

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA

CYNTHIA THAMIRES DA SILVA

Sistema de gerenciamento de baterias de lítio com estimação de estados com filtro de Kalman estendido adaptativo.

São Paulo
2022

CYNTHIA THAMIRES DA SILVA

Sistema de gerenciamento de baterias de lítio com estimação de estados com filtro de Kalman estendido adaptativo.

Versão Corrigida

Tese apresentada à Escola Politécnica da
Universidade de São Paulo para obtenção
do título de Doutora em Ciências.

Área de Concentração: Engenharia de
Energia e Automação Elétricas

Orientador:
Prof. Dr. Eduardo Lorenzetti Pellini

São Paulo
2022

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador

São Paulo, 15 de Julho de 2022

Assinatura do autor:



Assinatura do orientador:



Catlogação-na-publicação

da Silva, Cynthia Thamires

Sistema de gerenciamento de baterias de lítio com estimação de estados com filtro de Kalman estendido adaptativo / C. T. da Silva – versão corr. – São Paulo, 2022.

146 p.

Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas.

1. Gerenciamento de baterias 2. Filtro de Kalman 3. Modelamento matemático. I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Energia e Automação Elétricas II.t.

Dedico este trabalho a todos os cientistas e seus familiares, pelo incansável trabalho que engrandece nossa sociedade.

AGRADECIMENTOS

À CAPES, pela concessão da bolsa de doutorado e pelo apoio financeiro para a realização dessa pesquisa. À Escola Politécnica da USP pela estrutura cedida para a implementação do projeto, pelas excelentes aulas, professores e colegas que tive e conheci durante esta jornada.

Ao departamento de Engenharia Electrotécnica e de Computadores da Faculdade de Engenharia da Universidade do Porto (FEUP-U.PORTO) pela estrutura cedida para a implementação do projeto no período em que atuei como pesquisadora convidada dentro do programa de mobilidade e co-tutela do programa de doutoramento.

Ao Prof. Dr. Eduardo Lorenzetti Pellini, que orientou e incentivou a execução deste trabalho, guiando pelos melhores caminhos diante das diversas dificuldades encontradas, sendo uma pessoa sensata com ótimas sugestões, críticas e elogios durante todos os momentos da elaboração da pesquisa. Agradeço imensamente a revisão criteriosa de todo o texto, seu apoio nessa fase foi fundamental.

Ao Prof. Dr. Armando Antônio Maria Laganá que me acompanha desde o primeiro ano da faculdade, me incentivando em todos os momentos de dificuldade, vibrando com cada vitória e auxiliando em todas as grandes decisões de minha vida. Espero um dia contribuir para a vida acadêmica de alguém, assim como o senhor contribui para a minha.

Ao Prof. Dr. Rui Esteves Araújo pela excelente orientação acadêmica, me guiando pelos temas mais profundos dessa pesquisa com excelente maestria. Serei eternamente grata por ter me recebido em solo europeu e por ainda contribuir tanto para o meu crescimento.

Ao meu marido, sócio e parceiro de pesquisa, Bruno Martin de Alcântara Dias que aceitou participar dessa jornada comigo, com muitas incertezas e desafios, em busca de um propósito maior. Meu parceiro da vida, essa conquista também é sua.

À minha mãe, Josefina de Fátima Silva, por ser minha fã Nº 1, minha melhor amiga e meu apoio incondicional em todas as fases de minha vida. Ao meu pai, José Donizetti da Silva, por torcer sempre pelas minhas conquistas e me incentivar em todos os momentos.

A todos os familiares e amigos que me apoiaram durante este período.

E principalmente à Deus, pela saúde, pela força e pela fé. Sem dúvidas esses foram os principais elementos que permitiram a conclusão dessa tese.

“Toda a teoria deve ser feita para poder ser posta em prática, e toda a prática
deve obedecer a uma teoria.”

(PESSOA, 1926, p. 01)

RESUMO

DA SILVA, C. T. **Sistema de gerenciamento de baterias de lítio com estimação de estados com filtro de Kalman estendido adaptativo** / C. T. Silva. ver. corr. São Paulo, 2022. 146p.

Armazenar energia de forma eficiente é um dos principais fatores para um mundo mais sustentável. A eletrônica embarcada nos sistemas de armazenamento de energia possui um papel extremamente importante para garantir a eficiência, segurança e desempenho desses sistemas. A presente tese apresenta a metodologia de desenvolvimento de um sistema de gerenciamento de baterias completo, capaz de proteger e gerenciar adequadamente qualquer bateria (desde que se conheça os limites de tensão, corrente e temperatura), em qualquer aplicação (desde que se conheça a dinâmica de utilização da bateria na aplicação). O modelo matemático da bateria foi desenvolvido com foco em aplicações de empilhadeiras elétricas, comparando quatro modelos diferentes, quatro algoritmos de otimização e sete experimentos, com o objetivo de desenvolver o melhor modelo matemático com o melhor método de otimização e o melhor experimento para baterias de LiFePO₄ utilizadas em empilhadeiras elétricas. O modelo desenvolvido apresenta características únicas e inovadoras, que utiliza uma estrutura de múltiplas saídas, sendo capaz de aprimorar a exatidão dos parâmetros identificados em até 100 vezes quando comparado com modelos tradicionais que utilizam apenas uma saída. A metodologia apresentada nesse trabalho, permite criar os algoritmos do sistema de gerenciamento de bateria, principalmente para a estimação do estado da carga, que é feita por meio de um filtro de Kalman estendido adaptativo. O trabalho inova ao criar também uma política de ajuste das matrizes de ruído de processo (Q) e de medição (R) do filtro de Kalman, em tempo de execução. O algoritmo do filtro, juntamente com o modelo matemático, atingiu uma exatidão média de 99,56% em testes reais, em relação à tensão estimada e tensão medida da bateria. Também foi implementada uma estratégia de balanceamento das células, capaz de garantir a segurança e eficiência do banco de baterias em todos os testes realizados. Esse trabalho apresenta todos os métodos, equações e simulações necessárias para o desenvolvimento do sistema de gerenciamento de baterias e aplica o sistema em um ambiente prático, real. O *hardware* e o *firmware* do BMS foram desenvolvidos, testados e validados em um banco de baterias com 8 células de LiFePO₄, obtendo um ótimo desempenho em todos os testes realizados.

Palavras-Chave: Sistema de gerenciamento de baterias. BMS. Estimação do estado da carga. Modelamento matemático de baterias. Filtro de Kalman.

ABSTRACT

DA SILVA, C. T. **Lithium battery management system with adaptive extended Kalman filter state estimation** / C. T. Silva. ver. corr. São Paulo, 2022. 146p.

Perform energy storage efficiently is one of the main factors for a sustainable world. Embedded electronics in energy storage systems plays an extremely important role in ensuring the systems efficiency, safety, and performance. This thesis presents the methodology for developing a complete battery management system (BMS), capable of properly protect and manage any battery (since the voltage, current and temperature limits are known), in any application (since the battery dynamic use are known). The battery mathematical model was developed with a focus on practical applications, comparing four different models, four optimization algorithms and seven experiments, in order to develop the best mathematical model with the best optimization method and the best experiment for LiFePO₄ batteries used in electric forklifts. The mathematical model developed has unique and innovative features, which uses a multiples output structure, being able to improve the identified parameters accuracy by up to 100 times when compared to traditional models that use only the battery voltage as the system output. The presented methodology allows to create the battery management system algorithms, mainly for the state of charge estimation, which is done through and Adaptive Extended Kalman filter. The work innovates by also creating a policy to adjust the Kalman filter process noise (Q) and measurement noise (R) matrices at runtime. The filter algorithm, together with the mathematical model, achieved an average accuracy of 99,56% in real tests, in relation to the estimated and measured battery voltage. A cell balancing strategy was also implemented, capable of guaranteeing safety and efficiency of the battery pack in all tests performed. This work presents all the methods, equations, and simulations necessary for the battery management system development and applies in a real environment. The BMS hardware and firmware were developed, tested, and validated on a LiFePO₄ 8 cells battery pack, achieving excellent performance in all tests performed.

Keywords: Battery management system. BMS. State of charge estimation. Mathematical battery modeling. Kalman filter.

LISTA DE ILUSTRAÇÕES

Figura 2.1 - Célula eletroquímica típica.....	6
Figura 2.2 - Estados de operação da bateria.	7
Figura 2.3 - Fenômenos que ocorrem na bateria em diferentes escalas.	9
Figura 2.4 - Características dos modelos caixa branca, preta e cinza.	11
Figura 2.5 - Modelo de circuito equivalente da bateria.....	17
Figura 2.6 - Modelo KiBaM.....	20
Figura 2.7 - Bateria de lítio íon.	23
Figura 2.8 – Algumas aplicações da bateria de lítio.....	25
Figura 2.9 – <i>Hardware</i> básico do BMS.....	28
Figura 2.10 - Estrutura integrada da capacidade e da impedância em um BMS.	32
Figura 2.11 - A perda de capacidade e a capacidade remanescente do módulo da bateria.....	34
Figura 2.12 - Métodos para estimar o estado da carga da bateria.....	35
Figura 2.13 - Curva do OCV na carga e na descarga de células de lítio fosfato de ferro.	37
Figura 2.14 - Conceitos fundamentais do filtro de Kalman.....	39
Figura 2.15 - Linha do tempo das referências científicas da teoria do filtro de Kalman.	41
Figura 2.16 - Fluxograma do filtro de Kalman.	42
Figura 2.17 - Escala do ganho de Kalman (KG).....	43
Figura 2.18 - Exemplo de resultado do filtro de Kalman.....	44
Figura 2.19 - Representação do sistema por equações de espaço de estados.	45
Figura 2.20 - Diagrama de blocos do filtro de Kalman para modelos multidimensionais.	46
Figura 2.21 - Resistência interna da célula de lítio fosfato de ferro.....	50
Figura 2.22 - Distribuição da temperatura em uma célula cilíndrica, prismática e pouch.....	54
Figura 2.23 – <i>Pack</i> de bateria conectado a um BMS.	56
Figura 2.24 – Células desbalanceadas durante carga e durante descarga. ...	58

Figura 3.1 – Fluxo da identificação de sistemas.	64
Figura 3.2 – Teste de aplicação da bateria, em operação real, com empilhadeira elétrica.	65
Figura 3.3 – Pulsos longos de corrente, com um período de descanso de 5s entre os pulsos.	67
Figura 3.4 – Pulsos curtos de corrente, onde a corrente é diferente de 0,0A, com 1 minuto de descanso da bateria.	68
Figura 3.5 – Corrente de entrada e tensão de saída da bateria, medidos durante o teste OCV.	70
Figura 3.6 – <i>Breakpoints</i> e histerese da célula, presente na relação OCV-SOC.	71
Figura 3.7 – Parte do teste OCV usado para calcular os parâmetros R_0 , R_1 e C_1	73
Figura 3.8 – Identificação do sistema considerando pesos diferentes nas saídas.	76
Figura 3.9 – Diagrama de blocos do filtro de Kalman estendido.	78
Figura 4.1 – Placa de circuito impresso do hardware do BMS.	86
Figura 4.2 – Comparação entre cada resposta do modelo em relação ao dado de estimação e de validação.	88
Figura 4.3 – Resultado dos dados de estimação com o modelo NLGR com o melhor experimento.	91
Figura 4.4 – Comparação com os dados de estimação do modelo não linear caixa cinza com duas saídas estimado com o melhor experimento.	98
Figura 4.5 – Comparação com os dados de estimação do modelo não linear caixa cinza com duas saídas estimado com o melhor experimento – Sinal ampliado.	98
Figura 4.6 – Comparação com os dados de validação do modelo não linear caixa cinza com duas saídas estimado com o melhor experimento.	99
Figura 4.7 – Erro de predição em relação à tensão da bateria.	100
Figura 4.8 – Erro de predição em relação à tensão da bateria – Sinal ampliado.	100
Figura 4.9 – Erro de predição em relação ao estado da carga.	101
Figura 4.10 – Ruído de medição da tensão.	104

Figura 4.11 – Ruído de medição da corrente.	104
Figura 4.12 – Equações do algoritmo do filtro de Kalman estendido adaptativo.	106
Figura 4.13 – Covariância estimada e atualizada, relacionada ao estado x_1 (<i>VRC</i>)	107
Figura 4.14 – Covariância estimada e atualizada, relacionada ao estado x_2 (<i>SOC</i>)	107
Figura 4.15 – Covariância estimada e atualizada, relacionada ao estado x_2 (<i>SOC</i>) – Sinal ampliado.....	108
Figura 4.16 – Ganho de Kalman relacionado ao estado x_1	109
Figura 4.17 – Ganho de Kalman relacionado ao estado x_2	109
Figura 4.18 - Tensão total medida e estimada.	110
Figura 4.19 – Diferença porcentual entre a tensão medida e calculada.....	111
Figura 4.20 – Diferença entre tensão medida e tensão estimada.	111
Figura 4.21 – Tensão <i>VRC</i> “medida” e tensão <i>VRC</i> calculada.....	112
Figura 4.22 – Estado da carga calculado pelo algoritmo <i>coulomb counting</i> e estado da carga estimado pelo algoritmo de Kalman.....	113
Figura 4.23 – Comparação entre o algoritmo executado com simulação computacional e o algoritmo embarcado no BMS.	114
Figura 4.24 – Tempo computacional do algoritmo no BMS.....	115
Figura 4.25 – Corrente utilizada no teste do ciclo completo de carga e descarga.....	117
Figura 4.26 – Tensão das células no teste de ciclo completo.	117
Figura 4.27 – Estado da carga durante o ciclo completo de carga e descarga da bateria.....	118

LISTA DE TABELAS

Tabela 3.1 – Característica da célula de lítio empregada na bateria da empilhadeira.....	66
Tabela 3.2 – Combinação de incertezas.....	83
Tabela 4.1 – Ajuste com os dados de estimação com todos os métodos de otimização em cada modelo.....	87
Tabela 4.2 – Comparação entre os resultados de ajuste com dados de estimação e validação para cada um dos vários modelos avaliados.	88
Tabela 4.3 – Comparação entre todos os experimentos, relacionados aos dados de estimação e validação.	89
Tabela 4.4 – Desvio padrão dos parâmetros estimados e variância da saída de todos os experimentos.....	91
Tabela 4.5 – Parâmetros da bateria em todos os pontos de SOC.....	92
Tabela 4.6 – Comparação entre todos os experimentos, relacionados aos dados de estimação e validação, em relação à saída <i>Vbat (y1)</i>	94
Tabela 4.7 – Comparação entre todos os experimentos, relacionados aos dados de estimação e validação, em relação à saída <i>SOC (y2)</i>	94
Tabela 4.8 – Desvio padrão dos parâmetros estimados e variância da saída de todos os experimentos estimados com o modelo de duas saídas.....	95
Tabela 4.9 – Comparação entre a primeira estimação sem peso e a segunda estimação com peso nas saídas.	97
Tabela 4.10 – Parâmetros da bateria em todos os pontos do SOC, estimados com 2out_NLGR.....	102
Tabela 4.11 – Estado da carga final da bateria e das células individuais.	119

LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

AD	Analógico Digital
AFE	Analogic Front End
Ah	Ampere hora
ASIC	Application-Specific Integrated Circuit
BMS	Battery Management System
DSP	Digital Signal Processor
ECM	Equivalent Circuit Model
EDP	Equações Diferenciais Parciais
EKF	Extended Kalman Filter
EMC	Electromagnetic Compatibility
EMI	Electromagnetic Interference
KiBaM	Kinetic Battery Model
LiFePO4	Lítio Ferro Fosfato
NASA	National Aeronautics and Space Administration
NLGR	Nonlinear Grey Box Model
NLHW	Nonlinear Hammerstein Wiener
OCV	Open Circuit Voltage
OE	Output Error
PCM	Phase Change Materials
RC	Resistor Capacitor
RTOS	Real Time Operating System
SOC	Estado da Carga
SOF	State of Function
SOH	State of Health
TF	Transfer Function
2out_NLGR	2 Outputs Nonlinear Grey Box Model

SUMÁRIO

1	INTRODUÇÃO	1
1.2	OBJETIVOS E CONTRIBUIÇÕES.....	3
1.3	CONTEÚDO E ORGANIZAÇÃO.....	4
2	REVISÃO DA LITERATURA.....	6
2.1	MODELOS MATEMÁTICOS PARA BATERIAS	8
2.1.1	<i>Modelo caixa branca – modelo eletroquímico multifísico</i>	<i>12</i>
2.1.2	<i>Modelo caixa preta – modelo empírico.....</i>	<i>13</i>
2.1.3	<i>Modelo caixa cinza – modelo elétrico</i>	<i>14</i>
2.1.4	<i>Modelos analíticos.....</i>	<i>19</i>
2.1.5	<i>Modelos estocásticos.....</i>	<i>21</i>
2.2	BATERIAS DE LÍTIO-ÍON	22
2.3	SISTEMA DE GERENCIAMENTO DA BATERIA	26
2.3.1	<i>Tensão.....</i>	<i>30</i>
2.3.2	<i>Impedância</i>	<i>30</i>
2.3.3	<i>Capacidade</i>	<i>31</i>
2.3.4	<i>Estado da carga (SOC)</i>	<i>33</i>
2.3.4.1	Método da corrente ou de contagem de coulomb.....	35
2.3.4.2	Método da tensão de circuito aberto.....	36
2.3.4.3	Métodos com modelos e filtro de Kalman.....	38
2.3.4.4	Métodos utilizando redes neurais e lógica <i>fuzzy</i>.....	48
2.3.4.5	Outros métodos	49
2.3.5	<i>Estado de saúde (SOH)</i>	<i>51</i>
2.3.6	<i>Estado de funcionalidade (SOF).....</i>	<i>52</i>
2.3.7	<i>Gerenciamento térmico.....</i>	<i>53</i>
2.3.8	<i>Balanceamento das células</i>	<i>55</i>
2.3.9	<i>Outras funcionalidades.....</i>	<i>59</i>
3	METODOLOGIA.....	60

3.1	MODELO MATEMÁTICO	62
3.1.1	<i>Identificação de sistemas</i>	62
3.1.2	<i>Não linearidade da bateria</i>	69
3.1.3	<i>Cálculo dos parâmetros iniciais</i>	72
3.1.4	<i>Modelo não linear caixa cinza com duas saídas</i>	75
3.2	ESTIMAÇÃO DO ESTADO DA CARGA	76
4	RESULTADOS	86
4.1	MODELO MATEMÁTICO	87
4.1.2	<i>Modelo não linear caixa cinza com duas saídas (2out_ NLGR)</i>	94
4.1.3	<i>Modelo “2out_ NLGR” estimado com o melhor experimento</i>	96
4.2	ALGORITMO PARA ESTIMATIVA DO ESTADO DA CARGA.....	102
4.3	VALIDAÇÃO DO ALGORITMO EM UM CONJUNTO DE 8 CÉLULAS.....	116
5	CONCLUSÃO	120
6	PROPOSTAS FUTURAS	123
	REFERÊNCIAS	124

1 INTRODUÇÃO

Existem muitas técnicas possíveis para armazenamento de energia, encontradas em praticamente todas as formas, como: mecânica, química e térmica (IBRAHIM; ILLINCA; PERRON, 2008). Basicamente, a energia deve ser convertida para uma forma capaz de ser transformada em um tipo de energia capaz de ser armazenada, para então ser transformada novamente no tipo de energia mais prática para seu transporte e utilização (IBRAHIM; ILLINCA; PERRON, 2008). A técnica de armazenamento de energia que abrange o maior número de aplicações possível é a bateria, que pode ser utilizada em inúmeras aplicações, incluindo dispositivos portáteis, recursos de energia estacionária e até mesmo para o transporte (CHEN et al., 2008).

Neste contexto, o desenvolvimento das tecnologias relacionadas com a bateria é essencial, por exemplo, para viabilizar a substituição do uso de combustíveis fósseis, como os utilizados nos meios de transporte (CICCONI; LANDI; GERMANI, 2017). Muitos pesquisadores têm se concentrado em prolongar o ciclo de vida das baterias, aumentando a densidade de energia, densidade de potência, garantindo a segurança e a estabilidade. Uma bateria de lítio é um dos dispositivos de armazenamento de energia promissores neste contexto, devido ao seu peso leve, alta energia específica, alta potência específica e alta densidade de energia. Além disso, não tem efeito de memória e não utiliza metais pesados. Por exemplo, o LiFePO_4 (Lítio Ferro Fosfato) é um dos materiais mais atraentes e promissores para o cátodo dessas baterias, que é o candidato mais promissor para as baterias de íons de lítio modernas (ZHAO et al., 2015). As baterias de lítio apresentam maiores níveis de potência e energia por unidade de massa, devido ao fato de o lítio ser um elemento de pequeno tamanho e massa atômicas. Com seu emprego, a energia específica obtida é duas vezes maior em comparação com as baterias de níquel-metal-hidreto e quatro vezes maior com relação às baterias tipo chumbo-ácida. É importante ressaltar que o impacto das baterias de íons de lítio no meio ambiente é baixo, pois não possuem materiais tóxicos e venenosos, como o chumbo, o cádmio e o mercúrio.

O eletrólito da bateria de lítio é um material orgânico, reativo e que opera em uma faixa bem definida de tensão. Caso os limites de tensão elétrica (ou mesmo suas condições químicas, térmicas e mecânicas) sejam ultrapassados ou violados, podem ocorrer reações exotérmicas com a liberação de grande quantidade de energia, ocasionando até a explosão da bateria. Por esse motivo faz-se necessária a utilização de um circuito eletrônico, em cada célula da bateria, para monitorar e controlar sua operação, impedindo ou detectando condições de risco, tais como: temperatura elevada, alta tensão, baixa tensão, curto-circuito, violações mecânicas, vibrações etc. Se um dos limites for ultrapassado, um sistema de gerenciamento eletrônico deve desabilitar a bateria, prevenindo maiores danos à mesma ou ao local de sua aplicação, como num veículo elétrico. Também é necessário um sistema eletrônico que observe e controle a tensão individual de cada célula em série que compõem a bateria, para realizar o balanceamento de carga de cada célula, equilibrando sua distribuição energética, fazendo com que o conjunto da bateria tenha um aproveitamento ideal de suas capacidades.

Algumas das grandezas que devem ser rastreadas pelos sistemas de gerenciamento podem ser obtidas por medições diretas (como temperaturas, correntes e tensões). Entretanto, outras variáveis de interesse das células e das baterias só podem ser estimadas ou observadas por métodos indiretos, tais como o estado de carga, estado de saúde e estado de funcionalidade.

Por essa razão, faz-se necessário desenvolver algoritmos de estimação do estado da carga, estado de saúde e estado de funcionalidade, para que seja possível determinar a autonomia e a vida útil de uma bateria moderna (ROSOLEM, *et. al.* 2012). As dificuldades em se estabelecer estes algoritmos estão em torná-los aplicáveis a qualquer tipo de tecnologia e especificidade das células que compõem a bateria, sendo facilmente parametrizável e comissionável (LU, *et. al.* 2013).

Nesse contexto, a relevância deste trabalho está ligada ao desenvolvimento de um sistema de gerenciamento de baterias capaz, tanto de realizar o balanceamento de suas células, mas principalmente, capaz de estimar o estado da carga da bateria, por meio de um algoritmo robusto, preciso e flexível. O desenvolvimento deste algoritmo é apresentado com uma metodologia detalhada,

que permite a criação de um Filtro de Kalman Estendido Adaptativo, específico para cada aplicação.

O Filtro de Kalman é uma técnica muito utilizada para estimação de estados em geral, como para o estado a carga de baterias. Este parâmetro, que não pode ser medido diretamente por meio de sensores, e possui a necessidade de ser observado otimamente, por meio de outras medidas diretas, de outras grandezas. O Filtro se comporta essencialmente um conjunto de equações matemáticas recursivas que gera uma estimação ótima dos estados de um sistema, baseada em algumas entradas e saídas mensuráveis do sistema, que, no caso da bateria, podem ser a corrente e a tensão de suas células (RAHMOUN; BIECHL; ROSIN, 2012).

A otimização do Filtro de Kalman depende da qualidade de premissas sobre o ruído de processo e sobre o ruído de medição. Essas premissas são determinadas por meio do conhecimento de todos os processos relacionados aos sinais observados, seu condicionamento e digitalização, e são fatores cruciais que levam à otimização da técnica de filtragem de Kalman. A inadequação das premissas que representam o nível de ruído real pode levar a resultados não confiáveis (ALMAGBILE; WANG; DING, 2010).

Com base nesse contexto, esse trabalho apresenta uma metodologia para o *design* do Filtro estimador, incluindo a definição do ruído de processo e do ruído de medição (especialmente no contexto de baterias para eletro mobilidade), capaz de se adaptar às medições em tempo real da corrente e da tensão de cada célula da bateria.

1.2 OBJETIVOS E CONTRIBUIÇÕES

O objetivo geral desse trabalho é pesquisar e desenvolver novas ferramentas e algoritmos necessários para o desenvolvimento de um sistema completo de gerenciamento de baterias, seguro e eficiente, que possa ser utilizado em diferentes aplicações práticas, com foco no rastreamento preciso do estado de carga do sistema. Desse objetivo geral, decorrem outros objetivos, como o estudo e o ajuste

de um modelo matemático para uma bateria numa aplicação real, definindo o modelo de melhor estrutura, o melhor método de identificação e otimização de seus parâmetros, e o melhor experimento prático que permite obter estas informações para aplicações em empilhadeiras elétricas. Esse trabalho também aplica uma metodologia de desenvolvimento do algoritmo do filtro de Kalman estendido adaptativo, capaz de estimar o estado da carga, sendo capaz de definir as matrizes de ruído de processo e ruído de medição, considerando a medição, em tempo real, da corrente e da tensão de cada célula da bateria. Uma estratégia de balanceamento das células também foi desenvolvida, possibilitando a operação segura e eficiente do sistema. Para corroborar os resultados desse projeto, um sistema foi desenvolvido e aplicado em um banco de baterias real, com um sistema de gerenciamento especialmente desenvolvido (em *hardware* e *software*), para testar e para verificar as funcionalidades, validando as várias contribuições deste trabalho.

1.3 CONTEÚDO E ORGANIZAÇÃO

Este trabalho está dividido em quatro partes principais, onde a primeira parte apresenta a introdução e a motivação para o desenvolvimento de sistemas de gerenciamento de baterias. A segunda parte do trabalho apresenta o estado da arte de todas as funcionalidades de um sistema de gerenciamento de baterias (ou BMS), bem como os diferentes modelos matemáticos possíveis de serem utilizados para descrever a dinâmica da bateria e os diferentes métodos de estimação do estado de sua carga. Essa seção também apresenta uma breve descrição do estado de saúde, estado de funcionalidade e das diferentes estratégias para o gerenciamento térmico e para o balanceamento das células. A terceira parte apresenta a metodologia utilizada no desenvolvimento do BMS, tanto do seu hardware, bem como para seu software/firmware. Nesta parte, é mostrado o estudo e a definição do modelo matemático da bateria, o desenvolvimento do algoritmo de estimação do estado da carga, a estratégia de balanceamento das células e toda a estrutura organizacional do firmware de um BMS profissional. A quarta parte, apresenta os resultados atingidos em relação à adequabilidade e precisão do modelo matemático, do

algoritmo do filtro de Kalman estendido adaptativo e do balanceamento das células, para validar todos os métodos e algoritmos desenvolvidos no decorrer do trabalho.

Ao final, são apresentadas conclusões e discussões sobre os resultados, com comentários a respeito de futuros desenvolvimentos e pesquisas que podem ser originadas por esse trabalho.

2 REVISÃO DA LITERATURA

Uma bateria é composta basicamente de um conjunto de células (tipicamente eletroquímicas) conectadas em série, em paralelo ou em um arranjo série/paralelo. A bateria armazena energia química que é convertida em energia elétrica, através de reações eletroquímicas (KUSIAK, 2016). A Figura 2.1 mostra uma célula eletroquímica com seus elementos constituintes.




Figura 2.1 - Célula eletroquímica típica.

Fonte: (adaptado de KUSIAK et al., 2016).

Conforme a Figura 2.1, a célula possui dois eletrodos metálicos, o anodo com polaridade negativa, e o catodo com polaridade positiva. A corrente elétrica flui do anodo para o catodo no processo de descarga da bateria, e flui do catodo para o anodo no processo de carga. Os eletrodos são separados por um eletrólito condutor de eletricidade, o qual pode ser líquido ou sólido. O eletrólito é responsável pelo transporte das cargas elétricas entre os eletrodos, através de íons. Quando a bateria está sendo carregada, ocorre uma redução no anodo (recebendo elétrons), e uma oxidação no catodo (liberando elétrons). E quando a bateria está sendo descarregada, ocorre uma oxidação no anodo (liberando elétrons) e uma redução no catodo (armazenando elétrons) (KUSIAK, 2016).

Quando não há transporte de elétrons, ou seja, não há fluxo de corrente elétrica, a bateria se encontra em processo denominado por recuperação. Nesse

processo de recuperação, os elétrons disponíveis no eletrólito se reorganizam uniformemente após um certo período de tempo. Esse processo de homogeneização da distribuição de carga elétrica faz com que uma maior quantidade de carga possa ser armazenada, aumentando a capacidade da bateria (KUSIAK, 2016). A Figura 2.2 mostra os estados de operação da bateria, incluindo o processo de recuperação.

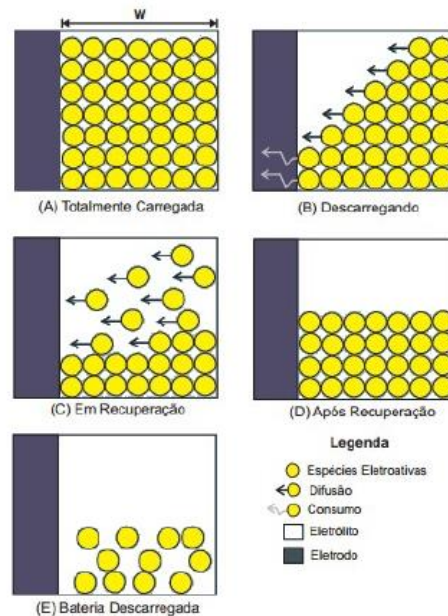


Figura 2.2 - Estados de operação da bateria.

Fonte: (adaptado de KUSIAK et al., 2016).

Na Figura 2.2 (A), há espécies eletroativas em todo o comprimento w do eletrólito, ou seja, a bateria encontra-se totalmente carregada. Ao iniciar o processo de descarga na Figura 2.2 (B), as reações eletroquímicas reduzem as espécies eletroativas próximos ao eletrodo. Esta redução faz com que seja formado um gradiente de concentração, fazendo com que a capacidade efetiva da bateria seja diminuída. Porém, quando não há corrente elétrica fluindo pela célula, as espécies eletroativas passam a se reorganizar de maneira uniforme, reequilibrando o sistema, como pode ser visto na Figura 2.2 (C). Neste momento é gerado um gradiente de concentração nulo no eletrólito, que aumenta a concentração de espécies

eletroativas próximas ao eletrodo, disponibilizando uma maior quantidade de carga ao sistema, como visto na Figura 2.2 (D) (KUSIAK, 2016).

Quando a bateria atinge o estado mínimo de carga, não ocorrem mais reações eletroquímicas e a bateria é considerada descarregada. As espécies eletroativas que ainda se encontram no eletrólito são incapazes de manter o sistema operacional, como representado na Figura 2.2 (E).

Quando a corrente de descarga é muito alta, o processo de recuperação não ocorre, pois não há tempo suficiente para que as espécies eletroativas se reorganizem no eletrólito, tornando a capacidade efetiva da bateria baixa (KUSIAK, 2016).

Devido a esses e outros processos, tais como gasificação, vazamentos, descargas parasitas, formação e depósito de compostos químicos estáveis nos eletrodos e eletrólitos, etc., a bateria se comporta como um sistema multifísico complexo e, sobretudo, não linear, do qual se desejaria ter uma exata compreensão do estado de sua carga e de sua verdadeira disponibilidade energética (HARTING et al., 2017). Entretanto, a medição direta de todos esses fenômenos, como a distribuição de cargas mostrada na Figura 2.2, não é tecnicamente viável, sendo papel para outros sistemas de apoio da bateria, que tentam observar e prever seu estado e comportamento.

Para compreender, interpretar e analisar o estado e o comportamento de uma bateria é necessário utilizar modelos matemáticos compatíveis. Na literatura, foram encontrados diversos modelos que descrevem as características reais de operação de baterias. Esses modelos diferem entre si, pela precisão e pela complexidade, e serão apresentados na próxima seção.

2.1 MODELOS MATEMÁTICOS PARA BATERIAS

O avanço no desenvolvimento das baterias é um processo historicamente lento, entretanto, tem sido impulsionado de forma notável por demandas dos setores

de mobilidade elétrica, eletroportáteis, telecomunicações e telefonia móvel como nunca havia ocorrido anteriormente. Então, desde a invenção da bateria, a busca por baterias recarregáveis, com maior capacidade, menor tamanho e peso se tornou o objetivo de muitos desenvolvedores e pesquisadores de diversas áreas. A essência dos modelos para os diferentes tipos de baterias é o mesmo, sendo necessário, apenas pequenas mudanças para adequação ao tipo de célula considerada (KUSIAK, 2016).

A partir de alguma compreensão sobre os mecanismos físicos e químicos internos da bateria, um modelo matemático permite simular e observar o comportamento da mesma em condições de operação controladas e específicas. Vários fenômenos físicos (elétricos, eletroquímicos, térmicos e mecânicos) ocorrem em diferentes perspectivas no sistema de bateria, desde um contexto atômico de sua constituição até macroscópico no sistema de sua aplicação (ABADA et al., 2015). Alguns fenômenos são mostrados na Figura 2.3.

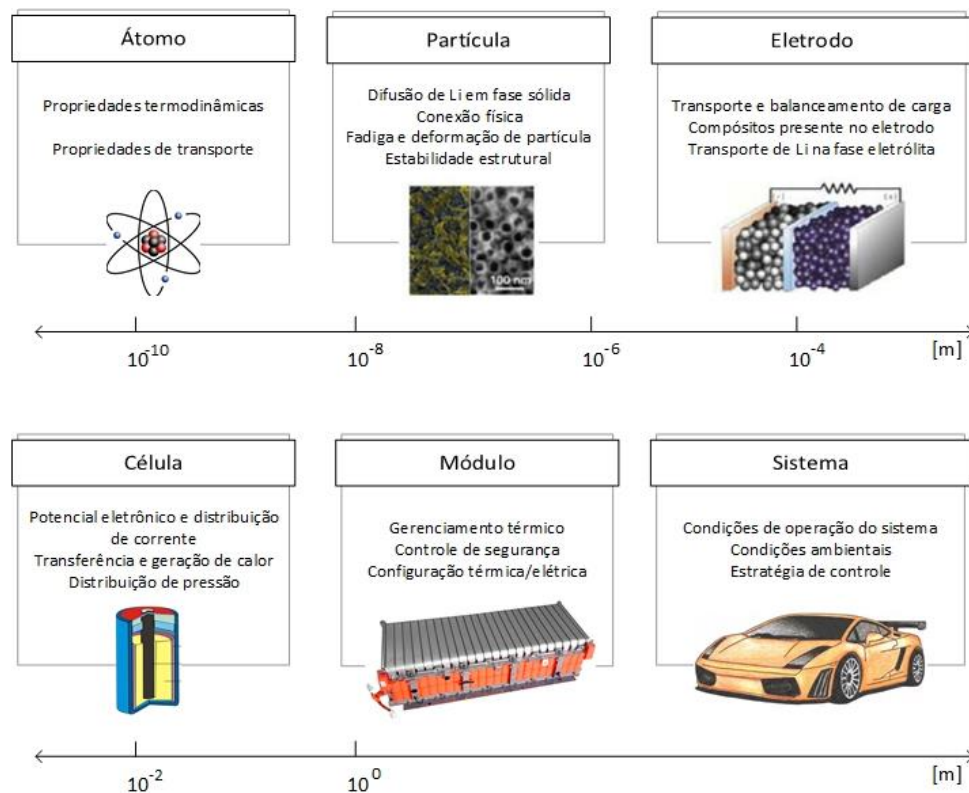


Figura 2.3 - Fenômenos que ocorrem na bateria em diferentes escalas.

Fonte: (adaptado de ABADA et al., 2015).

Descrever todos esses fenômenos com grande detalhe em um modelo de bateria requer considerações entre o potencial nível de melhoria na capacidade de previsão de seus estados, e entre os custos extras devido aos maiores requisitos computacionais, maior tempo de simulação e da quantidade de medições necessárias para sua parametrização (ABADA et al., 2015).

Algumas escalas podem ser consideradas no modelo de bateria de acordo com os fenômenos de interesse, desde a escala de material, até o design macroscópico do sistema como um todo. Além disso, em cada escala, diversos grupos de modelos podem ser distinguidos, sendo os mais comuns os: Eletroquímicos, Empíricos, Elétricos, Analíticos e Estocásticos.

As três escalas mais comuns são:

- No nível do material (escala de comprimento microscópica), são descritos os processos elementares, como por exemplo, a transferência de carga, a cinética química, a difusão de lítio através das partículas de material ativo e no eletrólito, ou a deformação de partículas;
- No nível da célula (em uma escala intermediária), os fenômenos de transporte, termodinâmicos, térmicos, mecânicos e cinéticos são descritos para determinar o desempenho 'celular'. Neste nível, os modelos físicos de microescala são geralmente reduzidos em complexidade, matematicamente, para maior velocidade de simulação;
- No nível do *pack* (ou macroscópico) as células são indiferenciadas e seu comportamento é calculado de forma a abordar questões relacionadas à sua integração em sistemas mais complexos (veículos, redes elétricas etc.).

Além disso, em cada escala, diversos grupos de modelos podem ser distinguidos, sendo os mais comuns os: Eletroquímicos, Empíricos, Elétricos, Analíticos e Estocásticos.

A capacidade de aferir modelos a partir de observações e estudar as suas propriedades, é exatamente o significado dessa ciência. Todos os modelos

possuem, como característica básica, a capacidade de transformar informações em determinados padrões. A teoria de identificações de sistemas lida com o problema de construir modelos matemáticos de sistemas dinâmicos baseados em dados observados do sistema. Esse assunto é parte da metodologia científica básica e, considerando que todo nosso ambiente é composto por inúmeros sistemas dinâmicos, as técnicas de identificação de sistemas possuem uma vasta área de aplicação, incluindo a área de baterias (LJUNG, 1999).

Na identificação de sistemas, os modelos podem ser separados em três grupos: Modelos caixa branca, modelos caixa preta e modelos caixa cinza.

Os modelos eletroquímicos são considerados modelos caixa branca, os modelos empíricos são considerados modelos caixa preta e os modelos elétricos são considerados modelos caixa cinza. A diferença entre eles é baseada na quantidade de conhecimento prévio, físico do sistema, que é necessária para gerar suas equações matemáticas algébricas-diferenciais-transcendentais (ALLAFI, et al., 2018). Um resumo sobre as características desses modelos, é apresentado na Figura 2.4, e suas características são detalhadas nas próximas subseções.

Modelo Caixa Branca	Modelo Caixa Cinza	Modelo Caixa Preta
<p>Requer:</p> <ul style="list-style-type: none"> • Equações Determinísticas; • Conhecimento Físico; • Submodelos Detalhados. 	<p>Requer:</p> <ul style="list-style-type: none"> • Conhecimento Prévio; • Dados. 	<p>Requer:</p> <ul style="list-style-type: none"> • Base de Dados; • Representação Entrada/Saída.

Figura 2.4 - Características dos modelos caixa branca, preta e cinza.

Fonte: (adaptado de NAVID et al., 2019).

2.1.1 Modelo caixa branca – modelo eletroquímico multifísico

Os modelos caixa branca se referem a modelos que são baseados em equações matemáticas complexas, em sua maioria, equações algébrico-diferenciais parciais que descrevem a física e os processos eletroquímicos que ocorrem nas baterias (HU et al., 2017; PENG et al., 2019). Essas equações podem ser complexas e computacionalmente pesadas para simular ou prever os comportamentos do sistema e, por esse motivo, geralmente esses modelos não são utilizados em projetos de controle (HU; LI; PENG, 2012). Seus parâmetros são, em sua maioria, obtidos a partir de experimentos e propriedades físicas do sistema (ALLAFI et al., 2018). Esses modelos capturam as dinâmicas internas da bateria como, a difusão dos íons, intercalação cinética e os potenciais elétricos (HU et al., 2017).

Um tipo de modelo caixa branca da bateria muito conhecido é o modelo eletroquímico. E uma de suas representações mais precisa é composta por um sistema de 6 Equações Diferenciais Parciais (EDP) não lineares. Os resultados dessas equações fornecem: a tensão, a corrente, as fases de potencial no interior do eletrólito e eletrodo, a concentração salina, a taxa de reação e a densidade de corrente no eletrólito. Geralmente, esse tipo de modelo é preciso, porém, sua implementação e resolução é demasiadamente complexa (ABADA et al., 2015; KUSIAK, 2016).

Os modelos eletroquímicos normalmente simulam as reações eletroquímicas reais, ou seja, são baseados na construção física e química da bateria. (HU; LI; PENG, 2012; YANG et al., 2014). Essa classe de modelos oferece conhecimentos significativos para a análise do sistema, e atingem o mais alto nível de precisão porque conseguem caracterizar os mecanismos fundamentais do armazenamento e da geração de energia da bateria (HU; LI; PENG, 2012). Porém, é necessário um grande esforço na identificação dos seus parâmetros, e ainda possui um alto custo para sua resolução numérica, ou seja, devido ao seu nível de complexidade e precisão, são computacionalmente difíceis para implementação prática, sobretudo para simulação em tempo real (ALLAFI et al., 2018; CORNO; SAVARESI, 2013; HU et al., 2017). Existem modelos na literatura que buscam resolver a questão desse elevado custo computacional, porém, esses modelos ainda sofrem com uma

dificuldade excessiva na caracterização dos parâmetros da bateria, onde é necessário conhecer dezenas de parâmetros físicos, que somente podem ser identificados com experimentos laboratoriais custosos, invasivos e específicos (CORNO; SAVARESI, 2013). Além disso, devido à natureza proprietária da engenharia e tecnologia da maioria das baterias disponíveis, os parâmetros necessários para ajustar o modelo geralmente não estão disponíveis (HU; LI; PENG, 2012). Porém, considerando a precisão como o aspecto mais importante dessa modelagem, esses modelos são excelentes, e podem ser utilizados para complementar dados experimentais e para avaliação de outros modelos. Uma grande vantagem de modelos eletroquímicos é que seus estados são completamente observáveis, permitindo “medições virtuais” de quantidades que não poderiam ser medidas na prática (FOTOUHI et al., 2016).

2.1.2 Modelo caixa preta – modelo empírico

A abordagem do modelamento caixa preta necessita de poucos princípios físicos da bateria e se baseia na teoria de estimação estatística, baseada em dados experimentais reais (ALLAFI et al., 2018). Um bom desempenho na estimação de métodos desses modelos, orientados por dados, depende da quantidade e qualidade das informações disponíveis e para inferência e treinamento de alta qualidade, além de alta complexidade computacional (ZHENG et al., 2018). A representação detalhada dos processos eletroquímicos internos que ocorrem nas baterias é negligenciada nesses tipos de modelo (PENG et al., 2019).

Os modelos caixa preta assumem que a bateria não é conhecida e todos os parâmetros do modelo são ajustáveis, independentemente do contexto físico. Existem diferentes abordagens dentro dessa classe de modelo, a variar entre modelos não lineares, baseados em blocos estruturados - como os modelos Hammerstein-Wiener (DA SILVA et al., 2021), a modelos baseados em redes neurais - como os modelos não lineares autorregressivos (NARX), os quais se tornam uma abordagem conveniente e robusta para modelagem de diferentes tipos de baterias (KHALFI et al., 2021; YANG; FOLEY; ZHANG, 2014). Esses modelos

podem, por exemplo, fornecer uma predição de temperatura precisa - considerando que dados suficientes estão disponíveis para o treinamento do modelo - mas ao custo de perder a relevância ou relacionamento físico com seus parâmetros de capacidade térmica e a condutividade térmica (ALLAFI et al., 2018).

Os modelos empíricos também são chamados de modelos caixa preta, devido ao pouco conhecimento que possuem do sistema. São baseados em parâmetros empíricos, os quais muitas vezes não possuem qualquer significado físico. As abordagens matemáticas, utilizadas para definir uma função de transferência a partir das entradas e saídas do sistema, fazem esses modelos serem fáceis de configurar e capazes de entregar rápidas respostas e boas predições. Entretanto, sua precisão permanece limitada, especialmente se o modelo for muito simples. Modelos mais sofisticados atingem melhores resultados quando são baseados em modelagem estocástica ou com lógica nebulosa (fuzzy) (ALLAFI et al., 2018). A precisão e o conhecimento físico podem ser aprimorados se o modelo caixa preta for combinado com um modelo caixa branca (SAIDANI et al., 2017).

Atualmente, em virtude da disponibilidade de arcabouços (*frameworks*) e *softwares* de domínio público, muito é investigado no desenvolvimento de modelos tipo caixa preta a partir de técnicas de aprendizado de máquina profundo (*deep-learning*), com grandes massas de dados (KHUMPROM; YODO, 2019).

2.1.3 Modelo caixa cinza – modelo elétrico

A técnica de modelagem caixa cinza surgiu como um “meio termo” entre os modelos caixa branca e caixa preta. Essa técnica combina um conhecimento físico preliminar com dados experimentais para realizar uma interpretação física, a fim de atribuir valores numéricos aos parâmetros do modelo (NAVID; HASSAN, 2019). Esse modelo assume que alguma informação na dinâmica de certos parâmetros físicos é conhecida, e que os parâmetros podem ter certas restrições ou limites operacionais, ou seja, utiliza informações conhecidas para inferir informações

desconhecidas, as quais seriam difíceis ou impossíveis de medir (KHALFI et al., 2021; ZHENG et al., 2018).

Os modelos abstratos também são conhecidos como modelos caixa cinza. No contexto de baterias, esses modelos representam uma diferente - mas equivalente - representação do sistema da bateria. Diferentes formas de representação são possíveis, mas a representação por um circuito elétrico equivalente (ECM – *Equivalent Circuit Models*) é, uma das mais populares, uma vez que possui um bom compromisso entre precisão e usabilidade. Os modelos baseados em circuitos também são simples e práticos, porque permitem que os processos eletroquímicos complexos sejam substituídos por um circuito elétrico simples, de dinâmica análoga. Tais modelos usam uma combinação de bipolos ou quadripolos, ideais ou vinculados, por exemplo, com uma fonte de tensão ideal que tem sua intensidade dependente do estado da carga, resistores, capacitores e inclusive, elementos não lineares, como a impedância de Warburg (SANTORO, 2014), para aproximar a dinâmica subjacente. Circuitos equivalentes, como do tipo Thèvenin, ou um modelo de impedância variável são muito utilizados. Nesse tipo de modelo, a correlação com a dinâmica da bateria real consegue ser preservada (ou emulada), sem comprometer muito sua precisão. Porém, a precisão desses modelos é altamente dependente da estrutura e da topologia do circuito (HU; LI; PENG, 2012; SAIDANI et al., 2017; YANG et al., 2014).

Os modelos de circuito equivalente são chamados de caixa cinza devido uma analogia física existente entre os componentes utilizados na modelagem e os componentes e fenômenos da bateria real (HU; LI; PENG, 2012). Ou seja, não são caixa branca, pois não usam EDP relacionados aos fundamentos físicos-químicos, e também não são caixa preta, pois não são baseados apenas em dados experimentais.

Quando um sistema complexo é modelado, o modelo contém alguns parâmetros desconhecidos. Por exemplo, considerando uma bateria de lítio, sua impedância interna é grandemente afetada pela temperatura e pelo estado de carga (SOC), mas sua exata relação não é bem definida. Esses valores paramétricos são estimados utilizando correlações estatísticas (identificação de sistemas) a partir de

dados experimentais (NAVID; HASSAN, 2019). Tais modelos de baterias não conseguem refletir os efeitos da corrente, do SOC, do SOH, da temperatura ou da autodescarga, das características internas da bateria. Esses modelos são menos precisos que os modelos caixa branca, pela falta de uma representação mais fiel e exata dos processos eletroquímicos internos e de não linearidades (PENG et al., 2019). Logo, modelos precisos (que deveriam ser capazes de atingirem desempenho ótimo) são difíceis de serem obtidos apenas com algoritmos baseados em modelos caixa cinza e caixa preta (HU et al., 2017).

Enquanto os modelos de circuito equivalente não são tão precisos quanto os modelos eletroquímicos, os primeiros são geralmente muito mais simples em sua estrutura, tornando-os factíveis de serem utilizados e processados em ambiente de computação embarcadas (com restrições de velocidade de processamento, tipo de aritmética e capacidade de memória). Quando operados em condições específicas (por exemplo, dentro de uma certa faixa de temperatura e SOC), a imprecisão desses modelos pode ser menor que 5% e, quando tratados apropriadamente, podem produzir resultados úteis para o gerenciamento da energia armazenada, em de qualquer aplicação (HU; LI; PENG, 2012).

Existem diferentes tipos de modelos de circuito equivalente da bateria, e a seleção do melhor modelo para cada aplicação é realizada através de uma análise de custo-benefício, entre uma complexidade computacional baixa, e uma boa precisão do modelo. Um ECM típico geralmente utiliza circuitos RC (Resistor e Capacitor) para simular as características dinâmicas da bateria. Quanto mais circuitos RC, maior será a precisão do modelo, bem como sua ordem e complexidade (DA SILVA et al., 2021).

No desenvolvimento de um modelo tipo ECM para uma bateria, é necessário representar diversos fenômenos físicos, como:

- A relação OCV (*Open Circuit Voltage*) com o SOC (*State of Charge*);
- O efeito da histerese na carga e na descarga;
- A temperatura;
- A influência da Taxa de Capacidade;

- A degradação da sua Capacidade.

Cada recurso adicionado ao modelo irá aumentar significativamente o esforço computacional e sua complexidade. Considerando que modelos complexos são tipicamente mais suscetíveis às incertezas, os modelos preferidos são aqueles que são suficientemente precisos e simples. Em (HU; LI; PENG, 2012) um estudo comparativo foi realizado com diversos circuitos equivalentes de baterias de lítio. Os autores concluíram que a melhor representação para baterias de lítio ferro fosfato (LiFePO₄) pode ser feita com um modelo de circuito RC de primeira ordem, com um estado de histerese. Considerando esse estudo, em (DA SILVA et al., 2021) foi desenvolvido um modelo com um circuito RC, considerando a relação OCV-SOC e o efeito de histerese. O modelo desenvolvido em (DA SILVA et al., 2021) é apresentado na Figura 2.5.

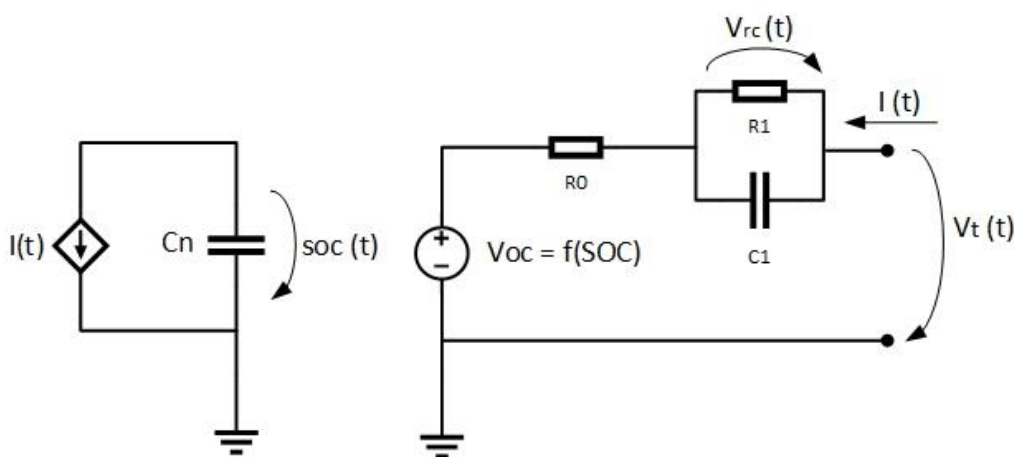


Figura 2.5 - Modelo de circuito equivalente da bateria.

No que se refere à estrutura da Figura 2.5, a fonte de tensão é utilizada para descrever o SOC dependente do OCV, enquanto que o $V_t(t)$ representa a tensão total da bateria, R_0 é a resistência ôhmica (interna) da bateria e o circuito RC é uma analogia que possui como finalidade modelar os efeitos da polarização, incluindo, carga, difusão, convecção, migração, os efeitos de transferência nos eletrodos, entre outros. Considerando a Figura 2.5, as equações em espaço de estados, no domínio

do tempo contínuo, que representam esse circuito são os seguintes (DA SILVA et al., 2021):

$$u(t) = I(t); \quad (1)$$

$$y(t) = V_t(t); \quad (2)$$

$$x_1(t) = V_{RC}(t); \quad (3)$$

$$x_2(t) = soc(t). \quad (4)$$

onde:

$u(t)$ é o sinal de entrada,

$y(t)$ é o sinal de saída,

$I(t)$ é a entrada da corrente aplicada,

$V_t(t)$ é a tensão total (ou terminal) da bateria,

$x_1(t)$ and $x_2(t)$ são os estados desse sistema,

$V_{RC}(t)$ é a queda de tensão no circuito RC, e;

$soc(t)$ é o valor instantâneo do estado da carga da bateria.

As derivadas dos estados são:

$$\dot{x}_1(t) = -\frac{1}{R_1 * C_1} * x_1(t) - \frac{1}{C_1} * u(t) \quad (5)$$

$$\dot{x}_2(t) = \frac{1}{3600 * Cn} * u(t) \quad (6)$$

Onde R_1 and C_1 são, respectivamente, o resistor e o capacitor do circuito equivalente da bateria e Cn representa a capacidade nominal da bateria. A constante 3600 é necessária para realizar a conversão da unidade de tempo da capacidade nominal, a qual é representada por Ampere Hora, para a unidade de tempo da contagem de Coulomb, a qual é representada diretamente por Coulomb (1 hora = 3600 segundos).

A tensão sobre a bateria é descrita pela Eq. 7.

$$y(t) = V_{OCV} - x_1(t) - R_0 * u(t) \quad (7)$$

Um dos desafios desse tipo de modelo é representar a relação não linear entre o OCV e o SOC, representado pelo termo V_{OCV} na Eq. 7. Existem diferentes formas de descrever essa relação, sendo as mais comuns: uma tabela de valores para consulta (*lookup table*), uma aproximação polinomial, ou uma série de funções linearizadas por partes (*Piecewise Linear Function*). A definição de cada método deve ser realizada de acordo com a capacidade computacional disponível e a precisão desejada (DA SILVA et al., 2021).

2.1.4 Modelos analíticos

Em modelos analíticos, diferentes conceitos físicos podem ser utilizados, e, na maioria desses modelos, são utilizadas apenas algumas equações para descrever as propriedades da bateria, tornando esse tipo de modelo de fácil implementação (FOTOUHI et al., 2016; KUSIAK, 2016).

Existem diversos tipos de modelo analíticos. Os mais simples e menos precisos consideram a bateria como um sistema linear, desconsiderando os efeitos não lineares do processo de descarga. Alguns modelos consideram apenas uma parte das propriedades não lineares da bateria, como por exemplo, a relação não linear entre o tempo de vida da bateria e sua taxa de descarga (KUSIAK, 2016).

Também existem modelos analíticos que são baseados na difusão dos íons no eletrólito, e descrevem a evolução da concentração dos elétrons durante o processo de descarga. Já outros modelos analíticos, se baseiam nos processos cinéticos que ocorrem no interior da bateria e consideram, por exemplo, a velocidades das reações químicas (KUSIAK, 2016).

Um dos exemplos mais comuns de modelos analíticos, é o KiBaM (*Kinetic Battery Model*), que foi desenvolvido a partir da compreensão da cinética do processo químico da bateria. Nesse, a carga total da bateria é modelada numa analogia hidráulica, como o líquido em dois tanques relacionados por razões fracionárias de 'c', conforme Figura 2.6.

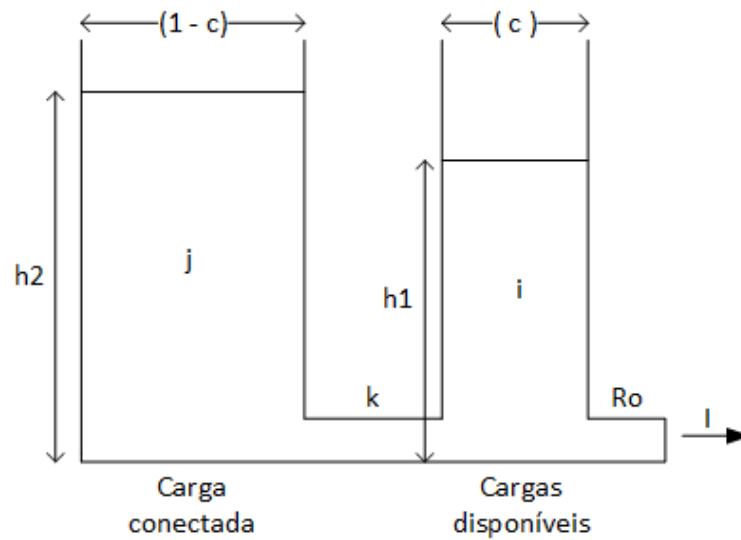


Figura 2.6 - Modelo KiBaM.

Fonte: (Adaptado de FOTOUHI et al., 2016).

Um tanque representa as “cargas disponíveis” e é conectado diretamente à carga. Já o outro tanque representa a “carga conectada”, o qual drena a carga do tanque de “cargas disponíveis” (FOTOUHI et al., 2016). As seguintes equações diferenciais descrevem como a carga muda em cada tanque:

$$\frac{di}{dt} = -I + k(h_2 - h_1) \quad \text{onde } i = h_1 \cdot c \quad (8)$$

$$\frac{dj}{dt} = -k(h_2 - h_1) \quad \text{onde } j = h_2(1 - c) \quad (9)$$

O parâmetro h_1 representa o estado da carga da bateria. Os dois tanques são conectados através de uma válvula que possui um coeficiente de vazão de valor k . Quando a corrente (I) é drenada da bateria, o parâmetro h_1 diminui e então a diferença entre h_1 e h_2 causa um fluxo entre os dois tanques até que eles se tornem equilibrados (FOTOUHI et al., 2016).

2.1.5 Modelos estocásticos

Os modelos estocásticos utilizam uma abstração matemática para descrever a bateria. Os processos que são considerados estocásticos são: a descarga da bateria e o efeito de recuperação. Neste tipo de modelo, a bateria é representada por um número finito de unidades de carga, e o comportamento da descarga é modelado utilizando um processo estocástico. À medida que o tempo evolui, este processo é dividido em intervalos iguais, e o estado da bateria é controlado pelo número de unidades restantes de carga. O modelo estocástico fornece uma boa descrição qualitativa do comportamento de baterias, entretanto a sua precisão em termos quantitativos ainda não está clara (KUSIAK, 2016).

Esse tipo de modelo funciona baseado no princípio da cadeia de Markov de tempo discreto. Um processo Markov é um processo que não armazena dados anteriores e que pode prever o futuro do processo baseado no estado presente sem conhecer sua história completa. Esse método pode ser utilizado para modelar um sistema aleatório cujas suas mudanças de estado se baseiam em uma regra de transição, que somente depende do estado atual do sistema (FOTOUHI et al., 2016).

Foi encontrado na literatura (FOTOUHI et al., 2016), uma versão estocástica do modelo KiBaM, representada como um processo Markov tridimensional. Esse modelo tem parâmetros de três estados (i, j, t) . O parâmetro i é o nível (volume) do tanque de “carga conectada”, o parâmetro j é o nível do tanque de “carga disponível” e o parâmetro t é o tempo desde que alguma corrente foi drenada da bateria até o instante presente. O modelo da bateria realiza a mudança de um estado para o outro (isso é chamado de “transição”), e cada transição tem uma probabilidade associada (FOTOUHI et al., 2016).

Em resumo, existem diferentes tipos de modelos de baterias, cada um desenvolvido para suprir os requisitos específicos de suas aplicações. Modelos com alta complexidade são tipicamente utilizados para análise de sistemas offline, enquanto modelos mais simples são preferidos para aplicações de controle, estimação em tempo real, predição e diagnóstico (ALLAFI et al., 2018). Uma

apresentação mais detalhada de cada tipo de modelo pode ser encontrada em (KUSIAK, 2016) e em (FOTOUHI et al., 2016).

2.2 BATERIAS DE LÍTIO-ÍON

A escolha do tipo de bateria depende muito da aplicação em que será utilizada. Existem diversos tipos de baterias, com diferentes tecnologias e diversas densidades de energia e potência. A bateria mais tradicionalmente utilizada, até 2020, são as baterias de chumbo-ácido. Trata-se de baterias consagradas, cuja operação e ciclo de vida são bastante conhecidos. Entretanto, apesar de serem relativamente seguras - a ponto de praticamente dispensarem qualquer tipo de sistema de gerenciamento ou controle dedicados - essas baterias possuem um custo maior, baixa densidade de energia e potência, além de empregarem metais pesados. Pode-se admitir que estas baterias possuem um desempenho inferior do que soluções mais recentes.

O desempenho da bateria não é uma grandeza simples de definir e, há muitas variáveis interligadas que podem estabelecer o seu valor. Uma bateria com bom desempenho, pode ser uma bateria com alta autonomia, ou uma bateria com alta potência, ou até mesmo uma bateria com alta durabilidade. O desempenho da bateria é determinado pelo principal requisito do projeto e da aplicação, pois a autonomia, a potência e a durabilidade, em conjunto, são conceitos paradoxais, por vezes inversamente correlacionados. Por exemplo, a potência da bateria pode ser maior, porém, com a densidade de energia e a durabilidade menores (COELHO, 2001).

As baterias de lítio íon são um dos sistemas de armazenamento de energia mais promissores, pois são leves, compactas, não possuem efeito memória e possuem picos de potência específica de mais de 1000W/kg, e energia específica de mais de 100Wh/kg (COELHO, 2011; POLLET; STAFFEL; SHANG, 2012; TIE; TAN, 2013). Também possuem um alto ciclo de vida, alta densidade energética, bom

comportamento em alta temperatura, são recicláveis, e não possuem metais tóxicos (como o chumbo, mercúrio ou cádmio) (KHALIGH; LI, 2010; TIE; TAN, 2013).

O eletrodo positivo é feito de um material de cobalto oxidado, enquanto que o eletrodo negativo é feito de um material derivado de carbono. O eletrólito é o sal de lítio, que é um solvente orgânico. (KHALIGH; LI, 2010). Neste tipo de baterias, tanto o anodo (grafite), como o catodo (óxido de lítio), são materiais nos quais, e dos quais, o lítio (como Li^+) migra através do eletrólito (POLLET; STAFFEL; SHANG, 2012). A Figura 2.7 apresenta um diagrama da bateria de lítio íon e seus componentes.




Figura 2.7 - Bateria de lítio íon.

Fonte: (Adaptado de AKINYELE; RAYUDU, 2014).

As baterias de lítio íon possuem maior eficiência energética do que as baterias a base de chumbo e de níquel (COELHO, 2011; KHALIGH; LI, 2010), com menos perdas ôhmicas e perdas advindas de outros fenômenos de transporte. Devido a essas características, essas baterias têm sido usadas frequentemente em aplicações modernas.

A principal desvantagem dessa bateria é possuir um custo de produção maior do que os outros tipos de baterias, devido principalmente à baixa disponibilidade dos materiais que a constituem (POLLET; STAFFEL; SHANG, 2012; TIE; TAN, 2013).

Existem diversos tipos de baterias de lítio, sendo que as baterias de metal de lítio são, em 2020, as mais caras, mas, entretanto, as menos seguras. Dentre as baterias de lítio, as baterias de enxofre de lítio são as que possuem maior capacidade de energia com um menor peso, porém possuem um ciclo de vida menor. As baterias de titanato de lítio possuem a vantagem de serem mais velozes na carga. Já as baterias de polímero de lítio possuem maior confiabilidade e robustez, porém possuem uma condutividade ruim e uma baixa densidade de potência. Para uma alta densidade de potência e uma alta corrente de descarga, as baterias de lítio fosfato de ferro são as mais indicadas, uma vez que também possuem uma maior estabilidade térmica e química, tornando-a bastante segura (TIE; TAN, 2013). Devido a essas características, as baterias de lítio são utilizadas em diversos equipamentos, desde smartphones, notebooks, ferramentas elétricas e dispositivos eletroportáteis, até aplicações estáticas, como em data centers (UPS), *smart grids (energy storage)*, aplicações móveis, como em veículos autônomos, cadeiras de roda elétricas, empilhadeiras, drones, veículos elétricos, aplicações navais, aeronáuticas, etc. A Figura 2.8 apresenta algumas aplicações da bateria de lítio.



Figura 2.8 – Algumas aplicações da bateria de lítio.

Cada aplicação exige um projeto de bateria dedicado, suprimindo as necessidades de tensão terminal, corrente, potência, capacidade, taxa de carga, taxa de descarga, etc. Portanto, é essencial conhecer e entender onde a bateria será utilizada, para que ela seja projetada da melhor maneira possível.

Entretanto, independente da aplicação da bateria de lítio, é necessário utilizar um circuito eletrônico de proteção para manter sua operação segura (COELHO, 2011). As baterias de lítio devem operar em uma faixa restrita de temperatura e tensão, caso contrário, terá diminuída sua segurança, seu desempenho e confiabilidade.

Atualmente, as baterias de lítio íon comerciais são equipadas com um sistema de gerenciamento que permite um controle e uma supervisão efetiva de suas células da bateria, onde cada uma deve operar dentro de condições adequadas (LU et al., 2013). Nesse contexto, o sistema de gerenciamento da bateria (BMS), principalmente com foco nas baterias LiFePO₄, será detalhado na próxima seção.

2.3 SISTEMA DE GERENCIAMENTO DA BATERIA

O sistema de gerenciamento da bateria é um dos sistemas mais importantes em aplicações com baterias de lítio. Ele protege o conjunto de danos e aumenta a vida útil de todo o sistema e de suas partes integrantes (DAOWD et al., 2011).

As baterias são dispositivos eletroquímicos peculiares, com um comportamento não linear distinto, que depende de várias condições internas e externas. Por esta razão, seu monitoramento é complexo, agravado durante sua vida útil por constantes mudanças em suas partes integrantes. A principal função do sistema de gerenciamento da bateria é realizar um monitoramento preciso e confiável deste conjunto. Essa função permite a operação segura e confiável de suas partes integrantes e, conseqüentemente, da aplicação total onde a bateria está instalada (WAAG; FLEISCHER; SAUER, 2014).

As baterias são constituídas de *packs*, cada *pack* contém vários módulos, cada um com várias células. A quantidade de *packs* é definida de acordo com a necessidade de cada aplicação. Geralmente, o sistema de bateria de veículos elétricos possui centenas ou milhares de células, e o controle de todas, ou de grupos de células, deve ser realizado pelo *battery management system*, ou BMS (LU et al., 2013).

O BMS é qualquer sistema que gerencia uma bateria. Ele pode ser eletrônico, mecânico ou um outro dispositivo tecnológico. Esse sistema é constituído de diferentes sensores, atuadores, controladores e algoritmos, que monitoram, ajustam, protegem, e detectam os parâmetros da bateria, estimando seus estados operativos, reportando dados para outros sistemas, realizando o balanceando das células, etc. (LU et al., 2013). Entretanto, muitos dos estados que devem ser monitorados não podem ser diretamente medidos.

Devido a isso, algoritmos especiais para o monitoramento da bateria são necessários. O algoritmo de monitoramento da bateria deve considerar as características da mesma. O desafio é que as características da bateria dependem, além de seu cenário de aplicação, significativamente das condições internas e

externas a que está submetida. Ainda, quase todas as características da bateria, incluindo, a capacidade e a impedância, mudam significativamente durante sua vida útil devido ao envelhecimento. O algoritmo de monitoramento também deve levar em conta a curva de capacidade da bateria, que impõe fortes limitações ao seu uso, de acordo com as condições em que ela está operando em cada instante.

Essa curva deve ser desenvolvida de acordo com a área segura de operação de uma bateria e é formada pelos seguintes limites principais, que também apresentam correlações entre si:

- Máxima corrente de descarga;
- Máxima corrente de carga;
- Máxima tensão das células;
- Mínima tensão das células;
- Temperatura máxima, e;
- Temperatura mínima.

Por exemplo, a máxima corrente de carga depende da temperatura. Esta corrente deve ser menor em temperaturas muito baixas, para prevenir o depósito de íons de lítio no anodo na forma de lítio metálico (WAAG; FLEISCHER; SAUER, 2014).

As principais funções do BMS são: proteger as células e os *packs* da bateria de serem danificados; garantir que a bateria opere dentro da tensão e temperatura adequadas, garantindo segurança e prolongando o tempo de vida da bateria; e mantendo-a operando em condições que possam suprir as necessidades do veículo (LU et al., 2013).

Os algoritmos que implementam as funcionalidades do BMS são executados em microcontroladores, onde a capacidade computacional e a memória disponível devem ser consideradas nos requisitos de seu *hardware* (WAAG; FLEISCHER; SAUER, 2014). Um exemplo das características de um *hardware* de um BMS são mostradas na Figura 2.9

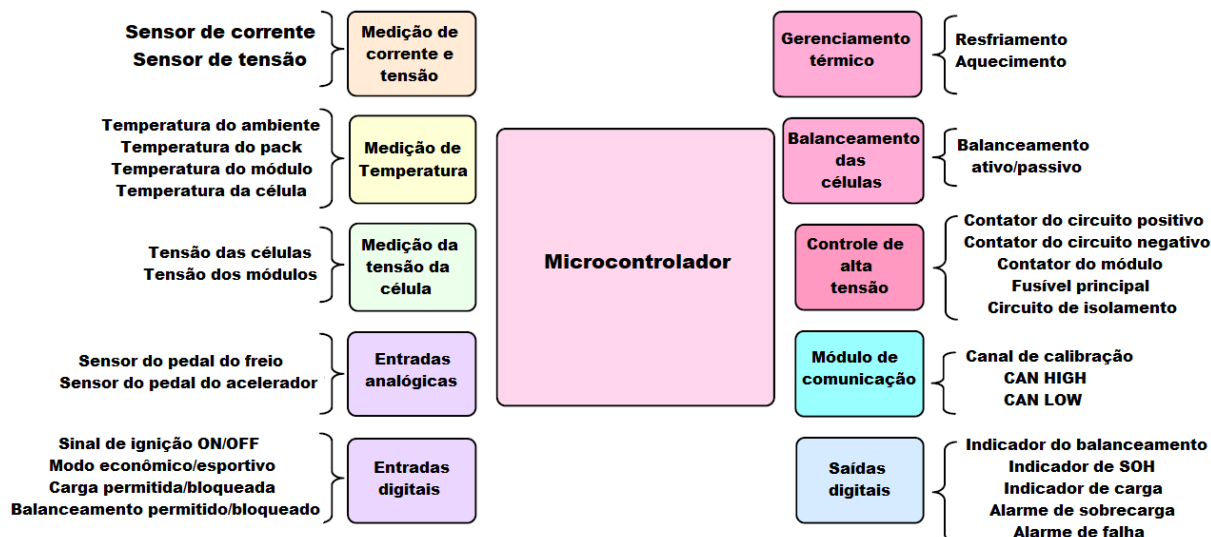


Figura 2.9 – *Hardware* básico do BMS.

Fonte: (adaptado de LU et al., 2013).

Conforme mostra a Figura 2.9, o *hardware* do BMS deve ser desenvolvido conforme as necessidades de cada aplicação, mas pode possuir entradas, circuitos e módulos (LU et al., 2013) diversos, tais como:

- Para medição de corrente e tensão;
- Para medição de sensores de temperatura em cada célula, no pack, nos módulos, no ambiente e, dependendo da aplicação, sensores de temperatura ligados ao sistema de resfriamento do conjunto da bateria;
- De entradas analógicas, para aferir as solicitações do sensor do pedal acelerador, do freio, etc.;
- De entradas digitais, para intertravar a operação com o sinal do sistema de ignição e marcha do veículo, etc.;
- Elementos comutadores (interruptores, chaves, e estados de contadores), para permitir ou bloquear a carga e a descarga da bateria.

Ainda, a Figura 2.9 mostra que o *hardware* do BMS pode possuir como saídas vários tipos de circuitos e módulos, tais como:

- De gerenciamento térmico, para acionamento de ventoinhas e aquecedores elétricos, para realizar o resfriamento e aquecimento das células;
- De comandos para balanceamento das células, com capacitores, transistores e resistências dissipadoras, para realizar sua equalização;
- De gerenciamento de segurança da tensão das células;
- Com saídas analógicas e digitais gerais, como para indicadores de carga, erros, alarmes, etc.;
- De comunicação, para se integrar corretamente com outros módulos eletrônicos de controle e automação do veículo (LU et al., 2013).

Desta forma, em seus algoritmos o BMS realiza várias tarefas, como medir a tensão do sistema, a corrente, a temperatura, estimar o estado da carga das células, estimar o estado de saúde, determinar a vida útil restante, proteger as células, realizar o gerenciamento térmico, controlar a carga / descarga, realizar o diagnóstico das falhas, fazer a comunicação com outros módulos e realizar o balanceamento de células (DAOWD et al., 2011). Todas essas tarefas em conjunto resultam num algoritmo complexo com um estrito compromisso entre robustez, precisão, adaptabilidade e aplicabilidade, programado em *hardware* embarcado, com baixo custo e alta eficiência energética (WAAG; FLEISCHER; SAUER, 2014).

Além de medir a temperatura da bateria, estimar a capacidade e a impedância, o BMS pode possuir recursos para detecção de fumaça, falhas de isolamento, detecção de colisões e impactos mecânicos, sistemas de prevenção e proteção contra sobre carga, sobre descarga, sobre corrente e curto-circuito. Em geral, para isso o BMS deve detectar a tensão total e a corrente total da bateria, além da tensão individual de cada célula (LU et al., 2013).

A seguir serão detalhadas diversas características e desafios para a medição correta desses sinais, parâmetros e para o estabelecimento dessas funcionalidades.

2.3.1 Tensão

Para medir a tensão das células de uma bateria é importante ressaltar que, na maioria das aplicações modernas, um *pack* possui dezenas de células associadas em série, para constituir o nível de tensão desejado para a aplicação. Assim, o BMS deve possuir diversos canais analógicos individuais de medição, conectados a um microcontrolador, através de um conversor analógico digital (AD) multiplexado ou com vários conversores AD individuais. A rigor, essa medição deve ser realizada de forma diferencial, para que seja possível aferir a tensão de cada célula ao longo do arranjo em série do *pack*. Outros arranjos também são possíveis, mas como a tensão se acumula no arranjo série, e o potencial distribuído ao longo das células pode ser diferente, torna-se complexo obter uma medição simples e única e utilizar métodos de eliminação para medir essas tensões individuais (LU et al., 2013).

A estratégia mais comum para a medição da tensão das células é utilizar um amplificador diferencial conectado em cada parte do arranjo série. A medição da tensão das células deve possuir alta exatidão, preferencialmente com resolução em torno de 1mV. Pelo acúmulo de tensão ao longo do arranjo série, podendo chegar a centenas de Volts, por questões de segurança e compatibilidade eletromagnética, as células devem estar eletricamente isoladas do restante do sistema do microcontrolador. Esse isolamento galvânico pode ser realizado por reles, opto-acopladores, amplificadores isolados, transformadores ou capacitores, ou através de barramentos de comunicação isolados entre vários módulos individuais (SINGH; KHURANA; JAIN, 2015). A escolha do melhor componente para o isolamento dos circuitos depende de alguns fatores, que são determinados pelos requisitos do projeto, como custo, precisão, estabilidade, tamanho, velocidade de resposta etc.

2.3.2 Impedância

Um dos principais motivos para estimar a impedância da bateria, é determinar a potência disponível na mesma. Em aplicações em que a potência disponível é o parâmetro mais importante, como nos veículos híbridos por exemplo, o fim da vida

útil da bateria naquela aplicação é estabelecido quando esta impedância tem seu valor duplicado (FARMANN et al., 2015).

A impedância de uma bateria nova é definida pelo seu *design*. Entretanto, seu valor muda significativamente, durante a vida útil da bateria, devido a um processo de envelhecimento (WAAG; FLEISCHER; SAUER, 2014). De um ponto de vista eletroquímico, o aumento da impedância nas baterias de lítio íon deve-se principalmente às reações secundárias que ocorrem no anodo (FARMANN et al., 2015). O conhecimento da impedância atual da bateria é geralmente adquirido estimando-se as perdas de energia durante sua operação. A impedância deve ser determinada com muita exatidão, incluindo sua relação com a corrente da bateria (WAAG; FLEISCHER; SAUER, 2014), uma vez que não possui um comportamento linear.

2.3.3 Capacidade

A capacidade nominal de uma bateria, em ampere-hora (Ah), é uma grandeza que corresponde à quantidade de carga possível de extrair da bateria até que uma tensão de descarga limite seja atingida, começando com a bateria totalmente carregada. A capacidade não é um parâmetro constante, e diminui durante a vida útil da bateria devido ao processo interno de envelhecimento, após serem realizados vários ciclos de carga e descarga, ou mesmo quando a bateria fica por longos períodos sem ser utilizada. De um ponto de vista eletroquímico, a perda da capacidade das baterias de lítio íon geralmente ocorre devido à diminuição da quantidade de ciclos possíveis do lítio, devido às conexões eletrolíticas sólidas que são formadas. Além disso, os processos de envelhecimento devido, ao aumento da resistência interna da célula também podem levar à perda de capacidade (FARMANN et al., 2015). O aumento da resistência interna pode ser gerado através da perda de contato dentro do eletrodo. Uma fonte inevitável de perda de contato são as mudanças de volume do material do anodo, que podem levar à desintegração mecânica dentro do eletrodo. Nesse caso, a perda de contato pode ser gerada entre as partículas de carbono, entre o coletor de corrente e o carbono,

entre o aglutinante (*binder*) e o carbono e entre o aglutinante e o coletor de corrente (VETTER et al., 2005).

A capacidade inicial se refere à maior quantidade de carga que pode ser extraída de uma bateria nova, começando com a bateria totalmente carregada. Já a capacidade atual da bateria é a maior quantidade de carga que pode ser extraída da mesma em seu estado atual, começando com a bateria totalmente carregada. Ou seja, quando a bateria é nova, sua capacidade inicial é a mesma da capacidade atual e, quando a bateria envelhece, a diferença entre as duas capacidades é a medida da perda da capacidade devido aos efeitos do envelhecimento (FARMANN et al., 2015).

A partir da medição da tensão, da corrente e da temperatura de uma bateria, é possível determinar sua capacidade e impedância, que são parâmetros importantes para estimar os demais estados da bateria. Os principais estados da bateria são: estado da carga (SOC); estado de funcionalidade (SOF – *State of Function*); e estado de saúde (SOH – *State of Health*). A Figura 2.10 ilustra essa relação.

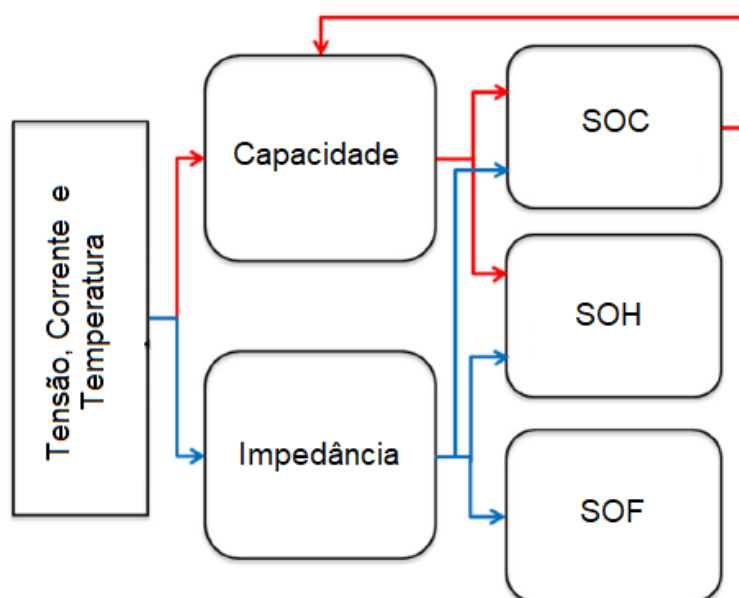


Figura 2.10 - Estrutura integrada da capacidade e da impedância em um BMS.

Fonte: (adaptado de FARMANN et al., 2015).

O estado da carga tem uma analogia semelhante ao indicador de combustível utilizado em veículos convencionais. O estado de funcionalidade é a capacidade da bateria de realizar as tarefas impostas pelas aplicações. O estado de saúde pode ser determinado como a condição atual da bateria, comparada com sua condição ideal ou original. Esses estados são comentados em detalhes adiante.

2.3.4 Estado da carga (SOC)

O SOC é basicamente uma relação entre a capacidade residual da bateria no estado presente e a capacidade total depois de totalmente carregada. Geralmente o SOC é representado em porcentagem, em que 100% significa um sistema totalmente carregado e 0% significa totalmente descarregado (LU et al., 2013). A forma de utilização do estado da carga também é capaz de influenciar no envelhecimento da bateria. Através do uso da bateria em uma determinada faixa de SOC, limitando seu uso entre 10% e 90% de SOC, é possível prevenir um envelhecimento excessivo da bateria (WAAG; FLEISCHER; SAUER, 2014).

A rigor, o SOC seria um estado simples de ser estimado se existisse um dispositivo de balanceamento das células ideal, sem perda e totalmente eficiente. Nestas condições, o SOC seria estimado pela Eq. 10.

$$SOC_M = \frac{\sum SOC_i C_i}{\sum C_i} \quad (10)$$

Em que SOC_M é o SOC do módulo de bateria, o SOC_i é o SOC de cada célula da bateria e o C_i é a capacidade de cada uma.

Porém, até o momento, não existem dispositivos de balanceamento tão eficientes, logo, o SOC real do módulo de bateria está relacionado com o desempenho real deste dispositivo. Uma vez que existem variações entre as capacidades individuais das células do módulo de bateria, sem um dispositivo de balanceamento, alguma perda na capacidade, em alguma célula, deve ocorrer, e não poderá ser reutilizada, conforme mostra a Figura 2.11.

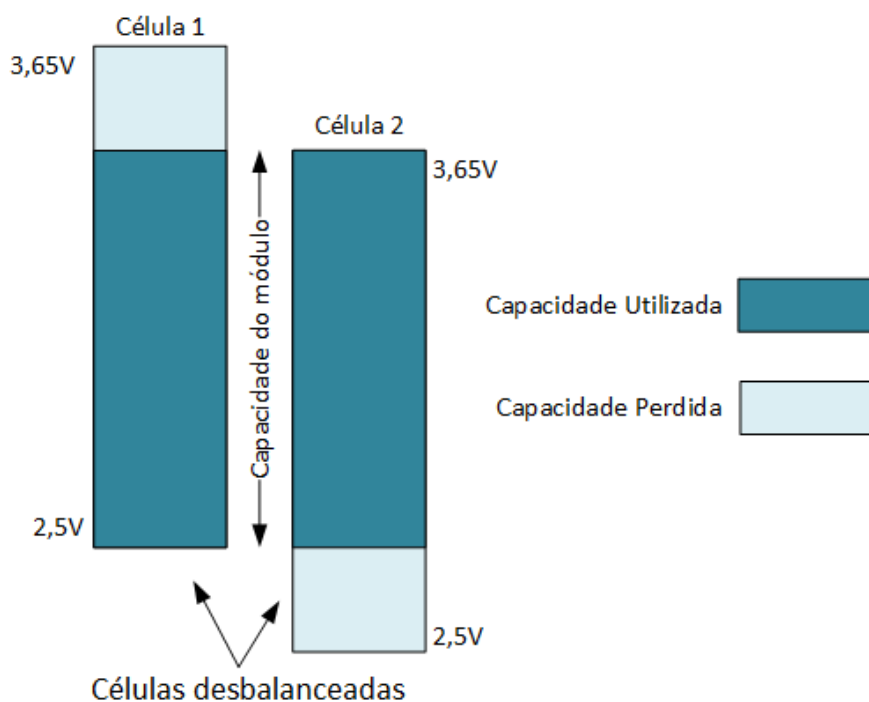


Figura 2.11 - A perda de capacidade e a capacidade remanescente do módulo da bateria.

Fonte: (adaptado de LU et al., 2013)

Analisando a Figura 2.11, é possível observar visualmente a diferença na distribuição de cargas entre duas células, onde a célula 1 pode descarregar até um certo limite inferior de tensão, enquanto que a célula 2 pode ser carregada até um dado limite de tensão superior. Nessa condição, numa descarga a célula 1 chegará antes da célula 2 a uma tensão interna de 2,5V, ou numa carga a célula 2 chegará antes da célula 1 a uma tensão interna de 3,65V. Nesse caso, as duas células se encontram desbalanceadas e a capacidade do conjunto é menor do que a capacidade disponível de cada uma. Devido a isso, é um desafio estimar o SOC da bateria por completo.

Existem diversas formas para se estimar o SOC em um laboratório de eletroquímica, por exemplo. Mas nenhum desses métodos estimam o SOC de baterias comerciais sem destruir a mesma ou interromper seu fornecimento ou o recebimento de energia (LU et al., 2013). Há muitas abordagens para a determinação do estado da carga na literatura, as abordagens mais comuns são baseadas em grandezas, modelos e lógicas, como mostrado na Figura 2.12. Alguns

desses meios de medição do SOC serão detalhados adiante (WAAG; FLEISCHER; SAUER, 2014).

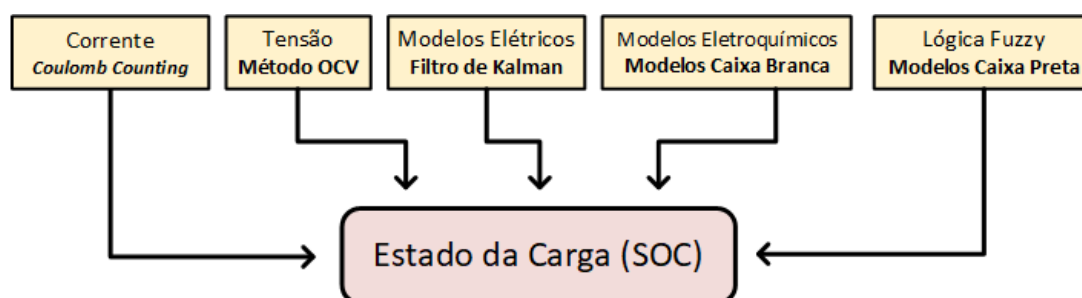


Figura 2.12 - Métodos para estimar o estado da carga da bateria.

2.3.4.1 Método da corrente ou de contagem de coulomb

O método do *coulomb counting* é mais simples e geral para estimar o SOC da célula. Quando a capacidade da bateria é conhecida e sua corrente pode ser medida precisamente, esse método permite cálculos precisos das mudanças do SOC ao longo de sua vida útil. Esse método é representado pela Eq. 11.

$$SOC = SOC_0 - \frac{1}{C_N} \int_{t_0}^t \eta I. d\tau \quad (11)$$

Onde SOC_0 representa o SOC no tempo inicial t_0 , C_N representa a capacidade nominal, I representa a corrente, admitindo-a negativa durante a carga e positiva durante a descarga e η representa a eficiência de coulomb. A eficiência de coulomb é a razão entre a capacidade de descarga e a capacidade de carga do mesmo ciclo. Seu valor é geralmente menor do que 1. Isso ocorre porque a resistência interna da bateria por si só, consome alguma energia elétrica então o total de energia elétrica descarregada é sempre menor do que o total de energia elétrica carregada (WANG et al., 2021).

Além da necessidade de se conhecer o SOC inicial, nesse método, quando a contagem de Coulomb é realizada por um longo tempo, os erros de medição na

corrente, acumulados, podem resultar em uma fonte significativa de imprecisão, e uma calibração adicional se faz necessária (WAAG; FLEISCHER; SAUER, 2014).

Os resultados desse método possuem uma exatidão satisfatória somente por um período, que ainda é relacionado com a precisão da amostragem (resolução e taxa) e da resposta em frequência do sensor de corrente utilizado no BMS (LU et al., 2013). Esse método é bastante utilizado devido ao baixo custo dos sensores de corrente (resistor shunt, efeito hall, etc.), ao baixo requisito computacional (se trata de um mero acumulador/integral), e à possibilidade de poder ser combinado com outros métodos (WAAG; FLEISCHER; SAUER, 2014).

Entretanto, possui as seguintes desvantagens: a exatidão do SOC inicial possui influência na exatidão do SOC instantâneo; o método não é capaz de estimar o SOC inicial automaticamente; e a precisão e grau de exatidão do sensor de corrente, que resulta nos erros na precisão do SOC comentados anteriormente. Portanto, os resultados da estimativa do SOC utilizando apenas o método de contagem de Coulomb não satisfazem os requisitos de precisão desejados para um BMS moderno (LU et al., 2013).

2.3.4.2 Método da tensão de circuito aberto

O SOC está relacionado à termodinâmica estática e à quantidade de íons de lítio presente no material ativo. Logo, a tensão de circuito aberto, ou OCV – *open circuit voltage*, (depois de um tempo adequado de descanso da bateria, que deve ser considerado para que a bateria alcance um potencial equilibrado) é um método efetivo para estimar o SOC, uma vez que existe uma correspondência praticamente direta entre a medida OCV e SOC. Ainda, essa relação muda tão lentamente durante a vida útil da bateria, que pode ser ignorada (LU et al., 2013) (WAAG; FLEISCHER; SAUER, 2014).

A grande vantagem do método de circuito aberto é sua alta precisão, porém, a grande desvantagem é que a bateria precisa ter um longo tempo de descanso antes de sua medição. Além disso, o tempo para a bateria se recuperar de um estado de

operação para um estado balanceado está relacionado com o estado do SOC, com a temperatura etc. A bateria de lítio fosfato de ferro, por exemplo, geralmente leva mais de três horas, em baixas temperaturas, para atingir um potencial balanceado. Devido a isso, esse método, se utilizado sozinho, é útil e prático somente quando é possível deixar a bateria sem utilização por algum tempo (LU et al., 2013), da ordem de dezenas a centenas de minutos.

O OCV está ainda relacionado com o histórico de carga e descarga da bateria e, por essa razão, deve ser estimado com cuidado. Também se sabe experimentalmente que o OCV na carga é diferente do OCV na descarga, produzindo uma pequena histerese (BARAI et al., 2015). A Figura 2.13 apresenta essa histerese para uma célula analisada experimentalmente, onde as curvas foram adquiridas em temperatura ambiente e depois de 3 horas de descanso da célula (LU et al., 2013).

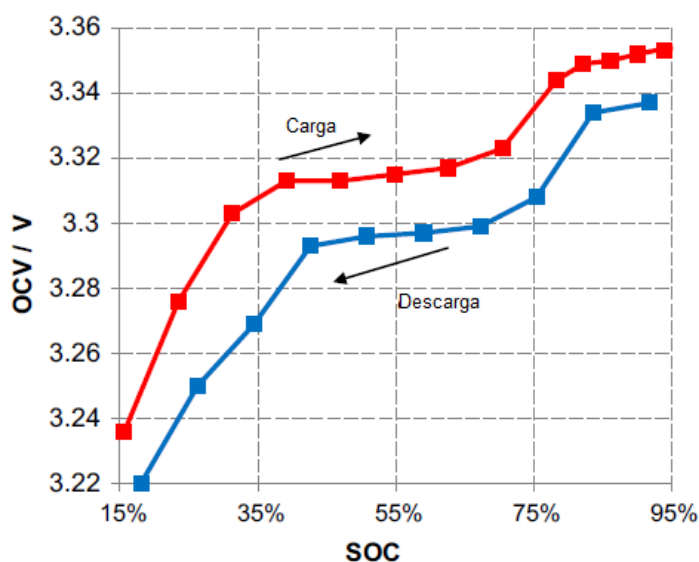


Figura 2.13 - Curva do OCV na carga e na descarga de células de lítio fosfato de ferro.

Fonte: (adaptado de LU et al., 2013)

Considerando as vantagens do método de contagem de Coulomb com o método OCV, pode ser realizada uma combinação entre eles levando a uma abordagem simples e precisa para se estimar o SOC de baterias de lítio íon (WAAG; FLEISCHER; SAUER, 2014).

2.3.4.3 Métodos com modelos e filtro de Kalman

O método de estimação do estado da carga da bateria através de um filtro de Kalman é um dos métodos mais utilizados atualmente, devido à sua precisão e capacidade de implementação em ambiente microprocessado embarcado. Ainda, o algoritmo do filtro de Kalman para estimação do estado da carga pode incluir o método de contagem de Coulomb e o método OCV em sua estrutura, tornando-se muito eficiente para estimar o SOC da bateria. Trata-se de um método que necessita de algum conhecimento do modelo dinâmico do sistema, fazendo uso de estimadores, mas que possui muitos desafios para se incorporar os efeitos das não linearidades e outros fenômenos, assim como para identificar e classificar os parâmetros dos seus modelos constituintes. A metodologia para se projetar e aplicar na prática, com sucesso, um filtro de Kalman em um BMS é apresentado no Capítulo 3 desse trabalho. Os fundamentos da técnica são mostrados com alguns detalhes a seguir.

O conceito de filtro, como instrumento capaz de remover informações ou medidas indesejadas num processo, foi muito utilizado em 1930 e 1940 para a separação de “sinais” de “ruídos”. Num filtro, um sinal e seu ruído (com ambos caracterizados por sua densidade de potência espectral), são submetidos a um processo em que se deseja maximizar a energia do sinal, enquanto se deprecia ou atenua a energia do ruído. Kolmogorov e Wiener utilizaram uma caracterização estatística para as distribuições probabilísticas do sinal e de seu ruído para formação de um estimador ótimo de sinal (MOHINDER; ANGUS, 2008).

Com o filtro de Kalman, o termo “filtro” assumiu um significado muito além da ideia original de separação ou remoção de componentes indesejados. A técnica também vem para incluir a solução de um problema de inversão, no qual ele representa as próprias variáveis medidas como funções das variáveis de interesse principal. Em sua essência, ele altera a relação funcional e estima as variáveis independentes como funções invertidas das variáveis dependentes (medidas). Essas variáveis de interesse também podem ter comportamentos dinâmicos próprios, que também não precisam ser totalmente conhecidos (MOHINDER; ANGUS, 2008).

O modelo de espaço de estados de um sistema dinâmico utiliza equações diferenciais para representar fenômenos determinísticos, mas também aleatórios. As variáveis de estado desse modelo são as variáveis de interesse e suas derivadas. Processos aleatórios são caracterizados em termos de suas propriedades estatísticas no domínio do tempo, ao invés de uma descrição estrita no domínio da frequência. O filtro de Kalman foi apresentado como uma solução para o problema do filtro de Wiener, utilizando modelos de espaço de estados para processos dinâmicos e aleatórios. O resultado é mais prático e fácil de utilizar do que o Filtro ótimo de Wiener-Kolmogorov proposto originalmente (MOHINDER; ANGUS, 2008).

Para que se conheça detalhadamente todos os fundamentos do filtro de Kalman, é necessário entender sobre diversos assuntos, a Figura 2.14 apresenta os assuntos essenciais para subsidiar toda a teoria. Os livros de (MOHINDER; ANGUS, 2008) e (MAYBECK, 1979) apresentam detalhes sobre esses tópicos.



Figura 2.14 - Conceitos fundamentais do filtro de Kalman.

Fonte: (Adaptado de MOHINDER; ANGUS, 2008).

Na teoria, o filtro de Kalman é um estimador para o que é chamado de problema quadrático linear. Neste problema deseja-se estimar o “estado” instantâneo de um sistema dinâmico linear, quando perturbado por um ruído branco, utilizando medidas linearmente relacionadas com esse estado, mas corrompidas por esse mesmo ruído. O estimador resultante é estatisticamente ótimo com respeito a qualquer função quadrática de estimação de erro. Portanto, o filtro de Kalman

também pode ser definido como um algoritmo de processamento de dados ótimo, mas recursivo. A palavra “recursivo” significa que, diferentemente de certos conceitos de processamento de dados, o filtro de Kalman não necessita de grandes quantidades de dados anteriores armazenados para serem reprocessados, toda vez que uma nova medida é adquirida, mas sim de um conjunto menor de dados e sua tendência naquele momento. Existem diferentes formas de definir “ótimo”, dependendo do critério escolhido para se avaliar um desempenho de sistema. Mas um aspecto da otimização é que o filtro de Kalman processa todas as medidas disponíveis, independente da sua precisão, para estimar o valor atual das variáveis de interesse, com o uso de três itens (MAYBECK, 1979; MOHINDER; ANGUS, 2008):

- Conhecimento do sistema e da dinâmica do dispositivo de medição;
- Descrição estatística do sistema de ruído;
- Qualquer informação disponível sobre as condições iniciais das variáveis de interesse.

Por exemplo, para se determinar a velocidade de um avião, pode ser utilizado um radar *Doppler*, ou a indicação de velocidade do sistema de navegação inercial, ou a medida de pressão em um tubo *Pitot*; ou informações relativas do vento e da pressão no sistema de dados do ar. Ao invés de ignorar ou comutar entre uma ou outra dessas informações, um filtro de Kalman pode ser construído para combinar todos esses dados, e o conhecimento dos vários sistemas dinâmicos associados, para gerar uma melhor estimativa geral de velocidade (MAYBECK, 1979).

O primeiro método para formalizar um estimador ótimo a partir de dados ruidosos é o método dos mínimos quadrados. Seu fundamento matemático foi desenvolvido por Carl Friedrich Gauss em 1795. A inevitabilidade de erros de medição é reconhecida desde o tempo de Galileo Galilei, mas esse foi o primeiro método formal para lidar com essa questão. Desde então, toda a teoria relacionada ao filtro de Kalman é baseada em diversas contribuições científicas no decorrer da história, com as principais personalidades apresentadas na Figura 2.15. Outras contribuições recentes e seus detalhes são apresentados no livro de (MOHINDER; ANGUS, 2008).




Figura 2.15 - Linha do tempo das referências científicas da teoria do filtro de Kalman.

Fonte: (MOHINDER; ANGUS, 2008).

Em um contexto mais estrito, o filtro de Kalman pode ser compreendido como um processo de aprendizagem que utiliza um modelo de problema de estimação, que distingue entre o que é capaz de ser observado, com o que realmente está acontecendo. Nesse “processo de aprendizagem”, o estado de conhecimento sobre o que realmente está acontecendo pode ser deduzido a partir do que é capaz de ser observado. Esse estado de conhecimento é caracterizado por distribuições probabilísticas, que representam um conhecimento do mundo real, enquanto o processamento acumulativo desse conhecimento é o processo de aprendizagem (MOHINDER; ANGUS, 2008).

De uma forma simples e prática, a Figura 2.16 apresenta o fluxograma de processamento de um algoritmo de filtro de Kalman, onde o erro original da estimativa e a estimativa original, são informações iniciais fornecidas ao algoritmo, destacadas em vermelho. A entrada de dados é o sinal medido por um sensor, destacado em azul. O erro na medida é um parâmetro de ajuste do filtro que pode ser, por exemplo, relacionado com a imprecisão do circuito e do sensor responsável por sua medição, ou o próprio ruído observado no sinal medido. A estimativa

atualizada é o resultado do algoritmo, destacado em verde. O processo iterativo envolve a execução contínua das etapas (1), (2) e (3).

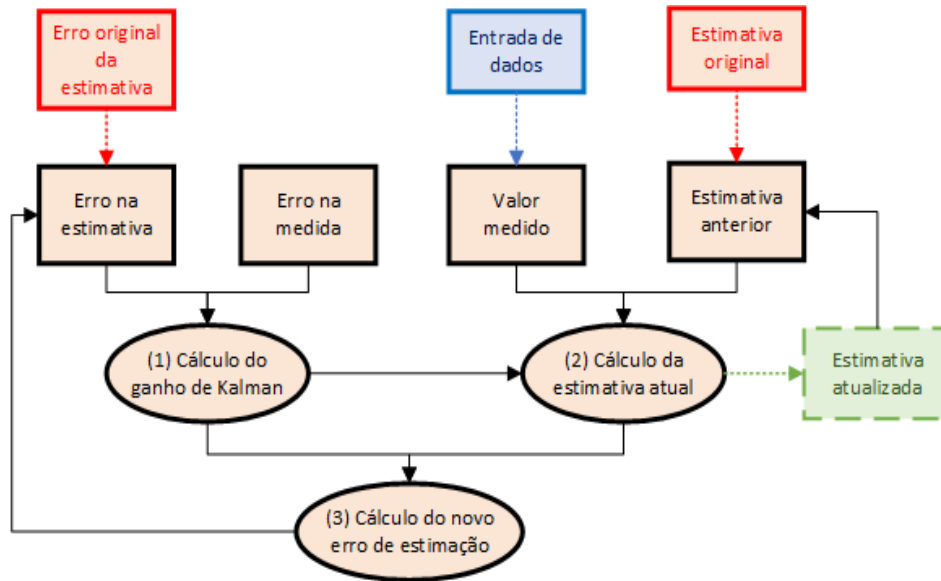


Figura 2.16 - Fluxograma do filtro de Kalman.

Fonte: (Adaptado de KHAN; BUGTI; BUGTI, 2018).

Nesse processo, em (1) o cálculo do ganho de Kalman pode ser realizado conforme a Eq. 12.

$$GK = \frac{E_{est}}{E_{est} + E_{me}} \quad (12)$$

onde: E_{est} é o erro de estimação e E_{me} é o erro de medição.

Na Figura 2.16, em (2) o cálculo da estimativa atual é realizado conforme Eq. 13.

$$EST_t = EST_{t-1} + GK * (ME - EST_{t-1}) \quad (13)$$

onde: EST_{t-1} é a estimativa anterior e ME é o valor medido.

Na etapa (3) da Figura 2.16, o cálculo do novo erro de estimação é realizado conforme a Eq. 14.

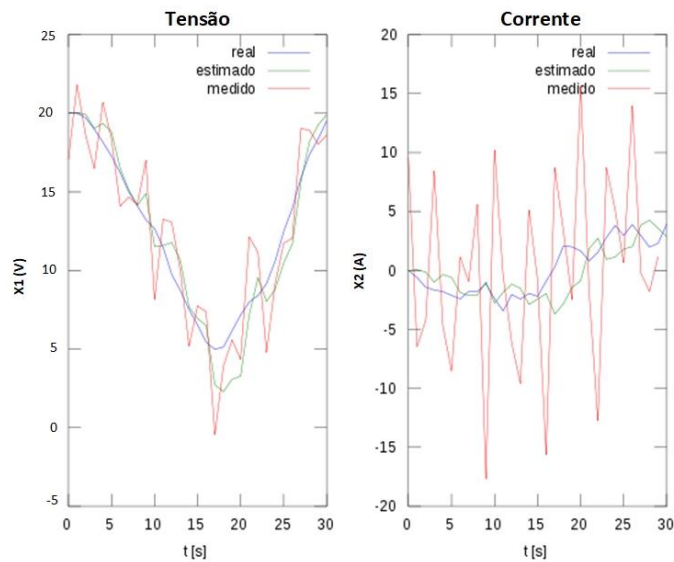


Figura 2.18 - Exemplo de resultado do filtro de Kalman.

Para que o filtro de Kalman possa ser realizado computacionalmente, e com diferentes variáveis de estado, é necessário representar o sistema dinâmico matricialmente na forma de espaço de estado, conforme Eq. 15 e 16.

$$x_k = Ax_{k-1} + Bu_k \quad (15)$$

$$y_k = Cx_k + Du_k \quad (16)$$

onde: x_k é o vetor de estados, A é a matriz de estados, u_k é o vetor das entradas, y_k é o vetor das saídas, B é a matriz das entradas, C é a matriz das saídas e D é a matriz de transmissão direta.

Dessa forma, é possível representar um sistema dinâmico linear matematicamente, e comparar sua saída estimada com uma saída medida desse sistema, para então estimar seu estado conforme apresenta a Figura 2.19. Nessa figura, u_k representa a entrada do sistema (corrente aplicada na bateria), x_k representa o estado real (SOC real da bateria), \hat{x}_k representa o estado estimado (SOC estimado pelo modelo), y_k representa a saída real (tensão total real da

bateria) e \hat{y}_k representa a saída estimada pelo modelo (tensão total estimada pelo modelo). Então, por meio da comparação entre a saída real (y_k) e a saída estimada (\hat{y}_k), o ganho de Kalman (K) é calculado ajustando o estado estimado (\hat{x}_k) para que a saída estimada (\hat{y}_k) seja a mais próxima possível da saída real (y_k), e conseqüentemente o estado estimado (\hat{x}_k) será o mais próximo possível do estado real (x_k). Logo, o modelo matemático deve ser o mais próximo possível do sistema real, para que seja possível ajustar o estado estimado, de forma que a saída estimada seja a mais próxima possível da saída real.

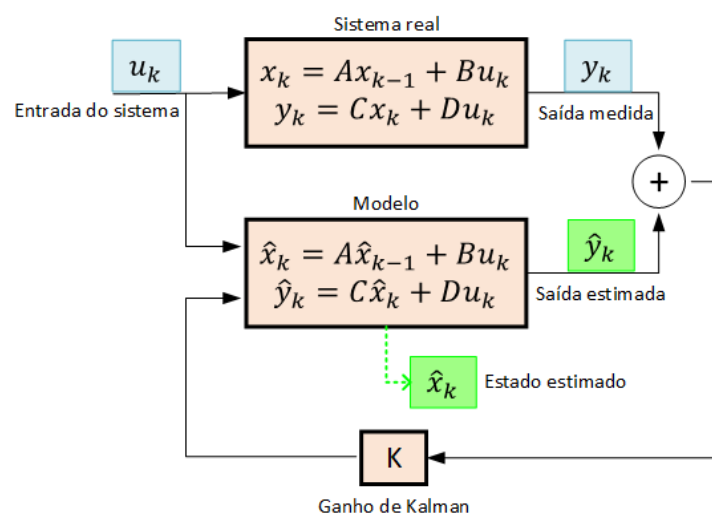


Figura 2.19 - Representação do sistema por equações de espaço de estados.

Com a representação do sistema através de equações de espaço de estados, é possível aplicar o filtro de Kalman, a sistemas com múltiplas entradas e saídas. Desse modo, baseado no diagrama apresentado na Figura 2.16, o diagrama que representa a lógica de funcionamento do Filtro para modelos multidimensionais é apresentado na Figura 2.20, onde X, P, A, B, w, Q, H, Y e z são vetores e matrizes cujas dimensões dependem da quantidade de estados sob análise.

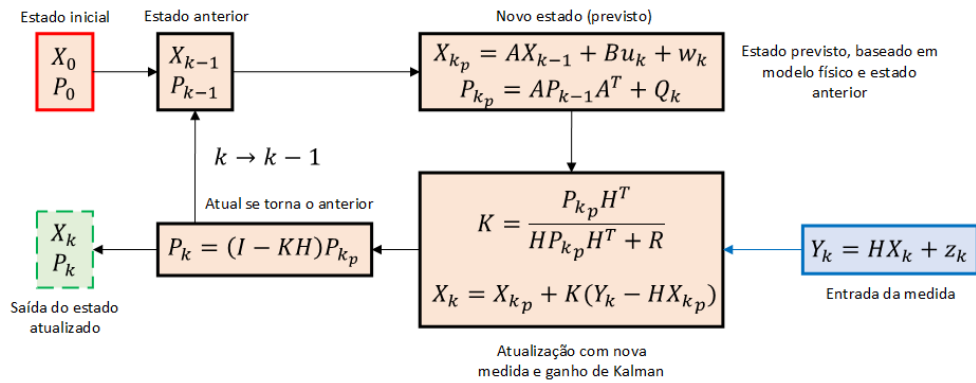


Figura 2.20 - Diagrama de blocos do filtro de Kalman para modelos multidimensionais.

Na Figura 2.20, X_0 representa um vetor com os estados iniciais, P_0 representa um vetor com as covariâncias iniciais (qualidade nas estimativas dos estados), X_{k-1} representa o vetor de estados anteriores, P_{k-1} representa a matriz de covariância anterior, X_{k_p} é um vetor dos estados estimados baseado no modelo físico e no estado anterior, A é a matriz de estados, B é a matriz de entrada, w_k é a matriz de ruído do estado previsto, P_{k_p} é a matriz da covariância estimada, baseada na covariância anterior e no ruído do processo, Q_k é a matriz de ruído do processo, K é o ganho de Kalman, baseado na covariância estimada e no ruído de medição, R é a matriz de ruído de medição, H é a matriz Jacobiana do sistema, X_k é o estado atualizado baseado no ganho de Kalman e no dado de medição, Y_k é a medida do estado, z_k é o ruído de medida, P_k é a matriz de covariância atualizada e I é a matriz identidade.

Para uma melhor compreensão da lógica do filtro de Kalman num espaço de estados, é importante conhecer alguns conceitos. Se a matriz de ruído de medição (R) for próxima de 0, então o ganho de Kalman (K) será próximo de 1. Isso significa que o estado atualizado (X_k) será ajustado primeiramente considerando a atualização dos dados de medição (Y_k). Caso contrário, o estado atualizado (X_k) será ajustado primeiramente considerando o estado previsto (X_{k_p}). Se a matriz de covariância (P_k) for próxima de 0, então a atualização do estado (X_k) será realizada por meio do estado previsto (X_{k_p}), praticamente ignorando os dados de medição (Y_k).

A primeira aplicação prática do filtro de Kalman em espaço de estados foi no projeto Apollo da NASA, para resolver o problema de controle e estimação da trajetória até a lua. Nesse projeto, entretanto, Stanley F. Schmidt desenvolveu um filtro de Kalman diferente, denominado por “Estendido”: o qual é utilizado até hoje para aplicações não lineares de tempo real, incluindo a estimação do estado da carga de baterias (COSTA, 2014). O conceito básico do filtro de Kalman estendido, é a linearização de funções não lineares, obtidas a partir de suas representações como expansões em séries de Taylor de ordem adequada.

Segundo (MOHINDER; ANGUS, 2008), na prática, o filtro de Kalman é certamente uma das maiores descobertas na história da teoria da estimação estatística e possivelmente a maior descoberta do século 20. Para controlar um sistema dinâmico, nem sempre é possível ou desejável medir todas as variáveis que se deseja controlar, e o filtro de Kalman fornece um meio de inferir a informação faltante a partir de medições (e ruídos) indiretamente. O filtro de Kalman pode ser utilizado para prever o futuro curso de sistemas dinâmicos, nos quais as pessoas não são capazes de controlar, como o fluxo dos rios durante uma tempestade, a trajetória de corpos celestes, ou até mesmo os preços de *commodities* (MOHINDER; ANGUS, 2008).

Como visto na literatura, o filtro de Kalman é comumente aplicado para estimar o estado da carga da bateria (COSTA, 2014; JOKIE; ZARKO; BOZO, 2018; PENG; LUO; HE; LU, 2019; SHI et al., 2021), pois através de um modelo matemático, é possível comparar a tensão da bateria estimada com a tensão da bateria realmente medida. E seguindo o fluxograma apresentado na Figura 2.16 e na Figura 2.20 é possível estimar o estado da carga da bateria sem realizar medições diretas em relação aos estados eletroquímicos da mesma. Além disso, apesar de envolver cálculos matriciais, dependendo da ordem do modelo, a implementação do filtro é viável e computacionalmente possível. Dessa forma, o filtro de Kalman pode resultar em uma boa exatidão e um bom desempenho quando usado nos sistemas eletrônicos embarcados de um BMS. Entretanto, sua aplicação requer modificações por conta das não linearidades (como o uso das técnicas do filtro estendido), além de procedimentos para inferência (identificação), parametrização e ajuste dos

modelos, covariâncias e estimativas iniciais, que são comentados adiante neste trabalho.

2.3.4.4 Métodos utilizando redes neurais e lógica *fuzzy*

O método com redes neurais estima o SOC de uma bateria através do mapeamento das características não lineares da tensão, corrente e temperatura (correlacionadas com o SOC) por meio de redes neurais artificiais. Quando construído, o método usando rede neural não leva em conta, diretamente, os detalhes intrínsecos da bateria, e possui universalidade, apropriada para a estimativa do SOC de qualquer tipo de bateria. Entretanto, muitas informações e amostras de dados são necessárias para o processo de treinamento da rede. Além disso, o SOC estimado pode ser influenciado pelos próprios dados e métodos de treinamento. Esses métodos com redes neurais podem ser divididos em três grupos: método de estimação direta do SOC com redes neurais artificiais; método baseado em redes neurais artificiais com tensão estimada combinada com um controlador ou filtro de Kalman; e redes neurais artificiais com correção pelo método *coulomb counting* (WAAG; FLEISCHER; SAUER, 2014). Todos esses métodos requerem muita computação, tanto durante o processo de treinamento e avaliação da rede, como em sua implementação para computação em tempo real, necessitando de microcontroladores com elevada capacidade de processamento, com aritmética de ponto flutuante (LU et al., 2013).

O método utilizando lógica *fuzzy* estima o SOC com base numa lógica que emula o processo do pensamento, análise e tomada de decisão dos seres humanos, utilizando ponderações, distribuições de pertinência e classificações das variáveis envolvidas, com regras pré-definidas. Esse método requer um entendimento básico das baterias e de seus processos internos, no estabelecimento das variáveis difusas e suas classificações, e utiliza um grande número de curvas e dados de testes e experimentos. Por esses motivos, a lógica é difícil de ser ajustada, e ainda requer uma computação relativamente elevada no seu processamento em tempo real (LU et al., 2013). A lógica *fuzzy* pode ser usada como uma extensão de outros métodos

para estimar o SOC, e também pode ser utilizada para relacionar o SOC, com outros parâmetros da bateria, como impedância, corrente, tensão e temperatura (WAAG; FLEISCHER; SAUER, 2014).

2.3.4.5 Outros métodos

Existem diversos outros métodos para estimação do SOC da bateria, como por exemplo, os métodos baseados na impedância e na resistência interna da célula. Entretanto, as relações da impedância e da resistência da bateria com os parâmetros do SOC não são lineares e mudam significativamente durante sua vida útil.

Por exemplo, no método da impedância, uma série de ondas senoidais, com amplitudes pequenas e diferentes frequências, devem ser aplicadas na bateria. Mede-se então a resposta em frequência desse sistema, caracterizando sua impedância. Este método requer um gerador de sinal interno, senoidal, aumentando o custo do BMS.

No método da resistência interna, é realizada a medição da resistência interna da bateria, e seu relacionamento com o SOC (a resistência interna tem relação direta com o estado de carga). Entretanto, sua medição não é simples, uma vez que essa resistência é muito pequena, da ordem de poucos $m\Omega$, o que torna difícil a obtenção de uma medida com precisão. Além disso, há muitos fatores influenciadores dessa precisão, incluindo a não uniformidade da resistência interna entre as células, e diferentes comportamentos dessa resistência dependendo da tecnologia da bateria. Por exemplo, a resistência interna das baterias de íons de lítio possui pouca variação com o SOC, tornando difícil sua caracterização. A Figura 2.21 mostra a variação da resistência interna de uma célula de lítio fosfato de ferro (LU et al., 2013).




Figura 2.21 - Resistência interna da célula de lítio fosfato de ferro.

Fonte: (adaptado de LU et al., 2013)

Esses métodos não apresentarão uma indicação do SOC adequada caso sejam utilizados de forma isolada. A literatura indica seu uso apenas para o diagnóstico de falhas do sistema (WAAG; FLEISCHER; SAUER, 2014).

Quando a carga da bateria permanece constante por um período suficiente de tempo, a relação entre a corrente da bateria, a tensão e a temperatura também podem ser usadas como base para estimar o SOC. O mais comum é utilizar uma ou mais funções $SOC = f(V_{charge}, I_{charge}, T_{battery})$ que podem ser parametrizadas para uma bateria nova, e armazenadas na forma de tabelas dentro da memória não volátil do BMS. Porém, essa abordagem é quase impraticável em veículos elétricos e híbridos, pois o regime de carga/descarga da bateria dos veículos é muito variado e intempestivo. Além disso, essas tabelas pré-calculadas são válidas somente para novas células, e o envelhecimento da bateria é praticamente impossível de ser considerado (WAAG; FLEISCHER; SAUER, 2014).

Diversos BMSs realizam somente a medição da corrente, tensão e temperatura da bateria. Porém, há abordagens na literatura que utilizam sensores adicionais para medir as características magnéticas da bateria. A característica magnética se altera com o SOC, portanto, pode ser utilizada como um indicador do seu SOC. A desvantagem é a necessidade de um sensor adicional, que aumenta o custo associado ao BMS. Ainda, a literatura não aborda se há mudança nessas características magnéticas ao longo da vida útil da bateria e como a respectiva

calibração ou compensação poderia ser realizada nesse caso. (WAAG; FLEISCHER; SAUER, 2014).

Apesar do foco desse trabalho ser sobre a estimação do estado da carga de uma bateria, para que seja possível entender o nível de complexidade do BMS, suas principais funcionalidades (além da determinação do SOC), são brevemente mencionadas nas seções seguintes.

2.3.5 Estado de saúde (SOH)

A capacidade da bateria para armazenar e fornecer energia diminui ao longo de sua vida útil devido a um processo de envelhecimento ou perda de vida útil. O estado de saúde (*State Of Health*) descreve o estado deste processo, entre aquele uma vez disponível em uma bateria nova, até seu estado quando a bateria está totalmente envelhecida (LU et al., 2013). Assim, o SOH é expresso em porcentagem: 100% quando a bateria é nova e 0% quando a capacidade da bateria para armazenar energia ou fornecer energia diminui abaixo de um determinado nível mínimo (WAAG; FLEISCHER; SAUER, 2014).

Por conta da inevitável diminuição do desempenho da bateria durante a sua vida útil, estimar o SOH com exatidão é essencial. O SOH é uma variável dependente do tempo, que deve ser consultada para rastrear mudanças nas características das células de lítio íon enquanto a bateria está envelhecendo (FARMANN et al., 2015). O SOH pode ser estimado a partir da capacidade, da resistência interna, da impedância, da taxa de autodescarga e da densidade de potência (LU et al., 2013).

Se o estado de saúde da bateria atingir 20%, o BMS deverá indicar que a bateria atingiu os critérios predefinidos para sua substituição. Entretanto, não significa que a bateria não possa ser utilizada em outras aplicações. Uma mudança significativa nas características da bateria também pode ser um indicador ou uma evidência de um problema incipiente ocorrendo em suas partes integrantes, ou de

uma maior probabilidade de falha durante sua operação (WAAG; FLEISCHER; SAUER, 2014).

2.3.6 Estado de funcionalidade (SOF)

Para aplicações veiculares ou de mobilidade elétrica, as baterias devem entregar certa quantidade de energia para a correta propulsão do veículo ou desempenho de seu movimento. Além disso, em diversas outras situações durante sua operação, a bateria deve poder entregar uma quantidade de energia adicional (dentro de seus limites de sobrecarga). A capacidade da bateria para realizar essas tarefas é geralmente referida como estado de funcionalidade, ou *state of function* (SOF). É essencial que o sistema de gerenciamento de energia do veículo conheça a máxima energia que pode ser aplicada, seja da bateria fornecendo energia ao veículo (descarga), no ciclo inverso (regeneração), ou durante seu recarregamento direto (WAAG; FLEISCHER; SAUER, 2014). Em geral, o SOF leva em consideração a impedância, o SOC e a temperatura da bateria (LU et al., 2013).

Para baterias utilizadas em sistemas que necessitam fornecer uma energia específica e muito bem definida, o SOF deve descrever como a bateria atende a essas demandas. Assim, o SOF pode ser definido como uma variável booleana, sim / não, ou seja, quando o SOF for igual a 1 significa que a bateria pode atender as demandas requisitadas e, quando o SOF for igual a 0, significa o contrário (LU et al., 2013). Como esse estado está associado a uma demanda energética, antes de ser classificado como variável booleana, ele pode ser calculado através de uma razão entre potências. Esse cálculo do SOF pode ser definido conforme Eq. 17.

$$SOF = \left(\frac{P - P_{demanda}}{P_{max} - P_{demanda}} \right) \quad (17)$$

onde: P significa a potência possível que a bateria pode suportar, $P_{demanda}$ significa a potência demandada, P_{max} significa a máxima potência possível fornecida

pela bateria. Nesses termos, um SOF menor ou igual a zero significa que a bateria mal pode entregar a potência demandada. É importante ressaltar que para baterias aplicadas em veículos elétricos, híbridos e híbridos plug-in, a bateria deve poder entregar além da demanda de potência dos motores de tração, a demanda de potência proveniente de sistemas de apoio e conforto, como do ar-condicionado elétrico, aquecedores, servo-freio etc. (LU et al., 2013). Na percepção de total perda de funcionalidade, o BMS pode instruir outros sistemas veiculares a diminuir ou cortar por completo a demanda imediata por energia, fazendo com que a potência requisitada fique dentro das capacidades da bateria.

Além dos parâmetros e dos estados da bateria comentados anteriormente, o BMS também deve ser capaz de realizar o gerenciamento térmico do conjunto e o balanceamento de suas células, fornecendo um sistema seguro e confiável.

2.3.7 Gerenciamento térmico

Idealmente, as baterias devem funcionar dentro de uma faixa de temperatura adequada para um melhor desempenho, preservando sua vida útil. Normalmente, a faixa de temperatura ideal para a operação da bateria (especificada pelo fabricante da mesma) é muito mais estreita do que o intervalo de temperaturas de operação do veículo (especificado pelo fabricante do veículo) (PESARAN, 2001). Além do gerenciamento térmico considerar a temperatura de toda a bateria, ele deve também considerar a distribuição desigual das temperaturas nas suas células e nos seus *packs*. As células da bateria podem ser cilíndricas, prismáticas e *pouchs*, e a Figura 2.22 mostra a distribuição da temperatura nesses três tipos de células.




Figura 2.22 - Distribuição da temperatura em uma célula cilíndrica, prismática e pouch.

Fonte: (NA et al., 2016)

Conforme ilustrado na Figura 2.22, a célula do tipo Cilíndrico tem uma diferença substancial de temperatura entre o seu centro e a superfície. A célula do tipo *Pouch* apresenta uma espessura pequena, sendo bastante fina. Essa célula apresenta uma grande diferença de temperatura entre o terminal e o corpo interno da célula, com “pontos quentes” de difícil medição, que e não podem ser ignorados pelo sistema de gerenciamento térmico. A célula de tipo Prismática exibe diferentes temperaturas de acordo com sua espessura, e a temperatura máxima é observada em seu centro, ao invés de suas seções terminais (NA; CHO, 2016).

Na bateria, a variação de temperatura de módulo para módulo em um pack pode levar a um comportamento de carga/descarga diferente para cada módulo. Isso, por sua vez, pode levar a módulos eletricamente desequilibrados e a um menor desempenho do pack (JAGUEMONT; BOULON; DUBÉ, 2016; PESARAN, 2001).

O gerenciamento térmico de baterias pode ser categorizado com base no meio de transferência de calor, os quais possuem um impacto significativo no desempenho e no custo do sistema de gerenciamento térmico da bateria. O meio de transferência de calor pode ser ar, líquido ou por meio de um material de mudança de fase (PCM – *phase change materials*) (PESARAN, 2001; ZHAO et al., 2015;

WANG et al., 2016). Mais detalhes sobre cada estratégia de gerenciamento térmico podem ser consultados em (WANG et al., 2016).

Todo esse gerenciamento térmico é realizado por meio do BMS, o qual recebe as informações dos sensores de temperatura das células, estima a temperatura de outros pontos quentes (algoritmo de sensores virtuais), e gerencia a transferência de calor para que seja possível controlar a temperatura de operação das células. Portanto, o BMS é responsável por acionar o sistema de refrigeração, seja ele ar ou líquido, no momento adequado para resfriamento das células. O material de mudança de fase é o único meio de transferência de calor que não pode ser acionado ou desligado, pois ele está em constante contato com a célula e será utilizado de acordo com a temperatura de fusão do material. Entretanto, em outra forma de gerenciamento térmico, o BMS também é capaz de limitar o uso da bateria para que a corrente de operação diminua e, conseqüentemente, a temperatura de suas células.

2.3.8 Balanceamento das células

A inconsistência de carga entre células é um problema sério nos sistemas de armazenamento de energia com baterias, principalmente nos projetos em que as células, como de lítio, precisam ser conectadas em série para atender aos requisitos de tensão da aplicação (LV et al., 2016).

As células de baterias modernas têm capacidades de armazenamento de energia surpreendentes, mas possuem tensões e capacidades de corrente individuais relativamente baixas. Por outro lado, a maioria das aplicações para baterias precisam de uma tensão e de uma capacidade de corrente muito superior as que podem ser obtidas a partir de uma única célula eletroquímica (GALLARDO-LOZANO, 2013). Portanto, para aumentar a capacidade de corrente da bateria, várias células são conectadas em paralelo, e para aumentar a tensão da bateria, vários conjuntos de células em paralelo são conectadas em série (BARONTI; RONCELLA; SALETTI, 2014; BONFIGLIO; ROESSLER, 2009).

Os montadores de baterias geralmente descrevem seus arranjos de células ou packs com uma terminologia como “3 P 50 S”, o que significa 3 células ligadas em paralelo, e 50 desses conjuntos de células ligadas em série. Um exemplo com uma conexão em série de 12 conjuntos de células combinadas em um bloco, ou matriz, tipo “3 P 12 S”, é mostrado na Figura 2.23.




Figura 2.23 – *Pack* de bateria conectado a um BMS.

Fonte: (adaptado de BONFIGLIO et al., 2009)

A tensão total de saída deste bloco de bateria depende do número de células em série e da tensão específica de cada uma. A tensão das células de lítio íon se situam tipicamente entre 2,5 e 3,6 V. No caso da Figura 2.23, a bateria possui uma tensão total entre 30 e 43,2 V, por exemplo.

Quando as células estão ligadas em paralelo em um módulo da bateria, a capacidade de corrente pode ser multiplicada. Neste caso, as tensões são obrigadas a ser iguais entre esses elementos ligados em paralelo, o que leva a um balanceamento automático (forçado) de suas cargas. O problema mais crítico ocorre na conexão em série, onde todos os conjuntos de células estão submetidos a uma mesma corrente. No caso de falta de uniformidade na carga dos conjuntos de célula, aquele conjunto mais fraco determina quando a corrente de carga e descarga de toda a bateria deve ser limitada ou interrompida (BONFIGLIO; ROESSLER, 2009).

A não uniformidade da bateria refere-se ao fenômeno de que, embora as baterias sejam integradas por células do mesmo tipo e especificação, existem certas diferenças intrínsecas entre cada uma. A inconsistência das células geralmente é expressa como diferenças em suas resistências internas, tensões ou desequilíbrio de suas cargas (LV et al., 2016). O desequilíbrio de células em sistemas de bateria é muito usual, fenômeno que pode ser oriundo de diversas razões ou fontes, internas

e externas. As fontes internas incluem variações na fabricação das células, pois mesmo que o processo de produção seja exatamente o mesmo, as células ainda apresentam uma pequena diferença entre elas, principalmente em relação à resistência interna das células, devido às diferentes características eletroquímicas e não homogeneidades e impurezas em seus materiais. E com o aumento do tempo de operação da bateria, a não uniformidade das células só tende a piorar sem algum mecanismo de balanceamento, o que acabará por influenciar na vida útil total da bateria. As fontes de desequilíbrio celular externo incluem alguns circuitos de proteção do *pack*, que podem drenar a energia das células de forma desigual, além da temperatura não homogênea do sistema, que influencia a taxa de autodescarga de cada uma das células. Quanto maior a temperatura, maior será a taxa de autodescarga. Se houver uma grande diferença térmica ao longo de toda a bateria, haverá diferentes taxas de autodescarga nas células, criando desequilíbrios (BARONTI; RONCELLA; SALETTI, 2014; CAO; SCHOFIELD; EMADI, 2008; DAOWD et al., 2011; GALLARDO-LOZANO et al., 2013; LU et al., 2013). A temperatura é um dos maiores fatores que influenciam a durabilidade da bateria. Conseqüentemente, a não uniformidade da temperatura das células exerce uma grande influência sobre a não uniformidade no seu desempenho geral, bem como a não uniformidade de outros parâmetros, como a resistência interna e capacidade, reduzindo a vida útil da bateria e aumentando o custo de uso da mesma (LU et al., 2013; LV et al., 2016).

A uniformidade das células geralmente é avaliada a partir de um método de estatística matemática. Esse método possui como parâmetros principais: a tensão, a capacidade celular, o SOC e a resistência interna. Dessa forma, um algoritmo de equalização para as células da bateria poderia ser dividido em três estratégias: (i) equalização baseada na uniformidade da tensão, (ii) equalização baseada na uniformidade do SOC e, (iii) equalização baseada na uniformidade de capacidade restante (LU et al., 2013). A Figura 2.24 mostra um módulo com células em série, não balanceadas, onde a célula na cor cinza escuro encontra-se totalmente carregada e a célula na cor cinza claro encontra-se totalmente descarregada, portanto, as células que apresentam as duas cores encontram-se parcialmente carregadas ou descarregadas.




Figura 2.24 – Células desbalanceadas durante carga e durante descarga.

Fonte: (adaptado de BONFIGLIO et al., 2009)

Na Figura 2.24 é possível verificar que a capacidade utilizável da bateria é menor do que a capacidade disponível, devido ao desbalanceamento das células. Portanto, é necessário realizar um manejo das cargas entre as células quando a tensão de qualquer uma começar a se diferenciar das demais. A equalização de carga é, portanto, uma tarefa importante a ser realizada pelo BMS, para garantir um uso seguro e efetivo da bateria, além de garantir a autonomia nominal da bateria e estender sua vida útil (BONFIGLIO; ROESSLER, 2009; GALLARDO-LOZANO et al., 2013; LU et al., 2013; LV et al., 2016). No trabalho de (BARONTI; RONCELLA; SALETTI, 2014), diferentes abordagens foram investigadas para modificar o nível de carga de cada célula de forma controlada, de modo a levar todas as células a um mesmo nível de carga no final do processo de balanceamento (BARONTI; RONCELLA; SALETTI, 2014).

2.3.9 Outras funcionalidades

Conforme apresentado nas seções anteriores, o BMS é responsável por todo o gerenciamento da bateria, entretanto, considerando uma aplicação real, o BMS também é responsável por se comunicar com todos os demais sistemas da aplicação. No caso de aplicações não estacionárias, o BMS deve garantir que todos os outros módulos do veículo recebam as informações da bateria de maneira segura e eficiente. Essa comunicação geralmente é realizada por meio de barramentos de comunicação via protocolo CAN e também por meio de entradas e saídas digitais, capazes de automatizar e interagir com as demais partes do veículo, garantindo a dirigibilidade, segurança, previsibilidade, eficiência, etc.

Além da conectividade com outros módulos da aplicação, o BMS também é responsável por acionar o contator de alta tensão, o qual realiza o seccionamento do circuito, controlando o fluxo de corrente da bateria e garantindo a segurança de todo o sistema. Em caso de falha em qualquer outro módulo do veículo, o BMS é informado sobre essa falha, por meio da rede CAN, realizando então as ações necessárias para a abertura do circuito de alta tensão, protegendo toda a aplicação e seus usuários. Outra funcionalidade do BMS é a proteção do sistema contra a corrente *in-rush* (RICO; ACHA; MADRIGAL, 2001) que é liberada durante o acionamento da recarga do veículo. No momento da recarga, o BMS deve acionar um resistor de pré carga (ou de pré inserção), garantindo que a corrente *in-rush* seja menor, com alguma energia dissipada no resistor, e não afete outros componentes do sistema.

Nesse contexto, é importante destacar, que o BMS não é somente responsável pela eficiência da bateria, mas também por toda a segurança da aplicação no que se refere ao uso inteligente de sua energia elétrica.

3 METODOLOGIA

Considerando o estado da arte apresentado na seção anterior, é possível concluir que o desenvolvimento de um sistema de gerenciamento de baterias é complexo, com muitas funcionalidades, e que deve ser realizado de formas diferentes, dependendo da química da bateria e da sua aplicação.

Para esse desenvolvimento é necessário priorizar algumas funcionalidades e requisitos, onde é fundamental a proteção da bateria em relação à tensão, à corrente e à temperatura. Logo, o BMS deve ser capaz de realizar a leitura da tensão individual das células, conforme apresentado na seção 2.3.1, realizar a leitura de temperaturas, além de incorporar um sensor de corrente de exatidão adequada. O BMS deve realizar a leitura desses parâmetros, identificar faltas (curto-circuitos, aberturas de circuitos), defeitos e sobrecargas, sinalizando esses estados e tomando ações para manter a operação do sistema segura, dentro das tolerâncias e faixas de valores fornecidos pelo fabricante das células.

Na implementação do algoritmo de proteção da bateria, também se faz necessário desenvolver o sistema de diagnóstico de falhas do BMS, garantindo que toda falha que vier a ocorrer, será diagnosticada e tratada corretamente durante o funcionamento do sistema.

A próxima funcionalidade que deve ser adicionada é a estimação do estado da carga, apresentada na seção 2.3.4, a qual pode depender diretamente da definição do modelo matemático da bateria, apresentado na seção 2.1. O modelo matemático deve ser definido com foco na aplicação desejada, considerando a estratégia de estimação do estado da carga. O modelo matemático e o algoritmo de estimação do estado da carga devem ser implementados no sistema considerando a quantidade total de células do banco de baterias. Entretanto, para que esse algoritmo possa ser testado em um banco com várias células, também se faz necessário implementar uma estratégia de balanceamento (seção 2.3.8), ao menos simples, para garantir a integridade das células que serão utilizadas.

Após a validação do algoritmo de estado da carga, o algoritmo de estado de saúde (seção 2.3.5) deve ser desenvolvido, de preferência seguindo o mesmo modelo matemático desenvolvido para o estado da carga. Para isso, também é necessário determinar a capacidade (seção 2.3.3) e a impedância da bateria (seção 2.3.2). Esse estado da saúde também é importante para que, durante o desenvolvimento dos demais sistemas do BMS, a própria condição operativa da bateria utilizada em testes e ensaios em bancada, por exemplo, possa ser rastreada.

A próxima funcionalidade para um bom desempenho do sistema é o de gerenciamento térmico (seção 2.3.7), que deve ser desenvolvido considerando a aplicação específica da bateria, incluindo definições a respeito da geometria, peso, temperatura de trabalho e custo do sistema. O gerenciamento térmico garante a integridade das células e prolonga a vida útil da bateria.

O estado de funcionalidade (seção 2.3.6) e o aprimoramento da estratégia de balanceamento são as funcionalidades finais que devem ser incorporadas ao desenvolvimento do BMS. A estratégia de balanceamento deve ser aprimorada considerando o tempo necessário e a corrente de balanceamento adequada para a aplicação desejada. O estado de funcionalidade deve considerar o funcionamento do sistema como um todo, e deve compreender a dinâmica de uso da bateria em seu cenário de aplicação.

Seguindo essa metodologia (adicionando as funcionalidades de acordo com essas prioridades), é possível garantir que o sistema preservará a integridade das células, mesmo durante os testes necessários para seu desenvolvimento.

Nesse contexto, o desenvolvimento do BMS desse trabalho, se inicia com a definição do *hardware* que por sua vez, depende da definição da aplicação em que o BMS será submetido. Para a presente tese, o desenvolvimento do *hardware* BMS foi realizado com um foco mais amplo, na construção de uma plataforma para a compreensão e domínio de toda a tecnologia envolvida nesse tópico.

Para que o BMS fosse capaz de realizar adequadamente todas as funções previstas, de forma virtualmente concorrente em um dispositivo microprocessado, foi

utilizado um sistema operacional RTOS (*Real time operating system*). O *firmware* do BMS foi desenvolvido com esse RTOS, com uma estratégia de “hierarquização” para as tarefas computacionais do sistema, onde cada uma recebe os dados necessários, trata essas informações, e envia seus resultados para tarefas de hierarquia superior, para que essas manipulem os dados para outras tarefas e funções. Entretanto, o foco desse trabalho se encontra na modelagem matemática da bateria e no algoritmo de estimação do estado da carga, que são ambos embarcados no BMS, como detalhado nas próximas seções.

3.1 MODELO MATEMÁTICO

A modelagem matemática é fundamental para o desenvolvimento das funcionalidades de estimação de estados e para a compreensão e processamento do comportamento dinâmico das grandezas medidas. Nesse trabalho, foi utilizada a teoria de identificação de sistemas para o desenvolvimento desse modelo. A identificação de sistemas se baseia na modelagem de sistemas dinâmicos utilizando dados de entrada e saída reais, medidos. Quando aplicada adequadamente, a identificação de sistemas também é uma ferramenta importante para ser utilizada em situações com tomadas de decisão complexas, como nos algoritmos de estado da carga, do estado da saúde, do estado de funcionalidade, do balanceamento e do gerenciamento térmico.

3.1.1 Identificação de sistemas

Conforme apresentado na seção 2.1, modelos podem ser apresentados em diferentes formas, com vários graus de formalismo matemático. O cenário de aplicação do modelo irá determinar o grau de sofisticação necessário para fazê-lo adequado e utilizável. A aceitação do modelo deve ser guiada por “utilidade” ao invés de “verdade” (DA SILVA et al., 2021). A construção de um modelo a partir de dados envolve três requisitos:

- Um conjunto de dados – coletados através de um experimento, especialmente desenvolvido, capaz de expor os comportamentos relevantes (dominantes) do sistema;
- Um conjunto de modelos candidatos – utilizados para representar a dinâmica do sistema;
- Um método de identificação – que tenta ajustar o resultado do modelo simulado com o conjunto de dados observados, ajustando os parâmetros internos do modelo adequadamente, e verificando a correlação dos dados reais com os dados simulados.

É importante frisar que quanto mais dados estão disponíveis num processo de identificação de sistemas, melhor. Entretanto, a realização de infinitos experimentos reais para coleta de informações não é prática num processo de engenharia com baterias, uma vez que, em cada montagem e ensaio, são feitos inúmeros ciclos de carga e descarga que, além de apresentarem riscos, também degradam a vida útil do dispositivo. Logo, um dos desafios dessa metodologia é fazer o *design* do experimento ou de um conjunto de ensaios, cujos dados coletados podem melhor representar os parâmetros e a dinâmica daquele tipo de arranjo de bateria para um dado modelo matemático que a representa. Os melhores experimentos selecionados podem ser aplicados de forma sistemática e simples num processo de produção em escala, sendo suficientes para a identificação dos parâmetros do modelo, sem degradar ou arriscar a vida útil da bateria. Além disso, deve-se analisar qual o modelo que, parametrizado, melhor representa a bateria, e qual o melhor critério que faz o ajuste (*fitting*) dos dados do ensaio com os dados resultantes do modelo. Esse procedimento de identificação de sistemas possui um fluxo lógico como o apresentado na Figura 3.1.

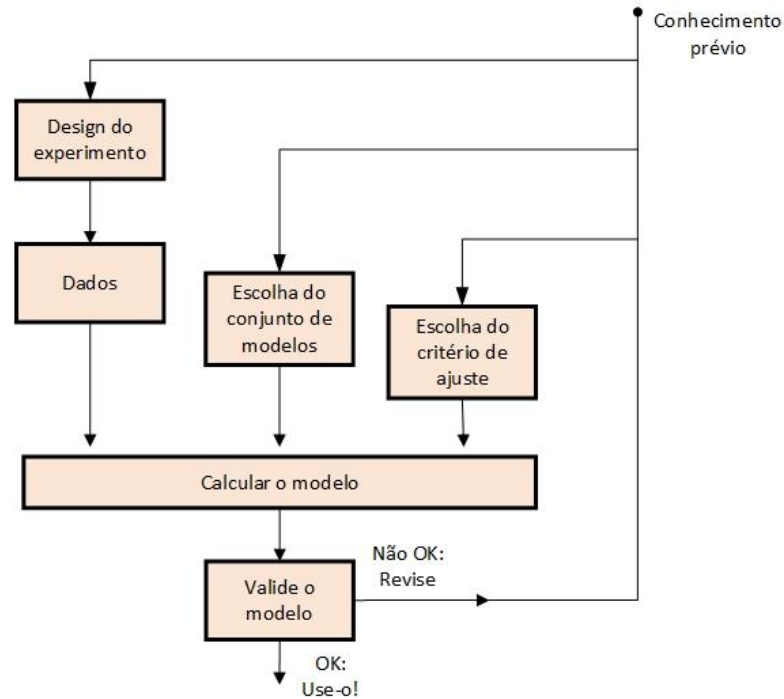


Figura 3.1 – Fluxo da identificação de sistemas.

Fonte: (adaptado de LJUNG, 1999).

Isso demonstra que o procedimento de identificação de sistemas se trata de um método recursivo e heurístico, com diversas iterações, até que um modelo passe por todos os critérios e testes de validação, garantindo sua qualidade, por exemplo, para reproduzir os dados medidos (DA SILVA et al., 2021).

No fluxo da identificação de sistemas, o primeiro passo é determinar um conjunto de experimentos. O conjunto de experimento deve ser capaz de explorar a dinâmica da bateria de acordo com aplicação em que a mesma será submetida, pois essa dinâmica pode ser totalmente diferente de acordo com cada aplicação. Por exemplo, um conjunto de experimentos capaz de explorar a dinâmica da bateria aplicada a um sistema de armazenamento de energia estacionário, residencial, será diferente do conjunto de experimentos capaz de explorar a dinâmica da bateria para uso em um veículo automotor híbrido (DA SILVA et al., 2021).

Nesse trabalho, foi dado enfoque para a aplicação de baterias em empilhadeiras elétricas. As empilhadeiras fazem parte de muitos ambientes comerciais e industriais modernos, e são recursos críticos, que influenciam

diretamente a eficiência geral e custos de qualquer instalação de manufatura ou armazém. Sua aplicação é evidente, principalmente na nova era da indústria 4.0, por exemplo, na mobilização rápida, segura e eficiente de cargas em armazéns, para suporte a atividades de logística e *e-commerce*. Portanto, empilhadeiras elétricas são amplamente utilizadas, e seu aprimoramento é um tópico relevante para pesquisa (DA SILVA et al., 2021). Nesse contexto, os experimentos desenvolvidos nesse trabalho estão orientados ao regime de trabalho de uma bateria utilizada em uma empilhadeira elétrica típica, conforme apresentado na Figura 3.2.

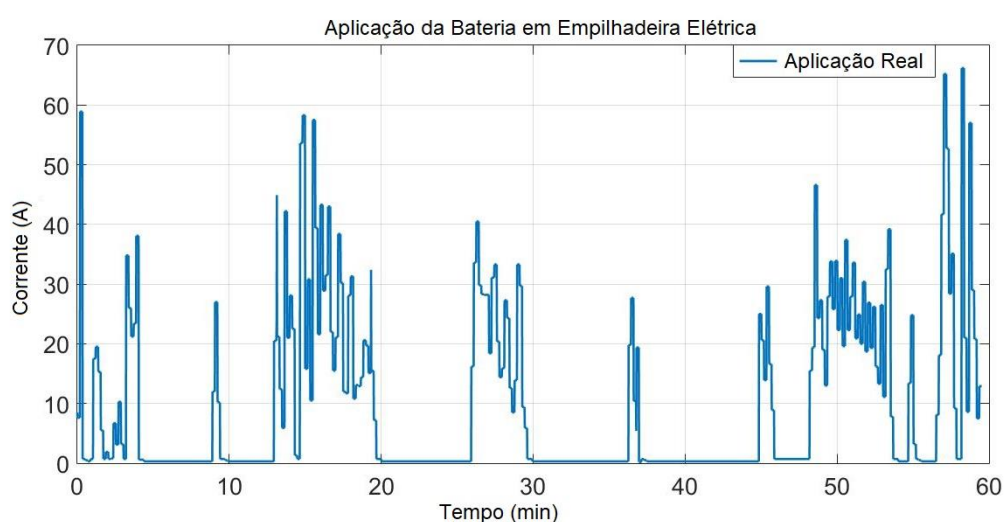


Figura 3.2 – Teste de aplicação da bateria, em operação real, com empilhadeira elétrica.

A bateria real utilizada na aplicação da empilhadeira possui a capacidade de 150Ah, totalizando 25 células em paralelo e na Figura 3.2 é possível observar diferentes amplitudes da corrente solicitada da bateria, referentes a várias situações em que a empilhadeira é empregada, por exemplo, com relação à altura em que o garfo da empilhadeira é elevado, com relação ao peso da carga que a empilhadeira está transportando, e com relação ao movimento e manobras em curso (com diferentes velocidades, torques, tipos de pavimento, etc.). Os momentos em que a corrente é igual a 0A, se referem aos momentos em que a empilhadeira está parada, ou seja, está ociosa, sem movimentação de seu garfo ou do próprio veículo.

As características da célula de lítio utilizada nos experimentos desse trabalho são apresentadas na Tabela 3.1.

Tabela 3.1 – Característica da célula de lítio empregada na bateria da empilhadeira.

Química	LiFePO4
Tipo	Cilíndrica
Capacidade nominal	6Ah
Tensão nominal	3,2V
Tensão máxima	3,65V
Tensão mínima	2V
Capacidade máxima de carga	1C
Capacidade máxima de descarga	1C

Os experimentos em laboratório poderiam até ser feitos com a bateria real, com até 150Ah de capacidade (25 células em paralelo). Entretanto, isso iria requerer grandes correntes de carga e descarga em bancada, o que dificulta e torna mais arriscado o ensaio. Para tornar a montagem mais simples e segura, foram realizados experimentos com apenas uma célula em paralelo, portanto, resultando numa capacidade para a bateria utilizada nos testes de 6Ah.

Todos os experimentos realizados para a identificação do sistema foram iniciados com a bateria totalmente carregada. Nos experimentos o SOC foi diretamente medido com um algoritmo de *coulomb counting* desenvolvido e implementado no BMS, para que fosse possível identificar o estado da carga durante os experimentos realizados. Os experimentos foram divididos em dois grupos:

- Grupo 1: pulsos longos de corrente com 3 períodos de descanso diferentes. O período de descanso é o momento que a bateria está próxima do seu estado de repouso, onde a corrente é próxima a 0,0 A. Esses experimentos são chamados de “30s de descanso”, “18s de descanso” e “5s de descanso”. Esse grupo de experimento é capaz de explorar a dinâmica da bateria em situações de uso leve, mediano e

pesado, respectivamente. Independentemente do tempo de descanso da bateria, esse grupo de experimento foi desenvolvido para explorar situações em que a empilhadeira é utilizada de forma em que a mudança na amplitude da corrente ocorre em períodos maiores de tempo, considerando que o menor tempo de elevação do garfo ou movimento da empilhadeira é de 2 segundos, e o maior tempo, de 12 segundos. A Figura 3.3 apresenta um desses experimentos, com 5 segundos de descanso da bateria.




Figura 3.3 – Pulsos longos de corrente, com um período de descanso de 5s entre os pulsos.

- Grupo 2: pulsos curtos de corrente com 2 períodos de descanso diferentes e 2 períodos de pulsos diferentes, como apresentado na Figura 3.4. O período de pulsos é o momento quando a corrente é diferente de 0,0A, com uma alta variedade de pulsos de corrente. Esses experimentos são chamados de “1m alto 30s baixo”, “30s alto 30s baixo” e “30s alto 1m baixo”. Esse grupo de experimento é capaz de explorar a dinâmica da bateria em situações de uso leve, mediano e pesado, respectivamente. Independentemente do tempo de descanso da bateria, esse grupo de experimento foi desenvolvido para explorar situações em que a empilhadeira é utilizada de diferentes formas, ou

seja, há uma grande variação entre os tempos de elevação do garfo ou de movimento da empilhadeira.




Figura 3.4 – Pulsos curtos de corrente, onde a corrente é diferente de 0,0A, com 1 minuto de descanso da bateria.

De acordo com o fluxo da identificação de sistemas apresentado na Figura 3.1, o segundo passo é determinar um conjunto de modelos. Nesse trabalho, a estrutura utilizada para o modelo pertence à família de circuitos equivalentes (modelos elétricos), apresentado na seção 2.1.3. Utilizando essa estrutura, foram escolhidos 4 modelos diferentes para serem testados e validados, são eles:

- Função de transferência discreta (TF – *Transfer function*);
- Erro de Saída (OE – *Output-error*);
- Modelo não linear Hammerstein Wiener (NLHW – *Nonlinear Hammerstein Wiener*);
- Modelo não linear caixa cinza (NLGR – *Nonlinear grey box model*).

O terceiro passo é definir um conjunto de critérios de ajustes, nesse caso, foram escolhidos os seguintes critérios:

- Método dos mínimos quadrados não linear (*Nonlinear least square*);

- Mínimos quadrados Gauss Newton em subespaço (*Subspace Gauss-Newton least square*);
- Gauss Newton em subespaço, adaptativo (*Adaptive subspace Gauss-Newton*);
- Mínimos quadrados Levenberg-Manquat (*Levenberg-Marquardt least square*);
- Mínimos quadrados com descida íngreme (*Steepest descent least square*).

Utilizando essas definições, o processo iterativo de identificação dos sistemas pode ser realizado, determinando ao final o melhor experimento, o melhor modelo e o melhor critério de ajuste que descrevem a dinâmica da bateria para um cenário de aplicação com empilhadeiras elétricas.

Adicionalmente a essas definições, é necessário escolher também o melhor método para descrever a não linearidade da bateria devido à relação entre o OCV e o SOC, conforme apresenta a Figura 2.13 na seção 2.3.4.2.

3.1.2 Não linearidade da bateria

Nesse trabalho, três diferentes estratégias foram analisadas para a definição do método capaz de descrever a não linearidade da bateria na relação entre o OCV e o SOC, a saber: Tabela de consulta direta (*Lookup table*), aproximação polinomial, e função linear particionada (*Piecewise linear functions*).

Esses métodos foram avaliados por meio do experimento apresentado na Figura 3.5, chamado de “Teste OCV”, onde o pulso de corrente da entrada da bateria é equivalente a 10% de SOC, e quanto maior for o tempo de descanso da bateria, melhor será a precisão da relação entre o OCV e o SOC, conforme descrito na seção 2.3.4.2. Porém, maior deverá ser o tempo total do teste. Nesse trabalho foram realizados dois testes OCV, um teste com o tempo de descanso de 10 minutos (Figura 3.5), e outro teste com o tempo de descanso de 1 hora.

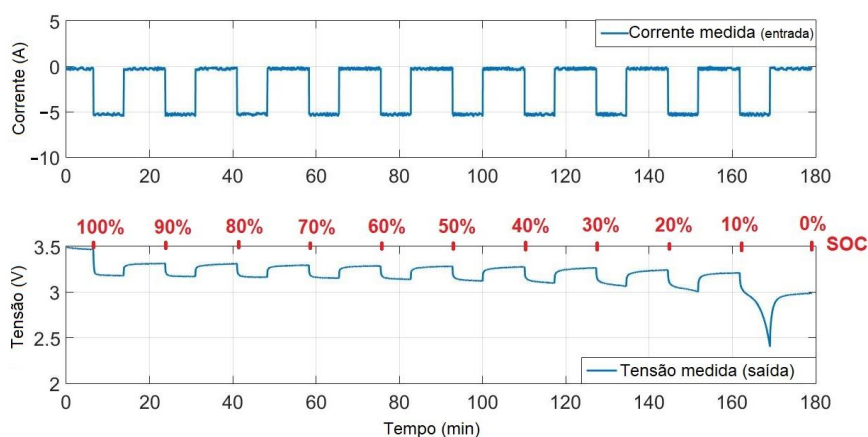


Figura 3.5 – Corrente de entrada e tensão de saída da bateria, medidos durante o teste OCV.

A *lookup table* possui uma boa exatidão, entretanto, requer uma grande quantidade de memória do microcontrolador, disputando espaço com os dados e os programas que dão suporte a todas as demais funções do BMS. A Aproximação Polinomial também é uma boa opção, com melhor precisão e menos consumo de memória, porém é necessário um polinômio de ordem elevada (sétima ordem neste caso específico), o que requer um esforço computacional alto e aritmética de ponto flutuante. Entretanto, esse método é menos preciso do que uma função linearizada por trechos, ou *piecewise functions*.

O conjunto de *piecewise functions* é relativamente simples de implementar, possui menores requisitos computacionais do que a abordagem com o polinômio de alta ordem, e ocupa menos memória do que o método de *lookup table*. Os únicos inconvenientes dessas funções linearizadas por trechos são as descontinuidades em suas derivadas de primeira ordem na transição entre um trecho e outro. Isso poderia ser contornado pelo uso de funções quadráticas por trechos ou *splines*, mas que resultam em maior carga computacional.

A *piecewise function* adotada nesse trabalho possui 10 intervalos igualmente espaçados (*breakpoints*), os quais os parâmetros b_0 (intercepção no eixo y) e b_1 (inclinação da curva no trecho com aproximação linear) precisam ser previamente calculados para o conhecimento da relação OCV-SOC.

É importante ressaltar que, uma vez que as baterias de lítio íon possuem uma histerese na relação OCV-SOC na condição de carga e descarga da bateria, faz-se necessário descrever duas curvas, como a histerese apresentada na Figura 3.6.

Os 10 pontos igualmente espaçados, mostraram ser suficientes para descrever apropriadamente o comportamento da relação OCV-SOC. Os *breakpoints* podem ser visualizados no eixo x da Figura 3.6. Os valores intermediários do SOC e OCV podem ser encontrados através de simples interpolações nos trechos.




Figura 3.6 – *Breakpoints* e histerese da célula, presente na relação OCV-SOC.

Considerando que a relação OCV e SOC é descrita por *piecewise linear functions*, cada uma dessas funções pode ser representada pela Eq. 18, com diferentes valores de b_0 e b_1 de acordo com o trecho onde se situa o valor atual do SOC.

$$V_{OCV} = b_0 + b_1 * soc \quad (18)$$

De acordo com o modelo de circuito equivalente, apresentado na Figura 2.5, na seção 2.1.3, a tensão da bateria é descrita conforme Eq. 19.

$$y(t) = V_{OCV} - x_1(t) - R_0 * u(t) \quad (19)$$

Substituindo a Eq. 18 na Eq. 19, a tensão da bateria é representada pela Eq. 20.

$$y(t) = -x_1(t) - R_0 * u(t) + b_0 + b_1 * soc \quad (20)$$

Considerando a Eq. 20, as equações em espaço de estados que representa a dinâmica da bateria, pode ser escrita como:

$$\dot{x} = Ax + Bu \quad (21)$$

$$y = Cx + Du \quad (22)$$

$$\begin{bmatrix} \dot{x}_1(t) \\ \dot{x}_2(t) \end{bmatrix} = \begin{bmatrix} -\frac{1}{R_1 * C_1} & 0 \\ 0 & 0 \end{bmatrix} * \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix} + \begin{bmatrix} -\frac{1}{C_1} \\ \frac{1}{3600 * C_n} \end{bmatrix} * u(t) \quad (23)$$

$$y_1(t) = [-1 \quad b_1] * \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix} + [R_0] * u(t) + b_0 \quad (24)$$

Nesse modelo, os parâmetros R_0 , R_1 e C_1 devem ser identificados através do critério de ajuste definido. O parâmetro C_n é a capacidade nominal da bateria, a qual pode ser encontrada no *datasheet* das suas células. Os parâmetros b_0 e b_1 dependem do SOC, conforme mostrado anteriormente.

É importante ressaltar que a exatidão de modelos elétricos equivalentes depende da estrutura do modelo, ou seja, sua complexidade em topologia de circuito, ordem e estados, e dependem da precisão na identificação de seus parâmetros. Para que a identificação desses parâmetros seja realizada utilizando a estrutura do modelo não linear caixa cinza, também é necessário informar os valores iniciais para esses parâmetros do sistema.

3.1.3 Cálculo dos parâmetros iniciais

Para realizar a identificação dos parâmetros do modelo, é necessário informar o estado inicial (SOC) e os parâmetros iniciais (R_0 , R_1 e C_1). Os parâmetros iniciais

foram calculados utilizando partes do teste OCV apresentado na Figura 3.5. Conforme apresentado na seção 3.1.2, o teste OCV caracteriza-se pela facilidade de identificação do estado da carga, pois o teste é realizado em corrente constante, com um período suficiente para descarregar 10% da bateria. Após esse período, a bateria permanece em descanso por um tempo determinado, geralmente entre 1 hora e 4 horas, até que os elétrons se estabilizem na célula, indicando o estado real da carga da bateria. Esse procedimento é repetido por 10 vezes, até que a bateria seja totalmente descarregada.

Nesse contexto, a metodologia apresentada nessa tese, realiza o cálculo dos parâmetros iniciais em todos os pontos de SOC da bateria. Por exemplo, se os parâmetros do modelo forem identificados em 40% de SOC, os parâmetros iniciais devem ser calculados na parte do teste OCV que representa 40% de SOC e assim por diante.

A Figura 3.7 apresenta a parte do teste OCV que representa 40% de SOC e será utilizada para exemplificar a metodologia do cálculo dos parâmetros iniciais.

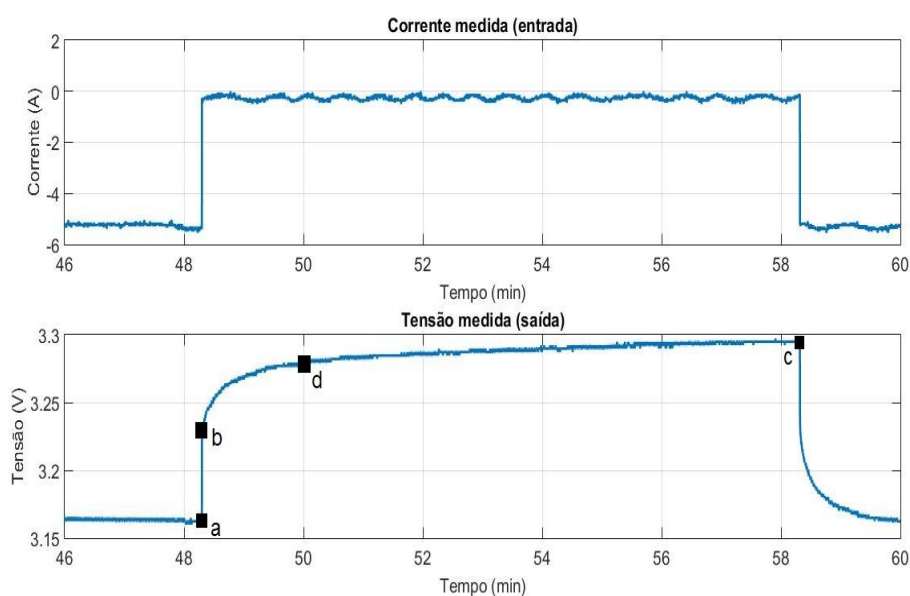


Figura 3.7 – Parte do teste OCV usado para calcular os parâmetros R_0 , R_1 e C_1 .

De acordo com os pontos (a, b, c e d) apresentados na Figura 3.7, as seguintes equações foram aplicadas para se determinar os parâmetros iniciais.

$$R_0 = \frac{b-a}{I} \quad (25)$$

Onde a é o exato ponto em que a corrente cai e a tensão sobe, b é o ponto subsequente onde outra dinâmica ocorre, e I é a corrente aplicada durante o teste OCV.

$$R_1 = \frac{c-b}{I} \quad (26)$$

Onde c é o ponto exato em que a corrente é novamente aplicada.

Admitindo que a dinâmica entre os pontos b, d e c pode ser aproximada por um sistema de primeira ordem, pode-se afirmar que:

$$d = [(c - b) * 0,632] + b \quad (27)$$

$$t_b - t_d = \tau \quad (28)$$

Onde t_b é o instante de tempo do ponto b , t_d é o instante de tempo do ponto d , e τ é a constante de tempo do capacitor C_1 . A constante de tempo (τ) corresponde ao tempo, em segundos, necessário para carregar um capacitor conectado em série com um resistor até atingir 63% (0,632 da Eq. 27) do valor da tensão contínua aplicada sobre ele. Logo, o valor do capacitor C_1 é determinado por:

$$C_1 = \frac{\tau}{R_1} \quad (29)$$

Utilizando esses parâmetros iniciais e seguindo a metodologia apresentada na seção 3.1.1, foi possível determinar o melhor modelo capaz de descrever essa dinâmica da bateria em aplicações com empilhadeiras elétricas. O resultado foi utilizado como base para o desenvolvimento de um modelo diferenciado, que não foi encontrado previamente na literatura, e cujos detalhes serão descritos adiante.

3.1.4 Modelo não linear caixa cinza com duas saídas

Para que os parâmetros identificados possuam uma maior exatidão e para que o resultado do modelo não seja enviesado, também foi analisado um modelo não linear caixa cinza com duas saídas (*2out_NLGR – 2 outputs nonlinear grey box model*), onde as duas saídas são apresentadas pelas equações:

$$y_1(t) = V_{OCV} - x_1(t) - R_0 * u(t) \quad (30)$$

$$y_2(t) = x_2(t) \quad (31)$$

onde: $x_2(t) = soc(t)$.

Dessa forma, o estado da carga da bateria é considerado como uma das saídas do modelo. Logo, considerando os termos mencionados no sistema das Eq. 5, 6 e 7, apresentadas na seção 2.1.3, as matrizes desse sistema descrito no espaço de estados são apresentadas abaixo:

$$A = \begin{bmatrix} -\frac{1}{R_1 * C_1} & 0 \\ 0 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} -\frac{1}{C_1} \\ 1 \\ \frac{1}{3600 * C_n} \end{bmatrix}, \quad C = \begin{bmatrix} -1 & b_1 \\ 0 & 1 \end{bmatrix} \quad \text{e} \quad D = \begin{bmatrix} R_0 \\ 0 \end{bmatrix}$$

Utilizando um modelo com duas saídas, é necessário determinar qual das duas devem ter maior peso no momento de identificação dos parâmetros, ou seja, qual saída possuirá mais informações para que o algoritmo consiga calcular os parâmetros com a maior precisão possível. De forma padrão, os modelos são identificados considerando que todas as saídas possuem exatamente o mesmo peso. Porém, a estratégia adotada nesse trabalho, consiste em realizar uma primeira identificação no sistema, considerando o mesmo peso para as duas saídas, para calcular a variância de cada saída. A seguir, realiza-se uma segunda identificação do sistema, considerando como pesos o inverso da variância de cada saída. Esse método foi baseado em estratégias apresentadas no livro de (CARROLL et al., 1988), e é apresentado na Figura 3.8.

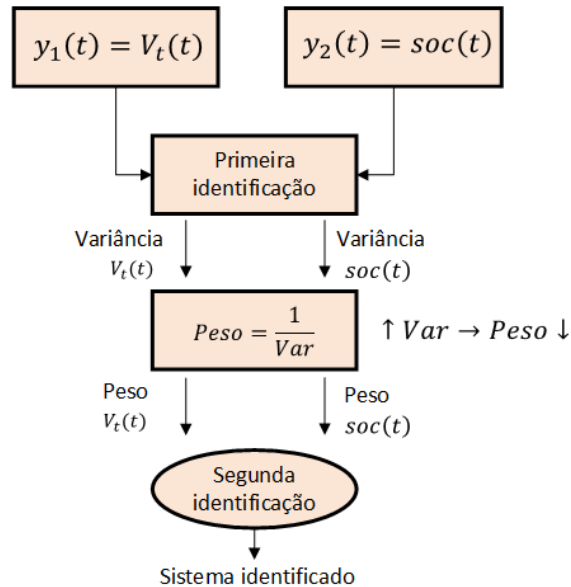


Figura 3.8 – Identificação do sistema considerando pesos diferentes nas saídas.

Analisando a Figura 3.8, é possível concluir que a saída que possui maior variância, conseqüentemente possuirá o menor peso, ou seja, os parâmetros serão identificados considerando um peso maior na saída em que o sistema possui maior confiança (menor variância).

Dessa forma, é possível obter um modelo preciso, sem viés, de baixa complexidade e fácil implementação. Os parâmetros do modelo, identificados através dessa estratégia, serão utilizados no algoritmo de estimação do estado da carga da bateria.

3.2 ESTIMAÇÃO DO ESTADO DA CARGA

Nesse trabalho, o filtro de Kalman estendido apresentado na seção 2.3.4.3 será utilizado para realizar a estimação do estado da carga da bateria.

O modelo apresentado na seção 3.1.1 deve ser aplicado no filtro, porém, para isso, é necessária sua conversão para o domínio do tempo discreto. O modelo no espaço de estados discreto é representado pelas Eq. 32 e 33.

$$x_k = A_{d_{k-1}}x_{k-1} + B_{d_{k-1}}u_{k-1} \quad (32)$$

$$y_k = C_{d_k}x_k + D_{d_k}u_k \quad (33)$$

onde: as matrizes A_d , B_d , C_d e D_d são as matrizes A , B , C e D do sistema no espaço discreto das amostras. Essas matrizes, em tempo contínuo, foram apresentadas na seção 3.1.4. Para a discretização do modelo, foi escolhido o método *backward Euler*, por resultar numa aritmética bastante simples e elementar para representar a integração numérica. Nesse caso, as matrizes do modelo espaço de estados discreto são calculadas através das seguintes equações.

$$A_d = (I - A * T_s)^{-1} \quad (34)$$

$$B_d = (I - A * T_s)^{-1} * B * T_s \quad (35)$$

$$C_d = C * (I - A * T_s)^{-1} \quad (36)$$

$$D_d = D + C * (I - A * T_s)^{-1} * B * T_s \quad (37)$$

onde: as notações com o índice subscrito d representam as matrizes com coeficientes do sistema no domínio discreto das amostras, e T_s é a taxa de amostragem que será utilizada.

O sistema discreto do filtro de Kalman estendido é mostrado nas equações 38 e 39.

$$x_k = f(x_{k-1}, u_k, w) \quad w \sim (0, Q_k) \quad (38)$$

$$y_k = h(x_k, u_k, v) \quad v \sim (0, R_k) \quad (39)$$

onde: x_k é a variável de estado do sistema, y_k é a variável de observação do sistema, u_k é a entrada do sistema, f é a função não linear do estado, h é a função

não linear da medida, w e v são os ruídos brancos gaussianos com média 0 e covariância Q_k e R_k respectivamente.

O filtro de Kalman estendido utiliza uma expansão em série de Taylor para realizar uma aproximação linear de uma função não linear, a qual, nesse caso, se encontra na equação da tensão total da bateria (Eq. 30), ou seja, na saída do sistema (y_1). Para a definição da tensão total da bateria é necessário determinar a tensão de circuito aberto da bateria (V_{OCV}) a qual possui uma relação não linear com o estado da carga da bateria (x_2). Nesse contexto, a expansão em série de Taylor deve ser realizada na equação da tensão de circuito aberto da bateria, que poderia ser representada por um polinômio de ordem n conforme descrito na seção 3.1.2. Desse modo, a linearização é realizada em relação a uma trajetória nominal fixa.

O diagrama de blocos que representa o fluxo de dados do filtro de Kalman estendido é apresentado na Figura 3.9, onde as não linearidades da bateria são aproximadas utilizando a linearização através de uma expansão em série de Taylor, a qual é representada pelas matrizes F e H .

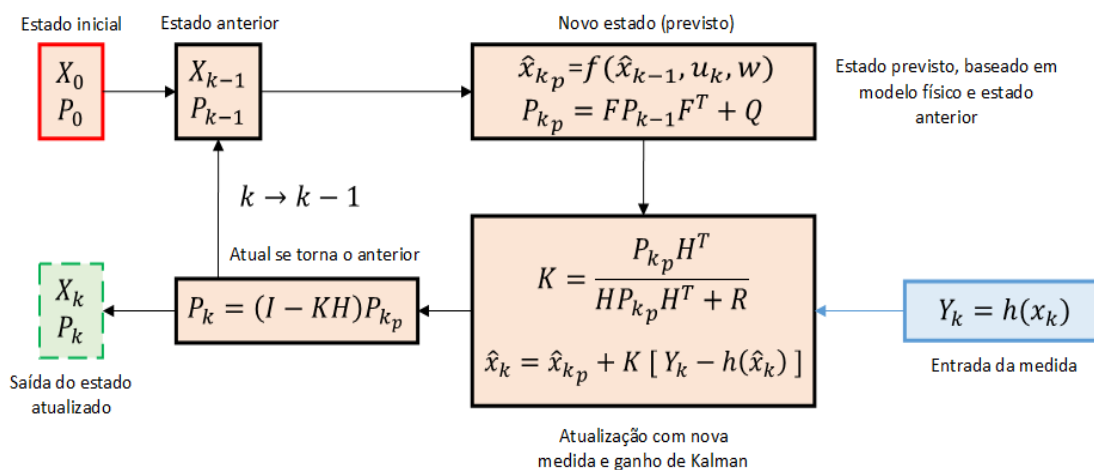


Figura 3.9 – Diagrama de blocos do filtro de Kalman estendido.

A matriz F apresentada na Figura 3.9 é uma matriz Jacobiana de derivadas parciais de f , onde $f = (f_1(x), f_2(x), \dots, f_n(x))^T$ e $x = (x_1, x_2, \dots, x_n)^T$. A matriz F possui uma relação com os estados anteriores x_{k-1} e a entrada u_k , e é dada por:

$$F_k = \left. \frac{\partial f(\hat{x}_{k-1}, u_k)}{\partial x} \right|_{x=\hat{x}_k} \quad (40)$$

Logo, a matriz F é dada por:

$$F = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} \end{bmatrix} \quad (41)$$

Para a resolução da Eq. 41, a discretização pelo método de Euler é realizada considerando os estados apresentados nas Equações 42 e 43:

$$\dot{x}_1(t) = -\frac{1}{R_1 * C_1} * x_1(t) - \frac{1}{C_1} * u(t) \quad (42)$$

onde: $\dot{x}_1(t) = f_1(x_1)$

$$\dot{x}_2(t) = \frac{1}{3600 * C_n} * u(t) \quad (43)$$

onde: $\dot{x}_2(t) = f_2(x_2)$

Logo, temos as equações dos estados no tempo discreto, na forma de equações de diferenças:

$$x_{1k} = x_{1k-1} + \left(-\frac{1}{R_1 * C_1} * x_{1k} - \frac{1}{C_1} * u_k \right) * T_s \quad (44)$$

$$x_{2k} = x_{2k-1} + \left(\frac{1}{3600 * C_n} * u_k \right) * T_s \quad (45)$$

A matriz H apresentada na Figura 3.9 é uma matriz Jacobiana de derivadas parciais de h onde $h = (h_1(y), h_2(y), \dots, h_n(y))^T$ e $y = (y_1, y_2, \dots, y_n)^T$. A matriz H possui relação com os estados do sistema e é dada por:

$$H(\hat{x}, k) = \left. \frac{\partial h(x, k)}{\partial x} \right|_{x=\hat{x}_k} \quad (46)$$

Logo, a matriz H é dada por:

$$H = \begin{bmatrix} \frac{\partial h_1}{\partial x_1} & \frac{\partial h_1}{\partial x_2} \end{bmatrix} \quad (47)$$

onde: $h_1 = y_1(t)$ dada por:

$$y_1(t) = V_{OCV} - x_1(t) - R_0 * u(t) \quad (48)$$

A expansão em série de Taylor para a relação SOC-OCV deve ser realizada até a ordem necessária. Nesse caso, utilizando funções linearizadas por trechos (*Piecewise Linear Functions*), a aproximação até a primeira ordem é suficiente, ou seja:

$$V_{OCV} = b_0 + b_1 x_2 \quad (49)$$

onde: x_2 é o SOC. Logo, a equação da saída se torna:

$$y_1(t) = b_0 + b_1 x_2(t) - x_1(t) - R_0 * u(t) \quad (50)$$

Para a resolução da Eq. 47, a discretização pelo método de Euler é realizada resultando na Eq. 51:

$$y_{1k} = y_{1k-1} + [b_0 + (b_1 * x_{2k}) - x_{1k} - (R_0 * u_k)] * T_s \quad (51)$$

Um dos maiores desafios na implementação do filtro de Kalman, é a definição da matriz do ruído de medição (R) e do ruído de processo (Q_k).

A matriz de ruído de processo (Q_k) representa a variância do ruído de todo o processo matemático inerente ao sistema (incluindo aproximações e truncamentos) e a matriz de ruído de medição (R) representa a variância do ruído de medição do sistema. Foram encontrados diversos trabalhos na literatura que inserem valores fixos à essas matrizes sem uma explicação a respeito dessa definição (JOKIE; ZARKO; BOZO, 2018; YUAN; HONGJIE; CHENGLIANG, 2013). Porém, se essas

matrizes forem definidas de forma qualquer, a precisão do filtro de Kalman estendido será afetada. Se Q_k e R forem muito pequenos, a faixa de incerteza será pequena, resultando em uma estimativa enviesada, e se Q_k e R forem elevados, pode causar divergência no filtro (LI, et al., 2020; SHI, et al., 2021). O filtro de Kalman estendido considera que essas matrizes são constantes, entretanto, em algumas aplicações é necessário considerar que os ruídos poderão variar durante condições reais de operação.

Para melhorar a precisão dessa estimativa, filtros de Kalman adaptativos foram desenvolvidos com o objetivo de ajustar essas variâncias dos ruídos em tempo real. No trabalho de (SHI, et al., 2021), as matrizes Q_k e R são atualizadas em tempo real, utilizando o método de janela deslizante (*sliding window*), considerando o erro entre o valor da saída do modelo $h(\hat{x}_k)$ e o valor medido $h(x_k)$. Durante testes para o estimador de SOC, esse método se mostrou capaz de se adaptar à diferentes condições de temperatura e diferentes estados de saúde das células (SOH), além de possuir maior precisão e melhor robustez em comparação com outros algoritmos de filtragem. (ZHANG, et al., 2021) apresenta um método similar, porém, utiliza um fator de esquecimento em conjunto com a janela deslizante. As simulações e os resultados experimentais mostraram que o algoritmo proposto no trabalho de (ZHANG, et al., 2021) conseguiu estimar o SOC com precisão mesmo quando a característica estatística do ruído se desviou dos valores nominais. Em (SUN, et al., 2021) foi desenvolvida uma abordagem que também considera o erro entre o valor da saída do modelo $h(\hat{x}_k)$ e o valor medido $h(x_k)$ utilizando o método da janela deslizante, porém a atualização da matriz Q_k considera o ganho de Kalman (K), enquanto que a atualização da matriz R considera a matriz de covariância P_k . Essa abordagem atingiu uma precisão do SOC 43,34% maior do que a abordagem tradicional, e resultou em um aumento de apenas 4,59% no tempo computacional.

Foram encontradas diversas outras estratégias para o cálculo das matrizes Q_k e R em tempo real, porém, todas as abordagens encontradas, são similares em considerar o erro entre o valor da saída do modelo ($h(\hat{x}_k)$) e o valor medido ($h(x_k)$).

Nesse trabalho, uma abordagem diferente é apresentada.

Para o cálculo da variância do ruído de medição da tensão, a precisão do sensor de tensão é considerada em conjunto com a variância do ruído devido a EMI (*Electromagnetic Interference*) / EMC (*Electromagnetic Compatibility*) de circuitos de condicionamento. Esse cálculo é feito a cada 3 interações do algoritmo. Nesse contexto, a Eq. 52 apresenta a variância do ruído de medição da tensão.

$$u(V_T) = var_{r_v} + prec_{sens_v} \quad (52)$$

onde: var_{r_v} é a variância do ruído de medição da tensão calculada a cada 3 interações do algoritmo e $prec_{sens_v}$ é a precisão do sensor de medição da tensão informada pelo fabricante.

Desse modo, temos a matriz de covariância do ruído de medição, representada pela Eq. 53.

$$R = u(V_T) \quad (53)$$

De forma semelhante, para a medição de corrente, obtêm-se a Eq. 54 para a variância do seu ruído na medição.

$$u(I) = var_{r_I} + prec_{sens_I} \quad (54)$$

onde: var_{r_I} é a variância do ruído de medição da corrente calculada a cada 3 interações do algoritmo e $prec_{sens_I}$ é a precisão do sensor de corrente, como informado pelo fabricante.

Entretanto, o algoritmo deve ser capaz de diferenciar o que realmente é ruído e o que é apenas uma mudança ou transitório na amplitude da tensão ou da corrente. Para isso, a variância padrão (observada em regime permanente de operação) do ruído de medição foi calculada por meio de ensaio de laboratório. No algoritmo embarcado, é realizado o cálculo da variância a cada 3 interações, caso essa variância seja maior do que a variância padrão, o algoritmo ignora esse valor, pois o mesmo representa uma variação da amplitude da tensão ou da corrente e não representa verdadeiramente o ruído.

A matriz de covariância do ruído de processo (Q_k) é calculada considerando como processo o próprio fluxo de dados para a identificação dos parâmetros, onde cada um possui seu desvio padrão, ou seja, sua incerteza. Nesse contexto, a matriz de covariância do ruído de processo é representada pela Eq. 55, onde o primeiro termo da matriz é relacionado à derivada do primeiro estado do sistema ($V_{RC} = \dot{x}_1$) e o segundo termo da matriz é relacionado à derivada do segundo estado do sistema ($S\dot{O}C = \dot{x}_2$).

$$Q_k = \begin{bmatrix} u(V_{RC}) & 0 \\ 0 & u(S\dot{O}C) \end{bmatrix} \quad (55)$$

O cálculo da Eq. 55 é realizado com base na combinação de incertezas de cada parâmetro das equações 56 e 57.

$$\dot{V}_{RC} = -\frac{1}{R_1 * C_1} * V_{RC} + \frac{1}{C_1} * I \quad (56)$$

$$S\dot{O}C = \frac{1}{3600 * Cn} * I \quad (57)$$

O cálculo de combinação de incertezas deve levar em conta a relação algébrica entre as grandezas e se essas são estatisticamente independentes ou correlacionadas, como apresentado na Tabela 3.2.

Tabela 3.2 – Combinação de incertezas.

	x_i correlacionadas
$y = x_1 + x_2$	$u(y) = u(x_1) + u(x_2)$
$y = x_1 - x_2$	
$y = x_1 * x_2$	$\frac{u(y)}{ y } = \frac{u(x_1)}{x_1} + \frac{u(x_2)}{x_2}$
$y = x_1/x_2$	
$y = x^p$	$\frac{u(y)}{ y } = p * \frac{u(x)}{ x }$
$y = k * x$	$u(y) = k * u(x)$
(k = Cte. Exata)	

Fonte: (adaptado de KIRKUP et al., 2006)

Para o cálculo da combinação das incertezas, consideramos que todas as variáveis são correlacionadas. Cabe ressaltar, que se as variáveis forem independentes entre si, as relações da Tabela 3.2 são diferentes, conforme apresentado em (KIRKUP, et al., 2021).

Para o cálculo da incerteza da Eq. 56, temos então:

$$u(V_{RC}) = u((R_1 C_1)^{-1} * V_{RC}) + u(C_1^{-1} * I) \quad (58)$$

onde: $u(R_1)$ é a variância do parâmetro R_1 , $u(C_1)$ é a variância do parâmetro C_1 , $u(I)$ é a variância do ruído da corrente determinada na Eq. 54 e $u(V_{RC})$ é a variância do cálculo da tensão V_{RC} determinada na Eq. 65.

Resolvendo a Eq. 58, temos a seguinte sequência de equações:

$$u(R_1 C_1) = \left(\frac{u(R_1)}{R_1} + \frac{u(C_1)}{C_1} \right) * R_1 C_1 \quad (59)$$

$$u((R_1 C_1)^{-1}) = 1 * \frac{u(R_1 C_1)}{R_1 C_1} * (R_1 C_1)^{-1} \quad (60)$$

$$u((R_1 C_1)^{-1} * V_{RC}) = \left(\frac{u((R_1 C_1)^{-1})}{(R_1 C_1)^{-1}} + \frac{u(V_{RC})}{V_{RC}} \right) * ((R_1 C_1)^{-1} * V_{RC}) \quad (61)$$

$$u(C_1^{-1}) = 1 * \frac{u(C_1^{-1})}{C_1} * C_1^{-1} \quad (62)$$

$$u(C_1^{-1} * I) = \left(\frac{u(C_1^{-1})}{C_1^{-1}} + \frac{u(I)}{I} \right) * (C_1^{-1} * I) \quad (63)$$

Por meio da análise do circuito apresentado na Figura 2.5, a tensão do circuito RC é calculada pela Eq. 64:

$$V_{RC} = -V_T + b_0 + (b_1 * soc) + (R_0 * I) \quad (64)$$

onde: V_T é a tensão total da bateria.

Logo, a variância da tensão do circuito RC, presente na Eq. 61, é calculada conforme Eq. 65.

$$\mathbf{u}(V_{RC}) = -\mathbf{u}(V_T) + \mathbf{u}(\mathbf{b}_0) + \mathbf{u}(\mathbf{b}_1 * soc) + \mathbf{u}(R_0 * I) \quad (65)$$

A seguir, utilizando as equações 61, 63 e 65 é possível calcular a Eq. 58.

E para o cálculo da incerteza da Eq. 57, temos:

$$u(SOC) = \frac{1}{3600} * u(Cn^{-1}) * u(I) \quad (66)$$

onde: $u(Cn)$ é a variância do parâmetro Cn e $u(I)$ é a variância do ruído da corrente, descrita pela Eq. 54.

Resolvendo a Eq. 66, temos a seguinte sequência de equações:

$$u(SOC) = 277,78 * 10^{-6} * u(Cn^{-1}) * u(I) \quad (67)$$

$$u(Cn^{-1}) = 1 * \frac{u(Cn)}{Cn} * Cn^{-1} \quad (68)$$

$$\mathbf{u}(S\hat{O}C) = 277,78 * 10^{-6} * \left(\frac{u(Cn^{-1})}{Cn^{-1}} + \frac{u(I)}{I} \right) * Cn^{-1} * I \quad (69)$$

Portanto, utilizando as equações 61, 63, 65 e 69 é possível determinar a matriz de covariância de processo (Q_k) dada pela Eq. 55. É importante ressaltar que essa abordagem é totalmente dependente da precisão dos parâmetros do modelo matemático da bateria, além de depender também da variância do ruído de medição da corrente e da tensão. Portanto, essa definição das matrizes Q_k e R deve estar associada à abordagem de identificação dos parâmetros do modelo.

Essa abordagem também pode ser utilizada como autodiagnostico do próprio BMS, indicando possíveis problemas de *hardware* nas células, no condicionamento dos sinais, na filtragem analógica, etc. Uma vez que esse método está atrelado à medição em tempo real do ruído de medição da corrente e do ruído de medição da tensão, nos momentos em que há mudanças abruptas em algum de seus coeficientes, pode-se analisar se alguma falha grave está em andamento, permitindo a tomada de medidas de proteção e segurança.

4 RESULTADOS

Todo o algoritmo de estimação do estado da carga foi devidamente embarcado em um BMS especialmente projetado para esse trabalho. O *hardware* do BMS foi desenvolvido com o apoio do grupo de pesquisa em eletrônica automotiva (GEAUTO) da POLI-USP e com o apoio da HION Tecnologia, uma startup de tecnologia embarcada, com DNA USP.

Além de diversos componentes auxiliares, o *hardware* do BMS se baseia, principalmente, nos seguintes componentes:

- Um circuito integrado, que possui como principal função, as medições das tensões individuais das células, o qual é chamado de AFE (*Analogic front end*);
- Um microcontrolador, capaz de receber e enviar informações para o AFE, controlando e configurando todos os parâmetros necessários, e executar os algoritmos desenvolvidos para todas as funcionalidades desejadas;
- Um sensor de corrente com precisão adequada.

A placa de circuito impresso completa desse *hardware* é apresentada na Figura 4.1.




Figura 4.1 – Placa de circuito impresso do hardware do BMS.

Utilizando esse *hardware*, foi possível validar o modelo matemático da bateria e o algoritmo de estimação do estado da carga, considerando um conjunto de 8 células conectadas em série. Os resultados de todo esse trabalho de implementação, testes e validação são apresentados nas próximas seções.

4.1 MODELO MATEMÁTICO

Seguindo o fluxo de identificação de sistemas, apresentado na Figura 3.1, para a definição do melhor modelo matemático e do melhor critério de ajuste para aplicação da bateria em empilhadeiras elétricas, foram desenvolvidos 4 modelos diferentes. Cada modelo foi testado com 5 critérios de ajuste, sendo que o melhor modelo foi testado em 7 experimentos diferentes, para escolha do experimento mais apropriado. Essa metodologia foi apresentada na seção 3.1.1 e foram utilizados os dados apresentados na Figura 3.5. Os resultados da aplicação desses dados nos diferentes tipos de modelos, com os diferentes critérios de ajuste utilizados para verificação do ajuste dos dados simulados com os dados originais, são apresentados na Tabela 4.1, onde os melhores resultados são apresentados em verde e os piores são apresentados em laranja.

Tabela 4.1 – Ajuste com os dados de estimação com todos os métodos de otimização em cada modelo.

Ajuste com os dados de estimação				
Critérios de Ajuste	Modelo			
	Transfer Function (TF)	Output Error (OE)	Hammerstein Wiener (NLHW)	Nonlinear Grey Box Model (NLGR)
Subspace Gauss-Newton Least Square	68,76%	60,60%	79,58%	92,65%
Adaptative Subspace Gauss-Newton	54,64%	40,47%	93,80%	92,98%
Levenberg-Marquardt Least Square	70,13%	73,21%	93,94%	93,10%
Steepest Descent Least Square	-146,90%	-130,60%	24,56%	90,04%
Nonlinear Least Square	73,9%	78,34%	-234,10%	93,13%

Uma comparação entre os resultados de ajuste de cada modelo é apresentada na Tabela 4.2 e a análise visual pode ser realizada através da Figura 4.2.

Tabela 4.2 – Comparação entre os resultados de ajuste com dados de estimação e validação para cada um dos vários modelos avaliados.

Modelo	Ajuste com os Dados de Estimação	Ajuste com os Dados de Validação
TF	73,90%	58,73%
OE	78,81%	73,00%
NLHW	93,94%	63,01%
NLGR	93,13%	78,98%




Figura 4.2 – Comparação entre cada resposta do modelo em relação ao dado de estimação e de validação.

Analisando a Tabela 4.2, o modelo NLHW possui um melhor resultado com os dados de estimação (93,94%). Porém, a estimação dos parâmetros deve ser realizada com um conjunto de dados, enquanto que a validação deve ser realizada com outro conjunto (DA SILVA et al., 2021). Nesse caso, com os dados de validação, o melhor resultado foi atingido pelo modelo NLGR (78,98%). Isso também pode ser visto através da Figura 4.2, onde as saídas produzidas para a tensão pelo NLGR seguem mais fielmente os conjuntos de dados de estimação e de validação.

Como resultado, o melhor modelo foi considerado como o não linear, tipo caixa cinza (NLGR), enquanto que o melhor critério de ajuste foi o método dos mínimos quadrados não linear. As informações complementares sobre os resultados, foram apresentadas em (DA SILVA et al., 2021).

Esses resultados preliminares foram usados para a definição do melhor experimento capaz de descrever a dinâmica da bateria para aplicação em empilhadeira elétrica. O modelo NLGR foi aplicado em todos os experimentos definidos na seção 3.1.1, cujos resultados de ajuste aos dados são apresentados na Tabela 4.3. Nessa tabela, em azul é dado destaque ao melhor ajuste obtido, enquanto que o pior ajuste é apresentado em laranja.

Tabela 4.3 – Comparação entre todos os experimentos, relacionados aos dados de estimação e validação.

Dados de Estimação em 40% de SOC	Ajuste com os Dados de Validação em 40% de SOC						
	30s de descanso	18s de descanso	5s de descanso	1m ALTO 30s BAIXO	30s ALTO 30s BAIXO	30s ALTO 1m BAIXO	OCV com 1h de descanso
	V_{bat} (V)	V_{bat} (V)	V_{bat} (V)	V_{bat} (V)	V_{bat} (V)	V_{bat} (V)	V_{bat} (V)
30s de descanso	93,09%	91,63%	84,75%	87,74%	84,04%	86,44%	37,49%
18s de descanso	91,37%	90,30%	86,16%	85,55%	82,03%	86,10%	54,31%
5s de descanso	84,36%	84,18%	83,52%	78,71%	76,34%	77,69%	49,38%
1m ALTO 30s BAIXO	89,92%	89,28%	86,71%	90,57%	87,56%	90,06%	45,86%
30s ALTO 30s BAIXO	83,70%	83,67%	85,69%	88,37%	89,56%	88,12%	43,41%
30s ALTO 1m BAIXO	89,16%	88,32%	86,62%	90,03%	87,62%	90,47%	46,06%
OCV com 1h de descanso	39,56%	32,03%	31,68%	52,79%	59,76%	59,64%	72,97%

Todas essas estimações foram feitas com 40% de SOC, pois nesse ponto, a dinâmica da bateria possui não linearidades pequenas e o ajuste com os dados de validação são mais precisos. Na Tabela 4.3 é possível notar (na diagonal principal, em laranja) que o melhor resultado aparece quando os dados de estimação e validação são os mesmos. Esse resultado não é considerado, porque o modelo deve ser validado com um conjunto de dados diferente do conjunto utilizado para sua estimação (DA SILVA et al., 2021).

Os dados de estimação que apresentam os melhores resultados com os dados de validação são: “18s de descanso”, “1m alto 30s baixo” e “30s alto 1m baixo”. Um ponto importante que deve ser mencionado são os piores resultados. De acordo com a Tabela 4.3, o teste OCV apresenta o pior resultado com relação a todos os dados de validação. Isso ocorre porque a dinâmica do teste OCV é extremamente diferente dos outros experimentos. Isso enfatiza que o modelo da bateria estimado com o teste OCV, não irá funcionar adequadamente em uma bateria aplicada em empilhadeiras elétricas, motivo pelo qual esse trabalho se dedica ao desenvolvimento de uma melhor forma de desenvolver esse modelo.

Um jeito apropriado de verificar a exatidão do modelo estimado com o melhor experimento é o desvio padrão dos parâmetros e a variância de sua saída. Um pequeno valor no desvio padrão, mostra que o parâmetro é importante para explicar a dinâmica do sistema quando essa estrutura de modelo é escolhida. E um pequeno valor na variância de saída indica que o modelo captura os dados de estimação de uma boa forma. O desvio padrão dos parâmetros e a variância da saída são apresentados na Tabela 4.4, onde o melhor resultado é apresentado em azul, o pior resultado é apresentado em laranja, e o melhor resultado entre os melhores resultados da Tabela 4.3 são apresentados em verde.

Tabela 4.4 – Desvio padrão dos parâmetros estimados e variância da saída de todos os experimentos.

Dados de Estimação em 40% de SOC	Desvio Padrão			Variância da Saída
	R_0 (m Ω)	R_1 (m Ω)	C_1 (F)	V_{bat} (mV)
30s de descanso	7,84	8,66	2.783,49	2,74
18s de descanso	8,34	143	2.979,60	3,64
5s de descanso	9,44	3.005	29.673,00	5,32
1m ALTO 30s BAIXO	4,47	5,23	1.488,38	4,19
30s ALTO 30s BAIXO	7,03	5,92	1.976,67	4,97
30s ALTO 1m BAIXO	5,39	6,03	1.752,36	4,31
OCV com 1h de descanso	1,42	1,33	770,58	23,99

De acordo com a Figura 4.3 e com a Figura 4.4, o melhor experimento é o “1m alto 30s baixo” e considerando esse experimento, o desvio padrão do parâmetro R_0 , é 33,68% do valor de R_0 , o desvio padrão do parâmetro R_1 é 58,04% do valor de R_1 e o desvio padrão do parâmetro C_1 é 119% do valor de C_1 . O desvio padrão do parâmetro R_0 possui o menor valor quando comparado com os outros parâmetros. Portanto, esse parâmetro é o mais importante para explicar o sistema da bateria com esse experimento e essa estrutura de modelo. Entretanto, o desvio padrão de C_1 possui um valor muito alto. Na Figura 4.3, pode ser notado que o resultado do modelo não pode atingir toda a dinâmica de capacitância, isso resulta em um grande desvio padrão do parâmetro C_1 .

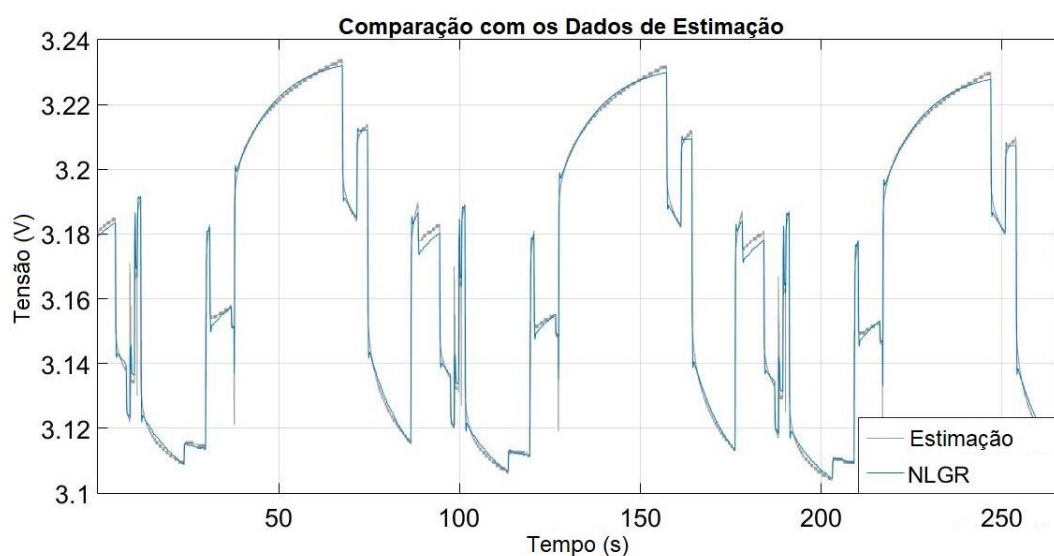


Figura 4.3 – Resultado dos dados de estimação com o modelo NLGR com o melhor experimento.

Considerando os melhores resultados da Tabela 4.3 e da Tabela 4.4, é possível concluir que o melhor experimento para a bateria LiFePO₄ utilizadas para empilhadeiras elétricas é o “1m alto 30s baixo”. Como apresentado na Tabela 4.3, esse experimento foi capaz de ajustar melhor a dinâmica da bateria em simulações, mesmo usando dados de diferentes características (“5s de descanso” e “30s alto e 1m baixo”). E como pode ser visto na Tabela 4.4, o experimento “1m alto 30s baixo” possui uma boa precisão nos parâmetros estimados e na saída estimada. Em outras palavras, os parâmetros identificados com esse experimento são capazes de descrever melhor a dinâmica da bateria sobre diferentes condições de uso em empilhadeiras elétricas.

É importante mencionar que o melhor desvio padrão é apresentado no teste “OCV com 1h de descanso”, similar à Figura 3.5, entretanto, esse experimento possui a pior variância de saída e o pior ajuste com os dados de validação. Essa informação mostra a importância de avaliar mais de um conjunto de dados na escolha do melhor experimento para a estimação do modelo. Agora, realizando o procedimento de identificação com o melhor experimento (“1m alto 30s baixo”), em todos os pontos de SOC, temos os parâmetros apresentados na Tabela 4.5. Os parâmetros b_0 e b_1 foram calculados através da metodologia apresentada na seção 3.1.2 e o teste OCV foi realizado com 1h de descanso da bateria.

Tabela 4.5 – Parâmetros da bateria em todos os pontos de SOC.

SOC (%)	b_0	b_1	R_0 (m Ω)	R_1 (m Ω)	C_1 (F)
10	2,87	3,35	14,01	27,10	420,55
20	3,16	0,39	13,60	12,33	833,84
30	3,18	0,32	13,38	9,98	1.109,31
40	3,25	0,08	13,27	9,01	1.249,35
50	3,28	0,01	13,23	8,25	1.399,30
60	3,26	0,04	13,15	7,71	1.473,69
70	3,15	0,23	13,13	7,40	1.526,64
80	3,25	0,09	13,29	7,77	1.509,14
90	3,31	0,01	13,56	8,22	1.445,43
100	2,12	1,33	15,35	7,23	1.927,32

Esses parâmetros são o resultado da estimação do modelo não linear caixa cinza, utilizando o experimento (“1m alto 30s baixo”), o qual foi desenvolvido com foco na dinâmica da bateria utilizada em empilhadeiras elétricas, tendo sido escolhi-

do entre outros 6 experimentos diferentes. A validação do resultado do modelo foi realizada comparando a tensão da bateria medida, e a tensão da bateria estimada pelo modelo, conforme apresenta a Figura 4.3, com 90,57% de precisão e com um erro de no máximo 50mV.

O resultado apresentado na Figura 4.3 foi atingido através da estimação do modelo em 40% de estado da carga inicial, esse estado da carga foi estimado utilizando o método do *coulomb counting* implementado no BMS durante os testes. Entretanto, durante a estimação dos parâmetros do modelo, também é possível estimar seus estados iniciais através do método de otimização dos mínimos quadrados. Nesse contexto, o ideal é que o estado da carga inicial estimado pelo modelo possua um valor próximo ao estado da carga inicial estimado pelo *coulomb counting*. Nesse caso, o SOC inicial estimado pelo modelo apresentou o valor de 29,17%. Portanto, o método de otimização, utilizado para estimar o estado da carga inicial da bateria, apresentou um resultado diferente do estado da carga pelo algoritmo de *coulomb counting*. Isso ocorre porque os dados utilizados para a estimação do modelo não conseguem descrever o estado da carga de forma precisa. Essa situação não ocorre quando utilizamos o teste OCV para estimação do modelo, pois o teste OCV é capaz de descrever o estado da carga em um regime estacionário. Entretanto, o teste OCV nem sempre é o melhor para a estimação dos parâmetros do modelo, pois trata-se de um teste com a bateria em vazio, sem a imposição das diversas condições e características de carga e descarga, específicas da aplicação. O modelo deve sempre ser estimado num teste com foco na aplicação em que será utilizado (DA SILVA et al., 2021).

Para que o método de otimização seja capaz de reconhecer o estado da carga da bateria, em qualquer tipo de experimento, foi desenvolvido um modelo não linear caixa cinza de duas saídas (2out_NLGR), considerando o estado da carga da bateria como uma das saídas do modelo, conforme apresentado na seção 3.1.4.

4.1.2 Modelo não linear caixa cinza com duas saídas (2out_ NLGR)

Esse novo modelo foi aplicado em todos os experimentos definidos na seção 3.1.1, e o resultado em relação à saída de tensão da bateria V_{bat} (y_1) é apresentado na Tabela 4.6, onde os melhores são apresentados em azul e os piores são apresentados em laranja. O resultado em relação à saída que representa o estado da carga da bateria SOC (y_2) é apresentado na Tabela 4.7.

Tabela 4.6 – Comparação entre todos os experimentos, relacionados aos dados de estimação e validação, em relação à saída V_{bat} (y_1).

Dado de Estimação em 40% de SOC	Ajude com os Dados de Validação em 40% de SOC						
	30s de descanso	18s de descanso	5s de descanso	1m ALTO 30s BAIXO	30s ALTO 30s BAIXO	30s ALTO 1m BAIXO	OCV com 1h de descanso
	V_{bat}	V_{bat}	V_{bat}	V_{bat}	V_{bat}	V_{bat}	V_{bat}
30s de descanso	93,03%	88,07%	76,45%	58,27%	73,45%	84,00%	37,32%
18s de descanso	87,10%	91,99%	79,39%	65,05%	78,18%	83,12%	35,52%
5s de descanso	69,26%	79,89%	87,60%	74,02%	82,06%	72,92%	30,84%
1m ALTO 30s BAIXO	61,84%	64,40%	62,91%	90,57%	82,83%	75,30%	38,09%
30s ALTO 30s BAIXO	70,24%	73,56%	75,56%	82,63%	89,56%	84,10%	40,40%
30s ALTO 1m BAIXO	82,36%	83,04%	79,91%	78,60%	86,12%	90,47%	44,89%
OCV com 1h de descanso	39,43%	31,14%	31,13%	52,64%	57,28%	46,77%	72,97%

Tabela 4.7 – Comparação entre todos os experimentos, relacionados aos dados de estimação e validação, em relação à saída SOC (y_2).

Dado de Estimação em 40% de SOC	Fit to Validation Data in 40% of SOC						
	30s de descanso	18s de descanso	5s de descanso	1m ALTO 30s BAIXO	30s ALTO 30s BAIXO	30s ALTO 1m BAIXO	OCV com 1h de descanso
	SOC	SOC	SOC	SOC	SOC	SOC	SOC
30s de descanso	99,53%	99,41%	99,31%	99,71%	99,49%	99,53%	99,93%
18s de descanso	99,50%	99,43%	99,29%	99,64%	99,47%	99,49%	99,92%
5s de descanso	99,48%	99,40%	99,32%	99,73%	99,51%	99,53%	99,91%
1m ALTO 30s BAIXO	99,43%	99,36%	99,27%	99,74%	99,50%	99,50%	99,93%
30s ALTO 30s BAIXO	99,51%	99,41%	99,31%	99,74%	99,51%	99,53%	99,94%
30s ALTO 1m BAIXO	99,50%	99,36%	99,30%	99,70%	99,48%	90,56%	99,79%
OCV com 1h de descanso	99,53%	99,42%	99,31%	99,74%	99,51%	99,51%	99,97%

Analisando a Tabela 4.6, o melhor experimento relacionado à tensão da bateria é o experimento “30s alto 1m baixo” e o pior é o “OCV 1h descanso”. O melhor resultado nesse caso, também foi um dos melhores resultados apresentados na Tabela 4.3 com o NLGR. O pior resultado nesse caso, também foi o pior resultado apresentado na Tabela 4.3 com o NLGR.

Analisando a Tabela 4.7, o melhor experimento relacionado ao estado da carga da bateria é o experimento “OCV 1h descanso”, enquanto que os piores são o “18s descanso” e “1m alto 30s baixo”. Entretanto, todos os resultados apresentados na Tabela 4.7 são maiores que 99%, ou seja, todos os experimentos são capazes de estimar o estado da carga com boa precisão. O experimento OCV é o que melhor representa o estado da carga da bateria, porém, não é capaz de representar a tensão da bateria com precisão.

Nesse caso, o experimento capaz de descrever a dinâmica da bateria com melhor exatidão foi o experimento “30s alto 1m baixo”, o qual obteve ótimos resultados, tanto em relação à tensão da bateria, quanto em relação ao estado da carga. Entretanto, conforme apresentado na seção anterior, o melhor experimento deve ser avaliado também em relação ao desvio padrão dos parâmetros e à variância da saída. Nesse caso, o desvio padrão dos parâmetros e a variância da saída são apresentados na Tabela 4.8, onde o melhor resultado é apresentado em azul, e o pior em laranja. O melhor entre os melhores resultados, seja na Tabela 4.6 ou na Tabela 4.7 é destacado em verde.

Tabela 4.8 – Desvio padrão dos parâmetros estimados e variância da saída de todos os experimentos estimados com o modelo de duas saídas.

Dados de Estimação em 40% de SOC	Desvio Padrão			Variância da Saída	
	R_0 (m Ω)	R_1 (m Ω)	C_1 (F)	V_{bat} (mV)	SOC (%)
30s de descanso	$2,15 * 10^{-2}$	$2,37 * 10^{-2}$	7,63	2,74	$2,19 * 10^{-5}$
18s de descanso	$2,61 * 10^{-2}$	$2,46 * 10^{-2}$	9,16	3,01	$2,99 * 10^{-5}$
5s de descanso	$4,11 * 10^{-2}$	$5,46 * 10^{-2}$	18,59	4,00	$2,85 * 10^{-5}$
1m ALTO 30s BAIXO	$1,87 * 10^{-2}$	$2,19 * 10^{-2}$	6,23	4,19	$2,60 * 10^{-5}$
30s ALTO 30s BAIXO	$3,49 * 10^{-2}$	$2,94 * 10^{-2}$	9,82	4,97	$2,87 * 10^{-5}$
30s ALTO 1m BAIXO	$2,15 * 10^{-2}$	$2,60 * 10^{-2}$	7,56	4,31	$2,54 * 10^{-5}$
OCV com 1h de descanso	$3,42 * 10^{-2}$	$3,17 * 10^{-2}$	18,31	23,99	$2,70 * 10^{-5}$

Analisando a Tabela 4.8 é possível notar que o desvio padrão de todos os parâmetros é 100 vezes menor do que aqueles obtidos com o modelo NLGR, apresentado na Tabela 4.4. A variância da saída da tensão da bateria é muito similar em comparação com o NLGR em todos os experimentos, entretanto, os parâmetros estimados são 100 vezes mais precisos utilizando o modelo 2out_ NLGR.

Em resumo, considerando os melhores resultados da Tabela 4.6, Tabela 4.7 e Tabela 4.8, é possível concluir que o melhor experimento para identificação dos parâmetros do modelo matemático de baterias LiFePO₄ utilizadas em empilhadeiras elétricas é o “30s alto 1m baixo”.

4.1.3 Modelo “2out_ NLGR” estimado com o melhor experimento

Nessa seção, o modelo não linear caixa cinza com duas saídas será apresentado em mais detalhes. As seguintes estimações serão realizadas com o melhor experimento, definido na seção 4.1.2, com 40% de SOC. Os parâmetros iniciais foram calculados conforme seção 3.1.3 e os estados iniciais foram estimados através do método dos mínimos quadrados não linear. O ajuste com os dados de estimação foi de 69,61% em relação à tensão da bateria (y_1), 94,86% em relação ao estado da carga (y_2) e o resultado dos estados iniciais são:

- $V_{RC} = 0,0633 V$
- $SOC = 0,3997$ ou 39,97 %

É importante ressaltar que o estado da carga inicial estimado pelo método dos mínimos quadrados não linear foi muito próximo do estado da carga calculado através do algoritmo *coulomb counting*.

Conforme descrito na seção 3.1.4, é possível determinar qual será o peso dado à cada saída no momento da identificação dos parâmetros da bateria. Nesse caso, é necessário inicialmente identificar os parâmetros do modelo com pesos iguais nas duas saídas, calcular suas variâncias, para então identificar os parâmetros do modelo novamente com o inverso da variância em cada saída,

conforme apresentado na Figura 3.8. A Tabela 4.9 apresenta uma comparação do resultado do modelo sem peso nas saídas e com peso nas saídas.

Tabela 4.9 – Comparação entre a primeira estimação sem peso e a segunda estimação com peso nas saídas.

Primeira estimação (Sem peso nas saídas)						
Ajuste com a Estimação		Desvio Padrão			Variância da Saída	
V_{bat}	SOC	R_0 (m Ω)	R_1 (m Ω)	C_1 (F)	V_{bat} (mV)	SOC (%)
90,47%	99,56%	$2,32949 * 10^{-2}$	$2,60569 * 10^{-2}$	7,56323	4,31780389	$2,5477742 * 10^{-5}$
Segunda estimação (Peso = 1/Var)						
Ajuste com a Estimação		Desvio Padrão			Variância da Saída	
V_{bat}	SOC	R_0 (m Ω)	R_1 (m Ω)	C_1 (F)	V_{bat} (mV)	SOC (%)
90,47%	99,56%	$2,32958 * 10^{-2}$	$2,60496 * 10^{-2}$	7,56253	4,31780368	$2,5477737 * 10^{-5}$

Analisando a Tabela 4.9, o ajuste com o dado de estimação obteve exatamente o mesmo resultado, independente da estimação sem peso ou com peso. Em relação ao desvio padrão dos parâmetros, somente o parâmetro R_0 não obteve uma diminuição em seu desvio quando estimado com peso nas saídas. Já a variância na saída, também obteve melhor resultado na segunda estimação, com peso nas saídas. Ou seja, em geral, a estimação realizada com peso na saída obteve resultados melhores, aumentando a precisão do modelo. É possível realizar uma inspeção visual do resultado com os dados de estimação através da Figura 4.4.

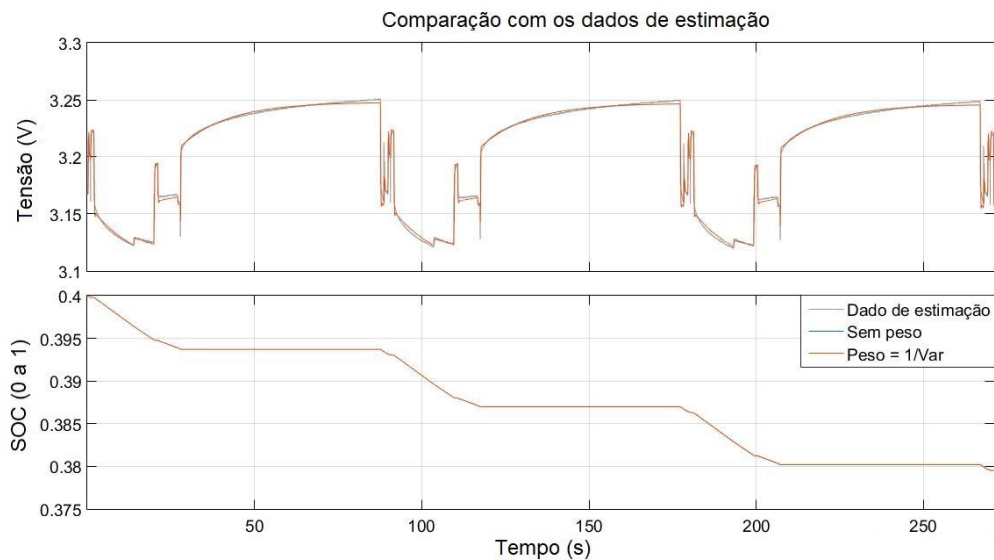


Figura 4.4 – Comparação com os dados de estimação do modelo não linear caixa cinza com duas saídas estimado com o melhor experimento.

É possível observar que o resultado do modelo estimado sem peso e com peso possuem valores muito semelhantes. Para facilitar a comparação entre as grandezas, a Figura 4.5 apresenta detalhes de uma parte do sinal, ampliado.




Figura 4.5 – Comparação com os dados de estimação do modelo não linear caixa cinza com duas saídas estimado com o melhor experimento – Sinal ampliado.

Porém, é necessário validar o modelo com dados diferentes dos dados utilizados para estimação. Nesse caso, o dado de validação escolhido foi o experimento “1m alto 30s baixo”, pois de acordo com a Tabela 4.6, esse experimento apresenta o pior resultado de ajuste para o modelo estimado com o experimento “30s alto 1m baixo”, então iremos validar o modelo em seu pior caso. A Figura 4.6 apresenta a comparação com os dados de validação, sendo possível obter um ajuste em relação à tensão da bateria de 78,9% (sem peso) e 78,6% (com peso). O ajuste em relação ao estado da carga (principal objetivo desse trabalho) foi de 89% (sem peso) e 99,7% (com peso).




Figura 4.6 – Comparação com os dados de validação do modelo não linear caixa cinza com duas saídas estimado com o melhor experimento.

Analisando a Figura 4.6, é possível visualizar a diferença entre o resultado do estado da carga com o modelo estimado sem peso nas saídas e com peso nas saídas, com uma discrepância de aproximadamente 10%. Já em relação à tensão da bateria, a diferença entre o resultado do modelo estimado com peso e sem peso é de apenas 0,3%. O erro de predição entre a tensão da bateria medida e a tensão da bateria estimada é apresentado na Figura 4.7.




Figura 4.7 – Erro de predição em relação à tensão da bateria.

Analisando a Figura 4.7 é possível notar que o erro geral é de no máximo 60mV, o que confirma uma boa precisão do modelo, mesmo com o pior conjunto de dados como entrada para validação. É possível observar que o erro de predição do modelo estimado sem peso e com peso possuem valores muito semelhantes. Para facilitar a comparação entre as grandezas, a Figura 4.8 apresenta detalhes de uma parte do sinal, ampliado.




Figura 4.8 – Erro de predição em relação à tensão da bateria – Sinal ampliado.

O erro de predição entre o estado da carga calculado pelo *coulomb counting* e o estado da carga estimado pelo modelo é apresentado na Figura 4.9.




Figura 4.9 – Erro de predição em relação ao estado da carga.

Analisando a Figura 4.9 é possível notar um valor baixo do erro entre o valor estimado e o medido. Entretanto, é possível notar também, alguma diferença entre o resultado do erro com o modelo estimado sem peso e com peso. Apesar de pequeno, o erro de predição maior, no caso sem peso, evidencia que o estado de carga calculado pelo modelo possui algum viés, ou alguma influência (*biased*) com outros parâmetros ou fenômenos. Entretanto, o ajuste proposto no peso das saídas, melhorar a estimativa do SOC, com um erro de predição bastante inferior, fortalecendo a ideia de definir pesos específicos entre as duas saídas do modelo.

Dessa forma, pode-se afirmar que o modelo não linear caixa cinza com duas saídas, e com pesos específicos nas saídas, estimado com o melhor experimento, foi apropriadamente validado.

Foi possível realizar o procedimento de identificação dos parâmetros em todos os pontos de SOC, resultando nos parâmetros apresentados na Tabela 4.10.

Tabela 4.10 – Parâmetros da bateria em todos os pontos do SOC, estimados com 2out_NLGR.

SOC (%)	b_0	b_1	R_0 (m Ω)	R_1 (m Ω)	C_1 (F)
10	2,87	3,35	15,27	19,20	712,97
20	3,16	0,39	14,46	12,38	1.102,95
30	3,18	0,32	14,23	10,91	1.296,85
40	3,25	0,08	14,00	9,91	1.443,59
50	3,28	0,01	13,84	9,16	1.578,57
60	3,26	0,04	13,66	8,42	1.645,65
70	3,15	0,23	13,59	8,36	1.679,73
80	3,25	0,09	13,83	9,95	1.628,80
90	3,31	0,01	13,99	9,60	1.575,89
100	2,12	1,33	13,92	8,43	1.512,54

O modelo atingiu uma exatidão de 78,6% em relação à tensão da bateria e 99,7% em relação ao estado da carga no seu pior caso, o qual possui um erro de no máximo 60mV em relação à tensão da bateria, conforme apresentado na Figura 4.7, e no máximo 0,01% em relação ao estado da carga, como mostrado na Figura 4.9.

Os parâmetros apresentados na Tabela 4.10 possuem uma precisão 100 vezes maior do que os parâmetros apresentados na Tabela 4.5 e são importantes para descrever a dinâmica da bateria, essa informação é necessária para um bom algoritmo de estimação de estado da carga aplicado em um BMS real no cenário de aplicação desejado.

4.2 ALGORITMO PARA ESTIMATIVA DO ESTADO DA CARGA

O estado da carga foi estimado através do filtro de Kalman estendido adaptativo, conforme a metodologia apresentada na seção 3.2. Para aplicação do filtro de Kalman estendido, é necessário discretizar o modelo no espaço de estados em tempo contínuo, o qual foi apresentado nas Equações 23 e 24. Dessa forma aplicando as equações 34 a 37, é possível obter as seguintes matrizes para o modelo, no domínio das amostras. Ressalta-se que o tempo de amostragem T_s utilizado foi de 10ms.

$$A_d = \begin{bmatrix} \frac{R_1 * C_1}{(R_1 * C_1) + T_s} & 0 \\ 0 & 1 \end{bmatrix} \quad (70)$$

$$B_d = \begin{bmatrix} \frac{-T_s * R_1 * C_1}{(R_1 * C_1) + T_s} \\ 1 \\ \frac{1}{3600 * C_n} \end{bmatrix} \quad (71)$$

$$C_d = \begin{bmatrix} \frac{-R_1 * C_1}{(R_1 * C_1) + T_s} & b_1 \end{bmatrix} \quad (72)$$

$$D_d = \left[\frac{T_s * R_1 * C_1}{(R_1 * C_1) + T_s} + \frac{b_1}{3600 * C_n} + R_0 \right] \quad (73)$$

O diagrama de blocos do filtro de Kalman estendido foi apresentado na Figura 3.9, onde as matrizes F e H são matrizes Jacobianas, necessárias para a discretização do sistema por meio do método de Euler, com linearização por meio da expansão em série de Taylor. Dessa forma aplicando as equações 40 a 45 detalhadas na seção 3.2, é possível obter as seguintes matrizes Jacobianas:

$$F = \begin{bmatrix} -\frac{T_s}{R_1 * C_1} & 0 \\ 0 & 0 \end{bmatrix} \quad (74)$$

$$H = [-T_s \quad b_1 * T_s] \quad (75)$$

Um registro de oscilografia real, obtido com o *hardware* do BMS, permite observar o ruído de medição da tensão da bateria, como o apresentado na Figura 4.10, onde se nota um ruído característico de um processo de digitalização e quantização, além de um comportamento levemente decrescente, uma vez que a bateria está num processo de descarga nesse momento. Apenas o ruído resultante do processo de condicionamento, filtragem analógica e quantização é de interesse nessa análise.

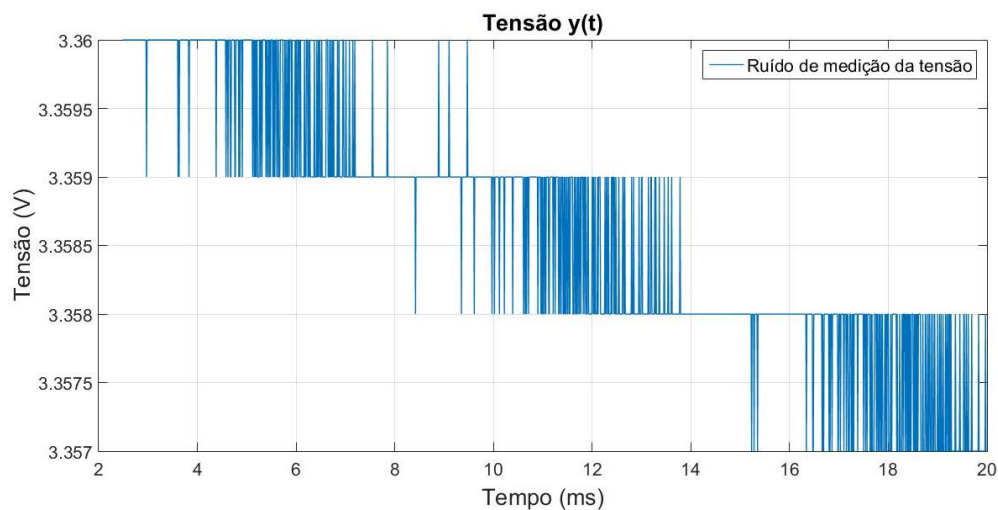


Figura 4.10 – Ruído de medição da tensão.

Em outro registro, é possível observar o ruído de medição da corrente da bateria, como o apresentado na Figura 4.11 onde, além de ruídos relacionados ao condicionamento, filtragem e quantização, notam-se outras componentes e influências no sinal medido. É importante frisar que a bateria estava submetida, nessa ocasião, a um regime de descarga a corrente constante a qual é proveniente do próprio consumo do BMS.

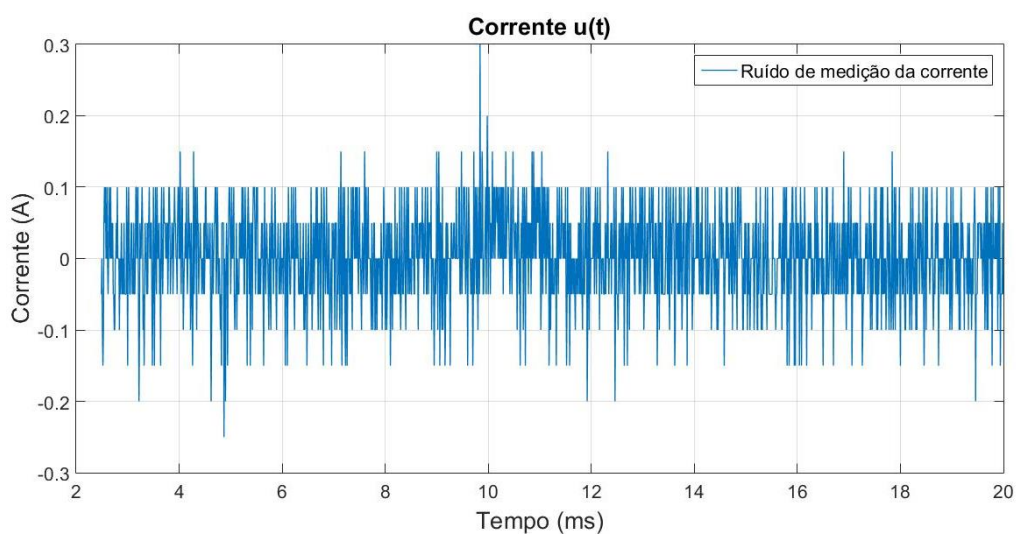


Figura 4.11 – Ruído de medição da corrente.

A covariância do ruído de medição da tensão (uV) e da corrente (uI), calculados por meio da análise da Figura 4.10 e Figura 4.11 são apresentados nas Eq. 76 e 77, entretanto, é importante ressaltar que esses valores são atualizados a cada 3 iterações do software (30,0ms) para melhor precisão do resultado.

$$uV = 7,50 * 10^{-4} \quad (76)$$

$$uI = 4,54 * 10^{-3} \quad (77)$$

Para validação em ambiente computacional do algoritmo do filtro de Kalman estendido, foi utilizado o experimento “30s alto 30s baixo”, pois esse representa uma condição de uso mediana da empilhadeira, além de ser suficiente para validar o algoritmo antes de embarcá-lo no BMS para validação em ambiente real. Nesse caso, foi inserido um erro de estimação inicial com desvio padrão de 33,33% (ou 2V, considerando a célula utilizada) para a tensão V_{RC} (x_1), e um erro de estimação inicial com desvio padrão de 10% para o SOC (x_2). Os valores iniciais foram colocados bastante elevados, mas devem ser corrigidos pelo próprio algoritmo em tempo de execução, convergindo para os valores observados para essas incertezas. Logo, a matriz de covariância inicial é apresentada na Eq.78.

$$P_{k-1} = \begin{bmatrix} 4 & 0 \\ 0 & 0.01 \end{bmatrix} \quad (78)$$

Onde os valores da Eq. 78 são definidos por meio da variância de cada parâmetro, a qual é calculada pela Eq. 79.

$$var = dp^2 \quad (79)$$

Onde var é a variância do parâmetro e dp é o desvio padrão do parâmetro.

Na matriz de estados iniciais, foram admitidos 0V para a tensão V_{RC} (x_1) e 100% para o SOC (x_2). Assim, temos a matriz de estados iniciais apresentada na Eq. 80.

$$X_{k-1} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (80)$$

O algoritmo do Filtro de Kalman Estendido Adaptativo foi feito conforme apresentado na Seção 3.2 e a Figura 4.12 apresenta um resumo dos cálculos necessários para sua execução, com base no diagrama apresentado na Figura 3.9.

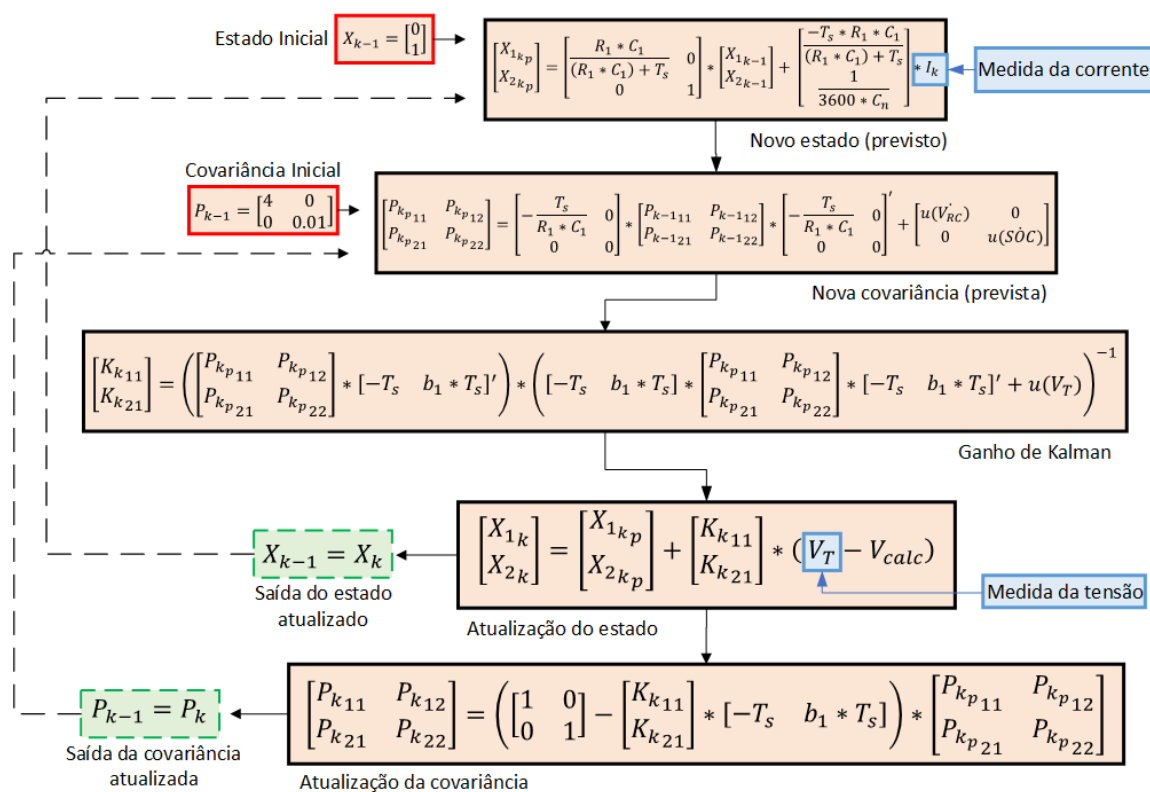


Figura 4.12 – Equações do algoritmo do filtro de Kalman estendido adaptativo.

O resultado ao longo do tempo dos coeficientes da matriz de covariância (P_{kp} e P_k) relacionada ao estado x_1 é apresentada na Figura 4.13.




Figura 4.13 – Covariância estimada e atualizada, relacionada ao estado x_1 (V_{RC})

A Figura 4.13 mostra a covariância estimada (P_{k_p}) em azul, e a covariância atualizada (P_k) em vermelho. Nessa Figura é possível concluir que ambas as covariâncias (estimada e atualizada), possuem uma característica muito semelhante, com um valor médio em torno de $1,09 * 10^{-4}$. A matriz de covariância (P_{k_p} e P_k) relacionada ao estado x_2 é apresentada na Figura 4.14.




Figura 4.14 – Covariância estimada e atualizada, relacionada ao estado x_2 (SOC)

Analisando a Figura 4.14 também é possível concluir que ambas as covariâncias (estimada e atualizada), possuem características semelhantes, com um valor médio em torno de $1,0 * 10^{-5}$. Para facilitar a visualização da diferença entre os dois sinais, a Figura 4.15 apresenta um detalhe ampliado.




Figura 4.15 – Covariância estimada e atualizada, relacionada ao estado x_2 (SOC) – Sinal ampliado.

Analisando a Figura 4.15 é possível verificar que a covariância atualizada é sempre menor do que a covariância estimada, ou seja, o erro na estimativa do estado SOC diminui no decorrer do algoritmo. Além disso, a covariância é baixa, na ordem de $2 * 10^{-5}$, o que indica que o erro na estimativa do estado da carga é pequeno, como desejado para um estimador nessas condições.

A matriz do ganho de Kalman (K) relacionada ao estado x_1 é apresentada na Figura 4.16.




Figura 4.16 – Ganho de Kalman relacionado ao estado x_1

A matriz do ganho de Kalman (K) relacionada ao estado x_2 é apresentada na Figura 4.17.




Figura 4.17 – Ganho de Kalman relacionado ao estado x_2 .

Analisando a Figura 4.17 é possível observar que os maiores ganhos ocorrem no início e no fim do teste, onde a bateria apresenta maior não linearidade. Nesses pontos, o filtro de Kalman está considerando que a medição da tensão da bateria possui maior peso na estimativa do estado. Entretanto, os pontos centrais do teste,

indicam que o filtro de Kalman está considerando que a estimativa do estado anterior possui mais peso na estimativa do estado atual do que a medição da tensão da bateria, pois esses são os pontos de menor não linearidade da bateria.

A tensão da bateria estimada (através desse modelo matemático) e a tensão medida são apresentadas na Figura 4.18. O algoritmo do filtro de Kalman realiza uma comparação entre os dois valores para realizar a estimação dos estados (SOC e V_{RC}) da bateria.

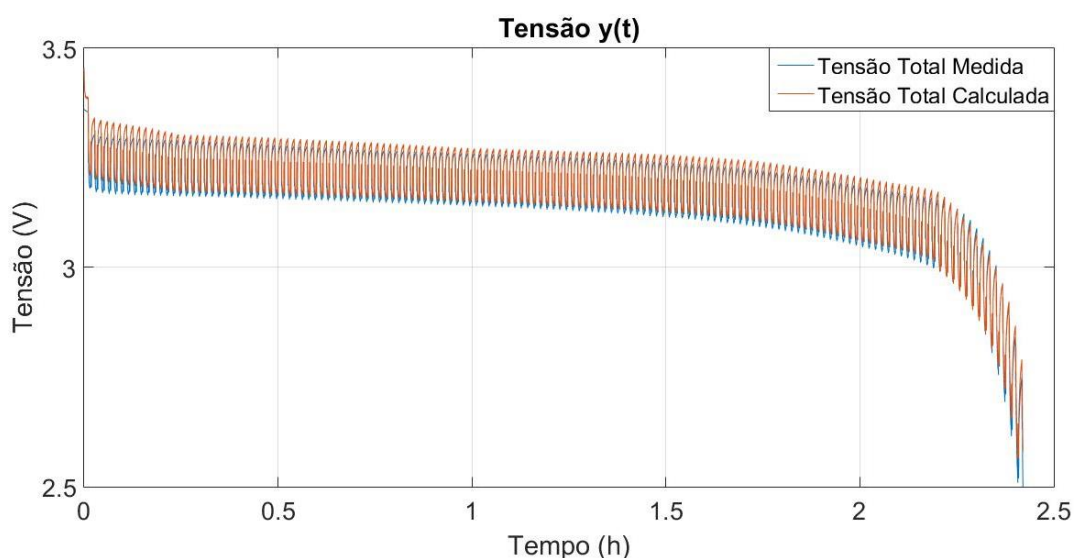


Figura 4.18 - Tensão total medida e estimada.

Analisando a Figura 4.18 é possível observar que os valores medidos e calculados são muito semelhantes.

A diferença percentual entre a tensão medida e a tensão estimada é de no máximo 5,4%, no ponto de maior não linearidade da célula, conforme apresenta a Figura 4.19. Entretanto, em média, a diferença percentual se encontra em 0,44%, obtendo então, uma precisão de 99,56% em média.




Figura 4.19 – Diferença percentual entre a tensão medida e calculada.

A diferença entre a tensão medida e a tensão estimada é apresentada na Figura 4.20 e é utilizada no algoritmo do filtro para o cálculo do ganho de Kalman.




Figura 4.20 – Diferença entre tensão medida e tensão estimada.

Na Figura 4.20 é possível observar a diferença inicial (delta inicial) em azul, a qual é utilizada no cálculo do ganho de Kalman, e a diferença final (delta final) em vermelho, a qual é calculada ao final de cada iteração do algoritmo. Sabe-se que a diferença inicial deve ser sempre maior do que a diferença final. A maior diferença

final foi de 0,10V, com média de -0,01V. Os resultados e as informações apresentadas nas Figura 4.18, Figura 4.19 e Figura 4.20 são capazes de validar por completo o modelo matemático utilizado para descrever a dinâmica da bateria, apresentando uma diferença média de apenas 0,44% entre a tensão medida e a tensão estimada pelo modelo. A tensão no circuito RC (V_{RC}), representada pelo estado x_1 , calculada ao final do algoritmo do filtro de Kalman, é apresentada na Figura 4.21.

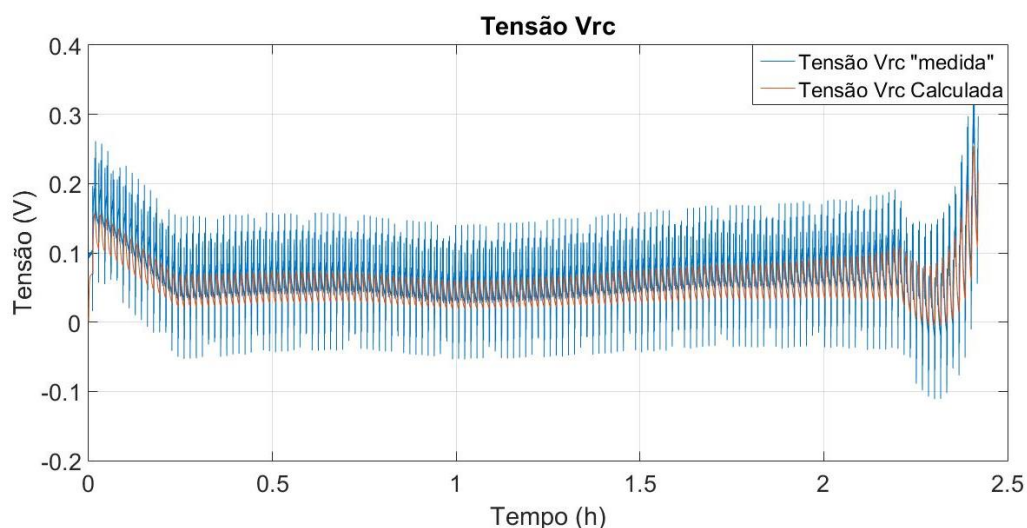


Figura 4.21 – Tensão V_{RC} “medida” e tensão V_{RC} calculada.

A Figura 4.21 apresenta a tensão V_{RC} “medida” (azul), a qual é calculada através da Eq. 64, e a tensão V_{RC} (vermelho), a qual é calculada ao final do algoritmo de Kalman. É possível observar que os dois valores são muito próximos e possuem um comportamento semelhante, validando o algoritmo de Kalman e o modelo da bateria.

O estado da carga da bateria foi validado realizando uma comparação entre o estado da carga calculado através do algoritmo *coulomb counting* (SOC CC BMS) implementado no BMS, e o estado da carga estimado através do algoritmo do filtro de Kalman estendido (SOC Kalman). Dessa forma, o estado da carga estimado por ambos é apresentado na Figura 4.22.




Figura 4.22 – Estado da carga calculado pelo algoritmo *coulomb counting* e estado da carga estimado pelo algoritmo de Kalman.

O resultado apresentado na Figura 4.22 indica que o algoritmo do filtro de Kalman foi implementado com sucesso e totalmente validado no ambiente computacional com simulações digitais. É importante ressaltar que o estado da carga estimado pelo algoritmo do Filtro de Kalman possui um valor final mais coerente do que o algoritmo *coulomb counting*, pois no teste realizado, a célula é descarregada até o final e o SOC deveria apresentar o valor de 0%, entretanto, o valor final apresentado pelo algoritmo *coulomb counting* foi de 1,56% de SOC e o valor final apresentado pelo algoritmo do filtro de Kalman foi de 0,59% de SOC.

Portanto, a precisão do algoritmo foi calculada por meio da diferença entre a tensão medida por meio do sensor e a tensão estimada por meio do modelo matemático inserido no algoritmo do filtro de Kalman Adaptativo, essa diferença porcentual foi apresentada na Figura 4.19. A avaliação da precisão do algoritmo foi realizada dessa maneira, uma vez que a tensão medida da bateria é a única informação retirada de um sensor, portanto, se a avaliação da precisão for realizada em comparação com o estado da carga pelo algoritmo de *coulomb counting*, o resultado será impreciso pois o *coulomb counting* também se trata de um estimador, e acumula erros durante sua execução conforme apresenta a seção 2.3.4.1.

Para validação completa do algoritmo, foi realizada sua implementação no *hardware* real de um BMS. A Figura 4.23 apresenta uma comparação entre o algoritmo executado em ambiente de simulação (Matlab) e no ambiente embarcado. No ambiente embarcado foi utilizada linguagem C, com aritmética de ponto flutuante de precisão dupla, com todas as rotinas desenvolvidas de forma autoral, incluindo todos os cálculos com matrizes e vetores. Dessa forma, foi possível evitar rotinas prontas com funções muitas vezes não utilizadas que ocasionariam em um grande custo computacional desnecessário. Nesta figura são mostradas as saídas do SOC de ambas as implementações.




Figura 4.23 – Comparação entre o algoritmo executado com simulação computacional e o algoritmo embarcado no BMS.

Para a validação do algoritmo, os dados da corrente da bateria foram inseridos de forma artificial no código embarcado utilizando um computador externo, o qual fez o envio sincronizado dos dados ao BMS, para que fosse possível inserir uma grande quantidade de informações, sem resultar em tempo extra computacional para o BMS. Os dados inseridos foram exatamente os mesmos utilizados no ambiente de simulação (Matlab), garantindo assim, exatamente as mesmas entradas para ambos os algoritmos, esperando-se produzir exatamente as mesmas saídas. Analisando a Figura 4.23 é possível observar que os dois sinais são exatamente

iguais, dessa forma, foi possível validar completamente a implementação do algoritmo do filtro de Kalman embarcado no BMS.

A Figura 4.24 apresenta o tempo que o BMS precisa para realizar um ciclo completo do algoritmo, e estimar o estado da carga da célula. O tempo computacional é o período com nível lógico alto na onda quadrada mostrada.




Figura 4.24 – Tempo computacional do algoritmo no BMS.

Conforme apresenta a Figura 4.24, o tempo necessário para um ciclo completo do algoritmo foi de $180 \mu s$, utilizando um microcontrolador com *clock* de 240MHz. Este algoritmo se trata do filtro de Kalman Estendido completo, incluindo a implementação da estratégia adaptativa de reajuste do ruído do processo e ruído de medição. Somente essa estratégia adaptativa corresponde a aproximadamente 30% desse tempo computacional. De qualquer forma, o resultado de $180 \mu s$ é suficiente para que o microcontrolador seja capaz de calcular o estado da carga de cada célula em um conjunto de diversas células em série, garantindo tempo suficiente para a implementação de todas as demais funções necessárias do BMS.

Também é importante ressaltar que esse algoritmo específico do filtro pode ser fortemente otimizado no futuro, utilizando aritmética mais simples (precisão simples, ponto fixo ou aritmética inteira), sendo capaz de ser executado em microcontroladores e DSPs (*digital signal processor*) de menor *clock* e custo mais baixo. Também é possível vislumbrar a criação de um ASIC (*application-specific integrated circuit*) para essa finalidade, sintetizando um *hardware* dedicado à essa função.

4.3 VALIDAÇÃO DO ALGORITMO EM UM CONJUNTO DE 8 CÉLULAS

O algoritmo de estimação do estado da carga foi validado em um conjunto real de 8 células em série. Entretanto, para que os testes de carga e descarga desse conjunto de células fossem feitos de forma segura, foi necessário desenvolver um algoritmo de balanceamento. Nesse contexto, foi criado um algoritmo relativamente simples, que consiste em reconhecer qual é a célula que está com maior tensão, e acionar um transistor tipo FET conectado em paralelo à essa célula, descarregando a energia da mesma em um resistor. Esse esquema de balanceamento, conhecido como “passivo dissipativo”, é realizado na célula até que outra se torne a célula com maior tensão. Uma banda de histerese ajustável é utilizada no classificador das tensões, para que o processo de balanceamento somente seja ativado, se um determinado patamar de tensão for detectado em uma célula. Por meio dessa estratégia, é possível garantir um balanceamento mínimo de todas as células durante os testes de validação do algoritmo.

A validação do algoritmo foi realizada através de um ciclo completo de carga e descarga nas 8 células conforme apresenta a Figura 4.25 e a Figura 4.26.




Figura 4.25 – Corrente utilizada no teste do ciclo completo de carga e descarga.




Figura 4.26 – Tensão das células no teste de ciclo completo.

Analisando a Figura 4.26 é possível verificar o momento do balanceamento das células. O balanceamento se inicia no ciclo de carga, perto da tensão de 3,4V, pois é o momento em que a tensão das células possui maior diferença entre si.

Durante o balanceamento, é possível visualizar a mudança no valor de tensão das células, pois no momento em que uma célula é balanceada, sua tensão diminui e outra se torna a célula com a tensão mais alta.

Nesse contexto, é possível compreender que o estado da carga é diretamente afetado pelo balanceamento, pois a energia das células se altera nesses instantes. O estado da carga de cada célula durante o teste de validação é apresentado na Figura 4.27.




Figura 4.27 – Estado da carga durante o ciclo completo de carga e descarga da bateria.

É possível notar que ao final do teste de validação, o estado da carga de cada célula é diferente, isso ocorre devido ao tipo de balanceamento utilizado. Por meio de uma melhor estratégia de balanceamento, é possível minimizar essa diferença e garantir que todas as células possuam o mesmo estado da carga ao final de um ciclo de carregamento. A Tabela 4.11 apresenta o SOC de cada célula e o SOC total da bateria ao final do teste de validação.

Tabela 4.11 – Estado da carga final da bateria e das células individuais.

SOC	SOC	SOC	SOC	SOC	SOC	SOC	SOC	SOC
Total	Cel. 1	Cel. 2	Cel. 3	Cel. 4	Cel. 5	Cel. 6	Cel. 7	Cel. 8
98,02%	97,46%	98,51%	98,26%	98,79%	98,94%	98,75%	96,54%	96,92%

O estado da carga total da bateria é calculado considerando a média do estado da carga individual de cada célula, resultando em um valor de 98,02%. Analisando a Tabela 4.11 é possível observar que todos os SOCs se encontram muito próximos, nesse caso, o desvio padrão calculado foi de apenas 0,92%.

Por meio do que foi apresentado, o algoritmo de estado da carga pode ser considerado como validado, sendo capaz de estimar o estado da carga de cada célula individualmente, considerando a troca de energia entre as mesmas nos instantes de balanceamento.

Por meio desse teste, foi possível comissionar o *hardware* e o *firmware* do BMS, os quais operaram de maneira adequada, corroborando as escolhas adotadas para essa pesquisa e seu desenvolvimento, incluindo o funcionamento do modelo matemático e do algoritmo do filtro de Kalman estendido adaptativo para estimação do estado da carga.

5 CONCLUSÃO

Esse trabalho apresentou as informações necessárias para o desenvolvimento de um sistema de gerenciamento de baterias (BMS), aplicado a um cenário específico, seja para baterias estacionárias ou para mobilidade elétrica. Um maior enfoque foi dado para a estimação do estado de carga (SOC), que é fundamental para a determinação dos demais aspectos funcionais de uma bateria moderna.

A metodologia de desenvolvimento do BMS, principalmente de seu *software*, foi apresentada considerando a segurança como aspecto fundamental para o trabalho dos pesquisadores, realizando testes simples e coletas de dados em bancada, com identificação de sistemas, modelagens e simulações computacionais, para assegurar a correta operação dos algoritmos criados, antes de sua aplicação real. Isso permite garantir a integridade das células reais que foram usadas durante todo o desenvolvimento, além de manter a segurança das pessoas e das instalações de laboratório.

Neste trabalho foram escolhidas células de LiFePO₄, em um cenário de aplicação com empilhadeiras elétricas. Entretanto, por meio da metodologia desse trabalho, é possível desenvolver um BMS para qualquer tipo de célula, para qualquer arranjo de bateria, e para qualquer cenário de aplicação.

Foi desenvolvido um modelo matemático novo, que utiliza o estado da carga como uma de suas saídas, sendo capaz de atingir uma precisão 100 vezes maior quando comparado com modelos tradicionais, que utilizam apenas a tensão da bateria como saída principal do sistema. O desenvolvimento do modelo matemático foi realizado por meio da teoria de identificação de sistemas, a qual realiza uma comparação (*benchmark*) entre diversos modelos, com diversos critérios de ajuste e diversos experimentos, com o objetivo de determinar a melhor combinação entre eles para uma dada aplicação.

Nesse contexto, o modelo matemático desenvolvido nesse trabalho, foi definido por meio da comparação com outros 4 modelos diferentes, com 4 critérios

de ajuste distintos, validados com 7 possíveis experimentos. O modelo não linear tipo caixa cinza avaliado com o critério dos mínimos quadrados apresentou melhores resultados. Todos os experimentos foram definidos com base na dinâmica da bateria aplicada em uma empilhadeira elétrica, com um regime de trabalho real. Também foi realizada a comparação do desempenho do modelo com o experimento chamado de “teste OCV”, que é amplamente utilizado em diversos artigos na literatura. Entretanto, esse foi o experimento com o pior resultado para aplicações em empilhadeiras elétricas, sendo que o melhor resultado foi obtido com o experimento denominado nesse trabalho como “30s alto 1m baixo”. Esse experimento é representativo e suficiente para ser realizado em uma linha de produção de baterias para essa aplicação, podendo extrair e caracterizar os parâmetros de forma coerente para a bateria, sem que suas células sejam submetidas a extenuantes (e desgastantes) testes.

Os parâmetros identificados foram utilizados no algoritmo do filtro de Kalman estendido adaptativo, que foi desenvolvido utilizando uma estratégia diferente, com ajuste em tempo de execução das matrizes de ruído de processo e ruído de medição. Essas matrizes são calculadas em tempo real pelo algoritmo, utilizando as medidas da tensão e da corrente da bateria. A matriz de ruído de processo utiliza o desvio padrão dos parâmetros identificados por meio do modelo matemático, desse modo, aliando a estratégia de identificação dos parâmetros com a adaptabilidade da matriz de ruído de processo, o algoritmo de estimação do estado da carga foi capaz de obter uma precisão média de 99,56%.

A estratégia apresentada utiliza o método de combinação de incertezas, o qual é capaz de simplificar a compreensão da matriz de ruído de processo, considerando que o mesmo é composto pelo próprio processo de modelagem e de identificação dos parâmetros do modelo. Sem otimizações computacionais, essa estratégia acrescenta um tempo de processamento de 30% no BMS desenvolvido e realiza uma interação completa em 180us, sendo capaz de considerar todas as incertezas do sistema em conjunto com os ruídos de medição da corrente e da tensão da bateria calculados em tempo real, se tornando um algoritmo robusto e confiável. É importante frisar que essas matrizes de ruído de processo e medição

podem ser utilizadas, no futuro, também como autodiagnóstico do próprio BMS, indicando problemas de *hardware* incipientes (nas células, no condicionamento e filtragem analógica, etc.) nos momentos em que há mudanças abruptas em seus coeficientes. Nessa ocasião, pode-se analisar se alguma falha grave está em andamento, permitindo ações e medidas de proteção e segurança. Isso deverá ser investigado em trabalhos futuros, pois também aborda o monitoramento avançado da bateria e de seu estado de saúde.

O *hardware* e o *firmware* do BMS foram desenvolvidos para garantir o funcionamento de todas as tarefas e funcionalidades em tempo real. O algoritmo de estimação do estado da carga da bateria foi devidamente embarcado no BMS, e validado em um banco de baterias com 8 células em série. Para que os testes nesse banco de baterias fossem realizados garantindo a integridade das células, foi desenvolvida uma estratégia simples de balanceamento, onde foi possível avaliar o desempenho do algoritmo de estado da carga em cada célula, considerando a troca de energia entre elas durante seu balanceamento, validando a precisão do algoritmo durante todo o teste.

Desse modo, todo o conjunto foi validado em ambiente real: tanto o *hardware*, como o *firmware*, com o modelo matemático criado, os parâmetros identificados e o algoritmo do filtro de Kalman estendido adaptativo, atingindo um ótimo resultado e contribuindo para a evolução da pesquisa na área de gerenciamento de baterias, área que tem se tornado cada vez mais relevante para uma sociedade energeticamente sustentável.

6 PROPOSTAS FUTURAS

A área de gerenciamento eletrônico de baterias está em constante evolução e os resultados atingidos nesse trabalho são capazes de contribuir ainda mais para o aprimoramento dessa área, por meio de algumas funcionalidades que poderão ser adicionadas ao BMS e ao algoritmo de estimação do estado da carga em trabalhos futuros, são eles:

- Identificação dos parâmetros e do desvio padrão de cada parâmetro de forma on-line e recursiva (periódica);
- Atualização da relação SOC-OCV de forma automática em um período pré-determinado;
- Atualização da variância padrão do ruído da corrente e da tensão enquanto a bateria se encontrar em repouso;
- Desenvolvimento de estratégias de balanceamento mais robustas, de acordo com o resultado de um artigo recentemente publicado pelo grupo de pesquisa ao qual essa dissertação também contribui (DE ALCÂNTARA DIAS et al., 2022).
- Desenvolvimento de algoritmos de estimação do estado da saúde e estado de funcionalidade, baseados no modelo matemático desenvolvido nesse trabalho;
- Desenvolvimento de estratégias de gerenciamento térmico, de acordo com a necessidade de cada aplicação.
- Desenvolvimento de uma estratégia de acompanhamento do SOC, em condições com baixíssima demanda de carga ou descarga, com menor carga computacional e menor consumo energético, para que a carga do BMS não seja elevada ou responsável pela auto-descarga do sistema.

É importante ressaltar, que todas essas funcionalidades são possíveis de serem adicionadas ao *hardware* e ao *firmware* do BMS desenvolvido nesse trabalho, sem a necessidade de qualquer alteração ao seu design.

REFERÊNCIAS

ABADA, S.; MARLAIR, G.; LECOCQ, A.; PETIT, M.; SAUVANT-MOYNOT, V.; HUET, F. Safety focused modeling of lithium-ion batteries: a review, **Journal of Power Sources**, França, Dezembro, v. 306, p. 178-192. 2015.

AKINYELE, D. O.; RAYUDU, R. K. Review of energy storage technologies for sustainable power networks, **Journal of Sustainable Energy Technologies and Assessments**, Nova Zelândia, Julho, v. 8, p. 74-91. 2014.

ALLAFI, W.; ZHANG, C.; UDDIN, K.; WORWOOD, D.; DINH, T. Q.; ORMENO, P. A.; LI, K.; MARCO, J. A lumped thermal model of lithium-ion battery cells considering radiative heat transfer, **Applied Thermal Engineering**, v. 143, p 472-481, 2018.

ALMAGBILE, A.; WANG, J.; DING, W. Evaluating the performances of adaptive kalman filter methods in GPS/INS integration. **Journal of Global Positioning Systems**. v. 9, n.1, p. 33-40. 2010.

BARAI, A.; WIDANAGE, W. D.; MARCO, J.; MCGORDON, A.; JENNINGS, P. A study of the open circuit voltage characterization technique and hysteresis assessment of lithium-ion cells. **Journal of Power Sources**. v. 295, p. 99-107, 2015.

BARONTI, F.; RONCELLA, R.; SALETTI, R. Performance comparison of active balancing techniques for lithium-ion batteries, **Journal of Power Sources**, Itália, Junho, v. 267, p. 603-609. 2014.

BONFIGLIO, C.; ROESSLER, W. A cost optimized battery management system with active cell balancing for lithium ion battery stacks. In: VEHICLE POWER AND PROPULSION CONFERENCE, **Proceedings...** Setembro, Dearborn, USA, p. 304-309, 2009.

CAO, J.; SCHOFIELD, N.; EMADI, A. Battery balancing methods: a comprehensive review. In: VEHICLE POWER AND PROPULSION CONFERENCE, **Proceedings...** Setembro, Harbin, China, 2008.

CHEN, H.; CONG, T. N.; YANG, W.; TAN, C.; LI, Y.; DING, Y. Progress in electrical energy storage system: a critical review, **Journal of Progress in Natural Science**, China, Julho, 2008.

CICCONI, P.; LANDI, D.; GERMANI, M. Thermal analysis and simulation of a li-ion battery pack for a lightweight commercial EV, **Journal of Applied Energy**, Itália, Fevereiro, 2017.

COELHO, K. D. **Estudo de uma fonte ininterrupta de corrente contínua de baixa potência gerenciada por um microcontrolador**. 2001. 162p. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Florianópolis, 2001.

CORNO, M.; SAVARESI, S. M. A diffusive electro-equivalent li-ion battery model. In: IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS (ISCAS), Beijing – China, May 19-23, 2013.

COSTA, S. C. L. **Análise e desenvolvimento de um método de estimação de estado de carga de baterias baseado em filtro de Kalman**. 2014. 128p. Dissertação (Mestrado) - Faculdade de Engenharia da Universidade do Porto - Portugal. 2014

DAOWD, M.; OMAR, N.; BOSSCHE, P. V. D.; MIERLO, J. V. Passive and active battery balancing comparison based on MATLAB simulation. In: VEHICLE POWER AND PROPULSION CONFERENCE, **Proceedings...** Outubro, Chicago, USA, 2011.

DA SILVA, C. T; DIAS, B. M. A.; ARAUJO, R. E.; PELLINI, E. L.; LAGANÁ, A. A. M. **Battery Model Identification Approach for Electric Forklift Application**. *Energies*, v.14, p.6221, 2021.

DE ALCÂNTARA DIAS, B. M.; DA SILVA, C. T.; ARAÚJO, R. E.; DE CASTRO, R.; PELLINI, E. L.; PINTO, C.; LAGANÁ, A. A. M. **Na Analytic Hierarchy Process for Selecting Battery Equalization Methods**. *Energies*, v.15, p.2439, 2022.

FARMANN, A.; WAAG, W.; MARONGIU, A.; SAUER, D. U. Critical review of on-board capacity estimation techniques for lithium-ion batteries in electric and hybrid electric vehicles. **Journal of Power Sources**, Alemanha, Janeiro, 2015.

FOTOUHI, A.; AUGER, D. J.; PROPP, K.; LONGO, S.; WILD, M. A review on electric vehicle battery modelling: from lithium-ion toward lithium-sulphur. **Journal of Renewable and Sustainable Energy Reviews**, v. 56, p. 1008-1021, 2016.

GALLARDO-LOZANO, J.; ROMERO-CADAVAL, E.; MILANES-MONTERO, M. I.; GUERRERO-MARTINEZ, M. A. Battery equalization active methods, **Journal of Power Sources**, Espanha, Setembro, 2013.

HARTING, N.; WOLFF, N.; RODER, F.; KREWER, U. Nonlinear frequency response analysis (NFRA) of lithium-ion batteries. **Electrochimica Acta**, v.248, p.133-139, 2017.

HU, X.; LI, S.; PENG, H. A Comparative study of equivalent circuit models for li-ion batteries. **Journal of Power Sources**, v. 198, p. 359-367, 2012.

HU, X.; ZOU C.; ZHANG, C.; LI, Y. Technological developments in batteries: a survey of principal roles, types, and management needs. **IEEE Power and Energy Magazine**, v. 15, n. 5, p. 20-31, Sept.-Oct. 2017.

IBRAHIM, H.; ILLINCA, A.; PERRON, J. Energy storage systems - characteristics and comparisons, **Journal of Renewable and Sustainable Energy Reviews**, Quebec, Janeiro, 2007.

JAGUEMONT, J.; BOULON, L.; DUBÉ, Y. Characterization and modeling of a hybrid-electric-vehicle lithium-ion battery pack at low temperatures. **IEEE Transactions on Vehicular Technology**, v. 65, n. 1, p. 1-14 Janeiro, 2016.

JOKIE, I.; ZARKO, Z.; BOZO, K. State of charge estimation of lithium-ion batteries using extended Kalman filter and unscented Kalman filter. In: INTERNATIONAL SCIENTIFIC-PROFESSIONAL CONFERENCE ON INFORMATION TECHNOLOGY, 23. **Proceedings...** Zabljak, Montenegro. p. 1-4, 2018.

KALMAN, R. E. A new approach to linear filtering and prediction problems. **Transactions of the ASME-Journal of Basic Engineering**, v. 82. p. 35-45, 1960.

KHALFI, J.; BOUMAAZ, N.; SOULMANI, A.; LAADISSI, E. M. Box-Jenkins black-box modeling of a lithium-ion battery cell based on automotive drive cycle data. **World Electric Vehicle Journal**, v.12, p.102, 2021.

KHALIGH, A. LI, Z. Battery, ultracapacitor, fuel cell, and hybrid energystorage systems for electric, hybrid electric, fuel cell, and plug-in hybrid electric vehicles: state of the art. **IEEE Transactions on Vehicular Technology**, v. 59, n. 6, p. 2806-2814 Julho 2010.

KHAN, Z.; BUGTI, H.; BUGTI, A. S. Single dimensional generalized kalman filter. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTING, ELECTRONIC AND ELECTRICAL ENGINEERING. **Proceedings...** p. 1-5, 2018.

KHUMPROM, P.; YODO, N. A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. **Energies**, v.12, p. 660, 2019

KIRKUP, L.; FRENKEL, R. B. **An introduction to uncertainty in measurement**, 2006, Cambridge University Press.

KUSIAK, R. S. **Modelagem matemática do tempo de vida de baterias de lítio íon polímero a partir de modelos híbridos considerando correntes de descarga va-**

riáveis, 2016. 87p. Dissertação (Mestrado) - Pós Graduação em Modelagem Matemática, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, 2016.

LI, L.; HU, M.; XU, Y.; FU, C.; JIN, G.; LI, Z. State of Charge Estimation for Lithium-ion Power Battery Based on H-Infinity Filter Algorithm. **Applied Sciences**. v.10, 2021

LJUNG, L. **System identification. theory for the user**, 2.ed.; Prentice Hall: Hoboken, NJ, USA, 1999; ISBN 0-13-656695-2.

LV, J.; SONG, W.; LIN, S.; CHEN, M.; FENG, Z.; LI, Y.; DING, Y. Influence of equalization on lifepo4 battery inconsistency. **International Journal of Energy Research**, China. Novembro 2016.

LU, L.; HAN, X.; LI, J.; HUA, J.; OUYANG, M. A review on the Key Issue for Lithium-ion Battery Management in Electric Vehicles, **Journal of Power Sources**, China. Novembro 2013.

MAYBECK, P. S. **Stochastic models, estimation, and control**. Nova York: Academic Press. 1979. v. 1 ISBN 0-12-480701-1

MOHINDER, S. G.; ANGUS, P. A. **Kalman filtering theory and practice using MATLAB**.3. ed. Nova Jersey: John Wiley & Sons, 2008 ISBN 0-471-26638-8.

NA, J. Y.; CHO, H. M. Battery thermal management system in HEV/EV, **International Journal of Applied Engineering Research**, India, 2016.

NAVID, Q.; HASSAN, A. An accurate and precise grey box model of a low-power lithium-ion battery and capacitor/supercapacitor for accurate estimation of state-of-charge. **Batteries**, v.5, p.50, 2019.

PENG, J.; LUO, J.; HE, H.; LU, B. An improved state of charge estimation method based on cubature Kalman filter for lithium-ion batteries, **Applied Energy**, v. 253, p. 113520, 2019.

PESARAN, A. A. Battery thermal management in EVs and HEVs: Issues and Solutions. In: ADVANCED AUTOMOTIVE BATTERY CONFERENCE. Las Vegas. **Proceedings...** Nevada: 2001.

PESSOA, F. **Revista de Comércio e Contabilidade**, Lisboa, 1926, n. 1,

POLLET, B. G.; STAFFELL, I.; SHANG, J. L. Current status of hybrid, battery and fuel cell electric vehicles: from electrochemistry to market prospects, **Journal of Electrochimica Acta**, África do Sul, Dezembro, 2012.

RAHMOUN, A.; BIECHL, H.; ROSIN, A. SOC estimation for li-ion batteries based on equivalent circuit diagrams and the application of a Kalman Filter. **Electric Power Quality and Supply Reliability**, p. 1-4, 2012

RICO, J. J.; ACHA, E.; MADRIGAL, M. The Study of Inrush Current Phenomenon Using Operational Matrices. **IEEE Transactions on Power Delivery**, v. 16, n. 2. p. 231-237, Abril 2001.

ROSOLEM, M. F. N. C.; BECK, R. F.; SANTOS, G. R.; ARIOLI, V. T. Bateria de lítio-íon: conceitos básicos e potencialidades. **Cad. CPqD Tecnologia**, v. 8, n.2, p. 59-72. 2012.

SAIDANI, F.; HUTTER, F. X.; SCURTU, R. G.; BRAUNWARTH, W.; BURGHARTZ, J. N. Lithium-ion Battery Models: A Comparative Study and Model-Based Powerline Communication, 2017, **Advances in Radio Science**, Vol. 15, pp 83-91.

SANTORO, P. A. **Uma Análise de Espectros de Impedância Utilizando o Modelo de Poisson-Nersnt-Planck com Difusão Anômala**. 2014, 86p. Tese Doutorado - Universidade Estadual de Maringá, Programa de Pós-Graduação em Física, 2014.

SHI, N.; CHEN, Z.; NIU, M.; HE, Z.; WANG, Y.; CUI, J. State of charge estimation for the lithium-ion battery based on adaptive extended Kalman Filter using Improved Parameter Identification. **Journal of Energy Storage**. 2021.

SINGH, M.; KHURANA, R.; JAIN, P. Low cost high voltage battery string monitoring system. In: CONFERENCE ON COMPUTING AND NETWORK COMMUNICATIONS. Trivandrum **Proceedings...** India: 2015.

SUN, D.; YU, XIAOLI; WANG, C.; ZHANG, C.; HUANG, R.; ZHOU, Q.; AMI-ETSZAJEW, T.; BHAGAT, R. State of charge estimation for lithium-ion battery based on an intelligent adaptive extended Kalman Filter with Improved Noise Estimator. **Energy** 214, 2021.

TIE, S. F; TAN, C. W. A review of energy sources and energy management system in electric vehicles. **Journal of Renewable and Sustainable Energy Reviews**, Malasia, Abril, 2013.

VETTER, J.; NÓVAK, P.; WAGNER, M. R.; VEIT, C.; MOLLER, K. C.; BESENHARD, J. O.; WINTER, M.; WOHLFAHRT-MEHRENS, M.; VOGLER, C.; HAMMOUCHE, A. ageing mechanisms in lithium-ion batteries. **Journal of Power Sources**, v. 147, p. 269-281, 2005.

WAAG, W.; FLEISCHER, C.; SAUER, D. U. Critical review of the methods for monitoring of lithium-ion batteries in electric and hybrid vehicles. **Journal of Power Sources**, Alemanha, Março, 2014.

WANG, Q.; JIANG, B.; LI, B.; YAN, Y. A critical review of thermal management models and solutions of lithium-ion batteries for the development of pure electric vehicles. **Journal of Renewable and Sustainable Energy Reviews**, Itália, Junho, 2016.

WANG, S.; YOGCUN, F.; STROE, D-I.; FERNANDEZ, C.; YU, C.; CAO, W.; CHEN, Z. Chapter 1 - Lithium-ion battery characteristics and applications, **Battery System Modeling**, Elsevier, 2021. p. 1-46, ISBN 9780323904728.

WIENER, N. The extrapolation, interpolation and smoothing of stationary time series. Nova York: John Wiley & Sons, 1949

YANG, Z.; LI, K.; FOLEY, A.; ZHANG, C. A New Self-Learning TLBO Algorithm for RBF Neural Modelling of Batteries in Electric Vehicles. In: IEEE CONGRESS ON EVOLUTIONARY COMPUTATION (CEC), **Proceedings...** Beijing – China, July 6-11, 2014,

YUAN, S.; HONGJIE, W.; CHENGLIANG, Y. State of Charge Estimation Using the Extended Kalman Filter for Battery Management Systems Based on the ARX Battery Model. **Energies**, v. 6, p 444-470, 2013.

ZHANG, Z.; JIANG, L.; ZHANG, L.; HUANG, C. State of charge estimation of lithium-ion battery pack by using an adaptive extended kalman filter for electric vehicles. **Journal of Energy Storage**. v. 37. 2021.

ZHAO, J.; RAO, Z.; YUTAO, H.; LIU, X.; LI, Y.; Thermal Management of Cylindrical Power Battery Module for Extending the Life of New Energy Electric Vehicles. **Journal of Applied Thermal Engineering**, China, Abril, 2015.

ZHENG, D.; WANG, H.; AN, J.; CHEN, J.; PAN, H.; CHEN, L. Real-Time Estimation of Battery State of Charge with Metabolic Grey Model and LabVIEW Platform. **IEEE Access**, v. 6, p. 13170-13180, 2018.