garantindo a coleta de trabalhos relevantes e atualizados na área. Como resultado dessa busca inicial, foram identificados 165 documentos relacionados ao tema, abrangendo diferentes abordagens metodológicas, incluindo modelos baseados em circuitos equivalentes, modelos eletroquímicos e técnicas avançadas de estimativa, como redes neurais e filtros de Kalman em suas diversas variantes.

Com o objetivo de garantir a relevância e a qualidade dos estudos selecionados, foram aplicados critérios de inclusão e exclusão baseados nos seguintes parâmetros:

- Relevância temática: Foram priorizados artigos focados na modelagem matemática de baterias e métodos de estimativa do SoC.
- Data de publicação: Foram considerados estudos publicados nos últimos dez anos, garantindo informações atualizadas.
- Qualidade e reconhecimento da fonte: Apenas publicações em revistas indexadas e conferências de alto impacto foram selecionadas.
- Aplicabilidade dos métodos propostos: Estudos teóricos sem validação experimental ou simulações relevantes foram descartados.

Após esse processo de filtragem, foram selecionados 67 documentos que apresentavam abordagens alinhadas com os objetivos deste trabalho. A análise detalhada desses estudos permitiu identificar semelhanças-chave na metodologia utilizada para a estimativa do SoC, destacando a importância do *EKF* como uma das técnicas mais robustas e amplamente utilizadas na literatura.

Além disso, os documentos analisados forneceram uma base sólida para a formulação do modelo matemático utilizado neste trabalho, evidenciando a relação entre a precisão da estimativa do *SoC* e fatores como a resistência interna da bateria, a temperatura e as condições de operação. Como resultado, este estudo se apoia em descobertas anteriores para desenvolver um método otimizado baseado no *EKF*, buscando melhorar a precisão e a estabilidade da estimativa do *SoC* em aplicações de sistemas *BMS*.

A análise da literatura, conforme apresentada na Tabela 4, permite examinar detalhadamente os artigos e suas contribuições, destacando dados relevantes e fundamentais para este estudo. Essa abordagem fornece uma contextualização sólida no campo de estudo, permitindo a identificação de lacunas no conhecimento e métodos que têm demonstrado resultados bem-sucedidos. Por meio dessa análise, obtém-se uma compreensão mais aprofundada da eficácia, segurança e aplicações da técnica em questão. Isso, por sua vez, estabelece as bases para o desenvolvimento do estudo e as decisões sobre os materiais e métodos a serem utilizados.

Tabela 4 – Revisão da literatura com as respectivas contribuições a serem levadas em conta no presente estudo.

Artigo	Contribuições	Implementações
<i>State of Charge Estimation of Lithium-Ion Batteries under Different Temperature Conditions Using Kalman Filters</i> [3].	O estudo propõe uma metodologia para estimar a carga de baterias em diferentes temperaturas (10, 25 e 40 °C) usando métodos matemáticos como o <i>EKF</i> . Além disso, apresenta um método para identificar e determinar o modelo elétrico equivalente (<i>ECM</i>) de uma bateria. Os experimentos foram realizados com uma bateria de Lítio (LiFePO_4) de 20 Ah e 3,3 V, permitindo a definição de um modelo com ramos RC e a estimativa de seus parâmetros.	-Estimação de carga de baterias para diferentes condições de temperatura utilizando métodos matemáticos. - <i>EKF</i> . - <i>ECM</i> da bateria. -Modelo com ramos RC.
<i>Experimental Data-Driven Parameter Identification and State of Charge Estimation for a Li-Ion Battery Equivalent Circuit Model</i> [9].	O estudo apresenta um método sistemático para identificar parâmetros de baterias a partir de dados experimentais e um algoritmo adaptativo de estimativa de <i>SoC</i> baseado no <i>AEKF</i> para aplicações em veículos elétricos. Utilizando um modelo <i>ECM</i> RC de segunda ordem e um algoritmo genético (<i>GA</i>), os principais parâmetros da bateria foram identificados. A validação foi feita comparando a tensão simulada e experimental sob o mesmo perfil de corrente. Por fim, a eficácia do estimador de <i>SoC</i> foi confirmada testando diferentes perfis de operação.	-Algoritmo adaptativo de estimativa de <i>SoC</i> . - <i>ECM</i> da bateria. - <i>EKF</i> .

Continuação da Tabela 4:

<i>Battery Management Systems, Volume I: Battery Modeling</i> [13].	Os capítulos 2 e 5 apresentam abordagens complementares para a modelagem de baterias. O Capítulo 2 introduz modelos empíricos baseados no uso de circuitos lineares como análogos dos comportamentos de entrada e saída das células de bateria. Já o Capítulo 5 aprofunda a análise dos modelos de espaço de estado, considerando-os a forma final do desenvolvimento, e apresenta o algoritmo de realização em tempo discreto <i>DRA</i>) como um método eficiente para criar esses modelos.	-Modelagem de baterias. - <i>ECM</i> . -Modelo de espaço de estados. Algoritmo em tempo discreto.
<i>Lithium Battery Management System with State Estimation Using Adaptive Extended Kalman Filter</i> [14].	A tese apresenta uma metodologia para o desenvolvimento de um <i>BMS</i> completo, capaz de proteger e gerenciar diferentes baterias em diversas aplicações, desde que seus limites de tensão, corrente e temperatura sejam conhecidos. O estudo foca em baterias de Li-FePO ₄ para empilhadeiras elétricas, comparando quatro modelos matemáticos, quatro algoritmos de otimização e sete experimentos para identificar a melhor abordagem em termos de modelagem, otimização e experimentação.	- <i>BMS</i> . -Algoritmos de otimização. -Experimentos. -Modelos matemáticos.
<i>Research on Online Identification of Lithium-ion Battery Equivalent Circuit Model Parameters</i> [16].	Neste artigo, uma <i>LIB</i> ternária é estudada usando um <i>ECM</i> RC de segunda ordem. Inicialmente, os parâmetros da bateria são identificados offline por meio do teste <i>HPPC</i> . Em seguida, o método de mínimos quadrados recursivo com fator de esquecimento é aplicado para calcular o <i>ECM</i> . A identificação de parâmetros online é realizada e validada por meio de simulação no MATLAB/Simulink, comparando-a com a identificação offline para avaliar suas vantagens e desvantagens.	- <i>LIB</i> . - <i>ECM</i> RC. -Testes <i>HPPC</i> . -Identificação de parâmetros online.
<i>Accurate Equivalent Circuit Parameter Estimation Using Electrochemical Battery Modelling for Pulsed Load Applications</i> [20].	Neste artigo, os parâmetros do circuito equivalente da bateria são obtidos a partir do modelo eletroquímico Doyle-Fuller-Newman (<i>DFN</i>), permitindo uma representação precisa da carga transitória. A metodologia é aplicada para determinar os parâmetros do <i>ECM</i> com dois pares RC. A validação é feita descarregando uma bateria LGM50 a uma taxa de 1C em intervalos regulares.	-Identificação dos parâmetros do modelo. - <i>HPPC</i> . - <i>ECM</i> . -Modelo eletroquímico Doyle-Fuller-Newman.

Continuação da Tabela 4:

<i>A Kalman Filter Based Battery State of Charge Estimation MATLAB Function [30].</i>	Este artigo propõe uma função MATLAB de estimativa do SoC baseada no KF usando um ECM RC de segunda ordem. A função requer a curva SoC-OCV, a resistência interna e os parâmetros da bateria RC ECM de segunda ordem. Os usuários têm a opção de usar um EKF ou algoritmos de AEKF, bem como dados de bateria dependentes da temperatura.	-EKF. -Estimativa do SoC. -Matrizes de covariância. -SoC-OCV. -ECM. -Algoritmo de estimativa em MATLAB.
<i>Lithium-Ion Batteries: Modelling and State of Charge Estimation [43].</i>	O estudo compara diferentes modelos e estratégias de estimativa do SoC, desde representações de caixa preta até modelos eletroquímicos detalhados. A estimativa do SoC é realizada com EKF e o filtro de estrutura variável suave SVSF, sendo aplicada a dados experimentais da BMW e validada com simulações no AVL CRUISE.	-OCV. -EKF.
<i>Battery Management Systems, Volume II: Equivalent-Circuit Methods [45].</i>	O livro aborda a modelagem de baterias com ECM para BMS, representando seu comportamento elétrico e térmico com resistências, capacitâncias e indutâncias. Discute a identificação de parâmetros por técnicas experimentais e otimização de dados, além de algoritmos para estimar SoC e SoH com KF e outros métodos de controle. Também explora estratégias para aprimorar a precisão e eficiência dos modelos em aplicações reais.	-Filtro de Kalman. -Representação do modelo em espaço de estados. -EKF. -SoC.
<i>A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations [55].</i>	Este artigo analisa a estimativa do SoC da LIB e seu BMS para aplicações sustentáveis de EV, destacando a importância do BMS na garantia de operação segura e confiável.	-SoC. -SoC-OCV. -ECM. -BMS. -Histerese em carga e descarga.
<i>Current Trends for State-of-Charge (SoC) Estimation in Lithium-Ion Battery Electric Vehicles [76].</i>	Esta revisão aborda os métodos atuais para modelar e estimar o SoC em LIB de (veículos elétricos a bateria (BEV), concluindo com uma breve discussão sobre os desafios na previsão do SoC.	-LUT. -EKF. -Coulomb counting. -SoC.

Continuação da Tabela 4:

<i>Battery Model Identification Approach for Electric Forklift Application</i> [99].	Este trabalho compara quatro modelos, quatro algoritmos otimizadores e sete projetos de experimentos para determinar a melhor combinação na estimativa de parâmetros de baterias. O objetivo é aprimorar a estimativa do SoC em baterias de empilhadeiras elétricas. O modelo de caixa cinza não linear, utilizando o método de mínimos quadrados não linear, apresentou os melhores resultados.	-Modelo no espaço de estados. -ECM. -HPPC. -SoC-OCV. -Identificação dos parâmetros do modelo.
<i>Battery Test Manual for Plug-In Hybrid Electric Vehicles</i> [100].	O Test Manual apresenta protocolos padronizados para avaliar baterias em veículos híbridos plug-in (PHEV), incluindo testes de capacidade, eficiência, vida útil e segurança. Define métodos para carga e descarga, variações de temperatura e estresse mecânico, além de critérios para analisar a degradação das células e módulos ao longo do tempo.	-Protocolos para testes de caracterização de baterias. -HPPC. -SoC-OCV.
Estimation of Lithium-Ion Battery Model Parameters Using Experimental Data [101].	Este artigo apresenta um procedimento detalhado para estimar os parâmetros do modelo de uma bateria a partir de dados experimentais. O experimento utiliza um computador para controlar o processo de carga e descarga, enviando Comandos Estándar para Instrumentos Programables (SCPI) via comunicação serial para uma fonte de alimentação Four Quadrant da Kepco Inc. (100 V, 10 A). A metodologia foi aplicada a uma bateria LIB de 20 Ah, mas pode ser adaptada a outros tipos de baterias. O objetivo principal é obter parâmetros para posteriormente estimar o SoC usando um método adaptativo.	-Identificação dos parâmetros do modelo. -HPPC. -ECM. -SoC-OCV.
<i>State of charge estimation of lithium-ion battery based on extended Kalman filter algorithm</i> [102].	Este artigo investiga a estimativa do SoC da LIB usando o algoritmo EKF, que é menos sensível a ruídos em comparação com o KF comum. Para isso, os parâmetros do modelo de bateria, baseado em um ECM de RC de segunda ordem, são identificados utilizando o software MATLAB/Simulink.	-SoC. -ECM. -LIB. -EKF.
<i>Overview of Lithium-Ion Battery Modeling Methods for State-of-Charge Estimation in Electrical Vehicles</i> [103].	Este artigo analisa métodos de modelagem de baterias para estimar o SoC com base em modelos. Após otimizar os parâmetros da bateria usando um algoritmo genético (GA), compara-se a precisão e o tempo de execução	-Comparação dos métodos de modelagem atuais. -ECM.

Continuação da Tabela 4:

	de quatro modelos: um modelo combinado, dois modelos <i>ECM RC</i> , um Modelo de Partícula Única (<i>SPM</i>) e um modelo baseado em Máquina de Vetores de Suporte (<i>SVM</i>).	
<i>Experimental validation for Li-ion battery modeling using Extended Kalman Filters [104].</i>	Este artigo estuda e projeta um <i>BMS</i> para <i>LIB</i> , apresentando as equações matemáticas do sistema e um modelo elétrico da bateria. A metodologia <i>EKF</i> é aplicada para estimar com precisão o <i>SoC</i> , sendo implementada experimentalmente em C em um microcontrolador.	- <i>EKF</i> . - <i>SoC</i> . - <i>BMS</i> . - <i>LIB</i> . - <i>HPPC</i> .
<i>Parameterization, Modeling, and Simulation of Batteries Using Battery Modeling in Simulink-Matlab [105].</i>	Este estudo investiga o potencial da ferramenta Battery Modeling da MathWorks no Simulink-Matlab para modelagem de baterias de íons de lítio. A pesquisa aborda a caracterização da bateria, a estimativa do <i>SoC</i> e <i>SoH</i> , além da simulação em tempo real para o desenvolvimento de sistemas de gerenciamento de baterias (<i>BMS</i>).	- <i>Battery Modeling</i> da MathWorks no Simulink-MATLAB.

3 Materiais e métodos

Neste capítulo, serão descritos em detalhes os materiais e os métodos utilizados no desenvolvimento desta pesquisa, destacando a função e a importância de cada componente para atingir os objetivos propostos. Cada etapa do processo será apresentada de forma estruturada, evidenciando como os recursos empregados e os métodos adotados contribuíram para garantir a qualidade, a precisão e a relevância dos resultados obtidos ao longo do estudo.

3.1 Materiais

A compreensão precisa do comportamento das células de uma bateria exige uma abordagem metódica, que inclui o uso de uma bancada experimental projetada especificamente para a realização de testes controlados. Esses testes submetem a bateria a diferentes condições operacionais controladas, como variações de temperatura e ciclos de carga e descarga, com o objetivo de capturar, com maior fidelidade, sua dinâmica operacional. A seguir, é descrita a estrutura da bancada experimental, apresentada na Figura 10. O processo de desenvolvimento desta bancada resultou na publicação de um artigo científico, em colaboração com o mestrando Leonardo de Souza Takehana, apresentado em [106].




Figura 10 – Esquema da bancada experimental.

3.1.1 Sistema computacional para aquisição de dados e controle de testes no MATLAB *Simulink*

O sistema central de controle e processamento é baseado em uma *Workstation* de alto desempenho, projetada para a aquisição, supervisão e processamento em tempo real dos experimentos. Essa estação está equipada com um processador *AMD Ryzen Threadripper 7970X*, com 32 núcleos operando a 4,00 GHz, acompanhado por 256 GB de memória *RAM* e executando o sistema operacional *Windows 10 Pro*.

A supervisão e o controle dos experimentos são realizados por meio do MATLAB *Simulink Desktop Real-Time (SDRT) 2024*, com um período de amostragem de 10 ms, permitindo uma interação em tempo real com a bateria e garantindo a precisão na aquisição de dados. Esse sistema processa medições de tensão, corrente, temperatura e *SoC* da célula em estudo, fornecendo informações detalhadas para a caracterização e validação do modelo de bateria.

Além disso, a bancada experimental foi projetada para operar com um alto grau de automação, integrando um algoritmo composto por múltiplos blocos de controle e processamento. Esses blocos possibilitam a execução estruturada e reproduzível dos testes, otimizando a coleta de dados e assegurando a consistência nos resultados obtidos.

Em termos de segurança, o sistema incorpora um módulo de proteção digital e analógico, que protege tanto a integridade da bateria quanto a do usuário. Esse sistema de segurança é essencial para prevenir condições operacionais perigosas, como sobrecorrente, superaquecimento ou estados de descarga profunda. Entre os principais blocos de controle implementados, incluem-se:

- **Módulo principal:** Foi desenvolvido sob uma arquitetura de máquina de estados, permitindo uma gestão estruturada e eficiente dos experimentos na bancada de testes. Essa máquina de estados não apenas coordena a ativação e desativação dos diferentes submódulos, mas também gerencia a comutação dos relés no sistema de *hardware*, assegurando uma execução precisa e automatizada dos ensaios. Sua principal função é garantir a execução correta das provas, facilitando uma transição fluida entre os diferentes estados operacionais e proporcionando um controle rigoroso sobre cada etapa do experimento.

O sistema conta com um painel de controle central, projetado para a supervisão e gestão em tempo real dos experimentos. Através dessa interface, o usuário pode selecionar e configurar testes específicos, como a medição da capacidade da bateria, a execução do teste *HPPC* e os ciclos de carga e descarga da célula. A interação com o sistema é realizada de forma intuitiva, com cada ensaio vinculado à lógica da máquina de

estados, garantindo uma execução ordenada, segura e reproduzível, minimizando erros operacionais e aumentando a confiabilidade dos dados obtidos.

Além disso, o painel de controle incorpora um campo de entrada configurável, permitindo que o usuário defina com precisão a corrente de descarga da bateria. Esse nível de personalização é fundamental para adaptar os ensaios a diferentes condições operacionais, contribuindo para uma caracterização mais detalhada e realista do comportamento da célula em estudo. A combinação desses elementos fortalece a robustez do sistema, otimizando a automação dos experimentos e garantindo tanto a integridade da bateria quanto a segurança do operador (Figura 11).




Figura 11 – Painel principal de controle dos testes no MATLAB *Simulink*

- **Bloco de medição de corrente:** O módulo responsável pela aquisição do sinal de corrente da bateria emprega uma medição indireta baseada em uma resistência de derivação (*shunt*). Esse método consiste em monitorar a queda de tensão em uma resistência conectada em série com a bateria e, conhecendo o valor preciso da resistência, calcular a corrente circulante por meio da Lei de Ohm. Para a implementação na bancada de testes, foi utilizado um resistor de $0,22\ \Omega$ e $10\ \text{W}$ [106].

Para melhorar a qualidade da medição e minimizar interferências, o sinal de tensão é processado por meio de um filtro passa-baixa, projetado para eliminar o ruído de alta frequência antes de ser convertido em uma grandeza de corrente real. Adicionalmente, esse módulo incorpora uma lógica de controle que permite habilitar ou desabilitar a medição conforme as condições operacionais de carga e descarga da célula, evitando medições incorretas em estados não representativos.

Com o objetivo de garantir um controle preciso sobre a corrente de descarga durante os experimentos de caracterização da bateria, foi implementado um laço de controle baseado em um controlador *PID* discreto. Esse sistema recebe como entrada a corrente de descarga desejada e a corrente real medida na bateria, calculando o erro entre

ambas. Esse erro é processado pelo controlador *PID*, cuja saída é ajustada por meio de um *offset* fixo para adequar a faixa de operação do circuito de controle.

Posteriormente, o sinal de controle é filtrado por um filtro passa-baixa de primeira ordem, permitindo suavizar a resposta dinâmica e minimizar a sensibilidade a perturbações antes de ser enviado à placa de aquisição. Essa abordagem não apenas otimiza a estabilidade do sistema, mas também melhora a precisão na regulação da corrente, assegurando uma caracterização confiável da bateria sob diferentes perfis de carga (Figura 12).




Figura 12 – Implementação da estimativa e controle da corrente no MATLAB *Simulink*

- **Sistema de estimativa do SoC:** O algoritmo Coulomb Counting foi implementado na Figura 13. Onde o módulo desempenha um papel fundamental na estimativa do SoC, servindo como medida de referência para os demais algoritmos de estimação desenvolvidos. Como a bancada experimental opera em um ambiente de laboratório controlado, todas as precauções foram tomadas para garantir medições precisas da corrente, minimizando possíveis erros na integração coulômbica. Esse controle rigoroso assegura que a estimativa obtida por este módulo reflita de forma confiável a carga real disponível na célula, permitindo a validação e calibração dos outros métodos de estimação do SoC. Dessa forma, os algoritmos implementados podem ser comparados e ajustados com base em uma referência robusta, garantindo maior confiabilidade nos resultados.




Figura 13 – Implementação da estimativa do SoC pelo método de Coulomb Counting no MATLAB *Simulink*

- **Bloco de medição da temperatura:** Responsável pela aquisição e processamento do sinal obtido do sensor NTC de temperatura (Figura 14). O bloco de medição de temperatura é responsável por calcular a temperatura da célula a partir do sinal de tensão de um sensor térmico. Para isso, converte o sinal de entrada em uma grandeza de temperatura em °C por meio de uma função de conversão calibrada. Esse bloco também incorpora parâmetros adicionais, como a resistência do sensor (R_t) e o coeficiente de calibração, garantindo que os ensaios sejam conduzidos dentro das faixas de temperatura permitidas.




Figura 14 – Implementação da estimativa da temperatura da bateria no MATLAB Simulink

- **Módulo de cálculo da capacidade:** Responsável por estimar a carga disponível na célula com base na integração da corrente ao longo do tempo e em outros parâmetros operacionais. O bloco responsável pelo cálculo da capacidade na Figura 15 determina a quantidade de carga armazenada na célula com base no SoC e na corrente fornecida ou extraída. Para isso, emprega um integrador que acumula a corrente medida ao longo do tempo e a converte para ampère-hora utilizando um fator de escala adequado (3600 s/h).




Figura 15 – Implementação do cálculo da capacidade da célula no MATLAB Simulink

Para o correto funcionamento de cada um dos módulos descritos anteriormente, é essencial o carregamento de um *script* de inicialização, que contém os parâmetros de calibração e configuração operacional necessários. Esse *script* não apenas define as condições

iniciais de operação, mas também deve ser atualizado após a execução de testes, como a identificação da capacidade da bateria. A eficácia de ensaios como o *HPPC* depende diretamente da atualização desses parâmetros em função da temperatura de operação. Além disso, valores críticos, como o SoC_{t0} , precisam ser recalibrados conforme o nível de carga inicial considerado para cada experimento, garantindo resultados consistentes e representativos do comportamento real da bateria.

Além disso, o *script* define parâmetros essenciais para assegurar um ambiente seguro durante a execução dos ensaios. Conforme mencionado anteriormente, o sistema conta com um mecanismo de proteção dupla, abrangendo tanto segurança digital quanto analógica. No contexto da proteção digital, são estabelecidos limites mínimos e máximos para variáveis críticas, como temperatura, corrente e tensão. Caso algum desses limites seja atingido, o sistema emite um sinal de parada, interrompendo imediatamente os processos de carga e descarga, bem como qualquer experimento em andamento. Isso evita danos à bateria e ao próprio sistema.

Já o sistema de proteção analógico baseia-se em uma lógica de acionamento de relés, que utiliza um sensor de temperatura para ativar um sinal de corte caso um valor fora da faixa permitida seja detectado. Além disso, foi implementada uma lógica adicional que impede a ativação simultânea dos relés de carga e descarga, eliminando o risco de curto-circuito. Essas estratégias de segurança garantem a integridade do sistema e a confiabilidade dos experimentos, minimizando riscos operacionais e assegurando uma caracterização precisa e segura da bateria.

3.1.2 Placa de aquisição de dados NI SCB-68A da *National Instruments*

A placa de aquisição de dados NI SCB-68A da *National Instruments* foi selecionada para os experimentos devido à sua capacidade de fornecer uma interface robusta e de alta precisão na aquisição e no processamento de sinais. Trata-se de um bloco de conexão de E/S blindado com 68 terminais de parafuso, projetado para facilitar a conexão de sinais a dispositivos de aquisição de dados de 68 ou 100 pinos, garantindo uma integração confiável e com baixa interferência eletromagnética. Esse hardware possibilita a aquisição de sinais por meio de entradas e saídas analógicas e digitais, além de oferecer compatibilidade com sinais de ativação *PFI* (Interface de função programável do inglês, *Programmable Function Interface*), permitindo a sincronização da aquisição de dados com outros dispositivos ou eventos no sistema de testes [107].

Em termos de capacidade, a NI SCB-68A oferece dois canais de saída analógica e múltiplos canais de entrada analógica, que podem ser configurados tanto no modo diferencial quanto no modo *single-ended*, adaptando-se a diferentes requisitos experimentais. Além disso, dispõe de entradas digitais e sinais de ativação *PFI*, possibilitando aquisições controladas e

sincronizadas com outros eventos na bancada de testes.

Para aprimorar a precisão das medições, a placa integra filtros passa-baixa e circuitos de atenuação de tensão diretamente na placa, permitindo a redução de ruído e a adaptação de sinais com diferentes níveis de tensão. Essa abordagem garante uma aquisição de dados com menor distorção e maior fidelidade. Graças a essas características, a NI SCB-68A torna-se uma ferramenta fundamental para a aquisição confiável de variáveis críticas, como tensão, corrente, temperatura e SoC no sistema experimental.



Figura 16 – Placa NI SCB-68A de aquisição de dados da *National Instruments*.


3.1.3 Sistema de comutação

Para gerenciar o processo de carga e descarga da bateria, foram utilizados relés controlados pelo *Simulink*. A configuração implementa um protocolo lógico que impede a ativação simultânea de ambos os modos, garantindo um controle seguro durante os ensaios experimentais. Os usuários podem iniciar diferentes testes, nos quais, por meio da comutação dos relés, seleciona-se entre os modos de carga ou descarga da bateria. Nessa configuração, o primeiro relé direciona a energia da fonte de alimentação do banco de testes para a bateria, enquanto o segundo canal permite a descarga da bateria por meio de uma carga programável (Figura 17a).


O processo de descarga da bateria é essencial para sua caracterização, pois diversos testes experimentais exigem um regime de descarga com corrente de magnitude constante. Esse procedimento controlado possibilita a obtenção de informações detalhadas sobre o desempenho e o comportamento da bateria sob condições específicas de operação. No entanto, para que essa descarga seja viável, é fundamental dispor de um sistema capaz de absorver a corrente e a energia extraída durante o processo. Para isso, emprega-se um circuito denominado Carga Programável [106].

Neste trabalho, foi projetado um circuito de carga programável utilizando um par de *MOSFET* IRF3205 em paralelo, controlados por uma saída digital da placa NI SCB-68A. Essa configuração permitiu que o *Simulink* gerasse um sinal PWM para ativação dos *MOSFET*. A saída da placa foi conectada a um filtro passa-baixa de primeira ordem, responsável por

converter os pulsos PWM em um sinal de tensão contínua. A corrente de descarga, I_d , flui através dos *MOSFET* em série com uma resistência de baixo valor, permitindo a medição precisa da corrente circulante com base na queda de tensão nessa resistência. O esquema do circuito pode ser observado na Figura 17b.



(a) Sistema de comutação.



(b) Diagrama de carga programável.

Figura 17 – Sistema de comutação e Diagrama de carga programável.

3.1.4 Monitoramento de temperatura

A temperatura da bateria é medida utilizando um termistor de coeficiente de temperatura negativo (*NTC* do inglês, *Negative Temperature Coefficient*), calibrado estaticamente para garantir medições precisas. Neste projeto, foi selecionado um termistor com uma resistência de referência de $10\text{ k}\Omega$ a $25\text{ }^{\circ}\text{C}$ e um coeficiente β de 3900 K . O cálculo da temperatura é realizado aplicando a equação de *Steinhart-Hart* (Equação 3.1):

$$\frac{1}{T} = \frac{1}{T_0} + \frac{1}{\beta} \ln\left(\frac{R_t}{R_0}\right) \quad . \quad (3.1)$$

Onde T , é a temperatura [K]; T_0 , é a temperatura de referência; β , é o coeficiente do termistor; R_t , é a resistência medida pelo sensor e R_0 , é a resistência de referência. Este sistema permite obter uma medição precisa e confiável da temperatura, o que é essencial para a caracterização das baterias em condições controladas e em cenários extremos.

3.1.5 Incubadora refrigerada com alternância de temperatura

No contexto da caracterização de células de bateria, o controle preciso da temperatura durante os ensaios é fundamental para garantir a consistência, repetibilidade e confiabilidade dos resultados experimentais. A temperatura afeta diretamente a capacidade, eficiência e dinâmica da bateria, sendo indispensável contar com um equipamento especializado que permita manter condições térmicas controladas (Figura 18).



Figura 18 – Incubadora refrigerada com alternância de temperatura da *SolidSteel*.

Para este propósito, foi utilizada uma incubadora térmica da marca *SolidSteel*, que desempenha um papel crucial ao regular a temperatura da célula em uma faixa definida de valores (-5, 0, 10, 20, 30, 40 e 50 °C). Esse equipamento garante que a bateria permaneça em condições estáveis durante cada teste, permitindo alternar entre diferentes níveis de temperatura para avaliar seu desempenho em diversas condições térmicas. Sua capacidade de manter um ambiente térmico controlado e homogêneo contribui significativamente para a precisão e confiabilidade dos dados coletados.

Adicionalmente, foi incorporada uma câmera webcam de monitoramento interno, cujo principal objetivo é monitorar visualmente o estado físico da bateria durante a execução dos ensaios. Essa ferramenta desempenha um papel crucial na detecção de eventos visuais inesperados, como a emissão de fumaça ou outros indicadores de falha catastrófica. A observação em tempo real proporcionada pela câmera adiciona uma camada adicional de segurança e controle, facilitando a identificação precoce de possíveis riscos durante os testes. A capacidade de monitoramento visual em tempo real reforça a segurança dos testes, permitindo a detecção precoce de condições perigosas e facilitando a intervenção oportuna em caso de emergências.

3.1.6 Fonte de alimentação

A fonte de alimentação desempenha um papel crucial no banco experimental, uma vez que sua principal função é fornecer energia às células da bateria, possibilitando o processo de carga. No presente estudo, foi utilizada uma fonte de alimentação modelo MPL3305

(Figura 19), fabricada pela empresa Minipa, a qual possui características de tensão ajustável e proteção integrada contra curto-circuito, garantindo assim um funcionamento seguro e confiável durante os testes.




Figura 19 – Fonte de alimentação MPL3305 da Minipa.

Este modelo opera sob um esquema de corrente constante (*CC* do inglês, *Constant Current*) quando a bateria se encontra em *DoD* e com uma tensão significativamente inferior à sua tensão nominal de carga. À medida que o processo de carga avança e a bateria se aproxima de seu *SoC* completo, a fonte transiciona para o modo de tensão constante (*CV* do inglês, *Constant Voltage*). Nesta etapa, a corrente de carga diminui progressivamente até valores próximos de zero, assegurando uma carga controlada e evitando possíveis danos à célula.

3.1.7 Células usadas nos experimentos

A seguir, apresentam-se as características técnicas da célula de bateria utilizada nos experimentos realizados neste estudo. Esta célula foi escolhida devido às suas propriedades específicas, como composição química, capacidade e tensão, que a tornam especialmente adequada para os testes de modelagem e estimativa do *SoC*. Na Tabela 5, são detalhadas as especificações técnicas do modelo de célula selecionado, fornecendo informações essenciais que facilitam tanto a replicabilidade quanto a contextualização dos métodos implementados neste trabalho.

Tabela 5 – Características da bateria utilizada (*LPF*: Fosfato de Ferro-Lítio).

Descrição	Valor numérico
Modelo	18650
Categoria da bateria	<i>LPF</i>
Capacidade nominal	1400 mAh
Taxa de descarga	2,0 C
Tensão nominal	3,2 V
Tensão de corte de carga (<i>Cut off voltage charge</i>)	3,6 V
Tensão de corte de descarga (<i>Cut off voltage discharge</i>)	2,5 V

3.1.8 *Toolbox Battery Modeling* de MATLAB

A *Toolbox* do MATLAB é utilizada neste trabalho para a identificação dos parâmetros do *ECM* da bateria, sendo essencial para a correta caracterização de seu comportamento dinâmico. Essa ferramenta permite determinar com precisão os principais parâmetros elétricos da célula, contribuindo para a modelagem e simulação do sistema de gerenciamento da bateria [108].

A *Battery Modeling Toolbox* do MATLAB, desenvolvida por Javier Gazzarri [109], é uma ferramenta especializada na caracterização de *LIB*, permitindo a identificação precisa dos principais parâmetros de um *ECM*. Seu funcionamento baseia-se em um processo de otimização, no qual, a partir de dados experimentais obtidos por meio de testes de carga e descarga, são identificados parâmetros fundamentais, como a resistência interna (R_0), a resistência de difusão (R_1) e a capacitância associada ao efeito transitório (C_1). Ao inserir esses dados experimentais, a *toolbox* ajusta iterativamente os valores desses parâmetros, gerando curvas simuladas que convergem para as medições reais. Durante esse processo, são estabelecidas restrições, como os limites mínimo e máximo dos parâmetros e os intervalos de temperatura dos testes, garantindo assim uma identificação coerente e fisicamente viável das características da bateria.

Entre suas principais vantagens, destaca-se a capacidade de automatizar a identificação de parâmetros, reduzindo significativamente o tempo e a complexidade em comparação com os métodos manuais. Além disso, sua integração nativa com o MATLAB e o *Simulink* facilita a validação e simulação de modelos em diferentes cenários operacionais. Essa ferramenta permite representar com alta precisão o comportamento dinâmico da bateria, o que é crucial para o desenvolvimento de estratégias avançadas de gerenciamento de energia.

No entanto, apresenta certas limitações, como a dependência de dados experimentais de alta qualidade para garantir a correta identificação dos parâmetros e uma curva de aprendizado acentuada, uma vez que seu uso requer conhecimento sólido tanto dos modelos de bateria quanto das técnicas de otimização implementadas na *toolbox*. Apesar desses desafios, a *Battery Modeling Toolbox* se consolida como uma solução eficiente e robusta para a caracterização de baterias em ambientes acadêmicos e industriais, proporcionando uma base confiável para a análise e o design de sistemas de armazenamento de energia.

3.2 Métodos

A Figura 20 apresenta os métodos utilizados e as etapas desenvolvidas neste trabalho, ilustrando o fluxo dos processos, desde os experimentos iniciais de caracterização das baterias, essenciais para determinar seus parâmetros dinâmicos, até a implementação do *EKF*, empregado como ferramenta principal para a estimativa precisa do *SoC*.

Em seguida, são detalhados os métodos aplicados em cada uma dessas etapas, destacando tanto as estratégias experimentais quanto computacionais que sustentaram o desenvolvimento do projeto. A metodologia adotada permitiu não apenas a caracterização detalhada das células, mas também a validação das técnicas utilizadas para alcançar os objetivos deste estudo.




Figura 20 – Estrutura dos métodos utilizados para o desenvolvimento desta pesquisa.

3.2.1 Caracterização da célula

O processo de caracterização da célula (ver Tabela 5) utilizada nesta pesquisa é estruturado em duas etapas principais. A primeira etapa foca na determinação da capacidade, um parâmetro cuja variabilidade significativa é influenciada pela temperatura. Avaliar o desempenho da célula em diferentes temperaturas (-5, 0, 10, 20, 30, 40 e 50 °C) é essencial para compreender como as condições térmicas afetam o seu comportamento eletroquímico, resultando em variações no valor da capacidade. A segunda etapa envolve a realização de um teste *HPPC*, o qual consiste em pulsos de descarga constante para a caracterização da bateria.

O protocolo para identificar a capacidade da bateria é composto por três etapas que garantem a precisão dos resultados, baseando-se na integração contínua da corrente extraída e fornecida à célula. Primeiramente, a célula é carregada até 100% de *SoC*. Em seguida, é mantida em repouso por 4 h para minimizar os efeitos da histerese e estabilizar seus parâmetros internos antes da próxima etapa.

Na sequência, realiza-se uma *DoD* da célula a uma corrente constante de 1C, até atingir a tensão de *cut-off* da célula, o que indica que a célula está completamente descarregada. Essa tensão de corte é característica de cada tipo de *LIB* e depende de sua composição química e design estrutural [110]. Após a descarga, a célula é submetida a um segundo período de estabilização de 4 h para mitigar os efeitos residuais da histerese e assegurar uma nova estabilização [13].

Finalmente, a célula é completamente recarregada e submetida a um último período de repouso de 4 h. Esse procedimento garante a determinação precisa do valor da capacidade para cada temperatura específica, proporcionando uma visão integral do impacto da temperatura no desempenho da bateria. Vale destacar que esses testes são realizados a temperatura constante, repetindo-se o mesmo procedimento para cada uma das temperaturas avaliadas.

Uma vez identificado o valor da capacidade, este é inserido no algoritmo implementado no *Simulink* (seção 3.1.1), responsável por executar os testes de caracterização da célula. A segunda etapa desse processo corresponde ao teste *HPPC*. Este teste é amplamente utilizado para avaliar a capacidade das células de fornecer energia sob diferentes condições operacionais. Ele é realizado a temperatura constante e consiste em ciclos de descarga com corrente constante de 1C, seguidos por um período de repouso de uma hora para estabilização eletroquímica. Durante cada ciclo, a corrente é aplicada até que o *SoC* reduza em 10%, repetindo-se o processo até atingir 0%.

Para obter uma caracterização mais detalhada da célula, adotou-se uma estratégia diferenciada na escolha dos intervalos de *SoC*, especialmente nas regiões onde a relação entre tensão e *SoC* apresenta comportamento não linear. Enquanto na literatura autores

como Hui [9], Bhat [20] e Alcázar [105] utilizam pulsos de descarga equivalentes a 10% de *SoC* ao longo de todo o experimento, neste trabalho, optou-se por reduzir esse valor para 5% nos intervalos de 100% a 80% e de 20% a 0%. Essa abordagem permite capturar com maior precisão as características não lineares presentes nos extremos da curva de *SoC*, proporcionando uma análise mais detalhada do comportamento da célula nessas regiões críticas, conforme ilustrado na Figura 4.

É importante mencionar que, após cada pulso de descarga, é incluído um período de repouso de 1 hora para estabilizar a célula e reduzir os efeitos da histerese. Segundo Plett [13], um tempo de repouso mais longo entre os pulsos pode reduzir significativamente a influência da histerese, melhorando a precisão dos dados obtidos. Ao final do teste, são registrados 15 níveis de *SoC*, obtidos por meio da integração da corrente, com uma duração total aproximada de 30 h. Esse conjunto de dados fornece uma base sólida para caracterizar o comportamento eletroquímico da célula em diferentes condições de operação.

3.2.2 Identificação do sistema

A escolha do modelo adequado depende das necessidades específicas de cada aplicação, considerando fatores como precisão desejada, limitações computacionais e a disponibilidade de dados experimentais. Portanto, para o desenvolvimento deste trabalho, foi escolhido o *ECM*. A identificação do modelo matemático que aproxima o sistema real a partir dos dados experimentais é uma etapa crucial nesta pesquisa. Uma identificação inadequada do modelo pode resultar em erros significativos nos processos subsequentes. Este procedimento foi realizado utilizando a *Toolbox* de *Battery Modeling* do MATLAB [109], descrita na seção 3.1.8.

Conforme mencionado na Seção 3.1.1, os dados coletados, incluindo tensão (V_{test}), corrente (I_{test}) e tempo (t), foram inicialmente amostrados a cada 10 ms. No entanto, como o processo de identificação do modelo precisa ser realizado para sete temperaturas distintas, a quantidade de dados gerada se tornou significativamente elevada, impactando diretamente o tempo necessário para cada identificação e o custo computacional. Para mitigar esse efeito, optou-se pela reamostragem dos dados com um intervalo de 1 s, permitindo uma redução substancial no volume de informações processadas sem comprometer a qualidade da identificação. Adicionalmente, verificou-se que os modelos obtidos a partir dos dados reamostrados apresentaram desempenho compatível ou superior aos modelos identificados com a taxa original de 10 ms (ver Capítulo 4.3).

A próxima etapa consiste na definição do número de ramos RC do modelo. Um maior número de ramos permite uma melhor representação do comportamento dinâmico da célula, porém, aumenta o custo computacional. Neste estudo, foi adotado um modelo de terceira ordem com três ramos RC, visando obter uma representação matemática mais fiel

ao comportamento real da célula durante o processo de identificação.

Entretanto, para a implementação do *EKF*, optou-se por um modelo reduzido com apenas um ramo RC, devido às restrições de carga computacional. Essa simplificação permite um processamento mais eficiente, mantendo um equilíbrio entre precisão e viabilidade computacional. Dessa forma, o *EKF* utiliza apenas um dos três ramos identificados no modelo completo. O layout da *Toolbox* de *Battery Modeling* pode ser visualizado na Figura 21.




Figura 21 – Tela principal da *Toolbox*, onde são configuradas as ramificações RC a serem identificadas. Adaptada de [109]

Na Figura 21, a entrada do modelo, denominada "*Current*", corresponde à corrente amostrada no teste *HPPC* experimental. A variável de saída do modelo, identificada como "*V_out*", representa a tensão terminal da célula. A identificação dos parâmetros do *ECM* é realizada por meio de um processo iterativo de otimização, ajustando-os para cada condição de temperatura. O objetivo é minimizar a diferença entre os dados experimentais e a resposta simulada do modelo, utilizando algoritmos como mínimos quadrados não lineares. Como resultado, obtém-se um conjunto de parâmetros que melhor representa o comportamento dinâmico da célula, garantindo a precisão do modelo nas condições operacionais específicas.

Como destacado no início, um modelo preciso é essencial para garantir resultados confiáveis na estimativa e análise do sistema. Por essa razão, foi implementado um segundo processo de identificação do modelo, baseado no método proposto por Sae [18]. Esse método utiliza ferramentas avançadas do MATLAB para a caracterização e modelagem de baterias, permitindo identificar os parâmetros chave do *ECM*. A seguir, são detalhadas as principais etapas:

- **Inicialização e carregamento dos dados:** A classe *Battery.PulseSequence* é utilizada para gerenciar a sequência de pulsos. Os dados experimentais (I_{test} , V_{test} e t) são

carregados de um arquivo .mat por meio da função *Battery.loadDataFromMatFile*. Esses dados correspondem aos testes *HPPC*.

- **Segmentação dos pulsos:** O método *createPulses* identifica os eventos de pulso nos dados de I_{test} (ver Figura 22) e segmenta os períodos relevantes, incluindo amostras antes e depois de cada pulso para capturar os efeitos dinâmicos de relaxação. Nesta etapa, define-se o número de ramos RC do modelo (**NumRCBranches=3**).




Figura 22 – Segmentação dos pulsos. Adaptado de [18].

- **Ajuste inicial dos parâmetros:** São definidos valores iniciais e restrições para os parâmetros do modelo (Em (que representa a *OCV* nas *LUT*), R_0 , R_x e τ). Os valores de τ (constantes de tempo) são ajustados iterativamente dentro dos limites especificados (T_{xMin} e T_{xMax}), garantindo que estejam no intervalo dinâmico dos dados.
- **Estimativa dos parâmetros por meio de otimização:** Algoritmos de otimização não linear, fornecidos pela Simulink *Design Optimization Toolbox*, são empregados para ajustar os parâmetros do modelo. O objeto *sdo.OptimizeOptions* configura as opções do otimizador, incluindo o uso da função *lsqnonlin* para minimizar a diferença entre o modelo e os dados experimentais.
- **Validação do modelo:** Finalmente, os parâmetros estimados são validados simulando a resposta do modelo e comparando-a com os dados experimentais. As funções *plotSimulationResults* e *plotLatestParameters* permitem visualizar os resultados e avaliar a qualidade do ajuste obtido.

Após a conclusão dos procedimentos de identificação do modelo por meio dos métodos previamente descritos, procede-se à construção das *LUT*, que representarão o modelo identificado. Como foram aplicados dois métodos distintos de identificação, são geradas duas *LUT*, cada uma correspondente a um dos métodos utilizados. Essas tabelas são essenciais

para armazenar os parâmetros identificados, que caracterizam o modelo em função dos diferentes elementos que o compõem.

O modelo identificado considera três ramos RC, e os experimentos de caracterização foram realizados em 7 temperaturas distintas. Além disso, para aprimorar a precisão da caracterização da bateria, foram definidos 15 níveis de *SoC*, resultando em um modelo de grande porte. Para a construção de cada LUT, são incluídas 105 linhas, equivalentes à combinação dos 15 níveis de *SoC* com as 7 temperaturas avaliadas, e 10 colunas, que representam os principais parâmetros da bateria: *SoC*, *OCV*, *R0*, *R1*, *R2*, *R3*, *C1*, *C2*, *C3* e *T*. Por fim, cada LUT apresenta uma dimensão de 105×10. Como foram identificados dois modelos distintos, há duas LUT com as mesmas dimensões, permitindo avaliar e comparar o desempenho de ambos em termos de precisão e capacidade de adaptação do modelo ao comportamento real da bateria. Essa abordagem assegura que as diferenças na precisão e aplicabilidade dos métodos possam ser quantificadas, oferecendo uma base sólida para a seleção do método mais adequado.

O processo de identificação para cada temperatura é um processo árduo devido à necessidade de realizar múltiplos testes experimentais para capturar as dinâmicas da bateria em diferentes condições térmicas. Além disso, é imprescindível processar grandes volumes de dados experimentais para identificar com precisão os parâmetros do modelo e gerar as LUT correspondentes. Este procedimento deve garantir que as tabelas sejam consistentes e reflitam com exatidão as variações dos parâmetros em função das condições de operação.

Apesar da complexidade e do tempo necessário, essa abordagem é crucial para capturar de forma detalhada e precisa as variações térmicas e operacionais dos parâmetros do modelo. Isso não apenas reforça a robustez e confiabilidade do sistema de estimativa do *SoC*, mas também assegura um comportamento adequado do modelo em cenários reais, nos quais as condições de operação da bateria podem variar significativamente.

3.2.3 Validação do modelo implementado

O processo de validação tem como objetivo garantir a qualidade dos dados obtidos e sua correspondência com o comportamento real da bateria. Para isso, realiza-se uma simulação no MATLAB-*Simulink* de uma bateria virtual, que será submetida ao mesmo perfil de corrente aplicado na bateria real. Essa abordagem permite avaliar o comportamento da simulação em comparação com os dados reais e quantificar, em termos percentuais, o nível de similaridade entre ambos os resultados.

A simulação inicia com a implementação do elemento *Battery (Table-Based)*, conforme mostrado na Figura 23, onde são carregados os parâmetros identificados do modelo juntamente com o número de ramificações RC definidas. Vale ressaltar que o elemento *Battery (Table-Based)* inclui uma seção para simular o comportamento térmico da célula, o

qual não será considerado nesta pesquisa.




Figura 23 – Elemento *Battery (Table-Based)* do MATLAB-Simulink.

Após configurar o elemento *Battery (Table-Based)*, são incorporados sensores de corrente e tensão, juntamente com as entradas do sistema (corrente e temperatura ambiente) e as saídas correspondentes (tensão, temperatura e SoC). A corrente utilizada nesse teste é idêntica ao perfil aplicado nos testes realizados com a bateria real. A configuração dos elementos para esta etapa é detalhada na Figura 24. Os componentes são organizados em um bloco único, com o objetivo de facilitar a visualização e o gerenciamento dos algoritmos implementados.




Figura 24 – Diagrama de conexões com a bateria simulada.

Posteriormente, adicionam-se ferramentas como *Scope* para visualizar as variáveis de saída, e o perfil de corrente real, denominado *current*, é conectado à entrada da simulação. Além disso, uma variável constante que representa a temperatura ambiente é incluída e atualizada para refletir os diferentes valores de temperatura abordados nesta pesquisa. Também são configurados parâmetros-chave dentro do elemento *Battery (Table-Based)*, como a capacidade da célula (*Cell capacity, Ah*) e a temperatura inicial da célula (*Battery.T_init*). É essencial ajustar o valor da capacidade da célula de acordo com os resultados obtidos nos diferentes testes de identificação da Cn. A configuração dessa segunda etapa é ilustrada na Figura 25, onde também é mostrado um bloco responsável por converter a temperatura de K para °C e uma equação para identificar a capacidade correspondente aos dados simulados.





Figura 25 – Modelo *Simulink* desenvolvido para a validação do modelo.

Para uma validação mais robusta, o processo não se limita apenas ao perfil de corrente do teste *HPPC*. São incorporados dois perfis de corrente adicionais que simulam cenários típicos em *EV* conforme mostrado na Figura 26. Esses perfis incluem períodos de repouso, descargas constantes em diferentes níveis de corrente e condições iniciais de *SoC* distintas (aproximadamente 60 e 100%). Isso permite avaliar a validade do modelo em cenários diversos. Assim como no perfil *HPPC*, esses dois novos perfis são avaliados para as diferentes temperaturas com seus respectivos valores de capacidade.



(a) Perfil de corrente para validação correspondente a 100% do nível SoC. (b) Perfil de corrente para validação correspondente a 60% do nível SoC.

Figura 26 – Perfis de correntes para validação.

A etapa final do processo de validação baseia-se na implementação das equações de ajuste e similaridade 2.31 e 2.32, utilizando tanto o cálculo do *FIT* quanto do *VAF*. Nessa fase, desenvolve-se um algoritmo no editor do MATLAB que, após cada simulação no *Simulink* (ver Figura 25), registra as saídas de tensão simulada ($V_{simulado}$) e as correspondentes ao teste real (V_{real}).

O algoritmo calcula o percentual de similaridade entre $V_{simulado}$ e V_{real} . Quanto mais próximo esse percentual estiver de 100%, maior será a correspondência entre o modelo simulado e o comportamento real da bateria, garantindo a validade do modelo. Essa análise é aplicada sistematicamente para cada uma das temperaturas avaliadas, assegurando a robustez do modelo e sua capacidade de representar fielmente o sistema sob diversas condições operacionais.

3.2.4 Estimativa do SoC pelo método do CC

Nesta etapa, é implementado o primeiro algoritmo responsável por estimar o SoC da célula. Para essa primeira abordagem, optou-se pelo método de CC devido à sua facilidade de implementação e precisão, tornando-o uma ferramenta fundamental para uma estimativa inicial. Além disso, esse método servirá como referência para a futura implementação do *EKF*, permitindo comparar seu desempenho com uma técnica de estimativa direta e amplamente utilizada.

O método de CC baseia-se na integração da corrente fornecida ou extraída da bateria ao longo do tempo, partindo de um estado inicial conhecido (Equação 2.2). Para sua imple-

mentação no ambiente MATLAB, emprega-se a expressão matemática definida na Equação 3.2, onde Ah representa a quantidade de carga transferida em Ah.

$$MeSOC = \frac{(Cn + Ah)100}{Cn} \quad . \quad (3.2)$$

A estimativa do SoC é obtida a partir da relação entre a corrente acumulada e a Cn da bateria, permitindo determinar o percentual de carga restante. Adicionalmente, com o objetivo de melhorar a interpretação temporal dos resultados e facilitar sua análise, o tempo de simulação é convertido de segundos para horas por meio da Equação 3.3.

$$TimeHours = \frac{t}{3600} \quad . \quad (3.3)$$

Esse procedimento é aplicado aos dados obtidos em diferentes ensaios experimentais, incluindo o teste *HPPC* e testes adicionais projetados para a validação do modelo. A correta implementação desse método garante uma estimativa confiável do SoC .

Para validar essa implementação, foi desenvolvido um modelo de simulação no *Simulink* utilizando o bloco *SoC Estimator (Coulomb Counting, Variable Capacity)*. Esse bloco requer a definição do perfil de corrente de entrada, a capacidade e do estado inicial do SoC . Para os ensaios em que foi utilizado o perfil de corrente do teste *HPPC*, bem como para um teste de validação no qual se garantiu que a bateria estivesse completamente carregada, o SoC_{t0} foi estabelecido em 1 (100%). Por outro lado, para o teste em que a bateria iniciou com um SoC de 60%, SoC_{t0} foi definido como 0.60 (60%).

Além disso, na simulação são considerados tanto os perfis de corrente dos ensaios reais (*current*), quanto aqueles obtidos a partir da bateria simulada, denotados como *Current_S*. É importante destacar que, nesse processo, o valor da capacidade deve ser atualizado adequadamente em função da temperatura, visto que esse parâmetro é definido como uma constante na simulação, conforme ilustrado na Figura 27.




Figura 27 – Modelo *Simulink* desenvolvido para a estimativa de SoC por meio do método CC.

3.2.5 Modelo matemático representado em espaço de estados

Retoma-se o *ECM* já mencionado, focando na sua representação na forma de espaços de estados junto à equação de Coulomb. Para a implementação do *EKF*, será considerado um único ramo RC, visando a redução do custo computacional sem comprometer a precisão da estimativa do *SoC*. A Equação 3.4 representa a tensão em uma das ramificações do *ECM* e sua $V(t)$ agora é apresentada na forma de espaço de estados, assim como a Equação 2.11, que descreve o método de Coulomb. Essa abordagem permite compreender a teoria fundamental necessária para a aplicação do *EKF* na estimativa do *SoC*.

$$\frac{\partial V_1}{\partial t} = -\frac{1}{C_1(SoC, T, t) + R_1(SoC, T, t)}V_1 + \frac{1}{C_1(SoC, T, t)}IV_1(t) \quad . \quad (3.4)$$

De acordo com a equação de resposta transitória RC, a tensão V_1 é expressa como

$$V1_k = e^{\frac{-\Delta t}{R_1 C_1}} V1[k-1] - e^{\frac{-\Delta t}{R_1 C_1}} I[k-1] + \omega_2[k-1] \quad . \quad (3.5)$$

A partir desse ponto, o modelo se baseia na equação do método de integração de corrente discretizada Equação 2.11. E todas as equações do espaço de estados.

$$\begin{bmatrix} SoC_k \\ V1_k \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & e^{\frac{-\Delta t}{R_1 C_1}} \end{bmatrix} \begin{bmatrix} SoC[k-1] \\ V1[k-1] \end{bmatrix} + \begin{bmatrix} \frac{-\Delta t}{C_n} \\ -R_1(1 - e^{\frac{-\Delta t}{R_1 C_1}}) \end{bmatrix} I[k-1] + \begin{bmatrix} \omega_1[k-1] \\ \omega_2[k-1] \end{bmatrix} \quad . \quad (3.6)$$

$$Vt = OCV(SoC_k) - V1[k] - R0(SoC_k)I[k] \quad . \quad (3.7)$$

Onde A ; é a matriz de transferência, B ; é a matriz de entrada do sistema, C ; a matriz de observação e D é a matriz de realimentação.

$$A = \begin{bmatrix} 1 & 0 \\ 0 & e^{\frac{-\Delta t}{R_1 C_1}} \end{bmatrix}; \quad B = \begin{bmatrix} \frac{-\Delta t}{C_n} \\ -R_1 \left(1 - e^{\frac{-\Delta t}{R_1 C_1}}\right) \end{bmatrix}; \quad C = \begin{bmatrix} \frac{\delta OCV}{\delta SoC} & -1 \end{bmatrix}; \quad D = -R0 \quad . \quad (3.8)$$

Nesta abordagem, o *SoC* e a tensão no capacitor do circuito equivalente são considerados as variáveis de estado, enquanto a tensão terminal da bateria atua como a saída do sistema. O modelo foi parametrizado em função da temperatura e do *SoC*, utilizando funções de interpolação para avaliar a resistência interna $R0$, a resistência do circuito equivalente $R1$ e a capacitância do capacitor $C1$.

A equação da *OCV* foi obtida a partir de um polinômio de ajuste, e sua derivada foi utilizada para a linearização da matriz de observação C . A dinâmica do sistema foi definida com base na equação de atualização do *SoC*, que considera a corrente da bateria e uma n variável de acordo com o regime de carga e descarga. Com esses elementos, o modelo em espaço de estados foi formulado com matrizes A e B , que descrevem a evolução do sistema, enquanto a matriz C estabelece a relação entre as variáveis de estado e a medição da tensão terminal.

3.2.6 Implementação do *EKF*

Considerando as equações de estado que descrevem o modelo do sistema, o cálculo do *SoC* é realizado por um processo sistemático. Esse processo inclui a modelagem da dinâmica da bateria, a previsão do estado e a atualização das estimativas com base nas medições. As etapas envolvidas no cálculo do *SoC* usando o *EKF* estão detalhadas abaixo:

- **Modelagem da dinâmica da célula:** Considera-se o modelo da célula em espaço de estados com as matrizes definidas na Equação 3.8.
- **Modelo de transição de estado:** O modelo de transição de estado descreve como o estado da bateria evolui ao longo do tempo, onde as equações de estado são representadas como Equação 3.9.

$$\hat{X}_{[k+1]|k} = A\hat{X}_{k|k} + Bu_k \quad . \quad (3.9)$$

onde A é a matriz de transição de estado, B é a matriz de entrada de controle e u_k é a entrada de controle (a corrente).

- **Etapa de previsão:** Na fase de previsão, o *EKF* projeta a covariância atual e o erro antecipadamente.

$$P_{[k+1]|k} = AP_{k|k}A^T + Q_k \quad . \quad (3.10)$$

Onde P , é a matriz de covariância de erro do estado inicial e Q_k é a covariância do ruído do processo.

- **Modelo de Medição:** O modelo de medição relaciona o estado com as medições observadas. Para a estimativa do *SoC*, a medição poderia ser a tensão.

$$z_k = C\hat{X}_{k|k} + v_k \quad . \quad (3.11)$$

Onde, z_k é a medição (tensão), C é a matriz de medição, e v_k é o ruído de medição.

- **Etapa de Correção:** O *EKF* atualiza o estado incorporando a nova medição do cálculo do Ganho de Kalman (*KG* do inglês, *Kalman Gain*), conforme a Equação 3.12, a

atualização do estado de acordo com a Equação 3.13, e a atualização da covariância do erro segundo a Equação 3.14.

$$K_{[k+1]} = P_{[k+1]|k} C^T (C P_{[k+1]|k} C^T + R_k)^{-1} \quad (3.12)$$

Onde R_k é a covariância do ruído de medição.

$$\hat{X}_{[k+1]|k+1} = \hat{X}_{[k+1]|k} + K_{[k+1]} (Z_{k+1} - C \hat{X}_{[k+1]|k}) \quad (3.13)$$

$$P_{[k+1]|k+1} = (I - K_{[k+1]} C) P_{[k+1]|k} \quad (3.14)$$

Esse ciclo de previsão e correção é repetido a cada etapa de tempo, permitindo que o *EKF* atualize continuamente a estimativa do *SoC* com base em novas medições e na evolução do status da bateria.

Para garantir a correta atualização do *SoC* a cada etapa de tempo, o modelo da bateria precisa fornecer parâmetros adequados em função das condições operacionais. Nesse sentido, o algoritmo implementado no MATLAB processa medições de corrente, tensão e temperatura da célula, empregando uma abordagem de interpolação para estimar os parâmetros internos da bateria (R_0 , R_1 e C_1) em temperaturas e níveis de *SoC* intermediários. Esses parâmetros já foram previamente identificados para sete temperaturas distintas (-5, 0, 10, 20, 30, 40 e 50°C) e para 15 níveis de *SoC*, formando uma base de dados discreta do modelo da bateria. A interpolação permite obter valores contínuos desses parâmetros para temperaturas e estados de carga que não coincidem exatamente com os pontos identificados, garantindo uma melhor adaptação do modelo às condições reais de operação. Além disso, a relação entre o *SoC* e a *OCV* foi modelada por meio de um polinômio de ajuste de sexto grau, cuja derivada foi integrada na matriz de observação C .

O processo do *EKF* é desenvolvido em duas etapas: predição e correção. Durante a fase de predição, a equação de estado é avaliada a partir das matrizes A e B , que são calculadas dinamicamente com base no modelo da bateria. Nesta etapa, a estimativa do estado é atualizada considerando a entrada de corrente. Na fase de correção, o erro entre a medição da tensão e sua estimativa é utilizado para ajustar o estado por meio do KG , permitindo reduzir a incerteza na estimativa.

Para melhorar a precisão do filtro, foi implementado um processo de otimização destinado a identificar as matrizes de covariância Q_k , P e R_k em cada temperatura, com o objetivo de ajustar a resposta do *EKF* aos dados experimentais. O código desenvolvido permite estimar o *SoC* da célula e armazena um histórico das matrizes P e KG para análise posterior. É importante destacar que os dados utilizados na estimativa correspondem aos obtidos na etapa de caracterização da bateria, incluindo um teste *HPPC* e dois testes de validação, cada um com um SoC_{t0} distinto.

Cálculo de matrizes de covariância

O desempenho do *EKF* na estimativa do *SoC* de uma bateria depende, em grande medida, da correta configuração de suas matrizes de covariância: a matriz de ruído de medição (R_k), a matriz de ruído de processo (Q_k) e a matriz de covariância do estado inicial (P). Essas matrizes afetam diretamente a capacidade do *EKF* de equilibrar a incerteza na medição e a confiança no modelo do sistema, influenciando, assim, a convergência e a precisão do estimador.

Na literatura, é comum que o ajuste dessas matrizes seja realizado de forma empírica ou a partir de métodos heurísticos baseados em testes experimentais. Alguns estudos abordaram esse problema estabelecendo valores com base na experiência ou ajustando-os por meio de testes de simulação e comparação com dados reais (Taborelli [111], Yang [112], Khanum [30], Xie [102]). Por outro lado, o trabalho de Silva [14] propõe uma abordagem iterativa para a estimativa do *SoC* em *LIB*, na qual se implementa um *EKF* adaptativo. Sua metodologia introduz uma política de ajuste dinâmico das matrizes de ruído de processo (Q_k) e de medição (R_k) em tempo de execução, otimizando, assim, o desempenho do filtro em diversas condições operacionais. Essa estratégia inovadora melhora significativamente a precisão da estimativa do *SoC* e foi validada em um *BMS* para aplicações industriais.

Neste trabalho, propõe-se uma abordagem alternativa e inovadora baseada na otimização das matrizes de covariância do *EKF* por meio da função *fmincon* do MATLAB. Diferentemente do método adaptativo de Silva [14], neste caso, realiza-se uma otimização prévia de R_k , Q_k e P , utilizando um critério baseado no erro de estimativa da tensão terminal ($V(t)$) e do *SoC*. A função objetivo da otimização penaliza a diferença entre a tensão estimada pelo modelo e a medição real, garantindo, assim, uma melhor resposta do *EKF*. Além disso, incorpora-se um termo de erro associado à estimativa do *SoC*, com um peso maior (0,8) em relação à tensão terminal, uma vez que o *SoC* é a variável chave a ser aprimorada no processo de estimativa (Equação 3.15). Dessa forma, a métrica de otimização é definida como uma combinação ponderada do erro quadrático médio (*RMSE* do inglês, *Root Mean Squared Error*) da tensão terminal e do *SoC* estimado (Equação 3.16).

É importante ressaltar que o processo de otimização das matrizes de covariância é realizado de forma *offline*. Inicialmente, as matrizes R_k , Q_k e P são calculadas para diferentes temperaturas por meio do processo de otimização descrito anteriormente. Os valores obtidos são então armazenados em uma *LUT*, permitindo que o *EKF* utilize diretamente os parâmetros otimizados durante a fase de estimativa em tempo real. Dessa forma, a carga computacional do filtro é reduzida, garantindo um equilíbrio entre precisão e eficiência no processo de estimativa do *SoC*.

$$f = 0,2 \quad V(t)_{RMSE} + 0,8 \quad SOC_{RMSE} \quad . \quad (3.15)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad . \quad (3.16)$$


Onde N , é o número total de observações; y_i , são os valores observados e $\hat{y}_i$ são os valores previstos pelo modelo.

Para garantir a viabilidade do processo de otimização, os valores iniciais, bem como os limites superiores e inferiores de R_k , Q_k e P , foram definidos a partir de valores empíricos e referências na literatura citadas previamente. Uma vez obtidos os valores otimizados, eles foram incorporados na implementação do *EKF* para avaliar seu desempenho na estimativa do *SoC*.

3.2.7 Validação do *EKF*

Uma das estratégias para validar o algoritmo implementado é submetê-lo a exigências mais próximas das condições reais, onde o *EKF* enfrente os desvios comuns que podem ocorrer nos sensores dos sistemas *BMS*. Nesse processo, busca-se introduzir ruídos nas medições de corrente com o objetivo de simular desvios sistemáticos e variabilidade aleatória. Esse procedimento permite avaliar a robustez do *EKF* diante de medições afetadas por erros comuns em sensores. Para isso, implementam-se dois tipos de perturbações: um erro sistemático (*bias*) e ruído gaussiano.

O *bias* em um sensor é um erro sistemático que afeta todas as medições de maneira uniforme dentro do seu intervalo operacional. Não é um erro aleatório, o que implica que as medições apresentam um deslocamento constante em relação ao valor real. Esse tipo de erro pode ser causado por diversos fatores, como calibração incorreta, envelhecimento do sensor, interferências ambientais ou escolha inadequada do sensor para a aplicação [113]. Como o *bias* introduz uma variação previsível nos dados, sua inclusão na validação do *EKF* permite analisar a resposta do filtro a esse tipo de erro. Neste estudo, um erro constante de 0,15A foi adicionado à segunda metade dos dados de corrente conforme ilustrado na Figura 28a, simulando um *bias* na medição. Além do *bias*, adiciona-se ruído aleatório com distribuição gaussiana de média zero, aumentando a variância do sinal de corrente conforme é mostrado na Figura 28b. Especificamente, adicionou-se um ruído branco de variância 0,2 ao sinal de corrente.



(a) Perfil de corrente aplicando um erro no sensor do tipo bias a em uma temperatura de $20^{\circ}C$.

(b) Perfil de corrente aplicando um ruído branco em uma temperatura de $20^{\circ}C$.

Figura 28 – Perfis de corrente aplicando diferentes tipos de erros no sensor a uma temperatura de $20^{\circ}C$.

A análise é desenvolvida em três etapas. Primeiro, avalia-se o comportamento do *EKF* na presença exclusiva de *bias*, permitindo analisar como o algoritmo responde a um erro sistemático na corrente medida. Em seguida, valida-se o filtro sob a presença exclusiva de ruído gaussiano, examinando sua capacidade de lidar com medições de alta variabilidade. Por fim, introduz-se um erro inicial de 10% na estimativa do *SoC*, com o objetivo de estudar como o *EKF* corrige a divergência ao longo do tempo. Essa abordagem permite avaliar a resposta do *EKF* frente a diferentes tipos de perturbações, garantindo sua precisão na estimativa do *SoC* sob condições adversas de medição. A validação desses cenários é essencial para assegurar a confiabilidade do algoritmo em aplicações reais, onde os sensores podem estar sujeitos a erros sistemáticos e ruído, afetando a qualidade dos dados de entrada do filtro.

Para avaliar a estimativa do filtro em um cenário de múltiplas estimativas, considera-se um caso mais representativo de um *BMS* real, no qual não apenas se estima o *SoC* de uma única célula, mas de um pack completo de baterias. Para isso, expande-se a simulação apresentada na Figura 24, na qual uma única célula foi modelada, e constrói-se um pack de baterias composto por 16 células conectadas em série. Nessa configuração, assume-se que o modelo identificado previamente é válido para cada uma das células e que a corrente que circula por elas é idêntica. Essa suposição simplifica a análise e permite estudar o desempenho do *EKF* quando aplicado a um sistema com múltiplas células, refletindo um cenário mais próximo de sua implementação em um *BMS* comercial.

Para adaptar o algoritmo a esse novo cenário, inicializa-se um vetor de estado para cada célula, onde são armazenados seu SoC_{t_0} e sua tensão inicial. Essa estrutura de dados permite um monitoramento individualizado de cada célula dentro do pack. O algoritmo

implementa um *loop* temporal no qual, a cada instante de simulação, o modelo da bateria é avaliado e o *EKF* é executado para atualizar o estado de cada célula com base nas medições de corrente, tensão e temperatura. Durante cada iteração, a tensão $V(t)$ é estimada, o erro de medição é calculado e a estimativa do *SoC* é ajustada, armazenando os valores em uma matriz específica. Esse procedimento garante que a evolução do *SoC* de cada célula seja registrada e possa ser analisada posteriormente, o que é crucial para a gestão eficiente do pack de baterias em aplicações práticas.

4 Resultados

Neste capítulo, são apresentados e analisados os resultados obtidos ao longo da pesquisa, seguindo os métodos estabelecidos na Figura 20. O estudo inicia-se com a caracterização da célula utilizada, submetendo-a a diferentes testes, incluindo o ensaio *HPPC* e testes de validação para avaliar seu comportamento sob diversas condições operacionais. Posteriormente, são detalhados os resultados da identificação e validação do modelo *ECM*, destacando sua capacidade de representar com precisão a dinâmica da bateria. Por fim, é apresentada a estimativa do *SoC* por meio do *EKF*, analisando seu desempenho na presença de diferentes condições operacionais e fontes de erro. Os resultados obtidos permitem validar a eficácia do método proposto e sua aplicabilidade em sistemas reais de gerenciamento de baterias, fornecendo uma base sólida para futuras otimizações e aprimoramentos na estimativa do *SoC*.

4.1 Caracterização da célula

O primeiro passo na caracterização da célula é a identificação de sua capacidade em diferentes temperaturas. Após a realização dos experimentos, obtém-se a Figura 29 na subfigura do meio, que ilustra a evolução da tensão na célula durante as fases de carga, estabilização e descarga em uma temperatura de 20 °C, evidenciando o comportamento característico de uma *LIB* nessas condições.

Inicialmente, no ciclo de carga, a tensão aumenta progressivamente até atingir seu valor máximo, indicando a saturação da célula. Em seguida, na fase de repouso, observa-se uma leve queda na tensão devido à redistribuição interna dos íons de lítio e à estabilização do potencial eletroquímico. Posteriormente, a célula é submetida a uma descarga profunda até alcançar sua tensão de corte, onde ocorre um fenômeno relevante: após um período prolongado de repouso, a tensão começa a se recuperar levemente. Esse comportamento é atribuído ao efeito de relaxamento eletroquímico, no qual os gradientes de concentração internos se redistribuem, permitindo uma recuperação parcial da tensão sem aporte externo de energia. Finalmente, após esse período de estabilização, a célula é novamente submetida a um ciclo de carga, repetindo-se o padrão anteriormente observado.




Figura 29 – Resultados do experimento de identificação da capacidade da célula em uma temperatura ambiente constante de 20 °C.

A Figura 29 na parte inferior apresenta o perfil da capacidade da célula ao longo do experimento. Inicialmente, o valor da capacidade é zero, pois, nesse instante, nenhuma carga foi fornecida ou extraída da célula. À medida que o processo de carga se inicia, a capacidade aumenta progressivamente, indicando o acúmulo de carga na célula. Durante o período de estabilização, a corrente se mantém nula, resultando em um trecho horizontal na curva. Posteriormente, quando a célula entra na fase de descarga, a capacidade começa a diminuir, representando a extração de carga da célula. Nesse ponto, observa-se uma queda abrupta na curva, correspondente à descarga profunda até alcançar a tensão de corte. Uma vez concluída a descarga, inicia-se um novo período de estabilização, no qual a corrente volta a ser zero e, consequentemente, a curva permanece constante.

Finalmente, em um novo ciclo de carga, a capacidade volta a aumentar, refletindo o armazenamento de carga na célula. Como o processo de carga é concluído e a célula recebe uma quantidade de carga superior à extraída durante a descarga (considerando possíveis efeitos de eficiência), a capacidade final medida no processo de carga é ligeiramente inferior (1,46 mA) à capacidade inicial (1,47 mA). Essa diferença entre a capacidade medida na carga e na descarga está relacionada com a eficiência do processo e é considerada no cálculo do parâmetro η do algoritmo de Coulomb Counting, definido como a razão entre a capacidade total medida na descarga e a capacidade total medida na carga. Embora essa diferença seja quase imperceptível, ela se deve à capacidade efetiva da célula, que pode ser influenciada pela

temperatura, pela dinâmica dos íons no eletrólito e pela resistência interna da célula. Esses fatores afetam tanto a carga armazenada quanto a eficiência do ciclo de carga e descarga.

Além disso, de acordo com a definição apresentada no livro de Plett [13], a capacidade total de uma célula é a quantidade de carga extraída da célula quando se leva de um estado completamente carregado até um estado completamente descarregado. Na prática é mais comum utilizar unidades de ampère-hora (Ah) ou miliampère-hora (mAh) para medir a capacidade total de uma célula de bateria. A capacidade total da célula é um parâmetro importante nos modelos, mas não é estritamente fixa: ela geralmente diminui lentamente com o tempo à medida que a célula envelhece.

Uma vez que o processo de identificação da capacidade deve ser repetido para cada uma das temperaturas consideradas neste estudo, torna-se fundamental analisar a variabilidade da capacidade da célula sob diferentes condições térmicas. Com esse propósito, apresenta-se a Tabela 6, na qual é possível visualizar a capacidade identificada nos experimentos para cada uma das temperaturas avaliadas. Essa tabela possibilita comparar o impacto da temperatura na capacidade da bateria, fornecendo informações essenciais para a compreensão de seu comportamento eletroquímico em diferentes ambientes operacionais.

Tabela 6 – Temperaturas consideradas na pesquisa em relação à capacidade identificada na célula.

	Temperatura [°C]						
	-5	0	10	20	30	40	50
Cn [Ah]	1,262	1,327	1,427	1,462	1,500	1,541	1,515

Dando continuidade aos resultados obtidos nesta etapa de caracterização, apresentam-se a seguir os resultados do experimento *HPPC*, realizado com uma taxa de descarga de 1 C a uma temperatura constante de 20 °C, os quais são ilustrados na Figura 30. No gráfico, identificam-se 15 níveis distintos do *SoC*, onde os quatro primeiros e os quatro últimos pulsos correspondem a uma descarga de 5% do *SoC*, enquanto os pulsos intermediários representam uma descarga de 10%. Observa-se também o comportamento característico da tensão da célula, no qual, após cada pulso de descarga, a tensão aumenta gradualmente até atingir um novo estado de equilíbrio. Esse padrão reflete a resposta eletroquímica da célula à remoção da corrente de descarga, evidenciando sua dinâmica de recuperação da tensão.

No entanto, à medida que o experimento avança, verifica-se uma redução progressiva na tensão de estabilização. Esse comportamento indica uma diminuição gradual da energia disponível na célula, conforme o processo de descarga se intensifica. Embora a célula demonstre uma capacidade inicial de recuperação da tensão após cada pulso, a redução acumulativa na energia armazenada pode comprometer seu desempenho em aplicações de longa duração. Esse efeito deve ser considerado em análises de degradação e modelagem de desempenho da bateria para garantir uma estimativa precisa da sua autonomia e eficiência.




Figura 30 – Resultado do teste de caracterização de *HPPC* da célula em uma temperatura constante de 20 °C.

4.2 Identificação dos parâmetros do *ECM*

Na Figura 31, são apresentados os resultados obtidos após a identificação do *ECM* utilizando a *Toolbox Battery Modeling* do MATLAB. A análise foi realizada com um tempo de amostragem de 1 s e uma temperatura ambiente constante de 20 °C. Na figura, a curva azul representa a resposta experimental da célula obtida em laboratório, enquanto a curva laranja corresponde à saída gerada pelo modelo identificado por meio da ferramenta. Observa-se que a *toolbox* ajusta progressivamente a resposta do modelo até alcançar uma aproximação aceitável em relação ao sinal experimental, o que sugere que o modelo captura de maneira eficaz a dinâmica predominante da bateria.

No entanto, foram identificadas discrepâncias na fase final de estabilização, possivelmente atribuídas a fatores como histerese eletroquímica, polarização transitória e distribuição não homogênea dos portadores de carga dentro do eletrólito e dos eletrodos. Apesar dessas discrepâncias, os resultados obtidos não devem ser descartados, pois fornecem uma representação adequada para aplicações nas quais a resposta do modelo é utilizada dentro de um intervalo operacional definido. Em um contexto real, uma bateria nunca deve ser levada a uma profundidade extrema de descarga, pois, conforme discutido em capítulos

anteriores, isso compromete significativamente sua integridade estrutural e sua capacidade de retenção de energia a longo prazo.




Figura 31 – Comparação entre a saída real do sistema e a saída identificada pela *Toolbox Battery Modeling* correspondente a uma temperatura de 20 °C

Por outro lado, a Figura 32 apresenta os resultados da identificação do modelo utilizando a *Toolbox* proposta por Sae [18]. Neste gráfico, a curva vermelha representa a resposta experimental da bateria, enquanto a curva azul corresponde à saída obtida a partir do modelo identificado. Observa-se um comportamento semelhante ao obtido com a *Battery Modeling Toolbox*, com uma alta correspondência entre a resposta experimental e a estimada pelo modelo. No entanto, identificam-se discrepâncias no primeiro período de repouso e na última fase de estabilização, onde a diferença entre os dados experimentais e os identificados é mais evidente. Isso sugere uma forte presença de histerese na bateria e evidencia as limitações do modelo em capturar essa dinâmica com precisão.




Figura 32 – Comparação entre a saída real do sistema e a saída identificada pela *Toolbox Sae* [18] correspondente a uma temperatura de 20 °C.

Os resultados obtidos por meio da *Toolbox* são apresentados na forma de *LUT*. A Tabela 7 exhibe os resultados correspondentes ao método de identificação *Battery Modeling* a uma temperatura de 20 °C, os quais estão associados à Figura 31. Nessa tabela, identificam-se 15 níveis do *SoC*, onde cada nível está vinculado aos diferentes parâmetros do modelo. É importante destacar que os dados apresentados na tabela correspondem exclusivamente a uma temperatura específica, neste caso, 20 °C. No entanto, o modelo final abrange um total de 7 temperaturas avaliadas, resultando em uma *LUT* com dimensões de 105x10, considerando os 15 níveis do *SoC* para cada temperatura analisada.

Tabela 7 – Resultados da identificação dos parâmetros do modelo *ECM* usando a *Toolbox Battery Modeling* em uma temperatura de 20 °C.

SoC [%]	Em [V]	R0 [Ω]	R1 [Ω]	R2 [Ω]	R3 [Ω]	C1 [F]	C2 [F]	C3 [F]
100	3,612	0,225	0,083	0,014	0,017	30,23	196,10	493,4
95	3,326	0,081	0,015	0,026	0,046	15,88	160,90	932,5
90	3,327	0,086	0,015	0,026	0,052	108,20	15,13	1,0e5
85	3,326	0,092	0,036	0,010	0,065	126,60	29,73	697,5
80	3,325	0,098	0,015	0,017	0,061	158,10	19,50	679,7
70	3,313	0,090	0,016	0,020	0,055	135,10	19,62	2,0e5
60	3,289	0,082	0,017	0,013	0,032	15,09	40,81	1,2e5
50	3,287	0,075	0,041	1,6e-7	0,035	20,26	122,00	1,0e5
40	3,286	0,084	0,038	0,008	0,043	29,72	252,60	886,0
30	3,277	0,090	0,019	0,025	0,046	148,20	19,98	1,5e5
20	3,240	0,099	0,025	0,009	0,053	100,50	25,58	1,1e5
15	3,212	0,104	0,021	0,015	0,060	120,80	39,87	1,2e5
10	3,204	0,102	0,038	0,010	0,061	33,16	206,80	1,3e5
5	3,140	0,087	0,011	0,051	0,090	153,70	26,65	165,1
0	2,814	0,013	0,338	0,068	0,089	159,90	416,80	1,7e5

Nesta etapa de identificação do modelo, também foi caracterizada a não linearidade da bateria, representada pela relação entre o SoC x OCV . Esses resultados são apresentados na Figura 33, que ilustra a não linearidade captada pela toolbox Battery Modeling, construída a partir da Tabela 7.

Na figura 33, observa-se que a curva apresenta uma inclinação não linear, característica das *LIB*. Em níveis altos e baixos do SoC , a variação do OCV é mais acentuada, enquanto na região intermediária a relação é mais estável. Esse comportamento se deve à dinâmica eletroquímica da célula, na qual a concentração de íons de lítio nos eletrodos e o equilíbrio afetam a resposta da tensão em repouso. Esses resultados são fundamentais para a parametrização do modelo, pois permitem definir com precisão a função SoC - OCV utilizada na representação do sistema. A correta identificação dessa relação é crucial para melhorar a precisão na estimativa do SoC e o desempenho do modelo.





Figura 33 – Caracterização da não linearidade da célula em diferentes temperaturas.


Nessa última fase de identificação, analisam-se os dois modelos identificados por meio das métricas *FIT* e *VAF* com o objetivo de determinar qual deles oferece uma representação dinâmica mais precisa do comportamento real da célula. Após selecionar o modelo de melhor desempenho, descarta-se aquele de menor precisão e procede-se à avaliação de seu comportamento em função do tempo de amostragem, eliminando a configuração menos favorável.

A primeira etapa consiste em determinar qual dos dois modelos apresenta maior fidelidade na reprodução do comportamento da célula. Os resultados dessa avaliação são

apresentados na Figura 34. Na subfigura 34a, é exibida a resposta em tensão do modelo identificado por meio da *Toolbox Battery Modeling*, denominado ModelTX. Nesse caso, a curva azul representa a resposta experimental, enquanto a curva vermelha corresponde à saída simulada pelo modelo, considerando o perfil de corrente correspondente ao teste HPPC a uma temperatura de 20 °C.



(a) Saída de tensão do ModelTX a uma temperatura de 20 °C.



(b) Saída de tensão do ModelSE a uma temperatura de 20 °C.

Figura 34 – Avaliação das saídas de tensão dos modelos identificados: ModelTX ($FIT = 92,5\%$) e ModelSE ($FIT = 87,8\%$) a uma temperatura de 20 °C.

De forma análoga, na subfigura 34b é ilustrado o desempenho do modelo identificado utilizando a *Toolbox* implementada pela Sae [18], denominado ModelSE, seguindo a mesma convenção de cores, temperatura e perfil de corrente. Observa-se que ambos os modelos oferecem uma representação adequada do sistema real, evidenciando sua capacidade de se aproximar da resposta experimental.

Para quantificar essa correspondência, a Tabela 8 apresenta os valores de FIT e VAF associados aos resultados da Figura 34. Nesta etapa, ambos os modelos foram avaliados com um tempo de amostragem de 1 s, garantindo uma comparação equitativa de seu desempenho.

Tabela 8 – Tabela de comparação dos dois modelos identificados, denominados ModelTX e ModelSE

Temperatura [°C]	ModelSE		ModelTX	
	FIT 1s [%](Tensão)	VAF 1s [%](Tensão)	FIT 1s [%](Tensão)	VAF 1s [%](Tensão)
-5	67,328	90,968	77,865	95,255
0	64,910	89,430	80,429	96,646
10	77,212	95,705	88,360	98,799
20	87,804	98,670	92,540	99,487
30	84,505	97,668	69,273	91,175
40	79,399	95,838	67,887	90,297
50	87,796	98,523	25,738	49,480

Com base nos resultados apresentados na Tabela 8, o ModelSE é descartado, pois, embora apresente melhor desempenho em temperaturas elevadas (30, 40 e 50 °C), o ModelTX demonstra um desempenho superior em um maior número de temperaturas. Além disso, seu comportamento em temperaturas altas continua sendo aceitável, com valores de VAF superiores a 90%, o que indica uma alta similaridade com os dados experimentais.

Na segunda etapa, analisa-se o desempenho do ModelTX em função de dois tempos de amostragem: 10 ms, utilizado na aquisição de dados, e 1 s, correspondente a reamostragem dos dados. A escolha do período de amostragem influencia diretamente a qualidade do modelo identificado, uma vez que determina quais componentes da dinâmica do sistema serão capturados. Quando a amostragem é realizada com um período muito curto, a maior resolução temporal pode levar à captação de ruídos de medição, que acabam sendo interpretados erroneamente como parte da dinâmica do sistema, comprometendo a acurácia do modelo. Por outro lado, um período de amostragem maior atua como um filtro natural, reduzindo a influência do ruído e permitindo que a identificação se concentre nas características essenciais do sistema. Esse efeito pode ser observado nos resultados apresentados, onde o modelo identificado com um período de amostragem maior apresentou melhores métricas de ajuste (Tabela 9), indicando que a escolha adequada do período de amostragem é fundamental para garantir um modelo mais representativo da realidade.

Com base nos valores de *FIT* e *VAF* apresentados na Tabela 9, o ModelTX 10ms é descartado, pois apresenta limitações significativas na representação do sistema em temperaturas extremas, especialmente a 40 e 50 °C. Nesses casos, os valores negativos de *FIT* e *VAF* evidenciam uma correspondência inadequada com os dados reais, indicando uma capacidade de modelagem deficiente. Embora a precisão do modelo em condições extremas seja um aspecto crítico, o ModelTX 1s oferece uma representação mais estável e confiável dos dados experimentais. Apesar de apresentar algumas discrepâncias em temperaturas elevadas, essas podem ser compensadas e otimizadas por meio da implementação do *EKF*.

Tabela 9 – Tabela de comparação referente ao comportamento do ModelTX em seus dois tempos de amostragem diferentes.

Temperatura [°C]	ModelTX 1s		ModelTX 10ms	
	FIT [%](Tensão)	VAF [%](Tensão)	FIT [%](Tensão)	VAF [%](Tensão)
-5	77,865	95,255	17,482	35,903
0	80,429	96,646	86,186	98,163
10	88,360	98,799	67,402	90,036
20	92,540	99,487	81,170	96,810
30	69,273	91,175	82,938	97,285
40	67,887	90,297	-0,938	-0,108
50	25,738	49,480	-5,878	-0,015

Cabe ressaltar que, embora o modelo com uma única ramificação RC represente uma simplificação estrutural significativa em relação ao modelo com três ramificações RC, os resultados obtidos durante o processo de identificação revelaram um comportamento extremamente similar entre ambas as abordagens. As diferenças observadas nos indicadores de desempenho e nas respostas do modelo foram consideradas insignificantes para os objetivos deste estudo. Por essa razão, optou-se por não apresentar os resultados detalhados da identificação do modelo simplificado, limitando-se à análise no contexto da identificação. Essa decisão visa manter a objetividade e a concisão do trabalho, sem prejuízo à compreensão da eficácia da estrutura reduzida.

4.3 Validação do modelo

Submeter as células a testes com diferentes perfis de corrente é fundamental para a validação do modelo e a avaliação de seu desempenho em diversas condições operacionais. Na Figura 35 são apresentados os resultados obtidos em um teste de validação projetado para simular um perfil de corrente representativo do uso em um *EV* sob condições reais. Neste experimento, a célula é submetida a descargas com diferentes níveis de corrente (1,5; 0,8; 1,8; 0,9 e 1,7 A) e tempos de drenagem variáveis, mantendo uma temperatura ambiente constante de 20 °C durante o ensaio e um SoC_{t_0} de 100%.

Assim como nos testes *HPPC*, observa-se um comportamento característico da tensão, onde a tensão se recupera progressivamente após cada descarga. No entanto, uma diferença fundamental reside na evolução térmica da célula. Conforme mostrado na parte inferior da figura, a temperatura aumenta de forma mais acelerada devido à ausência de períodos prolongados de repouso. Diferentemente dos testes *HPPC*, nos quais os intervalos entre os pulsos permitiam uma dissipação térmica mais eficiente, neste experimento o calor se acumula mais rapidamente. Esse resultado destaca o papel crucial da temperatura nesta pesquisa, uma vez que sua variação influencia diretamente o desempenho, a estabilidade e a

segurança da bateria.




Figura 35 – Resultado do teste para a validação do modelo correspondente a um SoC_{t0} de 100%, temperatura constante de 20 °C.

Em outro experimento, avaliou-se o comportamento da célula sob um perfil de corrente diferente, iniciando com um SoC_{t0} de 60%. Esse ensaio busca analisar o desempenho do modelo em condições nas quais a célula não parte de sua capacidade máxima, refletindo cenários mais realistas na operação de um EV. Na Figura 36 são apresentados os resultados obtidos ao submeter a célula a um ciclo de descarga com correntes de 1; 1,8; 0,6; 2; 0,8 e 1,2 A, com tempos de aplicação variáveis, mantendo uma temperatura ambiente de 20 °C.

Diferentemente do experimento anterior, neste caso observa-se uma menor recuperação da tensão após cada descarga, o que indica um impacto mais pronunciado na resistência interna da célula quando o SoC_{t0} é mais baixo. Além disso, a evolução térmica mostra um aumento sustentado da temperatura, embora em um ritmo ligeiramente menor do que no teste com SoC_{t0} de 100%, devido à menor quantidade de energia armazenada na célula. Esses resultados reforçam a importância de considerar o SoC_{t0} na validação do modelo, uma vez que afeta tanto a resposta de tensão quanto a dissipação térmica durante a operação.






Figura 36 – Resultado do teste para a validação do modelo correspondente a um SoC_{t0} de 60%, temperatura constante de $20\text{ }^{\circ}\text{C}$.

Esse processo permite avaliar a capacidade do modelo de generalizar seu comportamento em diferentes condições operacionais e garante que seu desempenho não esteja restrito apenas a cenários semelhantes aos de calibração. Para isso, aplicam-se os perfis de validação descritos, com o objetivo de analisar a precisão do modelo em condições em que o SoC não parte do nível máximo.

Os resultados obtidos na saída do sistema são apresentados na Figura 37, onde a subfigura 37a mostra a resposta do modelo para uma bateria completamente carregada e sua capacidade de ajuste aos dados experimentais, enquanto a subfigura 37b ilustra seu comportamento em cenários onde a bateria não está totalmente carregada.



(a) Validação com SoC_{t0} de 100% a uma temperatura de 20 °C.



(b) Validação com SoC_{t0} de 60% a uma temperatura de 0 °C.

Figura 37 – Resultados da validação considerando os melhores desempenhos experimentais para diferentes condições do SoC inicial (SoC_{t0}).

Na Tabela 10 são resumidos os valores de FIT e VAF correspondentes à saída de tensão nesses experimentos, observando-se que o modelo atinge um VAF de 99,5% no teste com SoC_{t0} de 100%, resultado obtido a uma temperatura de 20 °C. Para o caso em que a bateria possui um SoC_{t0} de 60%, o melhor desempenho é registrado a 0 °C, com um VAF de 97,6%.

Esses experimentos garantem um desempenho otimizado do modelo identificado, permitindo avançar para as próximas fases da pesquisa de acordo com os métodos estabelecidos. Vale destacar que, durante o processo de validação, alguns resultados iniciais apresentaram inconsistências na representação do sistema, o que levou à repetição dessa fase em diversas ocasiões até a obtenção dos valores apresentados nesta seção, da Tabela 8 à Tabela 10.

Tabela 10 – Resultados da validação do modelo em relação aos dois perfis de corrente diferentes em que o SoC_{t0} é diferente.

Temperatura [°C]	Test SoC_{t0} 100%		Test SoC_{t0} 60%	
	FIT [%]	VAF [%]	FIT [%]	VAF [%]
-5	40,362	84,768	62,682	86,161
0	49,096	76,862	48,279	97,647
10	41,048	70,223	55,124	96,087
20	90,974	99,506	5,329	73,501
30	51,343	76,976	37,085	91,793
40	84,910	98,025	8,322	59,797
50	79,316	95,775	8,434	60,946

4.4 Estimativa do SoC pelo método CC

Os resultados obtidos a partir da estimativa do SoC pelo método de CC demonstram uma redução gradual e escalonada do estado de carga da célula ao longo do tempo, refletindo o processo contínuo de descarga. Observa-se que a estimativa segue um padrão decrescente previsível, coerente com a integração da corrente ao longo do tempo. No entanto, como o método de CC está sujeito a erros acumulativos devido a imprecisões na medição da corrente e à variação da capacidade efetiva da bateria com a temperatura, sua precisão pode ser comprometida em aplicações de longo prazo. Além disso, a ausência de um mecanismo de correção pode levar a desvios progressivos na estimativa do SoC. Esses fatores destacam a necessidade de métodos mais avançados, como o *EKF*, que incorporam modelos dinâmicos para mitigar essas limitações e proporcionar uma estimativa mais precisa e robusta.




Figura 38 – Resultado do método de contagem de Coulomb para estimativa do SoC em temperatura de 20 °C.

4.5 Implementação do *EKF*

A implementação do *EKF* foi realizada com base no modelo de espaço de estados da célula, permitindo a estimação do *SoC* a partir das medições de corrente e tensão. O algoritmo foi desenvolvido em MATLAB e testado com dados experimentais obtidos na etapa de caracterização da bateria, incluindo testes *HPPC* e validações adicionais para diferentes condições iniciais do *SoC*.

As simulações realizadas demonstraram que a precisão na estimação do *SoC* pelo *FKE* é altamente sensível à escolha das matrizes de covariância, que desempenham um papel fundamental no equilíbrio entre a predição e a correção do estado. Para mitigar esse problema e aprimorar o desempenho do estimador, foi desenvolvido um processo de otimização das matrizes de covariância, permitindo uma melhor adaptação do filtro à dinâmica da bateria e resultando em estimativas mais precisas e confiáveis do *SoC*.

Em uma primeira abordagem, foi realizada uma otimização dessas matrizes, priorizando a minimização do erro na estimativa do *SoC*. Para isso, a função objetivo da otimização atribuiu um peso de 95% à estimativa do *SoC*, resultando em um *EKF* altamente preciso na previsão do *SoC*. No entanto, esse ajuste revelou uma limitação crítica: frente a erros iniciais significativos, o *EKF* não era capaz de realizar a correção adequada, perdendo sua característica fundamental de filtro. Essa limitação ocorreu porque, ao priorizar excessivamente a precisão na previsão do *SoC*, o comportamento do *EKF* se aproximou ao do método de Coulomb, que não realiza correções baseadas em medições da tensão da bateria.

Essa limitação foi confirmada ao analisar os valores da matriz de covariância Q_k , onde se observou que o primeiro elemento dessa matriz era praticamente zero. Esse valor extremamente baixo implica que o *EKF* atribuía uma confiança excessiva ao modelo de previsão, reduzindo drasticamente a influência das medições de tensão da bateria na correção do estado. Como consequência, o filtro perdeu sua capacidade de ajuste dinâmico a erros iniciais e ruídos de medição, tornando-se semelhante ao método de Coulomb, que estima o *SoC* apenas pela integração da corrente. Esse comportamento evidencia a importância de uma escolha adequada das matrizes de covariância para garantir que o filtro mantenha um equilíbrio entre a predição e a correção, permitindo estimativas mais precisas e robustas do *SoC*.

A Figura 39a ilustra a estimativa do *SoC* obtida pelo *EKF*, evidenciando sua alta precisão com um *RMSE* na saída de tensão de 0,011 e na estimativa do *SoC* de 0,029. No entanto, a Figura 39b demonstra que, ao introduzir um erro inicial significativo, o *EKF* otimizado para precisão se torna incapaz de corrigir essa discrepância, divergindo da estimativa real, com um *RMSE* na saída de tensão de 0,049 e na estimativa do *SoC* de 9,748 ou seja, o *EKF* não foi capaz de corrigir o erro inicial de 10% no valor do *SoC*.




Figura 39 – Resultados da estimativa de SoC em que a função objetivo do processo de otimização considera um peso de 95 % para o erro do SoC a uma temperatura de 20 °C.

Esse comportamento indica que a função objetivo da otimização deve considerar não apenas a precisão da estimativa do SoC, mas também a capacidade do *EKF* de corrigir erros ao longo do tempo. Para isso, torna-se necessário incluir na função objetivo um peso adequado para a saída de tensão estimada, garantindo que a correção do erro de tensão contribua para a melhoria da estimativa do estado de carga. Esse ajuste permitirá que o *EKF* mantenha sua capacidade de correção e melhore sua robustez frente a condições iniciais incertas ou medições ruidosas.

Portanto, os resultados obtidos indicam a necessidade de um balanceamento adequado na definição das matrizes de covariância para assegurar tanto a precisão do SoC quanto a resposta dinâmica adequada do *EKF*. Desta forma, a próxima estratégia utilizada envolveu a reformulação da função objetivo da otimização, ajustando os pesos atribuídos ao erro do SoC e à saída de tensão. Especificamente, a nova formulação considerou um peso de 0,8 para o erro do SoC e 0,2 para a saída de tensão, buscando um *EKF* equilibrado que concilie acurácia e capacidade de correção de erros.

Com base nessa reformulação, procedeu-se à identificação das matrizes de covariância que melhor atenderam aos critérios estabelecidos. A Tabela 11 apresenta os valores otimizados das matrizes, os quais foram utilizados em todas as simulações e análises a partir deste ponto do trabalho.

Tabela 11 – Valores das matrizes de covariância P , Q_k e R_k utilizadas no EKF para uma temperatura de 20 °C.

Matriz	Valores
P	$\begin{bmatrix} 0,95 & 0,00 \\ 0,00 & 8,00 \end{bmatrix}$
Q_k	$\begin{bmatrix} 9,99 \times 10^{-10} & 0,00 \\ 0,00 & 10,00 \end{bmatrix}$
R_k	8,00

Após o ajuste adequado das matrizes de covariância, foi realizada uma análise detalhada da estimativa do SoC por meio do EKF em diferentes perfis de corrente, considerando três cenários principais: o teste $HPPC$, um teste com SoC inicial de 100% e outro com SoC inicial de 60%.

A Figura 40a apresenta os resultados da estimativa do SoC no teste $HPPC$. No início da simulação, observa-se uma discrepância entre a estimativa do EKF e a referência baseada na contagem de Coulomb. No entanto, à medida que a simulação avança, o EKF converge para a estimativa correta, reduzindo progressivamente o erro. Na Figura 40b, é apresentada a estimativa da tensão terminal, onde fica evidente que o filtro mantém um esforço constante para convergir, alcançando uma estimativa precisa e próxima da medição real do sistema.




Figura 40 – Resultados da estimativa com o perfil de corrente $HPPC$ a uma temperatura de 20 °C.

Para o caso em que o SoC_{i0} é de 100%, a Figura 41a ilustra a comparação entre a estimativa do EKF e a referência CC . Assim como no teste $HPPC$, inicialmente observa-se um erro na estimativa, que é progressivamente reduzido à medida que a simulação avança, ajustando-se ao valor real do SoC. Essas discrepâncias iniciais devem-se à não linearidade da bateria, um aspecto que poderia ser aprimorado por meio de uma calibração mais precisa

das matrizes de covariância no processo de otimização. A Figura 41b mostra novamente que o *EKF* atinge uma estimativa confiável da tensão terminal.




Figura 41 – Resultados da estimativa com o perfil de corrente SoC_{t0} é de 100% a uma temperatura de $20^{\circ}C$.

Além dos resultados de estimativa do SoC e da tensão terminal, a Figura 41c apresenta a evolução temporal dos ganhos de Kalman (KG) durante a simulação. Observa-se que o ganho associado ao estado do SoC apresentado em azul, possui magnitude muito baixa e permanece praticamente constante após uma breve fase de transição. Esse comportamento indica que a correção da estimativa do SoC depende predominantemente do modelo dinâmico interno da bateria, uma vez que a tensão medida apresenta baixa sensibilidade direta ao SoC . Qual é um comportamento característico típico das *LIB*, cuja tensão varia muito pouco ao longo da faixa de carga. Já o ganho relacionado à tensão do ramo RC ($V1$, apresentado em laranja) apresenta valores negativos mais expressivos (em torno de -0,6), estabilizando-se ao

longo do tempo. Esse comportamento é coerente com a natureza do sistema, evidenciando que a tensão terminal, sendo diretamente mensurável, exerce um papel mais relevante na correção da estimativa correspondente. No geral, os ganhos demonstram estabilidade e coerência, contribuindo para a confiabilidade das estimativas fornecidas pelo filtro.

Na Figura 42a são apresentados os resultados da estimativa para o perfil de corrente com um SoC_{t0} de 60%. Nesse caso, não são observadas discrepâncias significativas na estimativa do SoC , resultando em uma maior precisão em comparação com os cenários anteriores. Para a estimativa da tensão terminal, o comportamento do *EKF* é consistente com os casos anteriores, fornecendo resultados satisfatórios (Figura 42b).




Figura 42 – Resultados da estimativa com o perfil de corrente SoC_{t0} de 60% em temperatura de $20^{\circ}C$.

A Tabela 12 apresenta os valores do erro quadrático médio para a estimativa do SoC e da tensão de saída nos diferentes cenários avaliados. Todos os testes foram realizados a uma

temperatura de 20 °C, com o objetivo de manter condições térmicas uniformes ao avaliar os diferentes perfis de corrente. Os resultados confirmam que o melhor desempenho do *EKF*, tanto na estimativa do *SoC* quanto na tensão terminal, é obtido no caso em que o SoC_{t_0} é de 60%, validando assim a robustez do modelo sob diversas condições operacionais.

Tabela 12 – Estimativa do *SoC* nos diferentes perfis de corrente em que os resultados são expressos em RMSE a 20 °C.

Perfil de corrente	Tempo [s]	RMSE-Tensão [%]	RMSE-SoC [%]
<i>HPPC</i>	6,578	0,014	1,266
$SoC_{t_0}=100\%$	0,164	0,011	0,809
$SoC_{t_0}=60\%$	0,096	0,008	0,368

Por fim, na Tabela 13 são apresentados os resultados obtidos para temperaturas de 10, 20 e 30 °C. Esses valores correspondem ao *RMSE* da estimativa do *SoC* e da tensão de saída no teste de validação com um *SoC* inicial de 100%. Observa-se que o melhor desempenho ocorre a 10 °C, com um *RMSE* de 0,360% na estimativa do *SoC* e 0,013% na tensão de saída. Essa melhora se deve a uma configuração mais otimizada das matrizes de covariância nessa temperatura, permitindo um ajuste mais preciso do *EKF* e uma maior exatidão na estimativa.

Tabela 13 – Resultados em termos de *RMSE* da estimativa de *SoC* e saída de tensão em as diferentes temperaturas.

Temperatura [°C]	Tempo [s]	RMSE-Tensão [%]	RMSE-SoC [%]
0	0,120	0,020	0,384
10	0,126	0,013	0,360
20	0,142	0,011	0,809
30	0,269	0,014	0,828
40	0,169	0,037	0,975

4.5.1 Validação do *EKF*

Os resultados obtidos na validação do *EKF* demonstram a robustez do filtro diante de diferentes fontes de erro nas medições, além de sua capacidade de correção frente a estimativas iniciais incorretas do *SoC*. A análise foi realizada considerando três cenários distintos: a introdução de um erro sistemático *bias* nas medições de corrente, a presença de ruído gaussiano e um erro com uma estimativa inicial incorreta do *SoC*.

A primeira análise avaliou o comportamento do *EKF* diante do erro sistemático introduzido na medição da corrente. Como mostrado na Figura 43, apesar da presença de um *bias* inerente no sinal de corrente (Figura 28a), o *EKF* consegue mitigar esse erro até torná-lo praticamente imperceptível, garantindo, assim, uma estimativa precisa do *SoC*. Essa

capacidade reforça a vantagem do *EKF* sobre o método de Coulomb, que, por não realizar correções com base na tensão da bateria, acumula erros ao longo do tempo, resultando em uma estimativa menos precisa do *SoC*.




Figura 43 – Estimativa do *EKF* em relação a um erro do tipo *Bias* em uma temperatura de 20 °C.

Na Figura 43a, apresenta-se a estimativa do *SoC*, onde, apesar das perturbações na corrente, o filtro é capaz de estimá-lo de maneira eficiente. No entanto, observa-se um pequeno desvio no início do processo de estimativa. Por outro lado, a Figura 43b mostra a estimativa da tensão terminal do sistema, evidenciando um desempenho semelhante ao obtido em testes anteriores. Apesar da presença de um *bias* no sensor de corrente, esse erro não afeta significativamente a precisão da estimativa da tensão de saída, demonstrando a robustez do *EKF* diante de erros sistemáticos na medição.

No segundo cenário, em que a corrente foi perturbada por ruído gaussiano com média zero e variância 0,2 conforme apresentado na Figura 28b, analisou-se a resposta do *EKF* com o objetivo de verificar sua estabilidade diante de medições ruidosas. A Figura 44 mostra que o filtro mantém um comportamento estável, conseguindo atenuar o efeito das flutuações aleatórias na corrente e proporcionando uma estimativa coerente do *SoC* da bateria.




Figura 44 – Estimativa do *EKF* em relação a um ruído gaussiano em uma temperatura de $20^{\circ}C$.

Na Figura 44a apresenta-se a estimativa do SoC na presença desse ruído, onde se evidencia a robustez do filtro, uma vez que sua precisão não é comprometida por essas perturbações. De maneira semelhante, a Figura 44b mostra a estimativa da tensão de saída, que também não apresenta inconsistências significativas, refletindo, assim, a capacidade do *EKF* de oferecer uma estimativa precisa e estável, mesmo em condições de ruído na medição da corrente.

O último cenário incorporou um erro inicial de 10% na estimativa inicial do SoC. A Figura 45 mostra que, apesar da divergência inicial, o *EKF* consegue corrigir progressivamente a estimativa, convergindo para o valor real do SoC. Esse comportamento é o esperado em um filtro de Kalman, pois ele combina previsões baseadas no modelo dinâmico da bateria com medições ruidosas para atualizar suas estimativas de forma ótima.




Figura 45 – Estimativa do *EKF* em relação ao erro inicial no SoC em uma temperatura de $20^{\circ}C$.

Na Figura 45a apresenta-se a estimativa do *SoC*, onde, como mencionado anteriormente, o *EKF* tende a convergir ao longo do tempo, reduzindo o erro inicial de 10% para 2,43%. Por outro lado, na Figura 45b mostra-se a estimativa da tensão de saída, que também começa com uma diferença de 10%, mas, nesse caso, converge muito mais rapidamente para a medição real, reduzindo o erro final para apenas 0,018%.

Para quantificar a precisão do *EKF* nos diferentes cenários, foram calculadas as métricas de erro quadrático médio para a estimativa do *SoC* e da tensão de saída. A Tabela 14 apresenta os valores obtidos, juntamente com o tempo médio de execução do algoritmo para cada resultado. Esses resultados demonstram que o *EKF* mantém um desempenho robusto mesmo sob condições adversas, garantindo estimativas precisas com um custo computacional viável para aplicações em sistemas embarcados de *BMS*.

Tabela 14 – Resultados da estimativa do *SoC* com o *EKF* nos diferentes cenários de validação para o teste em que SoC_{t0} é 100% a uma temperatura de 20 °C.

Tipo de erro	Tempo [s]	RMSE-Tensão [%]	RMSE- <i>SoC</i> [%]
<i>Bias</i>	0,136	0,011	0,809
Média zero	0,134	0,011	0,809
10% de erro inicial	0,156	0,018	2,439

Para avaliar a precisão do *EKF* em um cenário com um *SoC* inicial diferente, foram calculadas as métricas de *RMSE* para a estimativa do *SoC* e da tensão de saída considerando o teste com SoC_{t0} igual 60% a uma temperatura de 20 °C. A Tabela 15 apresenta os valores obtidos, bem como o tempo médio de execução do algoritmo para cada caso. Assim como no teste anterior, os resultados demonstram a robustez do *EKF* frente a diferentes fontes de erro nas medições. Observa-se que, para os cenários com erro sistemático e ruído gaussiano, o *RMSE* da estimativa do *SoC* permanece baixo, indicando que o filtro consegue lidar bem com essas perturbações. No entanto, no cenário com erro inicial de 10%, o *RMSE* do *SoC* é consideravelmente maior, refletindo a dificuldade do filtro em corrigir desvios iniciais significativos quando o estado de carga inicial está em um nível intermediário.

Tabela 15 – Resultados da estimativa do *SoC* com o *EKF* nos diferentes cenários de validação para o teste em que SoC_{t0} é 60% a uma temperatura de 20 °C.

Tipo de erro	Tempo [s]	RMSE-Tensão [%]	RMSE- <i>SoC</i> [%]
<i>Bias</i>	0,081	0,008	0,368
Média zero	0,075	0,008	0,368
10% de erro inicial	0,091	0,009	7,391

Por fim, na apresentação dos resultados, são mostrados os dados obtidos na simulação do pack de baterias, os quais demonstram a alta precisão do *EKF* na estimativa do *SoC* em

um cenário idealizado. Como o ambiente de simulação não introduz ruídos significativos nem variações inesperadas entre as células, o algoritmo conseguiu seguir com exatidão a evolução do *SoC* ao longo do tempo.

Observou-se que, para as 16 células do pack, a estimativa do *SoC* apresentou um erro mínimo em relação ao valor real, validando a eficácia do filtro no monitoramento individualizado de cada célula. Na Tabela 16 são apresentados os valores do *RMSE* obtidos tanto na estimativa do *SoC* quanto na tensão de saída do sistema para cada uma das 16 células que compõem o pack.

Para este caso específico, utilizou-se um perfil de corrente *HPPC* com 10 níveis do *SoC*, e as matrizes de covariância empregadas foram aquelas identificadas inicialmente, considerando que a função objetivo atribui um peso de 95% à estimativa do *SoC*. Neste estudo, as matrizes de covariância não foram atualizadas, pois o objetivo não é validar a precisão do *EKF*, mas sim avaliar sua capacidade de estimar o *SoC* em cada uma das células do pack. Além disso, tratando-se de um ambiente de simulação ideal, não é necessário analisar a precisão do filtro na presença de ruído ou perturbações externas.

Tabela 16 – Resultados da estimativa do *SoC* com o *EKF* em cada célula do pack de baterias com tempo de execução de 342,224 s.

Célula	RMSE-SoC [%]	RMSE-Tensão [%]
1	0,016	0,035
2	0,016	0,035
3	0,016	0,035
4	0,016	0,035
5	0,016	0,035
6	0,016	0,035
7	0,016	0,035
8	0,016	0,035
9	0,016	0,035
10	0,016	0,035
11	0,016	0,035
12	0,016	0,035
13	0,016	0,035
14	0,016	0,035
15	0,016	0,035
16	0,016	0,035

A uniformidade da corrente que circula pelo pack permitiu que o *EKF* operasse de maneira estável, sem oscilações abruptas nas estimativas. A análise dos dados armazenados revelou que as correções realizadas pelo filtro foram eficientes em todas as iterações, garantindo que a estimativa da tensão e do *SoC* de cada célula se mantivesse dentro de uma margem de erro muito baixa.

5 Conclusões

Neste capítulo, são apresentadas as conclusões mais relevantes da pesquisa, destacando as principais descobertas na modelagem, validação e estimativa do *SoC* por meio de um *EKF*. A seguir, analisam-se em detalhe os resultados obtidos ao longo do estudo.

Em relação aos testes *HPPC* evidenciaram uma recuperação progressiva da tensão após cada pulso de descarga, acompanhada de uma redução acumulativa da energia disponível, o que pode impactar negativamente a autonomia da célula. Além disso, os ensaios com perfis de corrente variáveis demonstraram que a dissipação térmica é menos eficiente na ausência de períodos de repouso, resultando em um aumento acelerado da temperatura.

Também foi identificado que a temperatura e o *SoC* inicial têm um impacto significativo na resposta eletroquímica e térmica da célula. Observou-se que um *SoC* inicial mais baixo reduz a capacidade de recuperação da tensão e intensifica os efeitos da resistência interna. Esses achados ressaltam a importância de considerar diversas condições operacionais para aprimorar a modelagem de baterias e prever com maior precisão seu desempenho e vida útil em aplicações reais.

A identificação dos parâmetros do *ECM* por meio de diferentes ferramentas confirmou a eficácia dos modelos na representação da dinâmica predominante da bateria. No entanto, foram detectadas discrepâncias nas fases de estabilização e repouso, atribuídas a fenômenos como histerese eletroquímica, polarização transitória e distribuição não homogênea dos portadores de carga. Esses fatores impactam a precisão do modelo em condições operacionais extremas.

Os resultados destacaram a importância da parametrização baseada nas *LUT*, permitindo associar os parâmetros do modelo a diferentes níveis de *SoC* e temperaturas. Foi confirmada a relação não linear entre *SoC* e *OCV*, reforçando a necessidade de uma modelagem metódica para garantir estimativas precisas do *SoC*. Os modelos identificados demonstraram-se adequados dentro de faixas operacionais definidas, sendo essenciais para a previsão do desempenho e a otimização da gestão energética em sistemas reais.

A validação experimental permitiu selecionar o modelo mais adequado para representar a dinâmica da bateria. O modelo *ModelTX*, identificado por meio da *Toolbox Battery Modeling*, demonstrou um desempenho superior em uma faixa mais ampla de temperaturas, justificando a exclusão do *ModelSE*. Com base nesses resultados, considera-se a possibilidade de desenvolver um modelo híbrido que combine as vantagens de diferentes métodos de identificação para otimizar a representação da bateria.

A análise do tempo de amostragem indicou que o *ModelTX* com uma taxa de amos-

tagem de 1 s oferece maior estabilidade e confiabilidade, enquanto uma configuração de 10 ms apresentou limitações em altas temperaturas como 40 e 50 °C.

Os testes de validação com perfis de corrente variáveis confirmaram a capacidade do modelo de generalizar seu comportamento sob diferentes condições operacionais, alcançando um VAF de até 99,5% para um SoC inicial de 100% e 97,6% para um SoC inicial de 60%. Esses resultados garantem que o modelo identificado é aplicável em cenários práticos, proporcionando uma representação precisa da resposta da bateria.

A estimativa do SoC pelo método de Coulomb demonstrou sua eficácia na representação do processo de descarga. No entanto, foram identificadas limitações significativas, especialmente a acumulação de erros devido a imprecisões na medição da corrente e à variabilidade da capacidade efetiva da célula em função da temperatura. Esses fatores afetam a exatidão do método em aplicações de longo prazo, especialmente sob condições térmicas variáveis.

A otimização das matrizes de covariância do *EKF* priorizou inicialmente a minimização do erro na estimativa do SoC, atribuindo um peso de 95% a esse parâmetro. Apesar de proporcionar uma alta precisão na previsão, essa configuração revelou uma limitação crítica: diante de erros iniciais significativos, o *EKF* não conseguia corrigi-los adequadamente, comprometendo sua função essencial de filtragem. Em cenários onde foi introduzido um erro inicial de 10%, o *RMSE* aumentou de 0,011 para 0,049 na saída de tensão e de 0,029 para 9,748 na estimativa do SoC, demonstrando a sensibilidade do filtro a erros iniciais.

Diante dessa limitação, foi realizada uma reformulação na função objetivo da otimização, ajustando os pesos atribuídos ao erro do SoC e à saída de tensão. Especificamente, a nova configuração atribuiu um peso de 0,8 para o erro do SoC e 0,2 para a saída de tensão, buscando um *EKF* equilibrado que conciliasse acurácia e capacidade de correção de erros. Os resultados obtidos com essa abordagem demonstraram uma melhoria significativa na performance do filtro, todos subsequentes correspondem a essa configuração, pelo menos para a temperatura de 20°C.

A implementação do *EKF* permitiu estimar o SoC a partir de medições de corrente e tensão, sendo validado com dados experimentais obtidos em testes *HPPC*. Observou-se que o desempenho do *EKF* está diretamente relacionado à seleção das matrizes de covariância, que determinam o equilíbrio entre predição e correção no filtro.

Em um cenário com SoC inicial de 100%, o *EKF* apresentou erros iniciais que foram reduzidos progressivamente, atingindo um *RMSE* de 0,809. Em contraste, com um SoC inicial de 60%, o *RMSE* foi de 0,368, indicando maior precisão nesse caso. A estimativa da tensão terminal mostrou uma consistência superior, com um *RMSE* de 0,011 para SoC de 100% e 0,008 para SoC de 60%.

A validação do *EKF* confirmou sua capacidade de estimar o *SoC* com um erro dentro de uma margem aceitável em comparação com os dados de referência. Durante a avaliação com dados simulados e experimentais, comprovou-se sua estabilidade sob diversas condições operacionais, demonstrando sua robustez diante de variações de corrente e temperatura.

Por fim, este trabalho representa uma contribuição significativa para a literatura sobre a estimativa do *SoC* com *EKF*. Enquanto estudos anteriores, como o de Espedal [76], relatam erros máximos de 1,4, os resultados obtidos nesta pesquisa mostram uma redução notável do erro, com um *RMSE* de 0,809 em cenários com ruído e 0,368 em condições mais estáveis, validando a eficácia da abordagem adotada.

Apesar dos avanços alcançados nesta pesquisa, ainda existem várias áreas de melhoria e linhas de investigação derivadas que podem ser exploradas no futuro. Nesse sentido, propõem-se os seguintes trabalhos futuros:

- Propõe-se a implementação de um modelo híbrido que combine os resultados mais precisos obtidos na identificação de parâmetros dos dois métodos abordados neste estudo. Isso permitiria construir um modelo mais robusto que aproveite as vantagens de cada abordagem e otimize a representação do comportamento dinâmico da bateria.
- Recomenda-se uma análise térmica mais aprofundada da célula para melhorar a precisão das simulações. Incluir modelos de dissipação de calor, variações térmicas em função da corrente e da temperatura ambiente e seu impacto na resistência interna e na capacidade da bateria permitiria aprimorar a precisão da estimativa do *SoC* em condições reais de operação.
- É necessário avaliar o desempenho do *EKF* em relação a outras técnicas avançadas de estimativa, como redes neurais profundas, filtros de partículas (*PF*) ou estimadores baseados em aprendizado de máquina. Isso forneceria informações valiosas sobre as vantagens e limitações do *EKF* em relação a métodos de maior complexidade computacional.
- Propõe-se estender a aplicação do *EKF* para outros tipos de baterias, como as de estado sólido, LiFePO_4 (LFP) ou NMC (Níquel-Manganês-Cobalto), a fim de avaliar sua versatilidade e precisão em diversas configurações e aplicações. Isso permitiria validar seu desempenho em diferentes sistemas de armazenamento de energia.
- Embora neste trabalho o *EKF* tenha sido implementado em um ambiente de simulação para um pack de baterias, sua avaliação em um sistema real é fundamental. Recomenda-se a realização de testes experimentais com baterias físicas, considerando medições de tensão, corrente e temperatura em condições dinâmicas, para verificar a robustez do algoritmo em cenários de aplicação real.

- Para sua aplicação em sistemas comerciais, sugere-se a integração do *EKF* em plataformas embarcadas, como microcontroladores de baixo consumo ou SoCs projetados para gerenciamento de energia. Isso permitiria avaliar seu desempenho em tempo real e otimizar sua implementação em um *BMS* para veículos elétricos ou outras aplicações industriais.
- Uma extensão relevante deste trabalho é a inclusão de modelos de degradação que permitam estimar a evolução do *SoC* ao longo do ciclo de vida da bateria. Poderiam ser desenvolvidas estratégias de atualização adaptativa de parâmetros para melhorar a precisão do *EKF* em função do estado de saúde (*SoH*) da célula.
- Por fim, recomenda-se a exploração de modelos eletroquímicos detalhados que complementem o *ECM*. Isso permitiria capturar com maior fidelidade os fenômenos internos da bateria, melhorando a precisão na estimativa do *SoC*, especialmente em aplicações onde as dinâmicas eletroquímicas sejam críticas.

Referências

- [1] S. Gerssen-Gondelach e A. Faaij, “Performance of batteries for electric vehicles on short and longer term”, *Journal of Power Sources*, v. 212, pp. 111–129, 2012, ISSN: 0378-7753. endereço: <https://doi.org/10.1016/j.jpowsour.2012.03.085> (https://www.sciencedirect.com/science/article/pii/S0378775312007069) (ver p. 17).
- [2] R. Bastos, “Sistema de gerenciamento para carga e descarga de baterias (chumbo-ácido) e para busca do ponto de máxima potência gerada em painéis fotovoltaicos empregados em sistemas de geração distribuída”, *Universidade de São Paulo*, 2013. DOI: 10.11606/D.18.2013.tde-27032013-093519. Acesso em: 2024-07-09 (ver p. 17).
- [3] R. Santos, “Estimação do Estado de Carga de Baterias de Lítio-íon em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman”, Dissertação de Mestrado, Universidade Federal da Paraíba, João Pessoa, Brasil, 2019 (ver pp. 17, 18, 25, 34, 47, 51).
- [4] N. Shafiei, M. Ordonez, M. Craciun, C. Botting e M. Edington, “Burst Mode Elimination in High-Power LLC Resonant Battery Charger for Electric Vehicles”, *IEEE Transactions on Power Electronics*, v. 31, n. 2, pp. 1173–1188, 2016. DOI: 10.1109/TPEL.2015.2420573 (ver p. 17).
- [5] J. Zhao, Z. Rao, Y. Huo, X. Liu e Y. Li, “Thermal management of cylindrical power battery module for extending the life of new energy electric vehicles”, *Applied Thermal Engineering*, v. 85, pp. 33–43, 2015, ISSN: 1359-4311. DOI: <https://doi.org/10.1016/j.applthermaleng.2015.04.012> (ver p. 17).
- [6] T. Chen, Y. Jin, H. Lv et al., “Applications of Lithium-Ion Batteries in Grid-Scale Energy Storage Systems”, *Transactions of Tianjin University*, v. 26, pp. 208–217, 2020. DOI: 10.1007/s12209-020-00236-w. endereço: <https://doi.org/10.1007/s12209-020-00236-w> (ver p. 17).
- [7] A. Kytt, “4 Reasons Your Electric BMW’s High Voltage Battery Fails”, *Ultimate Bimmer Service* [Acessado em 23/07/2024], 2021. endereço: <https://www.ultimatebimmerservice.com/4-reasons-your-electric-bmws-high-voltage-battery-fails/> (ver p. 17).
- [8] M. Winter e R. J. Brodd, “What Are Batteries, Fuel Cells, and Supercapacitors?”, *American Chemical Society*, v. 104, 2004, ISSN: 0009-2665. DOI: 10.1021/cr020730k. endereço: <https://doi.org/10.1021/cr020730> (ver pp. 17, 25).

-
- [9] H. Pang e F. Zhang, “Experimental Data-Driven Parameter Identification and State of Charge Estimation for a Li-Ion Battery Equivalent Circuit Model”, *Energies*, v. 11, n. 5, 2018, ISSN: 1996-1073. DOI: [10.3390/en11051033](https://doi.org/10.3390/en11051033). endereço: <https://www.mdpi.com/1996-1073/11/5/1033> (ver pp. 17, 18, 51, 69).
 - [10] R. Yamin e A. Rachid, “Embedded state of charge and state of health estimator based on Kalman filter for electric scooter battery management system”, em *2014 IEEE Fourth International Conference on Consumer Electronics - Berlin (ICCE-Berlin)*, 2014, pp. 440–444. DOI: [10.1109/ICCE-Berlin.2014.7034282](https://doi.org/10.1109/ICCE-Berlin.2014.7034282) (ver p. 17).
 - [11] A. Purwadi, A. R. Rizqiawan, A. Kevin e N. Heryana, “State of Charge estimation method for lithium battery using combination of Coulomb Counting and Adaptive System with considering the effect of temperature”, em *Proceedings of the 2nd IEEE Conference on Power Engineering and Renewable Energy (ICPERE)*, 2014, pp. 91–95. DOI: [10.1109/ICPERE.2014.7067233](https://doi.org/10.1109/ICPERE.2014.7067233) (ver p. 18).
 - [12] Y. Xing, W. He, M. Pecht e K. Tsui, “State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures”, *Applied Energy*, v. 113, pp. 106–115, 2014, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2013.07.008>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261913005746> (ver p. 18).
 - [13] G. Plett, “Battery Management Systems, Volume I: Battery Modeling”, 2015. endereço: <http://ieeexplore.ieee.org/document/9100168> (ver pp. 18, 21, 39, 40, 42–44, 47, 52, 68, 69, 86).
 - [14] C. Silva, “Sistema de gerenciamento de baterias de lítio com estimação de estados com filtro de Kalman estendido adaptativo”, Tese de doutorado, Universidade de São Paulo, 2022 (ver pp. 18, 21, 30, 52, 80).
 - [15] J. Zhang e C. Xia, “State-of-charge estimation of valve regulated lead acid battery based on multi-state Unscented Kalman Filter”, *International Journal of Electrical Power Energy Systems*, v. 33, n. 3, pp. 472–476, 2011, ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2010.10.010>. endereço: <https://www.sciencedirect.com/science/article/pii/S0142061510001973> (ver pp. 18, 32).
 - [16] Y. Wu, H. Chen, L. Cao, J. Duan, X. Chen e J. Zhai, “Research on Online Identification of Lithium-ion Battery Equivalent Circuit Model Parameters”, em *Proceedings of the 2022 9th International Forum on Electrical Engineering and Automation (IFEEA)*, 2022, pp. 130–136. DOI: [10.1109/IFEEA57288.2022.10038123](https://doi.org/10.1109/IFEEA57288.2022.10038123) (ver pp. 18, 52).
 - [17] A. Contreras, “Estimación de los estados de carga y salud de una batería de ion-lítio”, Tesis de Maestría, Instituto Tecnológico de Celaya, Celaya, México, 2018. endereço: <https://rinacional.tecnm.mx/jspui/handle/TecNM/472> (ver p. 18).

-
- [18] R. Ahmed, J. Gazzarri, S. Onori et al., “Model-Based Parameter Identification of Healthy and Aged Li-ion Batteries for Electric Vehicle Applications”, *Event: SAE 2015 World Congress Exhibition*, p. 15, 2015, ISSN: 2167-4191 (ver pp. 18, 70, 71, 88, 89, 91).
 - [19] C. Birkl e D. Howey, “Model Identification and Parameter Estimation for LiFePO₄ Batteries”, em *Proceedings of the IET Hybrid and Electric Vehicles Conference*, IET Conference Publications, 2013, pp. 2.1–2.1, ISBN: 978-1-84919-776-2. DOI: [10.1049/cp.2013.1889](https://doi.org/10.1049/cp.2013.1889) (ver p. 18).
 - [20] C. Bhat, J. Channegowda, S. Chaudhari e K. Naraharisetti, “Accurate Equivalent Circuit Parameter Estimation Using Electrochemical Battery Modelling for Pulsed Load Applications”, em *Proceedings of the 2021 IEEE Mysore Sub Section International Conference (MysuruCon)*, 2021, pp. 1–4. DOI: [10.1109/MysuruCon52639.2021.9641683](https://doi.org/10.1109/MysuruCon52639.2021.9641683) (ver pp. 18, 52, 69).
 - [21] G. L. Plett, “Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background”, *Journal of Power Sources*, v. 134, n. 2, pp. 252–261, 2004, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2004.02.031>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775304003593> (ver pp. 18, 35, 36, 39).
 - [22] S. Nikita e J. Sachin, “SoC Estimation of Li-Ion Battery for Electric Vehicle Using Extended Kalman Filter Including Temperature Effect”, em *Proceedings of the 2022 1st International Conference on Sustainable Technology for Power and Energy Systems (STPES)*, 2022, pp. 1–6. DOI: [10.1109/STPES54845.2022.10006632](https://doi.org/10.1109/STPES54845.2022.10006632) (ver p. 18).
 - [23] A. Lotfivand, D. Yu e B. Gomm, “State Of Charge Estimation Using Extended Kalman Filter in Electric Vehicles”, em *Proceedings of the 2022 27th International Conference on Automation and Computing (ICAC)*, 2022, pp. 1–5. DOI: [10.1109/ICAC55051.2022.9911137](https://doi.org/10.1109/ICAC55051.2022.9911137) (ver p. 18).
 - [24] S. Zhang, C. Zhang, S. Jiang e X. Zhang, “A comparative study of different adaptive extended/unscented Kalman filters for lithium-ion battery state-of-charge estimation”, *Energy*, v. 246, p. 123 423, 2022, ISSN: 0360-5442. DOI: <https://doi.org/10.1016/j.energy.2022.123423>. endereço: <https://www.sciencedirect.com/science/article/pii/S0360544222003267> (ver p. 18).
 - [25] H. Wang, C. Sun, G. Zhou, Y. Zhu e D. Hu, “SOC Estimation of Lithium Battery Based on AUKF Algorithm of Third-Order RC Model”, em *Proceedings of the 2022 25th International Conference on Electrical Machines and Systems (ICEMS)*, 2022, pp. 1–6. DOI: [10.1109/ICEMS56177.2022.9983375](https://doi.org/10.1109/ICEMS56177.2022.9983375) (ver p. 18).

-
- [26] V. Q. Dao, M.-C. Dinh, C. S. Kim et al., “Design of an Effective State of Charge Estimation Method for a Lithium-Ion Battery Pack Using Extended Kalman Filter and Artificial Neural Network”, *Energies*, v. 14, n. 9, 2021, ISSN: 1996-1073. DOI: [10.3390/en14092634](https://doi.org/10.3390/en14092634). endereço: <https://www.mdpi.com/1996-1073/14/9/2634> (ver p. 18).
 - [27] A. Rahmoun, H. Biechl e A. Rosin, “SOC Estimation for Li-Ion Batteries Based on Equivalent Circuit Diagrams and the Application of a Kalman Filter”, em *Proceedings of the 2012 Electric Power Quality and Supply Reliability Conference*, 2012, pp. 1–4. DOI: [10.1109/PQ.2012.6256238](https://doi.org/10.1109/PQ.2012.6256238) (ver p. 19).
 - [28] G. R. Pawar, L. S. Praveen e S. N. Nagananda, “Implementation of Lithium-Ion Battery Management System with an Efficient SOC Estimation Algorithm”, em *Proceedings of the 2020 International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT)*, 2020, pp. 27–34. DOI: [10.1109/RTEICT49044.2020.9315638](https://doi.org/10.1109/RTEICT49044.2020.9315638) (ver p. 19).
 - [29] C. Taborelli e S. Onori, “State of Charge Estimation Using Extended Kalman Filters for Battery Management System”, em *Proceedings of the 2014 IEEE International Electric Vehicle Conference (IEVC)*, 2014, pp. 1–8. DOI: [10.1109/IEVC.2014.7056126](https://doi.org/10.1109/IEVC.2014.7056126) (ver pp. 19, 35, 36).
 - [30] F. Khanum, E. Loubach, F. Duperly, C. Jenkins, P. J. Kollmeyer e A. Emadi, “A Kalman Filter Based Battery State of Charge Estimation MATLAB Function”, em *Proceedings of the 2021 IEEE Transportation Electrification Conference & Expo (ITEC)*, 2021, pp. 484–489. DOI: [10.1109/ITEC51675.2021.9490163](https://doi.org/10.1109/ITEC51675.2021.9490163) (ver pp. 19, 21, 36, 53, 80).
 - [31] Bateria-BSLBATT-Solar, “Una guía completa de la tabla de voltaje LiFePO4: 3,2 V 12 V 24 V 48 V”, *Bateria BSLBATT - Solar [Acessado em 14/01/2025]*, 2024. endereço: <https://www.bsl-battery.com/es/news/lifepo4-voltage-chart-3-2v-12v-24v-48v/> (ver pp. 19, 33).
 - [32] D. A. Notter, M. Gauch, R. Widmer et al., “Contribution of Li-Ion Batteries to the Environmental Impact of Electric Vehicles”, *Environ. Sci. Technol.*, v. 44, 2010, ISSN: 0013-936X. DOI: [10.1021/es903729a](https://doi.org/10.1021/es903729a). endereço: <https://doi.org/10.1021/es903729a> (ver p. 24).
 - [33] M. Seyedmahmoudian, A. Stojcevski e S. Mekhilef, “Batteries are the environmental Achilles heel of electric vehicles – unless we repair, reuse and recycle them”, *The Conversation [Acessado em 28/07/2024]*, 2023. endereço: <https://theconversation.com/batteries-are-the-environmental-achilles-heel-of-electric-vehicles-unless-we-repair-reuse-and-recycle-them-205404> (ver p. 24).

-
- [34] E. Cready, J. Lippert, J. Pihl, I. Weinstock e P. Symons, “Batteries for Electric Vehicles”, *U.S. Department of Energy* [Acessado em 28/07/2024], 2003. DOI: [10.2172/809607](https://afdc.energy.gov/vehicles/electric-batteries). endereço: <https://afdc.energy.gov/vehicles/electric-batteries> (ver p. 24).
 - [35] P. Sissonarchive, “How does an EV battery actually work”, *Mit Technology Review* [Acessado em 29/07/2024], 2023. endereço: <https://www.technologyreview.com/2023/02/17/1068037/how-do-ev-batteries-work/> (ver p. 24).
 - [36] R. B. Lakshmi, “The Environmental Impact of Battery Production for Electric Vehicles”, *EARTH.ORG* [Acessado em 28/07/2024], 2021. endereço: <https://earth.org/environmental-impact-of-battery-production/> (ver p. 24).
 - [37] N. Bocchi, L. Ferracin e S. Biaggio, “Pilhas e Baterias: Funcionamento e Impacto Ambiental”, *Química Nova Escola*, v. 11, pp. 3–9, 2000 (ver p. 25).
 - [38] R. Borah, F. Hughson, J. Johnston e T. Nann, “On battery materials and methods”, *Materials Today Advances*, v. 6, 2020, ISSN: 2590-0498. endereço: <https://doi.org/10.1016/j.mtadv.2019.100046> (ver p. 25).
 - [39] J. B. Goodenough e Y. Kim, “Challenges for Rechargeable Li Batteries”, *American Chemical Society*, v. 22, 2010, ISSN: 0897-4756. DOI: [10.1021/cm901452z](https://doi.org/10.1021/cm901452z). endereço: <https://doi.org/10.1021/cm901452z> (ver p. 25).
 - [40] P. Dutta, N. Sinhababu, B. Mukherjee et al., “Power Consumption Analysis, Measurement, Management, and Issues: A State-of-the-Art Review of Smartphone Battery and Energy Usage”, *IEEE Access*, v. 7, pp. 182 113–182 172, dez. de 2019. DOI: [10.1109/ACCESS.2019.2958684](https://doi.org/10.1109/ACCESS.2019.2958684) (ver p. 26).
 - [41] L-A123-Systems, “Battery Pack Design, Validation, and Assembly Guide using A123 Systems AMP20m1HD-A Nanophosphate Cells”, *A123 Energy solutions*, pp. 493 005–002, 2014 (ver p. 26).
 - [42] M. E. V. Team, “A guide to understanding battery specifications”, 2008 (ver p. 26).
 - [43] M. Farag, “Lithium-Ion Batteries: Modelling and State of Charge Estimation”, jun. de 2013 (ver pp. 26, 29, 47, 53).
 - [44] G. R. Pawar, L. S. Praveen e S. N. Nagananda, “Implementation of Lithium-Ion Battery Management System with an Efficient SOC Estimation Algorithm”, pp. 27–34, 2020. DOI: [10.1109/RTEICT49044.2020.9315638](https://doi.org/10.1109/RTEICT49044.2020.9315638) (ver p. 27).
 - [45] G. Plett, “Battery Management Systems, Volume II: Equivalent-Circuit Methods”, 2015 (ver pp. 27, 30, 31, 53).

-
- [46] J. Gallardo-Lozano, E. Romero-Cadaval, M. I. Milanes-Montero e M. A. Guerrero-Martinez, “Battery equalization active methods”, *Journal of Power Sources*, v. 246, pp. 934–949, 2014, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2013.08.026>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775313013669> (ver p. 28).
 - [47] F. Baronti, R. Roncella e R. Saletti, “Performance comparison of active balancing techniques for lithium-ion batteries”, *Journal of Power Sources*, v. 267, pp. 603–609, 2014. endereço: <https://api.semanticscholar.org/CorpusID:95243396> (ver p. 28).
 - [48] J. Lv, W. Song, S. Lin et al., “Influence of equalization on LiFePO₄ battery inconsistency”, *International Journal of Energy Research*, v. 41, pp. 1171–1181, 2017. endereço: <https://api.semanticscholar.org/CorpusID:100580696> (ver p. 28).
 - [49] L. Lu, X. Han, J. Li, J. Hua e M. Ouyang, “A review on the key issues for lithium-ion battery management in electric vehicles”, *Journal of Power Sources*, v. 226, pp. 272–288, 2013, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2012.10.060>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775312016163> (ver pp. 28–31).
 - [50] C. H. Bonfiglio e W. Roessler, “A Cost Optimized Battery Management System with Active Cell Balancing for Lithium Ion Battery Stacks”, em *Proceedings of the 2009 IEEE Vehicle Power and Propulsion Conference (VPPC)*, 2009, pp. 304–309. endereço: <https://api.semanticscholar.org/CorpusID:42698360> (ver p. 28).
 - [51] N. S. Electric, “Lithium batteries BMS theory - cell balancing”, *NAZ Solar Electric [Acessado em 04/08/2024]*, 2024. endereço: <https://www.solar-electric.com/learning-center/bms-theory-cell-balancing/> (ver p. 29).
 - [52] K. Scott e S. Nork, “Active Battery Cell Balancing”, *Analog Devices [Acessado em 04/08/2024]*, 2016. endereço: <https://www.analog.com/en/resources/technical-articles/active-battery-cell-balancing.html> (ver p. 29).
 - [53] J. Campoverde, D. Ochoa e P. Villa E Astudillo, “Reutilización de baterías de vehículos eléctricos para aplicaciones de segunda vida en sistemas eléctricos de potencia con una alta penetración de energía renovable: una revisión sistemática de la literatura”, *Ingenius*, n. 31, 2024 (ver p. 30).
 - [54] H. He, R. Xiong e H. Guo, “Online estimation of model parameters and state-of-charge of LiFePO₄ batteries in electric vehicles”, *Applied Energy*, v. 89, n. 1, pp. 413–420, 2012, Special issue on Thermal Energy Management in the Process Industries, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2011.08.005>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261911005010> (ver p. 31).

-
- [55] M. Hannan, M. Lipu, A. Hussain e A. Mohamed, “A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations”, *Renewable and Sustainable Energy Reviews*, v. 78, pp. 834–854, 2017, ISSN: 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2017.05.001>. endereço: <https://www.sciencedirect.com/science/article/pii/S1364032117306275> (ver pp. 31, 38, 53).
 - [56] N. Watrin, B. Blunier e A. Miraoui, “Review of adaptive systems for lithium batteries State-of-Charge and State-of-Health estimation”, pp. 1–6, 2012. DOI: [10.1109/ITEC.2012.6243437](https://doi.org/10.1109/ITEC.2012.6243437) (ver p. 31).
 - [57] V. Pop, H. J. Bergveld, J. H. G. O. het Veld, P. P. L. Regtien, D. Danilov e P. H. L. Notten, “Modeling Battery Behavior for Accurate State-of-Charge Indication”, *Journal of The Electrochemical Society*, v. 153, n. 11, A2013, set. de 2006. DOI: [10.1149/1.2335951](https://doi.org/10.1149/1.2335951). endereço: <https://dx.doi.org/10.1149/1.2335951> (ver p. 32).
 - [58] Y. Bao, W. Dong e D. Wang, “Online Internal Resistance Measurement Application in Lithium Ion Battery Capacity and State of Charge Estimation”, *Energies*, v. 11, n. 5, 2018, ISSN: 1996-1073. DOI: [10.3390/en11051073](https://doi.org/10.3390/en11051073). endereço: <https://www.mdpi.com/1996-1073/11/5/1073> (ver p. 32).
 - [59] Y. Zhang, W. Song, S. Lin e Z. Feng, “A novel model of the initial state of charge estimation for LiFePO₄ batteries”, *Journal of Power Sources*, v. 248, pp. 1028–1033, 2014, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2013.09.135>. endereço: <https://www.sciencedirect.com/science/article/pii/S037877531301642X> (ver pp. 32, 38).
 - [60] G. Dong, J. Wei e Z. Chen, “Kalman filter for onboard state of charge estimation and peak power capability analysis of lithium-ion batteries”, *Journal of Power Sources*, v. 328, pp. 615–626, 2016, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2016.08.065>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775316310746> (ver p. 32).
 - [61] R. Xiong, F. Sun, Z. Chen e H. He, “A data-driven multi-scale extended Kalman filtering based parameter and state estimation approach of lithium-ion polymer battery in electric vehicles”, *Applied Energy*, v. 113, pp. 463–476, 2014, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2013.07.061>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261913006284> (ver p. 32).
 - [62] R. Xiong, H. He, F. Sun e K. Zhao, “Evaluation on State of Charge Estimation of Batteries With Adaptive Extended Kalman Filter by Experiment Approach”, *IEEE Transactions on Vehicular Technology*, v. 62, n. 1, pp. 108–117, 2013. DOI: [10.1109/TVT.2012.2222684](https://doi.org/10.1109/TVT.2012.2222684) (ver p. 32).

-
- [63] B.-h. Seo, T. H. Nguyen, D.-C. Lee, K.-B. Lee e J.-M. Kim, “Condition Monitoring of Lithium Polymer Batteries Based on a Sigma-Point Kalman Filter”, *Journal of Power Electronics*, v. 12, pp. 778–786, 2012. endereço: <https://api.semanticscholar.org/CorpusID:108650465> (ver p. 32).
 - [64] M. Partovibakhsh e G. Liu, “An Adaptive Unscented Kalman Filtering Approach for Online Estimation of Model Parameters and State-of-Charge of Lithium-Ion Batteries for Autonomous Mobile Robots”, *IEEE Transactions on Control Systems Technology*, v. 23, n. 1, pp. 357–363, 2015. DOI: [10.1109/TCST.2014.2317781](https://doi.org/10.1109/TCST.2014.2317781) (ver p. 32).
 - [65] D.-J. Xuan, Z. Shi, J. Chen, C. Zhang e Y.-X. Wang, “Real-time estimation of state-of-charge in lithium-ion batteries using improved central difference transform method”, *Journal of Cleaner Production*, v. 252, p. 119 787, 2020, ISSN: 0959-6526. DOI: <https://doi.org/10.1016/j.jclepro.2019.119787>. endereço: <https://www.sciencedirect.com/science/article/pii/S0959652619346578> (ver p. 32).
 - [66] J. Peng, J. Luo, H. He e B. Lu, “An improved state of charge estimation method based on cubature Kalman filter for lithium-ion batteries”, *Applied Energy*, v. 253, p. 113 520, 2019, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2019.113520>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261919311948> (ver p. 32).
 - [67] Y. Wang, C. Zhang e Z. Chen, “A method for state-of-charge estimation of LiFePO₄ batteries at dynamic currents and temperatures using particle filter”, *Journal of Power Sources*, v. 279, pp. 306–311, 2015, 9th International Conference on Lead-Acid Batteries – LABAT 2014, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2015.01.005>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775315000063> (ver p. 32).
 - [68] B. Xia, Z. Sun, R. Zhang et al., “A Comparative Study of Three Improved Algorithms Based on Particle Filter Algorithms in SOC Estimation of Lithium Ion Batteries”, *Energies*, v. 10, p. 1149, 2017. endereço: <https://api.semanticscholar.org/CorpusID:32841549> (ver p. 32).
 - [69] X. Hu, F. Sun e Y. Zou, “Estimation of State of Charge of a Lithium-Ion Battery Pack for Electric Vehicles Using an Adaptive Luenberger Observer”, *Energies*, v. 3, n. 9, pp. 1586–1603, 2010, ISSN: 1996-1073. DOI: [10.3390/en3091586](https://doi.org/10.3390/en3091586). endereço: <https://www.mdpi.com/1996-1073/3/9/1586> (ver p. 32).
 - [70] Y. Huangfu, J. Xu, D. Zhao, Y. Liu e F. Gao, “A Novel Battery State of Charge Estimation Method Based on a Super-Twisting Sliding Mode Observer”, *Energies*, v. 11, n. 5, 2018, ISSN: 1996-1073. DOI: [10.3390/en11051211](https://doi.org/10.3390/en11051211). endereço: <https://www.mdpi.com/1996-1073/11/5/1211> (ver p. 32).

-
- [71] X. Tang, Y. Wang e Z. Chen, “A method for state-of-charge estimation of LiFePO₄ batteries based on a dual-circuit state observer”, *Journal of Power Sources*, v. 296, pp. 23–29, 2015, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2015.07.028>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775315300756> (ver p. 32).
 - [72] Q. Zhu, N. Xiong, M.-L. Yang, R.-S. Huang e G.-D. Hu, “State of Charge Estimation for Lithium-Ion Battery Based on Nonlinear Observer: An H Method”, *Energies*, v. 10, n. 5, 2017, ISSN: 1996-1073. DOI: [10.3390/en10050679](https://doi.org/10.3390/en10050679). endereço: <https://www.mdpi.com/1996-1073/10/5/679> (ver p. 32).
 - [73] H. Mu, R. Xiong, H. Zheng, Y. Chang e Z. Chen, “A novel fractional order model based state-of-charge estimation method for lithium-ion battery”, *Applied Energy*, v. 207, pp. 384–393, 2017, Transformative Innovations for a Sustainable Future – Part II, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2017.07.003>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261917308668> (ver p. 32).
 - [74] J. C. Alvarez, P. J. Garcia, C. B. Viejo e J. A. Vilan, “Support Vector Machines Used to Estimate the Battery State of Charge”, *IEEE Transactions on Power Electronics*, v. 28, pp. 5919–5926, 2013. endereço: <https://api.semanticscholar.org/CorpusID:23564640> (ver p. 32).
 - [75] S. Tong, J. H. Lacap e J. W. Park, “Battery state of charge estimation using a load-classifying neural network”, *Journal of Energy Storage*, v. 7, pp. 236–243, 2016, ISSN: 2352-152X. DOI: <https://doi.org/10.1016/j.est.2016.07.002>. endereço: <https://www.sciencedirect.com/science/article/pii/S2352152X16300949> (ver p. 32).
 - [76] I. Espedal, A. Jinasena, O. Burheim e J. Lamb, “Current Trends for State-of-Charge (SoC) Estimation in Lithium-Ion Battery Electric Vehicles”, *Energies*, v. 14, p. 3284, jun. de 2021. DOI: [10.3390/en14113284](https://doi.org/10.3390/en14113284) (ver pp. 32, 53, 110).
 - [77] PowMr, “Guía para el diagrama de voltaje y SOC de LiFePO₄ 12V/24V/48V”, *PowMr* [Acessado em 14/01/2025], 2024. endereço: <https://powmr.com/es/blogs/news/lifepo4-voltage-chart-and-soc> (ver p. 33).
 - [78] M. Burgos, D. Claudio, D. H. Sáez e M. E. O. Concha, “Estimación del estado de carga para un banco de baterías basada en modelación difusa y filtro extendido de Kalman”, *Repositorio académico de la universidad de Chile*, 2013. endereço: <https://repositorio.uchile.cl/handle/2250/114516> (ver p. 33).
 - [79] L. Zhao, M. Lin e Y. Chen, “Least-squares based coulomb counting method and its application for state-of-charge (SOC) estimation in electric vehicles”, *International*

- Journal of Energy Research*, v. 40, n/a–n/a, mar. de 2016. DOI: [10.1002/er.3530](https://doi.org/10.1002/er.3530) (ver p. 33).
- [80] K. Soon, C. Moo, Y. Chen e Y. Hsieh, “Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries”, *Applied Energy*, v. 86, n. 9, pp. 1506–1511, 2009, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2008.11.021>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261908003061> (ver p. 34).
- [81] P. Vágner, R. Kodým e K. Bouzek, “Thermodynamic analysis of high temperature steam and carbon dioxide systems in solid oxide cells”, *Sustainable Energy Fuels*, v. 3, pp. 2076–2086, 8 2019. DOI: [10.1039/C9SE00030E](https://doi.org/10.1039/C9SE00030E). endereço: <http://dx.doi.org/10.1039/C9SE00030E> (ver p. 34).
- [82] S. Lee, J. Kim, J. Lee e B. Cho, “State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge”, *Journal of Power Sources*, v. 185, n. 2, pp. 1367–1373, 2008, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2008.08.103>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775308017965> (ver p. 34).
- [83] W. Waag e D. Sauer, “Adaptive estimation of the electromotive force of the lithium-ion battery after current interruption for an accurate state-of-charge and capacity determination”, *Applied Energy*, v. 111, pp. 416–427, 2013, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2013.05.001>. endereço: <https://www.sciencedirect.com/science/article/pii/S0306261913003905> (ver pp. 34, 35).
- [84] G. Welch e G. Bishop, “An Introduction to the Kalman Filter”, *Proc. Siggraph Course*, v. 8, jan. de 2006 (ver pp. 35, 36).
- [85] NEWARE, “Principle and Method of HPPC Test for Power Batteries”, *NEWARE [Acessado em 03/01/2025]*, 2024. endereço: <https://www.neware.net/news/principle-and-method-of-hppc-test-for-power-batteries/230/79.html> (ver pp. 36, 37).
- [86] Idaho National Laboratory, “Battery Test Manual for Plug-In Hybrid Electric Vehicles”, *Idaho National Laboratory*, 2010. endereço: <http://www.inl.gov> (ver pp. 36, 37).
- [87] A. Porras, “Modelización matemática de una batería de uso espacial”, *Universidad Politécnica de Madrid*, 2018 (ver p. 38).
- [88] P. Balakrishnan, R. Ramesh e T. P. Kumar, “Safety mechanisms in lithium-ion batteries”, *Journal of Power Sources*, v. 155, n. 2, pp. 401–414, 2006, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2005.12.002>. endereço: <https://doi.org/10.1016/j.jpowsour.2005.12.002>.

- [//www.sciencedirect.com/science/article/pii/S0378775305016629](https://www.sciencedirect.com/science/article/pii/S0378775305016629) (ver p. 38).
- [89] S. S. Madani, C. Ziebert e M. Marzband, “Thermal Behavior Modeling of Lithium-Ion Batteries: A Comprehensive Review”, *Symmetry*, v. 15, n. 8, 2023, ISSN: 2073-8994. DOI: [10.3390/sym15081597](https://doi.org/10.3390/sym15081597). endereço: <https://www.mdpi.com/2073-8994/15/8/1597> (ver p. 38).
- [90] M. Mastali, J. Vazquez-Arenas, R. Fraser, M. Fowler, S. Afshar e M. Stevens, “Battery state of the charge estimation using Kalman filtering”, *Journal of Power Sources*, v. 239, pp. 294–307, 2013, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2013.03.131>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775313005259> (ver p. 38).
- [91] M. Doyle, T. F. Fuller e J. Newman, “Modeling of Galvanostatic Charge and Discharge of the Lithium/Polymer/Insertion Cell”, *Journal of The Electrochemical Society*, v. 140, n. 6, p. 1526, jun. de 1993. DOI: [10.1149/1.2221597](https://doi.org/10.1149/1.2221597). endereço: <https://dx.doi.org/10.1149/1.2221597> (ver p. 38).
- [92] Z. Ren e C. Du, “A review of machine learning state-of-charge and state-of-health estimation algorithms for lithium-ion batteries”, *Energy Reports*, v. 9, pp. 2993–3021, 2023, ISSN: 2352-4847. DOI: <https://doi.org/10.1016/j.egy.2023.01.108>. endereço: <https://www.sciencedirect.com/science/article/pii/S235248472300118X> (ver p. 39).
- [93] C. Wang, R. Li, Y. Cao e M. Li, “A hybrid model for state of charge estimation of lithium-ion batteries utilizing improved adaptive extended Kalman filter and long short-term memory neural network”, *Journal of Power Sources*, v. 620, p. 235 272, 2024, ISSN: 0378-7753. DOI: <https://doi.org/10.1016/j.jpowsour.2024.235272>. endereço: <https://www.sciencedirect.com/science/article/pii/S0378775324012242> (ver p. 39).
- [94] A. Aguilar, F. González e V. Jiménez, “Thevenin’s equivalent circuit for lithium battery modeling”, *Tecnológico Nacional de México en Celaya*, n. 141, 2021 (ver p. 39).
- [95] MathWorks, “Battery Modeling”, *MathWorks [Acessado em 05/12/2024]*, 2019. endereço: <https://www.mathworks.com/discovery/battery-models.html> (ver p. 49).
- [96] F. Heinrich, P. Klapper e M. Pruckner, “A comprehensive study on battery electric modeling approaches based on machine learning”, *Energy Informatics*, v. 4, 2021, ISSN: 0897-4756. DOI: [10.1186/s42162-021-00171-7](https://doi.org/10.1186/s42162-021-00171-7). endereço: <https://doi.org/10.1186/s42162-021-00171-7> (ver p. 49).

-
- [97] H. Yoganandan e K. Srinivasan, “Modeling and Validation of a Lithium-Ion Battery Pack”, *Journal of Testing and Evaluation*, v. 51, n. 4, pp. 2533–2552, jul. de 2023, ISSN: 0090-3973. DOI: [10.1520/JTE20220335](https://doi.org/10.1520/JTE20220335). eprint: https://asmedigitalcollection.asme.org/testingevaluation/article-pdf/51/4/2533/7146572/10_1520_jte20220335.pdf. endereço: <https://doi.org/10.1520/JTE20220335> (ver p. 49).
 - [98] V. S. Peric, T. Bogodorova, A. N. Mete e L. Vanfretti, “Model order selection for probing-based power system mode estimation”, pp. 1–5, 2015. DOI: [10.1109/PECI.2015.7064883](https://doi.org/10.1109/PECI.2015.7064883) (ver p. 49).
 - [99] C. Silva, B. Dias, R. Araújo, E. Pellini e A. Laganá, “Battery Model Identification Approach for Electric Forklift Application”, *Energies*, n. 14, 2021. endereço: <https://doi.org/10.3390/en14196221> (ver p. 54).
 - [100] T. I. N. L. is a U.S. Department of Energy Vehicle Technologies Program, “Battery Test Manual For Plug-In Hybrid Electric Vehicles”, 2010 (ver p. 54).
 - [101] R. Santos, C. Alves, E. Macedo, J. Villanueva e L. Hartmann, “Estimation of Lithium-ion Battery Model Parameters Using Experimental Data”, *Federal University of Paraíba*, 2019 (ver p. 54).
 - [102] J. Xie, X. Wei, X. Bo et al., “State of charge estimation of lithium-ion battery based on extended Kalman filter algorithm”, *Front. Energy Res.* 11:1180881., 2023. DOI: [10.3389/fenrg.2023.1180881](https://doi.org/10.3389/fenrg.2023.1180881) (ver pp. 54, 80).
 - [103] J. Meng, G. Luo, M. Ricco, M. Swierczynski, D. Stroe e R. Teodorescu, “Overview of Lithium-Ion Battery Modeling Methods for State-of-Charge Estimation in Electrical Vehicles”, *Appl. Sci.*, n. 8, 2018. endereço: <https://doi.org/10.3390/app8050659> (ver p. 54).
 - [104] F. Claude, M. Becherif, H. Saad e M. Ramadan, “Experimental validation for Li-ion battery modeling using Extended Kalman Filters”, *International Journal of Hydrogen Energy*, pp. 25 509–25 517, 2017 (ver p. 55).
 - [105] I. G. Alcázar, “Parametrización, modelado y simulación de baterías mediante la utilización de Battery Modeling en Simulink-Matlab”, *Universidad de Pamplona - E.T.S. de Ingeniería Industrial, Informátcay de Telecomunicación*, 2020 (ver pp. 55, 69).
 - [106] L. Souza, R. Vilela, C. Villarraga e A. Murilo, “Development of a test bench for lithium-ion battery evaluation: Towards high-performance battery management.”, 2023, XLIV CILAMCE (ver pp. 56, 58, 62).
 - [107] N. Instruments, “NI SCB-68A User Manual and Specifications”, *National Instruments Documentation*, 2012 (ver p. 61).

-
- [108] J. Gazzarri, “Battery Modeling”, *MATLAB Central File Exchange* [Acessado em 25/02/2025], 2025. endereço: <https://www.mathworks.com/matlabcentral/fileexchange/36019-battery-modeling> (ver p. 66).
- [109] J. Gazzarri, “Battery Modeling”, *MATLAB Central File Exchange*, 2025. endereço: <https://www.mathworks.com/matlabcentral/fileexchange/36019-battery-modeling> (ver pp. 66, 69, 70).
- [110] Large, “¿Cómo medir la capacidad de la batería de iones de litio?”, *LARGE* [Acessado em 17/01/2025], 2019. endereço: <https://es.large.net/news/8mu43mn.html> (ver p. 68).
- [111] C. Taborelli e S. Onori, “State of charge estimation using extended Kalman filters for battery management system”, *2014 IEEE International Electric Vehicle Conference (IEVC)*, 2014. DOI: [10.1109/IEVC.2014.7056126](https://doi.org/10.1109/IEVC.2014.7056126) (ver p. 80).
- [112] S. Yang, S. Zhou, Y. Hua et al., “A parameter adaptive method for state of charge estimation of lithium-ion batteries with an improved extended Kalman filter”, *Scientific Reports*, 2021. DOI: [10.1038/s41598-021-84729-1](https://doi.org/10.1038/s41598-021-84729-1) (ver p. 80).
- [113] S. C. G. Copyright, “Estudio de BIAS en Sistemas de Medición”, *SPC Consulting Group Copyright* [Acessado em 02/04/2025], 2017. endereço: <https://spcgroup.com.mx/estudio-de-bias-en-sistemas-de-medicion/> (ver p. 81).