



UNIVERSIDADE
ESTADUAL DE LONDRINA

KAWÉ MONTEIRO DE SOUZA

MULTIESTIMADOR INTELIGENTE DE ESTADO DE
CARGA PARA BATERIAS DE ÍON LÍTIO

LONDRINA

2024

KAWE MONTEIRO DE SOUZA

**MULTIESTIMADOR INTELIGENTE DE ESTADO DE
CARGA PARA BATERIAS DE ÍON LÍTIO**

Dissertação apresentada ao Programa de Mestrado em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof(a). Dr(a). Maria Bernadete de Moraes França

LONDRINA

2024

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

S729m Souza, Kawe Monteiro de.
Multiestimador inteligente de estado de carga para baterias de íon lítio / Kawe Monteiro de Souza. - Londrina, 2024.
63 f. : il.

Orientador: Maria Bernadete de Moraes França.
Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual de Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em Engenharia Elétrica, 2024.
Inclui bibliografia.

1. Estado de Carga - Tese. 2. Redes Neurais - Tese. 3. Veículo Elétrico - Tese. I. Bernadete de Moraes França, Maria . II. Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU 62

KAWE MONTEIRO DE SOUZA

**MULTIESTIMADOR INTELIGENTE DE ESTADO DE
CARGA PARA BATERIAS DE ÍON LÍTIO**

Dissertação apresentada ao Programa de Mestrado em Engenharia Elétrica da Universidade Estadual de Londrina para obtenção do título de Mestre em Engenharia Elétrica.

BANCA EXAMINADORA

Orientador: Prof(a). Dr(a). Maria
Bernadete de Moraes França
Universidade Estadual de Londrina

Prof. Dr. Heverson Renan de Freitas
Instituto SENAI de Inovação em
Eletroquímica – ISI Eletroquímica

Prof. Dr. Carlos Henrique Illa Font
Universidade Tecnológica Federal do Paraná
- Campus Ponta Grossa – UTFPR

Londrina, 27 de fevereiro de 2024.

AGRADECIMENTOS

Primeiramente agradeço à minha família pelo apoio durante todo o trajeto.

Expresso também minha gratidão aos professores da UEL, em especial à minha orientadora, Prof. Dra. Maria Bernadete Morais França, por sempre manter-se otimista e alegre, confiando em minha capacidade e proporcionando a oportunidade de desenvolver este trabalho.

Agradeço ao Instituto SENAI de Tecnologia da Informação e Comunicação, unidade Londrina PR, em particular ao laboratório de pesquisa em sistemas embarcados, por disponibilizar a infraestrutura, horas e equipe para colaboração na orientação deste trabalho. Também estendo meus agradecimentos ao Instituto SENAI de Inovação em Eletroquímica, especialmente ao Laboratório de Teste e Desenvolvimento de Baterias, por dedicar o tempo de seus especialistas para auxiliar nos ensaios de caracterização das baterias.

Agradeço à Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa, em especial a Professora Dr. Fernanda Cristina Corrêa e ao Dr. José Rodolfo Galvão do PPGEE, pela colaboração no desenvolvimento do conhecimento e produção/disponibilização de documentos técnicos.

Agradeço à banca por disponibilizar seu tempo para contribuir para a melhoria deste estudo. Expresso também minha gratidão especial ao Dr. Paulo Broniera Junior pela paciência e por coduzir as orientações, em conjunto com a orientadora, durante toda a execução do trabalho.

E, por último, mas não menos importante, expresso meu profundo agradecimento a todos os colegas de trabalho do time de sistemas embarcados do Instituto SENAI de Tecnologia da Informação e Comunicação. Agradeço sinceramente ao Dr. Jorge Pessato Mondadori, Edino, Luis Gustavo, Isis, Lucas, Guilherme, Callebe, Raul, Diogo e Adler.

É importante destacar que este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

*"A energia de um único pensamento pode
determinar o movimento de um universo"*
(Nikola Tesla)

SOUZA, KAWÉ MONTEIRO DE. **MULTIESTIMADOR INTELIGENTE DE ESTADO DE CARGA PARA BATERIAS DE ÍON LÍTIO**. 2024. 63f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Londrina, Londrina, 2024.

RESUMO

As baterias de Íon Lítio vêm conquistando cada vez mais espaço no segmento de armazenamento de carga, isto se deve às suas características que as tornam robustas e com alta densidade energética. Porém, durante sua produção é quando ocorre boa parte da poluição que estas apresentarão durante seu ciclo de vida. Assim, é necessário garantir o bom uso para que se estenda sua vida útil, além de garantir a segurança. Isto é ainda mais impactante em veículos elétricos, onde são utilizadas baterias em conjunto, ligadas em série ou paralelo. Para controlá-las é usado um BMS (do inglês, *Battery Management System*), que dentre outras funções faz a estimação de um dos principais parâmetros para verificar se a bateria tem energia para ser utilizada, que seria o Estado de Carga (SOC). Desta forma, este trabalho traz um comparativo entre 2 métodos de estimação de carga: *Kalman Filter Unscented* e Rede Neural Perceptron Multicamada. Para tal, foi gerado um banco de dados, a partir de um ensaio com 4 baterias em série, acopladas em um robô aspirador adaptado. Foi realizada a coleta de dados com BMS e estes foram utilizados no *Matlab/Simulink*[®] para verificar a resposta offline dos algoritmos. Na segunda etapa, enquanto foi realizada a coleta, os dados foram utilizados para que os algoritmos realizassem as estimativas em tempo real (online). Com os resultados computacionais foram calculadas as métricas estatísticas, além de verificar o erro, analisando o algoritmo com melhor resposta.

Palavras-chave: Filtro de Kalman Unscented. Redes Neurais. Veículos elétricos. Contagem de Coulomb. Perceptron Multicamadas

SOUZA, KAWE MONTEIRO DE. **INTELLIGENT MULTESTIMATOR OF STATE OF CHARGE FOR LITHIUM ION BATTERIES**. 2024. 63p. Master's Thesis (Master in Science in Computer Science) – State University of Londrina, Londrina, 2024.

ABSTRACT

Lithium-ion batteries have been increasingly gaining ground in the energy storage segment, thanks to their robust characteristics and high energy density. However, a significant portion of the pollution that these batteries will exhibit during their lifecycle occurs during their production. Therefore, it is essential to ensure proper usage to extend their lifespan and ensure safety. This becomes even more impactful in electric vehicles, where batteries are used in association, connected in series or parallel. To control them, a Battery Management System (BMS) is employed, which, among other functions, estimates one of the key parameters to determine if the battery has sufficient energy to be used—this parameter is known as the State of Charge (SOC). This work presents a comparison between two methods of charge estimation: the Kalman Filter Unscented and the Multilayer Perceptron Neural Network. To conduct this comparison, a database was generated from a test involving 4 batteries in connected in series to a modified robotic vacuum cleaner. Data was collected using BMS and then utilized in Matlab/Simulink[®] to assess the offline response of the algorithms. In the second stage, while data collection was ongoing, the algorithms used real-time data for online charge estimations. Computational results were used to calculate statistical metrics and assess the error, finally determining which algorithm provided the best response.

Keywords: Kalman Filter Unscented. Neural Network. Electric vehicle. Coulomb Counting. Multilayer Perceptron

LISTA DE ILUSTRAÇÕES

Figura 1 – Modelo de uma BIL em etapa de carregamento	18
Figura 2 – Diagrama do BMS	20
Figura 3 – Exemplo modelo circuito elétrico	24
Figura 4 – Diagrama esquemático do sistema de coleta de dados	30
Figura 5 – Interface para apresentação de dados	31
Figura 6 – Robô aspirador adaptado (a) parte traseira onde é verificado o local onde é adicionado as baterias (b) parte frontal do robô onde é possível verificar a placa de instrumentação	32
Figura 7 – Fluxograma operacional Descarga	33
Figura 8 – Fluxograma operacional Descarga	34
Figura 9 – Circuito de instrumentação	35
Figura 10 – Placa circuito de instrumentação	37
Figura 11 – Metodologia simulação offline	37
Figura 12 – Fluxograma para desenvolvimento do SOC de referência	38
Figura 13 – Metodologia para o ensaio online.	39
Figura 14 – Autolab PGSTAT302N	41
Figura 15 – Conexão de equipamentos para baterias	43
Figura 16 – Parametrização a partir de curva gerada pelo EIS (a) modelo a ser produzido (b) gráfico de Nyquist produzido do EIS	44
Figura 17 – Resposta do modelo utilizando capacitor no software NOVA	45
Figura 18 – Gráfico de Nyquist do modelo e experimental	46
Figura 19 – Parâmetros do modelo RC de 2ª Ordem	49
Figura 20 – Resultado do ensaio offline (a) e (b) apresentam o resultado do ensaio em curvas com descarga contínua e (c) e (d) indicam para as curvas de descarga com repouso	51
Figura 21 – Resultado do ensaio online com repouso (a) Saída dos estimadores na segunda bateria do primeiro ensaio.(b) Saída dos estimadores na segunda bateria no segundo ensaio.(c) Saída dos estimadores na segunda bateria no terceiro ensaio.(d) Saída dos estimadores na terceira bateria do terceiro ensaio.	53
Figura 22 – Resultado do ensaio online sem repouso (a) Saída dos estimadores na primeira bateria.(b) Saída dos estimadores na segunda bateria.(c) Saída dos estimadores na terceira bateria.(d) Saída dos estimadores na quarta bateria.	55

LISTA DE TABELAS

Tabela 1 – Vantagens e desvantagens dos principais métodos de estimação de carga	28
Tabela 2 – Parâmetros do PMC utilizado.	47
Tabela 3 – Configuração do bloco UFK	50
Tabela 4 – Métricas estatísticas para análise do ensaio offline	52
Tabela 5 – Métricas estatísticas para análise do erro durante ensaio online com repouso	54
Tabela 6 – Métricas estatísticas para análise do erro durante ensaio online com descarga contínua	56

LISTA DE ABREVIATURAS E SIGLAS

AEKF	Filtro de Kalman Estendido Adaptado (<i>Adaptative Extended Kalman Filter</i>)
Ah	Ampére-hora (<i>Ampere-hour</i>)
Amp Op	Amplificador Operacional
BIL	Bateria de íon Lítio
BMS	Sistema de Gerenciamento de Bateria (<i>Battery Managment System</i>)
BPNN	Sistema de Gerenciamento de Bateria (<i>Back Propagation Neural Network</i>)
C	Capacidade
CC	Contagem de Coulomb (<i>Coulomb Counting</i>)
CPE	<i>Constant Phase Element</i>
DC	Corrente Contínua (<i>Direct Current</i>)
DST	Teste Dinâmico de Estresse (<i>Dynamic Stress Test</i>)
ECM	Modelo de Circuito Equivalente (<i>Equivalent Circuit Model</i>)
EDP	Equações de Derivadas Parciais
EFK	Filtro de Kalman Estendido (<i>Extended Filter Kalman</i>)
EIS	Modelo de Impedância em Corrente Alternada (<i>Electrochemical Impedance Spectroscopy</i>)
FP	Filtro de Partículas
FUDS	<i>Federal Urban Driving Schedule</i>
GA	Algoritmo Genético (<i>Genetic Algorithm</i>)
GND	Terra (<i>Ground</i>)
GPIO	<i>General Purpose Input/Output</i>
GRU	<i>Gate Recurrent Unit</i>
IEKF	Filtro de Kalman Estendido Aperfeiçoado (<i>Improved Extended Kalman Filter</i>)

LFP	Fosfato de Lítio Ferro (<i>Lithium Iron Phospate</i>)
LS	<i>Least Squares</i>
LSTM	Memória de Longo e Curto Prazo (<i>Long Short Term Memory</i>)
MAE	Erro Médio Absoluto (<i>Mean Absolute Error</i>)
MAPE	Erro Percentual Médio Absoluto (<i>Mean Absolute Percentual Error</i>)
NARX	<i>Nonlinear Autoregressive with Exogenous Inputs</i>
NCA	Níquel Cobalto Alumínio (<i>Nickel Cobalt Aluminium</i>)
NMC	Lítio Níquel Manganês Cobalto (<i>Lithium Nickel Manganese Cobalt Oxide</i>)
OCV	Tensão de Circuito Aberto (<i>Open Circuit Voltage</i>)
PCB	Placa de Circuito Impresso (<i>Printed Circuit Board</i>)
PMC	Perceptron Multicamadas
PWM	Modulação de Largura de Pulso (<i>Pulse Width Modulation</i>)
RC	Resistor Capacitor
RMSE	Erro Quadrático Médio da Raiz (<i>Root Mean Square Error</i>)
RNA	Redes Neurais Artificiais
RNN	Rede Neural Recorrente
SEI	<i>Solid Electrolyte Interphase</i>
SOC	Estado de Carga (<i>State of Charge</i>)
SOH	Estado de Vida (<i>State of Health</i>)
SQL	<i>Structured Query Language</i>
SVM	Máquina de Vetores de Suporte (<i>Support Vector Machine</i>)
SVR	Máquina de Vetores de Regressão (<i>Support Vector Regression</i>)
UDDS	<i>Urban Dynamometer Driving Schedule</i>
UKF	Filtro de Kalman Unscented (<i>Unscented Kalman Filter</i>)
VE	Veículo Elétrico
VCU	Unidade de Controle Veicular (<i>Vehycle Unit Control</i>)
Wi-Fi	Fidelidade da Rede sem Fio (<i>Wireless Fidelity</i>)

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivos	16
1.1.1	Objetivos específicos	16
1.2	Organização do Trabalho	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	Bateria	18
2.2	Sistema de Gerenciamento de Baterias	19
2.3	Métricas de estimação	20
2.3.1	SOH	20
2.3.2	SOC	21
2.4	Métodos de estimação de carga	21
2.4.1	Métodos tradicionais de estimação	22
2.4.1.1	Contagem de Coulomb	22
2.4.1.2	Tensão de circuito aberto	23
2.4.1.3	Método da Impedância em Corrente Alternada	23
2.4.2	Métodos baseados em modelo	23
2.4.2.1	Filtro de Kalman	24
2.4.2.2	H_{∞}	25
2.4.2.3	Filtro de Partículas	25
2.4.3	Estimadores orientados por dados	26
2.4.3.1	Redes Neurais	26
2.4.3.2	Algoritmo Genético	27
2.4.3.3	<i>Support Vector Machine</i>	27
3	METODOLOGIA PARA SIMULAÇÃO E DESENVOLVIMENTO DE BANCO DE DADOS PRODUZIDOS A PARTIR DE UM ROBÔ ADAPTADO	29
3.1	Protocolo de coleta dos dados do robô adaptado	29
3.2	Robô aspirador adaptado	34
3.3	<i>Pack</i> de Baterias	34
3.4	Circuito de Instrumentação	35
3.4.1	Protocolo de simulação offline	36
3.4.2	Protocolo de simulação online	38
3.4.3	Implementação do Coulomb Counting	40
3.4.4	Implementação do <i>Unscented Kalman Filter</i> (UKF)	40

3.4.4.1	Determinação dos parâmetros	41
3.4.5	Implementação das Redes Neurais Artificiais (RNA)	46
3.4.6	Análise estatística	47
4	RESULTADOS E DISCUSSÕES	49
4.0.1	Parâmetros do UFK	49
4.1	Ensaio offline	50
4.1.1	Ensaio Online	52
5	CONCLUSÕES DO TRABALHO	57
5.1	Limitações de estudo	57
5.2	Perspectivas de trabalhos futuros	58
5.3	Trabalhos Publicados em Anais de Eventos	58
5.3.1	Artigo A: Comparative Study Between Unscented Kalman Filter and Multi-Layer Perceptron Applied in an Electric Vehicle Simulation with Pack Parameters Generated from the Database	58
5.3.2	Artigo B: MLP networks applied to State of Charge estimation in electric vehicle simulation with normed driving cycle	59
	REFERÊNCIAS	60

1 INTRODUÇÃO

A aplicação de baterias de íon de lítio (BIL) é cada vez mais abrangente, sendo encontrada não apenas em pequenos dispositivos eletrônicos, mas também associadas em bancos de energia de média e alta potência para armazenamento de energia. Sobretudo, em aplicações de mobilidade, sendo um elemento essencial para a operação de veículos elétricos (VE). Este crescimento se justifica pelas diversas vantagens dessas baterias, tais como alta densidade de carga, velocidade de recarga e baixa necessidade de manutenção [SUN et al., 2022].

No entanto, uma notável desvantagem é que a produção das BIL está associada a um período prolongado de geração de poluentes, principalmente na etapa de mineração. Além disso, a aquisição dessas baterias é onerosa. Portanto, torna-se necessário desenvolver ferramentas e modelos de negócios que visem prolongar a vida útil da bateria. Dessa forma, ao término de seu ciclo, os impactos econômicos e ambientais podem ser reduzidos [CHEN et al., 2023] e [VERMA et al., 2023].

A importância dessas ações se destaca ainda mais em veículos elétricos, dada a sua alta demanda energética, requer o uso de um *pack* com diversas baterias associadas em série e em paralelo, que com o tempo, podem apresentar variações nos parâmetros, o que pode levar a disparidades de carga. Se essas baterias não forem balanceadas, há a possibilidade de ocorrer o envelhecimento precoce, bem como a formação de dendritos, podendo causar curto-circuito e, posteriormente, desencadear o fenômeno conhecido como *Thermal Runway*, destruindo assim o *pack* e causando danos ao veículo e aos passageiros [GALVÃO et al., 2022] e [LI et al., 2021].

Para assegurar o funcionamento adequado de um *pack* de baterias, é necessário o uso de um BMS, responsável por monitorar e realizar o balanceamento de carga das células por meio da leitura dos sinais de tensão, corrente e temperatura de cada célula. O hardware do BMS é controlado por algoritmos embarcados, sendo o principal deles o de estimação do Estado de Carga (SOC), que têm como função estimar o estado de carga instantânea do *pack* durante a operação, contribuindo assim, com a integridade e a vida útil do *pack* [SUN et al., 2022].

As abordagens mais utilizadas para estimar o SOC em BIL se baseiam em equações determinísticas que correlacionam variáveis de entrada do sistema para estimar a saída, ou comparam sinais lidos pelos sensores com valores pré-estabelecidos, como nos casos do *Coulomb Counting* (CC) e *Open Circuit Voltage* (OCV). Ou ainda, se baseiam em modelos matemáticos que representam as principais características da dinâmica do *pack*, como na aplicação de Filtros de Kalman nas variações, UFK (do inglês, Unscented Kalman Filter)

e EKF (do inglês, Extended Kalman Filter) [GHAEMINEZHAD et al., 2023].

No entanto, apesar do grande número de aplicações, em alguns casos a representação matemática se torna complexa. Isso ocorre devido a dinâmicas não-lineares ou elementos externos que influenciam no comportamento do sistema como, por exemplo, a presença de distúrbios inesperados, principalmente quando o *pack* é constituído por inúmeras células como nos VEs. Por esse motivo, a maioria das contribuições encontradas na literatura com base nas técnicas citadas abordam a estimativa do SOC apenas para uma célula e não de um *pack* [GHAEMINEZHAD et al., 2023], [SUN et al., 2022] e [YANG et al., 2021].

Neste sentido, técnicas alternativas são propostas com o intuito de aprimorar a estimativa do SOC sem ser necessário o prévio conhecimento matemático da bateria. Segundo [ESPEDAL et al., 2021] e [VIDAL et al., 2020], a utilização de técnicas baseadas em redes neurais artificiais tem recebido maior atenção em aplicações veiculares, por serem menos sensível a variações do sistema, em relação a técnicas tradicionais como CC e OCV. Ainda, segundo [VIDAL et al., 2020], estimadores utilizando redes neurais artificiais tem sido foco de vários estudos atualmente, devido à apresentação de bons resultados e factibilidade de implementação.

Em [WEI et al., 2020a], é estudado o uso da rede NARX, tanto em *open loop* quanto em *closed loop*, para estimar o Estado de Carga de uma BIL 18650. Foram realizados dois ensaios, um utilizando o ciclo de condução UDDS (*Urban Dynamometer Driving Schedule*) e outro o DST (*Dynamic Stress Test*). Para analisar a resposta, foi feita a comparação com os estimadores UFK (*Unscented Filter Kalman*) e BPNN (*Backpropagation Neural Network*). Como critérios de comparação, foram utilizadas as métricas estatísticas RMSE (*Root Mean Square Error*) e MAPE (*Mean Absolute Percentage Error*). Cada ensaio durou 3.000 segundos, e após a produção dos dados, estes foram apresentados aos quatro estimadores. A rede que apresentou o melhor resultado foi a NARXNN *open loop*, com um valor de 0,13 % para o RMSE no ensaio DST e 0,16 % para o UDDS. Quanto ao MAPE, ela registrou um valor de 0,21 % para o DST e 0,11 % para o ciclo UDDS. O segundo melhor foi o NARXNN *closed loop*, que no ensaio DST apresentou o dobro do valor do *open loop*, já para o ciclo UDDS, a diferença ficou acima de 5 vezes o valor. Um ponto importante a destacar é que o ensaio foi realizado para apenas uma bateria, e o ensaio foi conduzido offline.

Em [WANG et al., 2023], é proposto o uso da rede LSTM em conjunto com um modelo eletroquímico simplificado da bateria para estimar o estado de carga de uma bateria A123 LFP 26650. Para comparação, foram desenvolvidas duas estruturas: uma com o modelo em conjunto com o LSTM e outra com o modelo em conjunto com o LSTM bidirecional. O ciclo DST foi utilizado para produzir dados para treinar as redes, já para analisar a desempenho foram empregados os ciclos US06 e FUDS. Como critério de

comparação, foi utilizado o valor de RMSE. O BiLSTM apresentou melhor desempenho, com valores de 1,09 % e 1,01 % para US06 e FUDS (do inglês, Federal Urban Driving Schedule), respectivamente. Já o LSTM obteve 1,61 % e 1,54 %. Este artigo apresentou um estudo apenas de uma bateria, e o ensaio foi conduzido offline.

Já [WEI et al., 2020b] traz um estudo comparativo entre LSTM, NARX em conjunto com LSTM, LS-SVM e BPNN-PSO. Esses foram aplicados para estimar o Estado de Carga de duas baterias, uma bateria de íon lítio fosfato no ciclo UDDS e uma bateria 18650 no ciclo DST. Como critérios de análise, foram selecionadas as métricas estatísticas MAE, RMSE e MAPE. O algoritmo que apresentou melhor desempenho foi o NARX-LSTM; no ciclo UDDS, ele apresentou valores de 0,76 %, 1,28 % e 0,72 % para o RMSE, MAPE e MAE, respectivamente. Já para o DST, os valores foram de 0,78 %, 1,24 % e 0,69 %. Este artigo traz um estudo interessante ao aplicar um sistema unindo duas estruturas de rede. No entanto, o ensaio foi realizado somente com uma bateria por ciclo. Outro fator importante é que o ensaio foi conduzido de forma offline.

Ao analisar os artigos na literatura, observou-se que muitos deles se limitam a uma análise de poucos ciclos, geralmente apenas de descarga, para validar o algoritmo. Além disso, é comum que essas análises ocorram em ambientes controlados, nos quais a temperatura e a corrente são especificadas arbitrariamente. Outro aspecto a ser considerado é a falta de estudo abrangente em relação a um *pack* de baterias, como o utilizado em veículos, sendo mais comum a abordagem individual de baterias.

Este trabalho realiza a comparação de dois algoritmos para estimar o Estado de Carga, sendo eles: O Filtro de Kalman *Unscented* e a Rede Neural Perceptron Multicamadas (MLP), para tal, é feito o uso do CC como estimador de referência. Estes foram implementados em um robo aspirador que foi implementado como carga e assim ser possível de coletar os dados de tensão, corrente e temperatura de baterias 18650 acopladas a ele. Foi então realizado um ensaio offline, utilizando banco de dados, e um ensaio online, onde em tempo real é realizada a estimação e é posteriormente feito a comparação com a referência. Para isto, é realizada a análise comparativa, utilizando métricas estatísticas e gráficos, entre os resultados de cada algoritmo com o valor de estado de carga de referência.

1.1 Objetivos

O objetivo deste trabalho é comparar os métodos de estimativa de carga (U FK e PMC) e dentre eles eleger o mais factível para embarcar em um BMS.

1.1.1 Objetivos específicos

Para alcançar o objetivo geral, foram seguidos os objetivos específicos:

- Realização do levantamento dos métodos mais utilizados, classificando-os de acordo com suas características;
- Classificação crítica dos métodos, verificando os que podem ser possivelmente utilizados para o projeto;
- Desenvolvimento da instrumentação para um *pack* de 4 baterias utilizadas em um robô aspirador de pó;
- Realização de testes, coletando os dados do aspirador de pó robô em funcionamento e o *pack* com BMS;
- Verificação dos estimadores utilizando os dados produzidos, realizando a estimação *offline*;
- Análise do ensaio *offline*;
- Realização da coleta de dados do *pack* de baterias e uso dos algoritmos (ensaio *online*);
- Análise do ensaio *online*.

1.2 Organização do Trabalho

No capítulo 2 tem-se a fundamentação teórica, são apresentados conceitos iniciais como bateria de íon Lítio, BMS, SOC e SOH. Além disto, são apresentados alguns dos métodos de estimação de carga, indicando sua característica de funcionamento, qualidades e defeitos, por fim apresentando uma tabela resumindo o que foi indicado.

O capítulo 3 traz a metodologia utilizada para a produção do banco com dados reais. É apresentado o fluxo de operação, circuitos e componentes usados, além da forma de implementação dos algoritmos para serem utilizados no estudo.

No capítulo 4 é apresentado o banco de dados que foi gerado com BMS. São apresentados os resultados dos ensaios *offline* e *online*, sendo utilizadas métricas estatísticas como RSME e MAE para realizar a análise final e verificar qual estimador se sobressaiu nos quesitos considerados relevantes para um algoritmo de estimação de carga.

Por fim, no capítulo 5 é apresentada a conclusão do estudo e indicações de melhorias para trabalhos futuros.

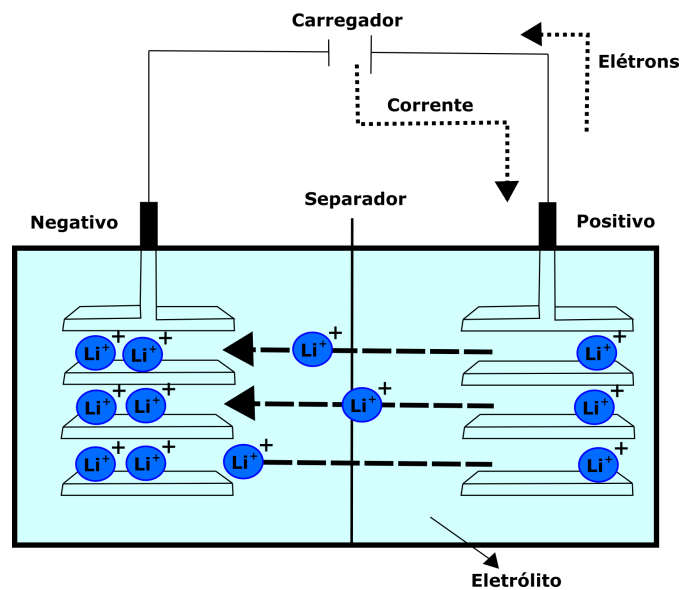
2 FUNDAMENTAÇÃO TEÓRICA

Para compreender os algoritmos de estimação de carga, é necessário ter conhecimento sobre alguns conceitos relacionados, como baterias e BMS. Portanto, esta seção tem como objetivo realizar um breve descritivo de termos correlacionados ao Estado de Carga.

2.1 Bateria

De maneira geral, uma bateria é um sistema que transforma energia química em energia elétrica e vice-versa. Este processo geralmente ocorre por meio de reações de oxirredução. A bateria é composta por dois eletrodos, conhecidos como negativo e positivo, que são isolados fisicamente por um material isolante elétrico e condutor iônico. Por fim, esses eletrodos estão mergulhados ou envolvidos por um eletrólito [ARANHA, 2018]. A Figura 1 apresenta um exemplo da BIL.

Figura 1 – Modelo de uma BIL em etapa de carregamento



Fonte: Autor, 2024

As baterias são empregadas em diversos equipamentos que não estão próximos de tomadas, sendo geralmente móveis. Dessa forma, tornam-se uma maneira de armazenar energia para alimentar esses equipamentos.

Em veículos, as baterias foram introduzidas por volta de 1.912, com funções limitadas à ignição e acionamento das luzes. Atualmente, a demanda por bateria é significativamente maior devido à presença de mais componentes eletrônicos nos veículos, incluindo automóveis nos quais a bateria desempenha uma função primordial, como em veículos

híbridos ou elétricos. Esse cenário levou à necessidade de baterias mais leves, compactas e com maior densidade energética, resultando na implementação das baterias de íon lítio [CASTRO; BARROS; VEIGA, 2013].

As BIL baseiam-se no princípio de intercalação iônica, envolvendo a difusão dos íons de lítio através da rede cristalina tanto do eletrodo positivo quanto do eletrodo negativo. Geralmente, o eletrodo negativo é feito de grafite, enquanto o eletrodo positivo é constituído de um óxido de metal de transição litiado. Atualmente, os tipos mais utilizados para veículos são NMC (Óxido de Lítio Níquel Manganês Cobalto), LFP (Fosfato de Lítio Ferro) e NCA (Óxido de Lítio Níquel Cobalto Alumínio) [CHAGAS; URBANO; SCARMINIO,].

O termo representativo da bateria está relacionado à composição de seu eletrodo positivo. Por exemplo, no caso do NMC, que utiliza Níquel, Manganês e Cobalto, sua sigla é formada pelos termos iniciais da composição química.

As baterias são sistemas complexos e sensíveis a situações que podem ocorrer durante seu uso, como sobrecarga, carga e variações de temperatura. A probabilidade de ocorrer eventos que causem efeitos negativos nas baterias aumenta quando são utilizadas em conjunto. Mesmo possuindo características químicas e físicas semelhantes, ainda existem discrepâncias intrínsecas que acabam desbalanceando o conjunto. Desta forma, o BMS é de extrema importância, pois é ele que irá garantir que todas as baterias do *pack* estejam funcionando dentro de seus limites permitidos, reduzindo assim a chance de ocorrer algum evento nocivo.

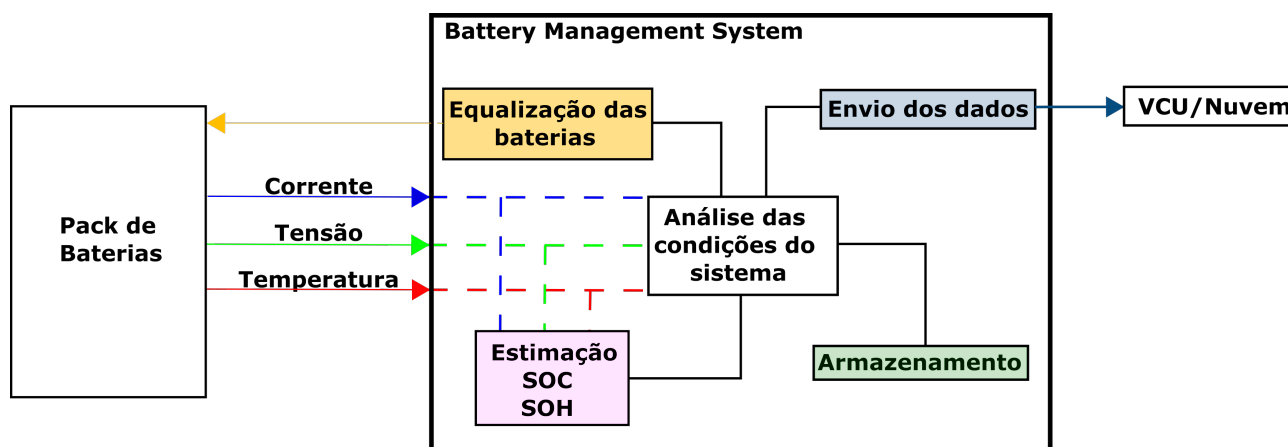
2.2 Sistema de Gerenciamento de Baterias

O BMS, ou Sistema de Gerenciamento de Bateria (*Battery Management System*), tem como função garantir a segurança e a confiabilidade das baterias utilizadas pelo veículo. Suas funções podem ser classificadas em quatro macros: controle, estimação de parâmetros, diagnóstico e armazenamento [GAO, 2015]; [HOW et al., 2019]; [XING et al., 2011]. A Figura 2 apresenta um esquemático representando as principais funções do BMS.

O controle está correlacionado à aquisição das variáveis medidas, geralmente temperatura, corrente e tensão. Ele realiza ações visando manter o funcionamento do *pack* em limites previamente estabelecidos, garantindo assim a segurança do sistema e do usuário. Um exemplo dessa função é quando o BMS verifica que as baterias apresentam valores de tensão que divergem entre si e, assim, executa o controle das baterias para ocorrer o balanceamento entre elas, equilibrando-as.

Para garantir o uso correto das baterias, é necessário que o BMS execute a estimação de alguns parâmetros que não são possíveis de serem medidos diretamente. Os

Figura 2 – Diagrama do BMS



Fonte: Autor, 2024

comumente utilizados são o SOC (State of Charge) e SOH (State of Health).

O sistema deve verificar constantemente a condição das baterias, identificando variações ou comportamentos que possam comprometer o funcionamento do sistema ou causar danos aos passageiros do veículo. Caso seja detectado algum problema, deve ser enviado um aviso ao operador.

Por fim, o sistema deve armazenar os dados por um determinado período, sendo que esses dados também são enviados para a VCU (Vehicle Control Unit) ou para a nuvem. Assim, podemos destacar que a estimativa do SOC e SOH é crucial, pois é por meio delas que o BMS pode executar com eficiência o controle sobre o *pack*.

2.3 Métricas de estimativa

Para realizar o controle das baterias, existem duas métricas muito importantes e que são estimadas: o SOH (*State of Health*) e SOC (*State of Charge*). No entanto, como indicado, esses parâmetros são estimativas, pois não são medidas físicas, sendo impossíveis de serem monitoradas diretamente por sensores. Assim, foram desenvolvidos algoritmos que, a partir de dados da bateria como tensão, corrente e temperatura, realizam a estimativa dessas métricas. Nesta seção, será apresentado o conceito de SOC e SOH, além de alguns algoritmos utilizados para a estimativa do SOC.

2.3.1 SOH

Ao ser utilizada, a bateria sofre uma pequena deterioração, que pode ser amplificada pela forma de uso e/ou ambiente de aplicação. Dessa forma, a bateria não consegue oferecer o mesmo valor de carga que possuía quando era nova, e caso isso não seja considerado, pode causar mau funcionamento [VIDAL et al., 2020].

Assim, é realizada a estimação da vida útil da bateria, também conhecida como *State of Health* (SOH). Este valor indica a capacidade da bateria em comparação com sua capacidade quando nova. Apesar de o valor da carga da bateria ser indicado pelo fabricante, ele decai com o uso, e essa alteração é irreversível. Vale ressaltar que descarregar totalmente ou a ocorrência de sobrecarga afeta profundamente a vida útil da bateria [PROCHAZKA et al., 2016].

O SOH é importante, pois a informação sobre a capacidade de carga que a bateria consegue armazenar torna a estimação do SOC mais precisa.

2.3.2 SOC

O SOC é o indicador de quanta carga há na bateria em comparação com a capacidade total. Esse valor estimado é então utilizado para apresentar a relação de carga em comparação com o valor total do sistema, que, no caso, seria a bateria. Ao indicar a quantidade de carga, auxilia na garantia da confiabilidade e segurança, pois uma estimação imprecisa pode ocasionar mau funcionamento nas baterias, prejudicando o conjunto e o veículo.

Devido à sua importância e complexidade devido ao comportamento não linear das baterias, foram desenvolvidas diversas estratégias de estimação, visando o bom uso e prolongando assim a vida útil da bateria, assegurando a segurança e eficiência do sistema. A seção 2.4 pretende, então, apresentar os métodos de estimação mais utilizados ou tradicionais neste ramo, demonstrando suas características, vantagens e desvantagens [VIDAL et al., 2020].

2.4 Métodos de estimação de carga

Como citado anteriormente, existem diversos métodos, sendo alguns notáveis devido à simplicidade, outros pela eficiência, e alguns por serem amplamente encontrados em diferentes trabalhos. Apesar de haver uma variedade de estimadores, podemos classificá-los em quatro categorias: modelos tradicionais, baseados em modelo, orientados por dados e híbridos [QAISAR, 2020], [ESPEDAL et al., 2021] e [CASTANHO, 2019].

Os modelos tradicionais são aqueles que empregam variáveis físicas da bateria, como corrente, tensão, temperatura, impedância e resistência. Esses dados são então utilizados e comparados com dados anteriores ou tabelados. Como exemplo de métodos amplamente disseminados, tem-se o CC (Corrente Contínua) e OCV (Tensão de Circuito Aberto).

Os estimadores baseados em modelos demandam um amplo entendimento do sistema em questão, no caso, a bateria. Com esse conhecimento, é possível desenvolver um modelo que replica precisamente o comportamento do sistema real. Esse tipo de modela-

gem é bastante empregado na engenharia, pois, com o conhecimento apropriado, é possível simular de forma precisa atividades como a carga da bateria. Para simular a bateria, são utilizados três tipos de modelos: empíricos, eletroquímicos e o modelo mais comum, que é o circuito elétrico equivalente. Este último recorre a uma fonte de tensão, resistor e uma ou mais malhas RC. Devido à sua simplicidade e versatilidade ao utilizar diferentes combinações, esse modelo é amplamente difundido. Ele é frequentemente utilizado em conjunto com um filtro adaptativo para realizar a estimação. Dentro desse grupo, dois exemplos notáveis são o H e o Filtro de Kalman, além de suas variações.

Estimadores orientados por dados são uma abordagem relativamente recente. Esses estimadores fundamentam-se na análise abrangente de vários dados relacionados ao processo. Dessa forma, quando introduzidos no ambiente, esses algoritmos conseguem realizar estimativas com base no aprendizado adquirido durante o treinamento prévio. Um exemplo notável são aqueles que empregam Redes Neurais para estimar a carga.

Os modelos híbridos combinam mais de um método de estimação, possibilitando assim a superação de limitações inerentes a cada modelo individual. Frequentemente, utiliza-se o CC (Constant Current) em conjunto com outro método para mitigar falhas, uma vez que o CC depende do sensor de corrente e do conhecimento da carga inicial da bateria. Essa abordagem híbrida visa aproveitar as vantagens de diferentes métodos para obter uma estimação mais robusta e precisa.

2.4.1 Métodos tradicionais de estimação

A seguir, serão apresentados os três métodos conhecidos deste grupo, sendo eles a Contagem de Coulomb, a Tensão de Circuito Aberto e o Método da Impedância em Corrente Alternada [ESPEDAL et al., 2021] e [CASTANHO, 2019].

2.4.1.1 Contagem de Coulomb

Este método, também conhecido como Ampère hora (Ah), pode ser utilizado para estimar tanto o SOC quanto o SOH. Sua metodologia é realizar a leitura de corrente que adentra ou sai da bateria. A estimação é feita verificando a carga restante em relação ao valor anterior da alteração da carga. A equação básica utilizada pelo CC para estimar o SOC é indicada a seguir

$$SOC(t) = SOC(t - 1) + \frac{\Delta ti(t)}{3600C} \quad (2.1)$$

Sendo $SOC(t)$ indica o valor do SOC no tempo t , $SOC(t - 1)$ o valor do SOC anterior, Δt representa o tempo da amostra, $i(t)$ seria a corrente no tempo e C a capacidade da bateria. Como pode ser verificado, o sistema possui uma dependência do sensor de corrente, sendo que caso indique um valor errôneo este irá ser integrado nas próximas

estimações [MOVASSAGH et al., 2021]. Além disso, o sistema deve garantir o conhecimento preciso tanto do SOC anterior à estimação quanto a carga da bateria. Porém, ao garantir estes 3 pontos sobre o CC, o método demonstra ser uma ótima opção para estimação, pois com ele é possível estimar precisamente com o sistema operando e com baixo processamento requisitado do BMS além de ser de fácil implementação. Contudo, ainda variações derivadas do envelhecimento da bateria e auto descarga não são consideradas neste algoritmo.

2.4.1.2 Tensão de circuito aberto

Do inglês *Open Circuit Voltage*, este método é baseado na comparação do valor de tensão quando a bateria está em repouso (equilíbrio termodinâmico), este valor então é verificado no gráfico que correlaciona a tensão de circuito aberto com o SOC [HOW et al., 2019]. Ele é muito preciso e de fácil implementação, porém, devido a sua sensibilidade a histerese e ao fato da bateria ter que estar em repouso por um período muito longo, podendo chegar a horas, o torna inviável para uso em um veículo comercial. No entanto, alguns autores fazem seu uso para estimar o SOC inicial, prosseguindo com outro estimador como, por exemplo, o CC para auxiliar na estimação [CHENG et al., 2011] e [JEONG et al., 2014].

2.4.1.3 Método da Impedância em Corrente Alternada

Este método usa a correlação entre a impedância e o SOC. É inicialmente injetado uma corrente alternada na bateria, então é feito o uso de um algoritmo para realizar a análise e encontrar o valor dos parâmetros, por exemplo, a resistência interna. Assim, com o valor de impedância encontrado, é verificado na tabela de correlação para encontrar o valor do SOC que se enquadra no valor de impedância [ESPEDAL et al., 2021]. Para que o teste seja realizado, a bateria necessita estar em repouso por um período bem longo, chegando a horas, inviabilizando para ser utilizada como estimador de carga em veículos.

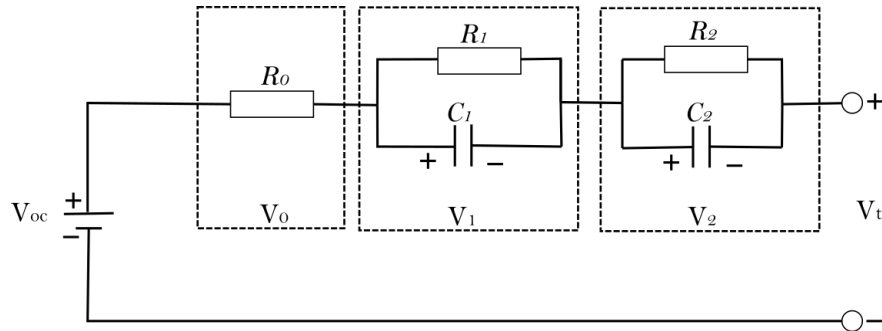
2.4.2 Métodos baseados em modelo

Este tipo de estimador faz o uso de um modelo que representa o comportamento da bateria, este trabalhando em conjunto com um algoritmo que realiza a estimação. Os modelos são classificados em três tipos, sendo eles: Modelos empíricos, de circuito equivalente e eletroquímico [MENG et al., 2018]; [HOW et al., 2019].

Os modelos empíricos são considerados modelos simplificados do modelo eletroquímico, no qual ele efetua a representação não linear da bateria utilizando expressões matemáticas ou polinômio de uma ordem reduzida. Os modelos eletroquímicos utilizam como base Equações de Derivadas Parciais (EDP) para descrever o comportamento. Estes modelos são precisos, porém, devido ao peso de processamento, é muito pouco utilizado para

estimar o SOC. Já os modelos de circuito equivalente utilizam componentes passivos para realizar a emulação do comportamento das baterias. A Figura 3 apresenta um exemplo de ECM (do inglês *Equivalent Circuit Model* - Modelo de Circuito Equivalente).

Figura 3 – Exemplo modelo circuito elétrico



Fonte: Autor, 2024

Sendo V_{oc} o que indica a tensão de circuito aberto, R_o é a resistência interna. Por fim, as malha RC (R_1 , C_1 , R_2 e C_2), tem como intuito simular os comportamentos dinâmicos da bateria, como, por exemplo, a reação de polarização. Este modelo apresenta baixo custo computacional e é versátil, permitindo a construção do modelo conforme o projeto, tornando-o assim comumente utilizado para modelar o comportamento da bateria. Tem como exemplo em [LI et al., 2020]; [LIU et al., 2021]; [YANG et al., 2021]; [MASTALI et al., 2013]. Vale ressaltar que a bateria muda sua resposta conforme o ciclo de uso, assim, o modelo pode perder sua precisão, sendo necessário o uso de um algoritmo para atualizar seus parâmetros.

Como indicado anteriormente, além do modelo é realizado também o uso de um algoritmo para a estimação da carga. A seguir serão apresentados três modelos bem conhecidos e utilizados para este tipo de estimação, o Filtro de Kalman, H_∞ e Filtro de Partículas.

2.4.2.1 Filtro de Kalman

O filtro de Kalman é um algoritmo de estimação que atua em conjunto com o modelo para realizar a estimação. Assim, ele consegue prever comportamentos de sistemas complexos lineares. Este sistema funciona em duas etapas, a primeira sendo a predição da variável estudada no estado atual e a segunda atualizando a estimativa com intuito de minimizar o erro entre o estimado e o real, devido a isto se faz um sistema com relativamente alto custo computacional porém com boa convergência [HOW et al., 2019]; [ESPEDAL et al., 2021]; [CASTANHO, 2019].

Como o sistema da bateria é não linear, o uso de Filtro de Kalman se torna não muito exato, porém existem variações que podem ser utilizadas. Tem como exemplo o Extended Kalman Filter, onde ocorre a linearização de um sistema não linear a cada

etapa, utilizado para tal derivadas parciais baseadas no princípio de linearização de função não linear. Este é bem utilizado para estimar a carga de baterias, tendo como exemplo [YANG et al., 2021]; [ZOU et al., 2015]; [MASTALI et al., 2013].

Por fim, existe o AEKF, que seria o Filtro de Kalman Estendido Adaptativo. A diferença entre ele e o EKF é que o AEKF tem os parâmetros ou as covariâncias do ruído alterados conforme a medição.

Outro também utilizado é o UKF (*Unscented Kalman Filter*), que no que lhe concerne, utiliza a transformação *Unscented*. Esta transformação funciona da seguinte forma: é selecionado um conjunto de pontos denominados como sigma-pontos; estes pontos são escolhidos de forma que a média e a covariância são geradas; é injetada a função não linear em cada ponto que gera uma nuvem de pontos transformados; é encontrada a média e covariância dos pontos transformados que podem ser calculados de modo a formar uma estimativa da média e covariância não-linear transformada [SILVA, 2016]. Apesar do UKF ser melhor, incertezas podem acabar reduzindo sua robustez.

2.4.2.2 H_∞

Também conhecido como *minimax filter*, este algoritmo minimiza o maior erro possível na estimação. Diferente do Filtro de Kalman, este modelo não necessita de suposições das perturbações e incertezas no modelo e por minimizar o maior erro, isto o faz robusto [YAN et al., 2010]; [SIMON, 2006]. Apesar das equações do H_∞ apresentarem a mesma forma que KF, os detalhes diferem, além de que o H_∞ leva muito mais tempo e esforço para afinar o algoritmo. Porém, um fator relevante sobre este algoritmo é que ele não considera envelhecimento, histerese nem variações de temperatura.

2.4.2.3 Filtro de Partículas

Na física, uma partícula subatômica indica de forma genérica que algo é muito menor de dimensão que o átomo (o todo), já na estatística, o termo partícula pode ser utilizado como a realização de um experimento para estimar características desconhecidas e a cada experimento é designado um valor possível para o que está sendo estimado [NASCIMENTO, 2014]. Ou seja, partículas são experimentos cujos possíveis resultados estão definidos no espaço paramétrico do valor desconhecido.

A ideia principal do filtro de partículas é representar a distribuição das partículas sobreviventes (possíveis soluções) do estado latente até um tempo determinado, utilizando um conjunto finito de amostras ou partículas que podem estimar qualquer característica, utilizando-se uma abordagem de estimação de Monte Carlo sequencialmente. Quando ocorre uma nova observação, as partículas são atualizadas para representar a nova *posteriori* (partículas sobreviventes) [NASCIMENTO, 2014].

Por gerar diversos pontos randômicos no espaço de estado e conforme a distribuição referente a cada ponto, isso traz consigo uma complexidade computacional elevada.

2.4.3 Estimadores orientados por dados

Com o *machine learning* e *deep learning* houve um aumento no leque de possibilidades de métodos para estimação. Estes são estimadores orientados por dados, nos quais é realizado o treinamento do algoritmo por meio de um banco de dados, estes então, após o treinamento conseguem, estimar a partir da análise dos dados que foram estudados. Assim, sua exatidão está altamente relacionada ao fato da qualidade e quantidade de dados no qual o algoritmo foi submetido. A seguir será apresentado um método que é muito utilizado para estimar o SOC, este método se chama Redes Neurais. Além deste, serão apresentados o Algoritmo Genético e *Support Vector Machine* [HOW et al., 2019].

2.4.3.1 Redes Neurais

As redes neurais são sistemas de nós que são interconectados, com a funcionalidade de organizar, agrupar e verificar relações entre dados, semelhante ao cérebro humano, por isso o nome. Estes utilizam algoritmos e encontram padrões de relação entre as variáveis. A estrutura básica deste método consiste em 3 camadas para sistemas não lineares, sendo a primeira captando as entradas, a segunda é a camada escondida, onde ocorrem transformações matemáticas e a terceira seria a saída. Neste trabalho a entrada seria os vetores de corrente, tensão e temperatura e a última camada apresenta os valores do SOC. A partir do treinamento da rede, esta então consegue criar as correlações ou sinapses e assim estimar a correlação entre os valores de entrada e o possível valor de saída [VIDAL et al., 2020].

O neurônio artificial é a unidade básica de processamento de uma RNA. Este neurônio, associado computacionalmente a uma estrutura matricial, possui uma ou mais entradas (X_1, \dots, X_n) e uma saída (Y), sendo que cada entrada possui um peso (W_1, \dots, W_n) que pondera quantitativamente cada entrada em relação à saída, além deste, temos o limiar de ativação (b), ele especifica qual seria o patamar apropriado para que o resultado produzido possa gerar um valor de disparo e por fim ($g()$) que seria a função de ativação, cuja função é limitar a saída do neurônio num intervalo.

A equação matemática que descreve o funcionamento de um neurônio é expressa por:

$$Y = g\left(\sum_{i=1}^n W_i X_i + b\right). \quad (2.2)$$

A partir da estrutura do neurônio artificial é possível obter várias topologias de RNA, estas podem ser classificadas como redes multicamadas ou redes de camada única.

A topologia Redes Perceptron Multicamadas, sendo a utilizada no projeto, se refere as redes que possuem camadas intermediárias entre a entrada e a saída. Nestas camadas intermediárias pode haver um neurônio ou vários [JUNIOR, 2014].

Conforme Silva et al. (2010), a rede Perceptron Multicamadas (PMC) pode ser encontrada em várias aplicações, por exemplo, um aproximador de função utilizado para a estimação de carga.

As redes PMC possuem arquitetura *feedforward*, isto significa que cada camada se conecta à próxima camada, no entanto, não há realimentação dos valores para as camadas anteriores. Para o treinamento do algoritmo utiliza-se o método de *backpropagation*, no qual o treinamento é realizado de forma supervisionada. Assim, ocorre a comparação do valor estimado de saída com uma referência, este então gera o erro calculado que será utilizado para o algoritmo corrigir os pesos em todas as camadas, retrocedendo da saída até a entrada [JUNIOR, 2014].

2.4.3.2 Algoritmo Genético

Esse algoritmo é uma técnica inspirada na biologia evolutiva, esse sistema recorre a candidatos à solução, chamados como elementos da população, estes representados de forma binária denominada cromossomos.

A adaptação é realizada ao se mover uma população para uma nova usando operadores de seleção genética de união, mutação e inversão [CHAOUÏ et al., 2015]. Assim, a cada geração é feita a análise dos indivíduos mais aptos, estes então se reproduzem para geração de soluções melhores. Esse processo se repete até que seja encontrado um valor de aptidão satisfatório.

Apesar de ser exato, este algoritmo apresenta baixa convergência e necessita de uma taxa de processamento relativamente alta [SHEN et al., 2018].

2.4.3.3 *Support Vector Machine*

É uma técnica do *Machine Learning* utilizado diversas vezes na resolução de problemas que envolvam classificação e regressão.

O SVM tem como conceito a classificação de dados ao se utilizar hiperplanos em um espaço dimensional.

Para a estimação do SOC é indicado o uso de uma variação conhecida como *Support Vector Regression* (SVR), esta técnica resolve um problema de regressão para dados que não são linearmente separados, isto a faz muito eficaz neste tipo de sistema, porém é oneroso computacionalmente e é lento no ajuste de parâmetros [VIDAL et al., 2020] e [HOW et al., 2019].

Assim, com o que foi verificado de características dos algoritmos de estimação, foi desenvolvida a Tabela 1, onde é apresentado resumidamente as vantagens e desvantagens dos algoritmos apresentados.

Tabela 1 – Vantagens e desvantagens dos principais métodos de estimação de carga

Método	Vantagens	Desvantagens
CC	Fácil implementação, baixo consumo computacional	Não considera envelhecimento, auto-descarga e erro de sensores
OCV	Fácil implementação, precisão	Sensível a histerese, necessita a bateria estar em repouso
EIE	Simples, exato	Não pode ser online
FK	Boa convergência mesmo com erros iniciais	Utilizado em sistemas lineares
FKE	Mais preciso que FK	Robustez depende da linearização e do modelo
FKU	Processamento reduzido em relação ao FKE	Incerteza do modelo, perturbações causam baixa robustez
FP	Alta precisão, consegue lidar com ruídos	Complexidade computacional
H_∞	Preciso e tempo computacional satisfatório	Não considera envelhecimento, histerese e temperatura
RNA	Versátil, eficaz e pode considerar envelhecimento e temperatura	Depende dos dados de treinamento (quantidade e qualidade)
MVS	Boa operação com sistemas não lineares	Oneroso computacionalmente lento nos ajustes dos parâmetros
GA	Precisão	Convergência lenta, baixa garantia de convergência

Fonte: Baseado em [HOW et al., 2019]; [CASTANHO, 2019]; [SALKIND et al., 1999]; [VIDAL et al., 2020]; [SHEN et al., 2018]; [CHAOUI et al., 2015]; [JUNIOR, 2014]; [NASCIMENTO, 2014]; [YAN et al., 2010]; [SIMON, 2006]; [SILVA, 2016]; [YANG et al., 2021]; [ZOU et al., 2015]; [MASTALI et al., 2013]; [LI et al., 2020]; [LIU et al., 2021]; [MENG et al., 2018]; [CHENG et al., 2011]; [JEONG et al., 2014] e [MOVASSAGH et al., 2021]

Assim, é possível verificar que cada algoritmo possui sua característica, dependendo da demanda requisitada algoritmos diferentes podem ser utilizados. Os requisitos considerados pelo projeto, são: complexidade computacional, que seria o consumo de processamento que o algoritmo requisitaria; aplicabilidade, sendo a capacidade de utilizar em ambientes e condições diferentes; online, conseguir estimar mesmo ocorrendo a carga ou descarga; confiabilidade, a resposta estimada deve representar com exatidão e precisão o Estado de Carga. Com base nestes requisitos, foram selecionados os algoritmos UFK e RNA para serem implementados e avaliados, no entanto, é necessário um algoritmo para atuar como estimador de referência, para tal foi selecionado o Coulomb Counting.

3 METODOLOGIA PARA SIMULAÇÃO E DESENVOLVIMENTO DE BANCO DE DADOS PRODUZIDOS A PARTIR DE UM ROBÔ ADAPTADO

Para realizar o estudo comparativo dos algoritmos de estimação de carga, foi produzido um banco de dados, gerado com carga real (robô adaptado). Para tal, foi desenvolvido uma metodologia onde um *pack* de 4 baterias de NMC trabalham em ciclos de descarga, tendo um circuito de instrumentação monitorando os valores de tensão, corrente e temperatura, por fim é utilizada a rede Wi-Fi para enviar os dados coletados para o servidor SQL armazenar.

Em primeira instância seria realizada a coleta dos dados para ser gerado um banco de dados, sendo posteriormente utilizado em tempo real com a estimação.

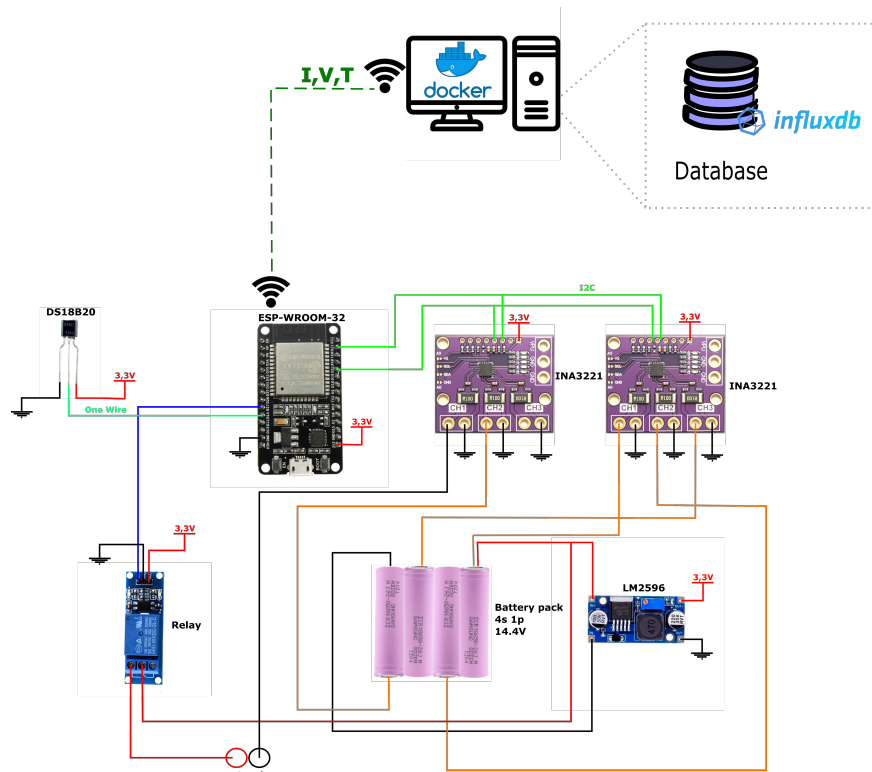
Nesta seção será apresentada a metodologia de coleta, os componentes utilizados e como foi realizado o ensaio offline e online.

3.1 Protocolo de coleta dos dados do robô adaptado

Inicialmente foi verificado quais os requisitos necessários para o desenvolvimento do banco de dados, assim, foi visto que seria necessária a coleta das variáveis de tensão, corrente e temperatura das baterias utilizadas. Estes valores em conjunto com o tempo devem ser armazenados indicando o ciclo e a data. Outro ponto seria selecionar um componente para ser a carga e o uso de uma fonte para carregar as baterias do *pack* utilizado.

A partir da análise desses requisitos foi feita a seleção dos componentes necessários para a implementação. O diagrama mostrado na Figura 4, apresenta o sistema projetado incluindo a etapa de envio dos dados.

Figura 4 – Diagrama esquemático do sistema de coleta de dados



Fonte: Autor, 2024

Para a produção do banco de dados foi selecionada a placa de desenvolvimento ESP32-WROOM, que possui integrado um módulo Wi-Fi, contando também com 520 Kb de SRAM e 16 Mbyte de Flash. Seu *clock* opera a 240 MHz e a tensão de operação varia de 2,2 V até 3,6 V. Este seria responsável por, a cada 1 segundo, enviar ao computador *host* os dados em JSON.

Foi selecionado o módulo INA 3221 como sensor de tensão e corrente. Este módulo possui três canais e permite a leitura tanto da tensão quanto da corrente por canal, com uma resolução de 13 bits e um erro de ganho da tensão, tanto do *shunt* utilizado para a leitura de corrente quanto da tensão externa, de 50 ppm/°C. Além de haver a possibilidade de alimentar entre 2,7 V à 5,5 V e permitir leitura da tensão da carga até 26 V. Ele envia os dados utilizando a comunicação I2C. Como são monitoradas quatro baterias, são necessários quatro canais para a leitura individual da tensão de cada uma, e um canal para a corrente do *pack*. Dessa forma, foi necessário o uso de dois INA's.

Para a leitura da temperatura do *pack* foi selecionado o sensor DS18B20, que consegue fornecer os dados via comunicação One Wire, reduzindo a quantidade de fios, além de possuir $\pm 0,5$ °C de exatidão e proporcionar leituras de temperatura com resolução de até 12 bits.

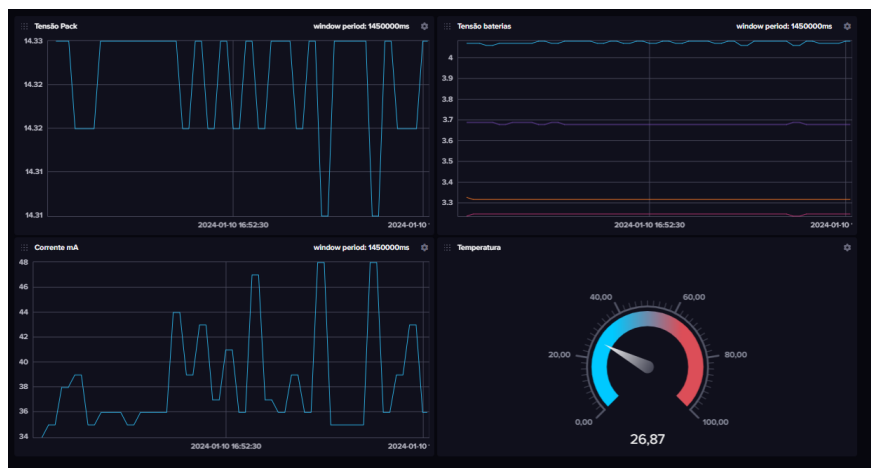
Além dos sensores, a placa possui um relé, este está conectado entre o *pack* de

baterias e o robô aspirador e tem como função desconectar a alimentação da carga em caso de falha ou caso seja requisito do ensaio.

Todos os componentes citados são alimentados pelo módulo LM2596. Este aceita como alimentação de entrada até 40 V e permite configurar a saída para até 12 V, tendo uma eficiência de 90 %. Este, então, recebe a tensão de 14,4 V do *pack* e converte para 3,3 V para ser utilizado pelos demais componentes.

O ESP32 organiza os dados em formato JSON e os envia para o computador host (via *Websocket*). Este, por sua vez, irá reajustar os dados para que possam ser salvos no banco de dados InfluxDB, além de disponibilizar uma interface para verificar o andamento do ensaio, a Figura 5 apresenta a interface desenvolvida para apresentação dos dados recebidos pelo banco de dados. O computador utilizado como *host* possui um processador i7, da 8ª geração e processador com 64 GB de RAM.

Figura 5 – Interface para apresentação de dados



Fonte: Autor, 2024

Assim foi desenvolvido todo o sistema, este foi integrado e alocado na parte superior do robô adaptado que seria utilizado como descarga, a Figura 6 apresenta a foto do sistema.

Figura 6 – Robô aspirador adaptado (a) parte traseira onde é verificado o local onde é adicionado as baterias (b) parte frontal do robô onde é possível verificar a placa de instrumentação



(a)



(b)

Fonte: Autor, 2024

Assim, os componentes utilizados para a realização do projeto são:

- Robô aspirador adaptado;
- *pack* de 4 células;
- Carregador para baterias 18650;
- Circuito de instrumentação;
- Case;
- BMS comercial.

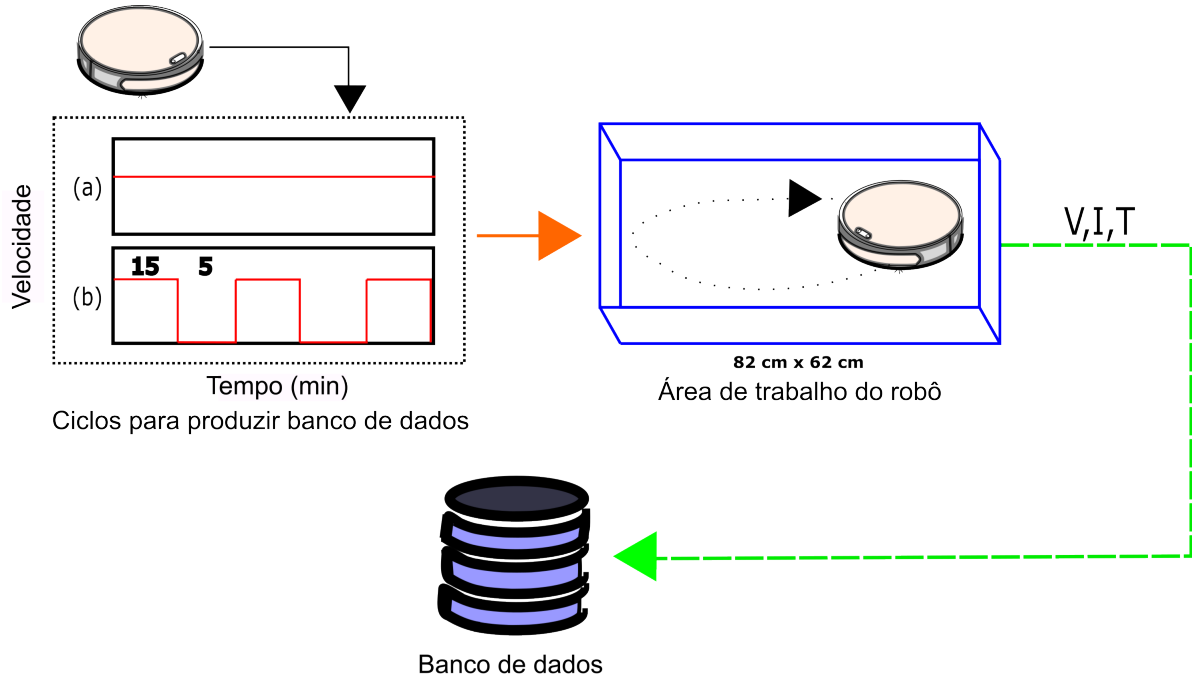
Com exceção da carregador, os demais são utilizados em ambas as etapas, as etapas que serão apresentadas a seguir.

Na etapa da coleta de dados foi utilizado o *pack* de baterias com o uso de um BMS para balanceamento das baterias e sem o controle da temperatura dentro da case.

Com a metodologia de coleta desenvolvida, a próxima etapa é o fluxo operacional, ou seja, as ações que devem ser tomadas em cada ciclo visando manter um padrão de

qualidade. A Figura 7 indica o processo operacional desenvolvido tanto para carga (a) quanto para a descarga (b).

Figura 7 – Fluxograma operacional Descarga



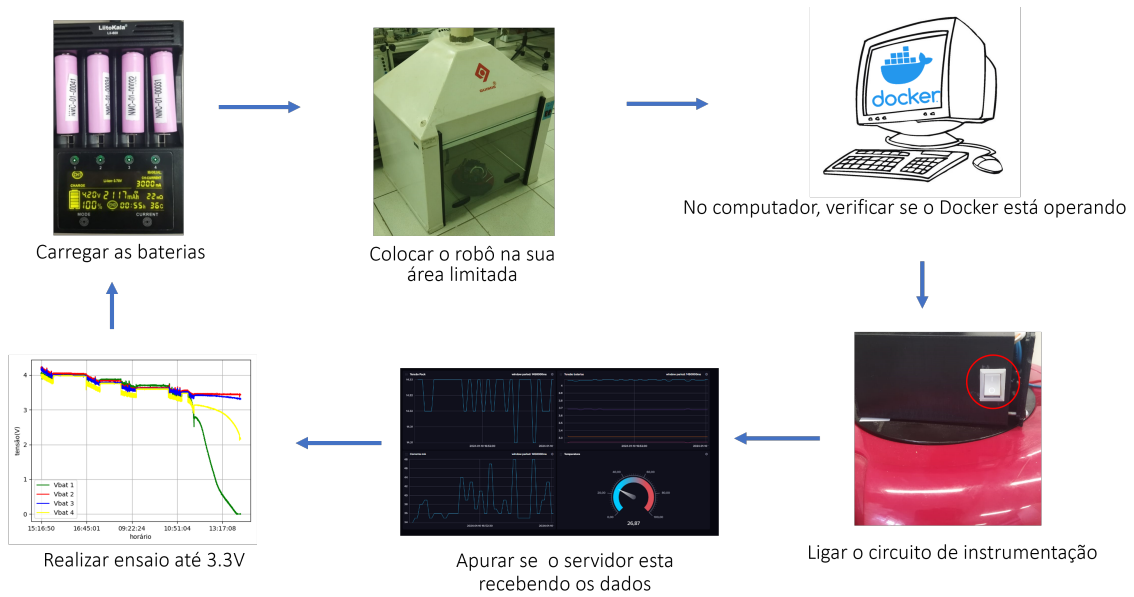
Fonte: Autor, 2024

Para a produção do banco de dados, foram realizados dois ensaios. A diferença entre eles está no fato de que, enquanto um envolve o consumo contínuo da capacidade das baterias, o outro inclui paradas de 5 minutos após 15 minutos de funcionamento.

Para que o robô não acabasse danificando o circuito de instrumentação foi montado um ambiente cercado, de dimensões de 62 x 82 cm, este foi montado no chão, assim o robô pode circular sob o piso de forma segura e sem obstáculos. A carga das baterias foi realizada utilizando o carregador modelo Liitokala Lii-600 da fabricante Liitokala. Este carregador possui 4 compartimentos separados, nos quais as baterias podem ser carregadas com três valores de correntes diferentes, ou no modo de reparo, onde é injetado 250 mA até que a bateria atinja o valor de 4,2 V.

O primeiro ensaio foi realizado 7 vezes enquanto o segundo foi realizado 8 vezes, lembrando que como foi utilizado um *pack*, o ensaio foi finalizado quando uma das 4 baterias apresentasse o valor considerado mínimo, que neste estudo é de 3,3 V. Cada bateria gera uma curva por ensaio, desta forma, cada ensaio produz 4 curvas. Foram gerados ao total 60 curvas, sendo 28 para o ensaio contínuo e 32 para o ensaio com repouso, no total foram produzidos 583.970 dados, deste valor 252.148 foi para ensaio contínuo. A Figura 8 apresenta o fluxograma utilizado para a realização de cada ensaio.

Figura 8 – Fluxograma operacional Descarga



Fonte: Autor, 2024

3.2 Robô aspirador adaptado

Um dos alicerces para a execução deste trabalho foi utilizar um robô aspirador como descarga para o *pack*, uma vez que sua dinâmica se assemelha, de forma simplificada, à de um veículo. Foi escolhido o robô da fabricante Multilaser®, modelo HO041, com dimensões de 11,50 cm de altura e 38,2 cm de diâmetro. Para seu funcionamento, é requerida uma tensão mínima de 12,8 V, uma potência de 17 W e corrente máxima de 900 mA.

3.3 Pack de Baterias

Dentre os modelos químicos utilizados de baterias, os que mais se destacam no mercado de veículos elétricos são as de LFP e NMC, sendo que a NMC apresenta maior densidade de energia, reduzindo assim o volume do *pack* necessário para mesma demanda que LFP.

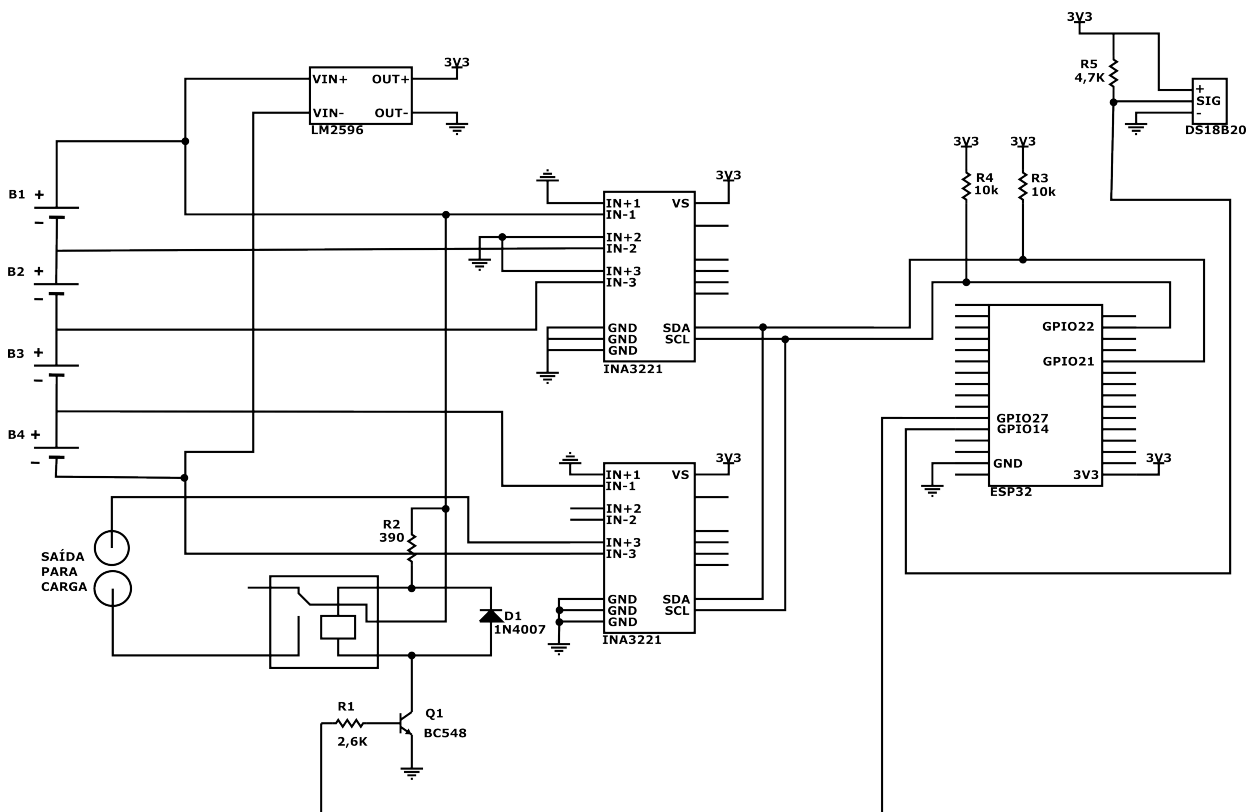
Assim, para a produção do *pack*, foi selecionada a bateria modelo INR18650-30Q da fabricante Samsung que utiliza NMC. Esta apresenta uma tensão nominal de 3,7 V e máxima de 4,2 V, com capacidade de 3.000 mAh. Para atender à demanda de consumo, foi fabricado um *pack* utilizando quatro baterias em série, resultando em uma tensão de 14,8 V. Para proteger o *pack*, foi empregado um BMS do modelo 4S 30 A, com 4 canais, possuindo dimensões de 50 mm x 22 mm e com balanceamento passivo das baterias, além de possuir proteção contra sobrecorrente, sobre-descarga e de curto-circuito.

Foi utilizado um suporte de baterias do modelo 18650 para alocar as baterias, desta forma tornando mais fácil o manuseio das baterias para carregá-las ou verificar sua saúde.

3.4 Circuito de Instrumentação

Para monitorar o *pack* de 4 baterias e fornecer os dados para gerar o banco de dados, foi necessário desenvolver um circuito de instrumentação. Assim, Foi desenvolvida uma placa dedicada com o circuito de instrumentação conforme ilustrado na Figura 9.

Figura 9 – Circuito de instrumentação



Fonte: Autor, 2024

Para a leitura da tensão, como mencionado anteriormente, são utilizados os canais do INA3221. O sistema foi desenvolvido de forma que realiza a leitura referencial, ou seja, o valor indicado de tensão é referente ao GND. Para obter a tensão da bateria em questão, é necessário realizar a subtração com o valor da bateria anterior. Esse método é aplicado para os quatro canais usados para a leitura de cada bateria. É importante destacar que o módulo INA3221 vem com um resistor *shunt* conectado em série às entradas de cada canal. Para utilizar o método descrito acima, foi necessário removê-lo.

A corrente foi medida utilizando o canal IN1 do segundo INA3221. Foi integrado um resistor *shunt* de $50\text{ m}\Omega$ conectado entre a carga e o sinal negativo da última bateria. Assim, o sistema verifica a tensão no resistor *shunt* e, a partir da Lei de Ohm, calcula a corrente. O valor da resistência é baixo para não interferir no sistema.

Ambos os INAs utilizam comunicação I2C, necessitando apenas da ligação em paralelo de um resistor *pull-up* de $10\text{ k}\Omega$. Esse resistor é utilizado para garantir que o sinal de linha de dados ou *clock* esteja sempre em nível lógico 'alto' quando não estiver sendo ativado pelo dispositivo mestre. A seleção do identificador do módulo requer apenas a realização de uma pequena solda, conforme o manual do mesmo.

Por fim, para realizar o monitoramento de temperatura, utiliza-se o DS18B20, conectado à entrada D14 do ESP32. Este sensor utiliza a comunicação Onewire, ou seja, envia os dados utilizando apenas um fio, sendo este um coletor aberto de um transistor NPN. Neste transistor, o pino emissor é conectado ao GND, tornando necessário o uso de um resistor *pull-up* $4,7\text{ k}\Omega$.

O relé é controlado utilizando um transistor NPN, o BC548, e neste sistema, sendo operado como chave nas regiões de saturação ou corte, ou seja, está conduzindo ou está aberto, respectivamente.


Para garantir a integridade do circuito do relé, foi adicionado um diodo conectado em paralelo à sua bobina (diodo de roda livre), para quando ocorrer a desenergização da bobina a corrente ter caminho por onde fluir, já que o transistor entra no modo de corte.

O circuito então foi desenhado utilizando o programa de desenvolvimento de PCBs Altium Designer[®], no mesmo e foi realizado o roteamento da placa. Por fim, foi utilizada a prototipadora PCB-Proto S1 para a produção da placa. A Figura 10 apresenta a placa finalizada após prototipagem e solda.

3.4.1 Protocolo de simulação offline

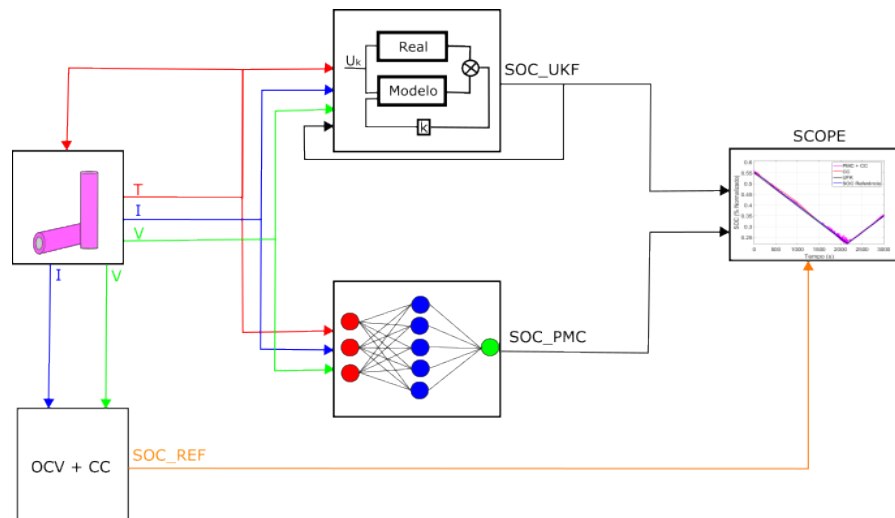
Para realizar o estudo comparativo entre os estimadores foi utilizado o software *Matlab/Simulink*[®]. A Figura 11 ilustra a arquitetura macro utilizada na simulação offline.

Figura 10 – Placa circuito de instrumentação



Fonte: Autor, 2024

Figura 11 – Metodologia simulação offline

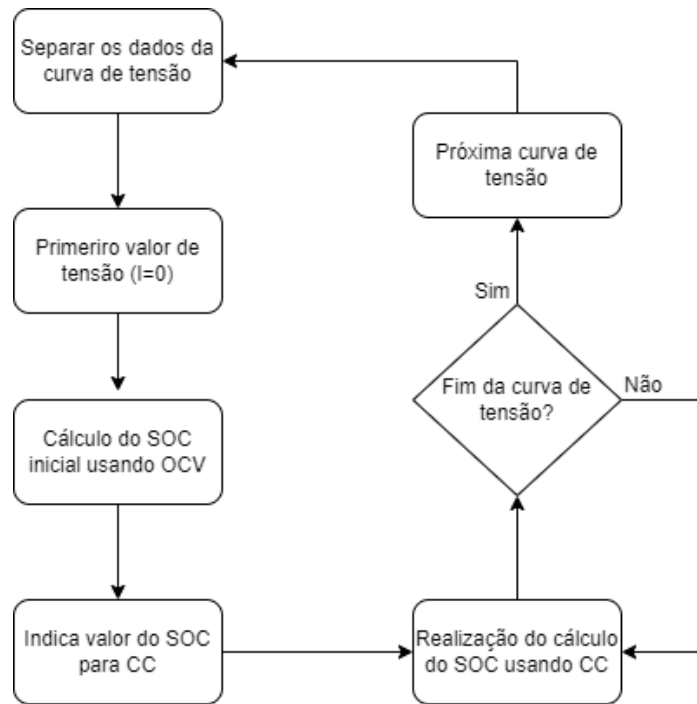


Fonte: Autor, 2024

Inicialmente, utilizando o banco de dados produzido, é realizada a produção de um SOC de referência, este para auxiliar na análise dos algoritmos. Assim foi feito o uso do algoritmo OCV em conjunto com o CC, no qual o OCV tem como função gerar o primeiro SOC do ciclo. Este valor é utilizado como entrada no algoritmo do CC que irá realizar o cálculo do SOC da bateria no restante do ciclo de carga ou descarga. Ao finalizar o

ciclo, é realizada novamente a verificação do SOC utilizando OCV para o próximo, desta forma reduzindo as chances de erro acumulativo derivado da integração do algoritmo de CC quando usado para diversos ciclos. Este método foi utilizado em cada bateria de cada *pack* separadamente, adquirindo assim o valor de referência de cada uma. A Figura 12 apresenta o fluxograma da metodologia de geração do SOC de referência.

Figura 12 – Fluxograma para desenvolvimento do SOC de referência



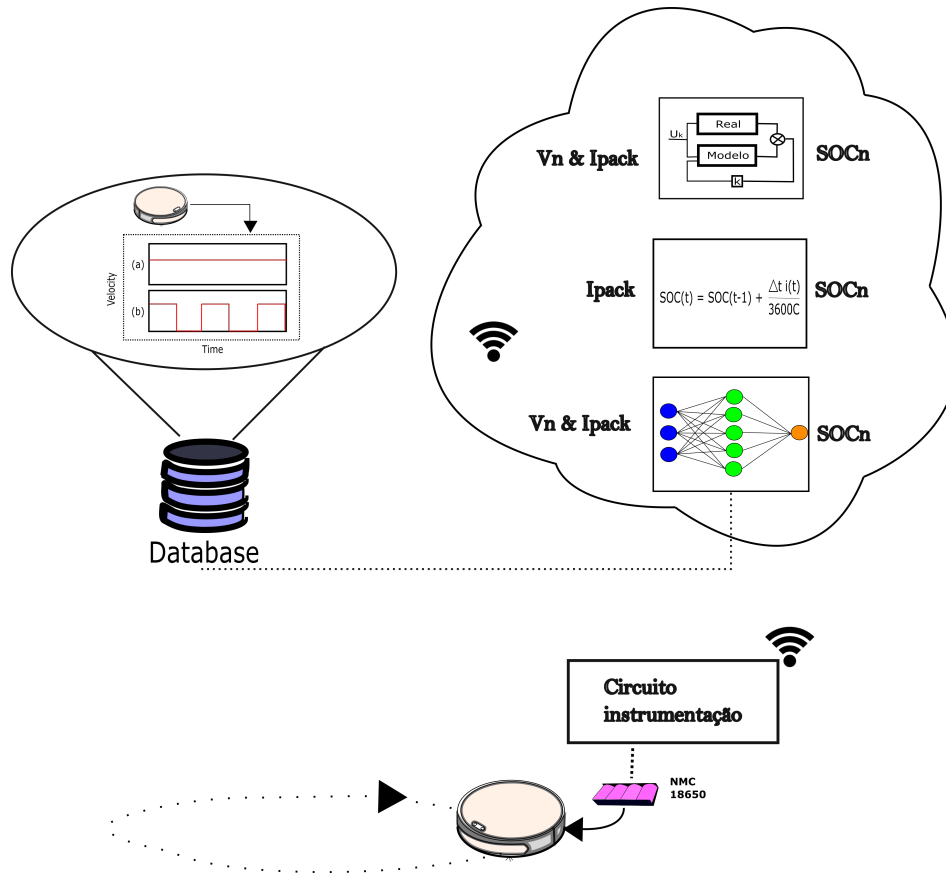
Fonte: Autor, 2024

Assim, foi selecionada a função apresentada por [FADLAOUI; ISMAIL; MASAIF, 2021]. Dentre elas a que teve melhor desempenho e em conjunto com CC desenvolvido no *Matlab/Simulink*[®] o SOC de referência para cada bateria foi produzido, sendo que cada ciclo foi calculado separadamente e no fim foi concatenado os ciclos.

3.4.2 Protocolo de simulação online

Para realizar o estudo comparativo entre os estimadores, foi conduzido quatro ensaios online no qual a estimação do Estado de Carga (SOC) é realizada em tempo real. A Figura 13 representa a arquitetura do ensaio online.

Figura 13 – Metodologia para o ensaio online.



Fonte: Autor, 2024

Foi empregada a mesma metodologia de descarga e repouso utilizada na geração do banco de dados, ou seja, até o terceiro ensaio a cada 15 minutos de descarga ocorre o repouso por 5 minutos, já o quarto foi realizada a descarga de forma contínua, utilizando as mesmas baterias que foram empregadas na produção do banco de dados. O ensaio online ocorre até que uma das baterias atinja 3,3 V, após isto é feito o encerramento visando reduzir possíveis danos ao *pack*. Durante a descarga, são coletados dados de tensão, corrente e temperatura em intervalos de 1 segundo. Esses dados são então enviados para um servidor local, que realiza a estimação em tempo real e apresenta as informações na interface do InfluxDB, incluindo os valores dos sensores, o cálculo da derivada de tensão e o Estado de Carga (SOC) estimado para cada bateria.

Os dados de corrente são posteriormente injetados em um modelo do Simulink para calcular o Estado de Carga (SOC) utilizando a técnica de Coulomb Counting (CC). O valor inicial do SOC é inicialmente configurado com o primeiro valor estimado pela rede neural.

3.4.3 Implementação do Coulomb Counting

O *Coulomb Counting* realiza a estimativa do SOC por meio da integral da energia que é injetada ou retirada da bateria (Movassagh et al., 2021). Foi utilizado o método *Forward Euler* que representa a referida técnica sendo dado por

$$u_{(n)} = (-I_{(n)}/3600)/C, \quad (3.1)$$

$$x_{(n+1)} = x_{(n)} + KT u_{(n)} \quad (3.2)$$

e

$$\hat{y}_{(n)} = x_{(n)}, \quad (3.3)$$

sendo $u_{(n)}$ a entrada do bloco que realiza a integração, $-I_{(n)}$ a corrente de carga/descarga no passo n , C a carga nominal da bateria, $x_{(n+1)}$ o estado estimado do sistema, $x_{(n)}$ é o estado do sistema, K indica o ganho¹, T é o tempo de amostragem e $\hat{y}_{(n)}$ a saída do bloco.

O sistema faz a integral do sinal de corrente considerando a carga da bateria e assim é encontrado o valor do SOC da bateria simulada.

3.4.4 Implementação do *Unscented Kalman Filter* (UKF)

O UKF foi implementado conforme [GAZZARRI, 2022], no qual recorre à biblioteca de *Unscented Kalman Filter* utilizada no *Matlab/Simulink*[®]. Este filtro é dividido em 3 subetapas, sendo elas: desenvolvimento da Função do Estado de Transição da Bateria, da Função de Medição da Bateria e o bloco *Unscented Kalman Filter* utilizado para a realização da estimação.

Os parâmetros calculados com base nos dados reais são adicionados em tabelas de equivalência para serem utilizadas pelas funções. Assim, inicia-se com a Função do Estado de Transição da Bateria, $xNext$, dada por

$$xNext = (f_{(x,u)}T_s) + \vec{x}, \quad (3.4)$$

sendo $f_{(x,u)}$ a função de transição de estados não linear, T_s tempo de amostragem e \vec{x} o vetor de estados. Para calcular a Função de Medição da Bateria, y , utiliza-se

$$y = V_{OC} - R_0 I - V_1 - V_2, \quad (3.5)$$

onde V_{OC} indica a tensão em circuito aberto, R_0 a resistência interna, I a corrente de carga/descarga, V_1 e V_2 indicam as tensões das malhas RC_1 e RC_2 respectivamente, sendo que R_0 e V_{OC} são dependentes da temperatura e do SOC anterior (Gazzarri, 2022; Mathworks, 2022).

¹ Ganho utilizado pelo modelo de integração sendo definido nos parâmetros do bloco *Discrete-Time Integrator* do *Matlab*[®]

Com ambas as funções prontas, estas são informadas para serem utilizadas no bloco *Unscented Kalman Filter*. O bloco do filtro receberá de entrada o valor de tensão com ruído e irá fornecer a estimação do Estado da Carga no tempo T_s . O algoritmo utilizado pelo bloco *UKF* é apresentado em [MATHWORKS®, 2022] e deve ser alimentado com valores de covariância inicial, parâmetros de transformação Alfa, Beta e Kappa, deve ser também indicado a covariância do sistema. Por fim, as tabelas dos parâmetros do modelo selecionado para representar a bateria, que no caso seria malha RC de segunda ordem.


3.4.4.1 Determinação dos parâmetros

Para ser utilizado o UFK na estimação do algoritmo, é necessário introduzir uma representação da bateria. Para tal foi selecionado o modelo RC de 2 malhas.

Para realizar a parametrização necessária para ser utilizada no Simulink, optou-se pelo método de *Electrochemical Impedance Spectroscopy* (EIS), que emprega um sinal de excitação (corrente ou tensão) abrangendo um intervalo de frequência. Utilizando um equipamento adequado, a impedância apresentada pela bateria é medida.

Devido à necessidade de um equipamento de alta precisão, foi solicitado ao Laboratório de Teste e Desenvolvimento de Baterias do Instituto Senai de Inovação em Eletroquímica a realização desse ensaio. Para tal, foi utilizado o equipamento Autolab PGSTAT302N com módulo de impedância. A Figura 14 apresenta o equipamento utilizado.

Figura 14 – Autolab PGSTAT302N



Fonte: Laboratório de Teste e Desenvolvimento de Baterias, 2024

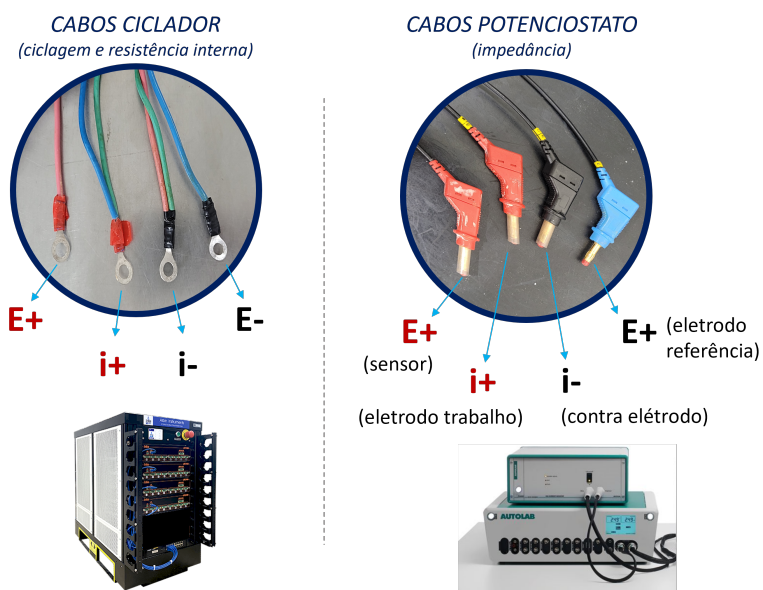
Para controlar o equipamento e extrair os parâmetros após o EIS, foi utilizado o software NOVA da empresa Metrohm. No entanto, antes de iniciar as medidas, procedeu-se à ativação das células, realizando 5 ciclos de carga e descarga com o intuito de obter resultados de impedância com maior precisão. Pois a ativação tem como função de tirar a célula de um estado de repouso, quando ela fica armazenada ela acaba alterando suas características elétricas, assim é necessário realizar um estímulo inicial para retirar ela do repouso e colocar no estado estacionário, que mais aproxima do seu estado de uso.

No processo de carga, foi empregado o método CC-CV (Corrente Constante - Tensão Constante), mantendo a corrente em 1C até atingir o limite superior de tensão de 4,2 V. Posteriormente, a tensão foi mantida nesse valor até que a carga atingisse 0,05C, que é equivalente à corrente de 150 mA. Já na descarga, foi utilizado um método de corrente constante de 1C até o limite inferior de tensão de 2,5 V. Para realizar tanto a carga quanto a descarga, foi utilizado o ciclador BT-M-25 da Arbin Instruments.

Após a ativação, procedeu-se à descarga da bateria a uma taxa de 1C durante 12 minutos para alcançar o valor de SOC previamente estabelecido. A bateria foi então deixada em repouso por 24 horas antes de ser realizado o registro da impedância. Foram selecionados intervalos de 80 %, 60 %, 40 % e 20 % do SOC para as descargas, as quais foram realizadas utilizando o ciclador mencionado anteriormente.

As medidas de impedância eletroquímica foram registradas em regime potencios-tático, abrangendo o intervalo de frequência entre 2 kHz e 10 mHz, com amplitude de 5 mV e registro de 10 pontos por década. A montagem do sistema seguiu o modelo de 4 contatos com a célula, conhecido como medida a *4-wires*. O uso dessa técnica de medição (*4-wires*) é extremamente importante, pois este modo reduz os ruídos que podem estar relacionados aos cabos utilizados, este método é utilizado nos equipamentos que requerem alta precisão e trabalham com pequenos valores, como a resistência de baterias, a Figura 15 apresenta alguns equipamentos utilizados pela equipe do Laboratório de Teste e Desenvolvimento de Baterias que apresentam esta configuração.

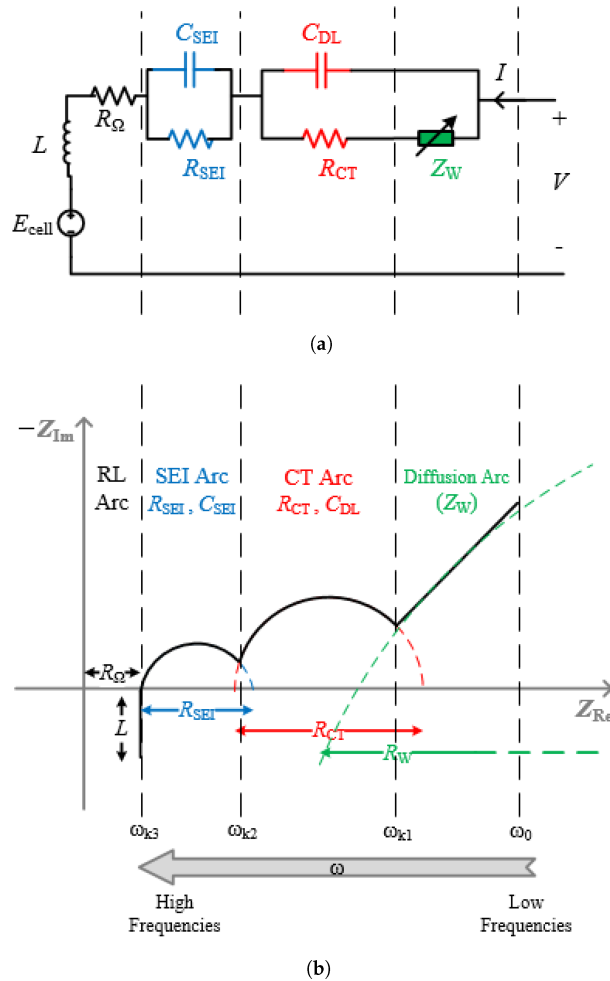
Figura 15 – Conexão de equipamentos para baterias



Fonte: Laboratório de Teste e Desenvolvimento de Baterias, 2024

Após o ensaio, foram gerados arquivos na extensão .NOX para serem utilizados no software NOVA. Na primeira etapa, verificou-se qual intervalo de dados seria utilizado para o estudo. A Figura 16 apresenta como analisar o resultado do EIS em relação à modelagem de baterias.

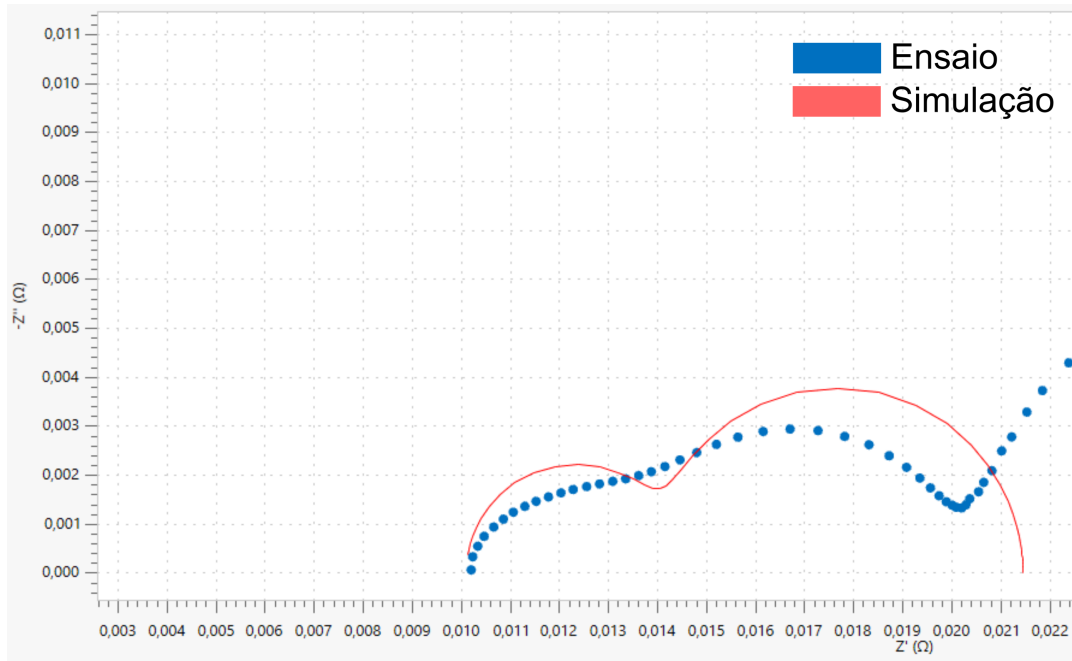
Figura 16 – Parametrização a partir de curva gerada pelo EIS (a) modelo a ser produzido (b) gráfico de Nyquist produzido do EIS



Fonte: Abaspour et. al., 2022

Como o modelo do estudo é um RC de segunda ordem, os intervalos representados como SEI Arc, CT Arc e RL Arc apresentam os dados de interesse. No entanto, para o desenvolvimento do modelo no programa NOVA, foi utilizado o CPE (Constant Phase Element) em vez do capacitor. Isso se deve ao fato de o sistema ser eletroquímico e não puramente capacitivo, sendo o CPE uma representação mais adequada e mais próxima do necessário. A Figura 17 traz o resultado de um modelo RC de segunda ordem no qual foram utilizados capacitores.


Figura 17 – Resposta do modelo utilizando capacitor no software NOVA



Fonte: Autor, 2024

O primeiro passo para a parametrização foi utilizar a ferramenta *Windower* para recortar somente o intervalo necessário para o estudo, começando pelo primeiro semicírculo. Foram utilizadas as ferramentas *Electrochemical Circle Fit* para selecionar os pontos do semicírculo, e os parâmetros iniciais da primeira malha foram exportados para a ferramenta *Electrochemical Circle Fit*. O mesmo processo foi repetido para o segundo semicírculo. Após a criação do circuito equivalente, realizou-se a alteração dos parâmetros visando aproximar-se do gráfico de Nyquist da bateria naquele intervalo. A Figura 18 apresenta o gráfico com ambos o Nyquist e a resultante do modelo.

Figura 18 – Gráfico de Nyquist do modelo e experimental



Fonte: Autor, 2024

Como pode ser verificado, o modelo teve uma boa resposta, este processo se repetiu para os demais intervalos para chegar a uma tabela e esta ser implementada no UFK do Simulink. Com os parâmetros encontrados para todo o intervalo selecionado, próxima etapa foi a conversão do CPE para capacitor, foi utilizado a fórmula apresentada por [BYOUNG-YONG, 2020].

3.4.5 Implementação das Redes Neurais Artificiais (RNA)

O primeiro passo para o treinamento supervisionado de uma RNA é elaborar o banco de dados de entrada, utilizado para o ajuste dos parâmetros internos da rede. Neste procedimento, a RNA deve ser exposta a um conjunto de dados que descreve satisfatoriamente o comportamento do sistema [GOEDTEL et al., 2010].

A arquitetura de RNA utilizada para a estimação de carga foi a Rede Perceptron Multicamadas e foram utilizados os dados do banco de descarga gerado para realizar o treinamento da rede PMC. Assim, foram apresentadas as entradas da rede, que consistem nos valores de tensão, corrente, temperatura, e na derivada da tensão calculada. A Tabela 2 exibe os parâmetros da PMC utilizada.

Tabela 2 – Parâmetros do PMC utilizado.

Arquitetura	PMC
Tipo de treinamento	Supervisionado
Número de dados	583.970
Relação Treinamento/Validação	80 %/20 %
Épocas	20.000
Número de camadas	5
Neurônios na 1ª camada escondida	10
Neurônios na 2ª camada escondida	10
Neurônios na 3ª camada escondida	10
Algoritmo de treinamento	Backpropagation + Adam
Taxa de aprendizagem	$1 * 10^{-3}$
Função de ativação camada escondida	Tangente Hiperbólica
Função de ativação camada de saída	Linear

Fonte: Autor, 2024

Os dados foram normalizados antes de serem utilizados, e a entrada da derivada de tensão foi gerada para indicar à rede neural os pontos em que o sistema estaria em repouso. Isso se deve ao fato de que, durante a descarga, presume-se que

$$V_{(t)} < V_{(t-1)}, \quad (3.6)$$

enquanto em repouso

$$V_{(t)} = V_{(t-1)}. \quad (3.7)$$

Além disso, utilizou-se a variação de 3,3 V até 4,2 V como o valor inicial (0 % SOC) e totalmente carregado (100 % SOC).

Um ponto importante é a forma de apresentação dos dados. Cada curva é considerada como um agrupamento e não pode ser separada. Além disso, 80 % de cada grupo foi utilizado para o treinamento e 20 % para a validação.

Foi desenvolvido um algoritmo em Python para realizar o treinamento da rede e gerar seu modelo de saída para utilização. Após o treinamento, o modelo foi salvo com a extensão .pth. Esse modelo é então integrado a outro firmware, desenvolvido em Python, responsável por receber os dados, ajustá-los, inseri-los na rede e enviar os resultados para o InfluxDB.

3.4.6 Análise estatística

Para a realização da análise estatística entre os erros (Estimadores/SOC de referência) foram utilizadas as métricas de Raiz do Erro Quadrático Médio (do inglês *Root*

Mean Square Error - RMSE) e o Erro Médio Absoluto (do *inglês Mean Square Error* - MAE) de cada *pack* (Tertuliano et al., 2020; Fawcett, 2006). Para calcular o MAE e RMSE são utilizados

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (3.8)$$

e

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2}, \quad (3.9)$$

sendo n o número de amostra, y_j o valor do estado de carga de referência e \hat{y}_j o valor do estado de carga estimado.

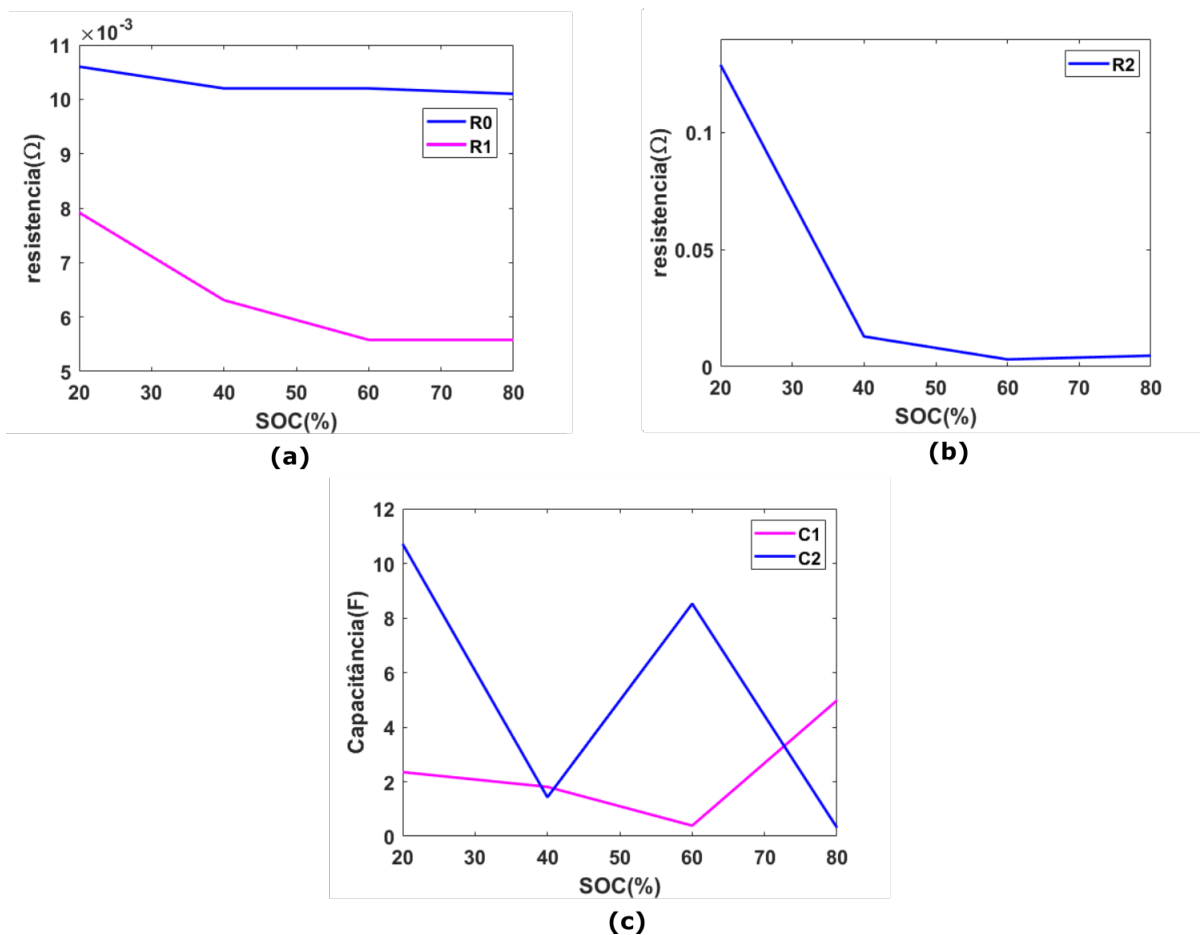
4 RESULTADOS E DISCUSSÕES

Nesta seção, são apresentados os resultados do desenvolvimento do banco de dados com BMS. Além disso, são apresentados os valores dos parâmetros encontrados para introduzir no UFK e a configuração utilizada no mesmo. Por fim, são indicados e analisados os resultados dos estimadores em comparação com o SOC referencial calculado.

4.0.1 Parâmetros do UFK

Conforme a metodologia apresentada na seção 3.4.4.1, os parâmetros a serem aplicados no UFK foram calculados. A Figura 19 exibe gráficos representando o resultado desses parâmetros.

Figura 19 – Parâmetros do modelo RC de 2ª Ordem



Fonte: Autor, 2024

A resposta dos valores de resistência está conforme o esperado, de acordo com o indicado em [HOSSAIN et al., 2019] e [ZHANG et al., 2014], nos quais o aumento do

Estado de Carga resulta na redução do valor das resistências. Isso se deve ao transporte limitado de massa e às restrições de difusão, ou seja, à velocidade com que os íons de lítio conseguem se mover através dos eletrodos. Já a capacitância apresentou variação, alternando entre momentos de aumento e diminuição, ao longo de todo o intervalo medido. Com os parâmetros calculados, foram incorporados ao bloco do UFK os parâmetros intrínsecos do sistema. A Tabela 3 a seguir apresenta a configuração realizada.

Tabela 3 – Configuração do bloco UFK

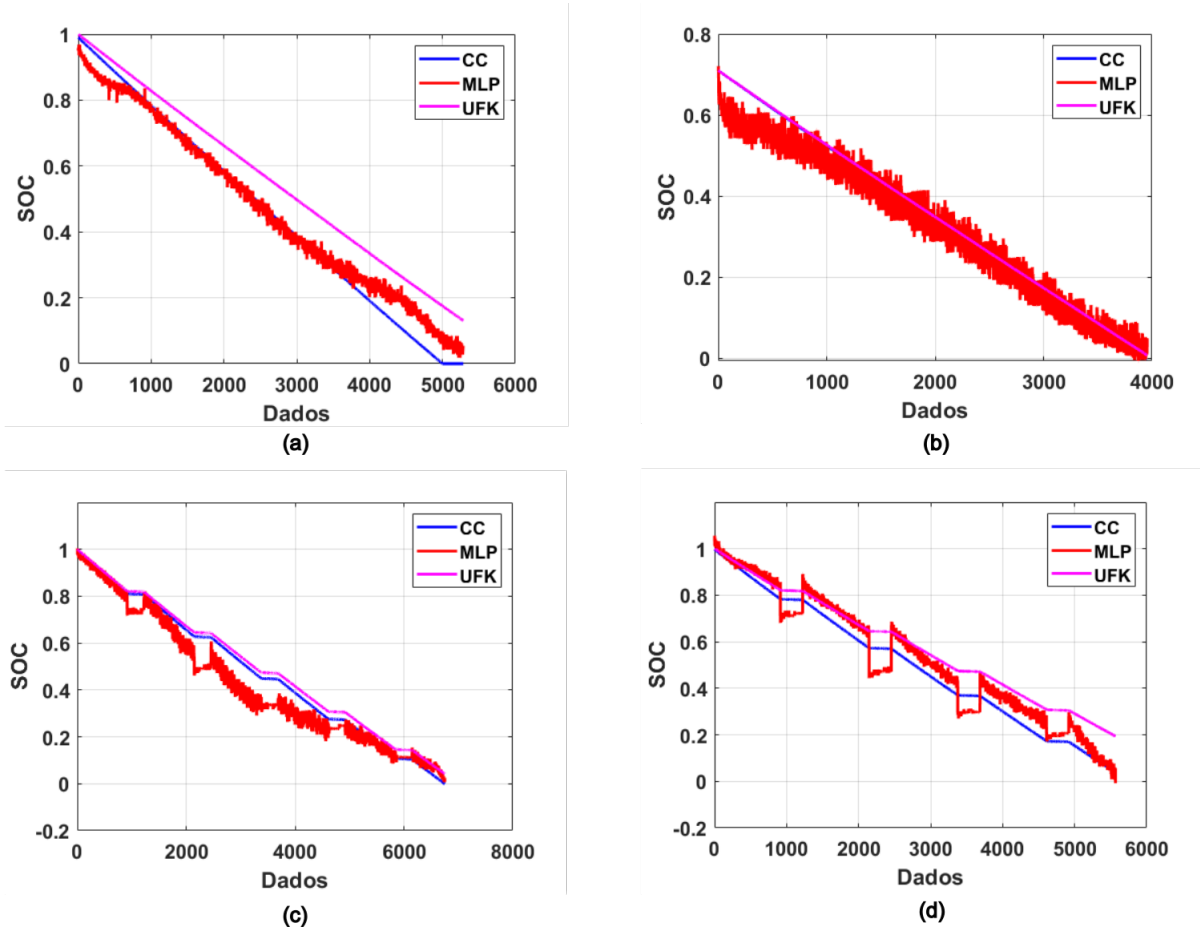
Alfa	1
Beta	0,5
Kappa	1
Covariância inicial	[1e-7 1e-4 1e-4 1e-2]
Covariância	5

Fonte: Autor, 2024

4.1 Ensaio offline

O ensaio offline foi realizado no ambiente do Matlab com dados gerados conforme especificado na seção 3.1, a Figura 20 apresenta o resultado.

Figura 20 – Resultado do ensaio offline (a) e (b) apresentam o resultado do ensaio em curvas com descarga contínua e (c) e (d) indicam para as curvas de descarga com repouso



Fonte: Autor, 2024

Nos ensaios com repouso, a rede apresentou uma queda no valor do SOC no instante em que o robô parava. No entanto, durante o período de repouso, o SOC manteve-se praticamente constante, e quando o robô voltava a operar, ocorria um acréscimo no SOC. Possivelmente, a rede acompanhou a variação de tensão, que exibe tal comportamento nesse momento.

Por outro lado, o UFK apresentou respostas muito próximas à referência em (b) e (c), mas em (a) e (d), ele mostrou uma divergência crescente com a descarga. Essa diferença na resposta pode estar atrelada ao fato de que os dados são provenientes de um conjunto de baterias. Assim, o modelo apresentado para o UFK pode estar mais próximo de uma bateria do que de outra, além de fatores intrínsecos, como a capacidade das baterias, que também podem diferir.

A tabela 4 apresenta os valores de RMSE e MAE das curvas retiradas do ensaio offline.

Tabela 4 – Métricas estatísticas para análise do ensaio offline

Curva	PMC		UFK	
	RMSE	MAE	RMSE	MAE
a	0,0438	0,0333	0,1085	0,0972
b	0,0494	0,0339	0,0065	0,0056
c	0,0719	0,0563	0,0263	0,0238
d	0,0621	0,0568	0,0939	0,0839

Fonte: Autor, 2024


É possível confirmar que, embora o UFK tenha apresentado grande exatidão nas curvas (b) e (c), nas demais curvas o valor chega a ser consideravelmente maior. Se considerarmos, por exemplo, o pior e o melhor valor de RMSE, temos uma discrepância de até 16 vezes maior, indicando uma variação significativa.

Essa disparidade pode ser derivada das diferenças nas características das baterias, que, mesmo sendo do mesmo modelo, ainda apresentam variações naturais durante o processo de produção, as quais se tornam mais evidentes durante o uso. Por outro lado, a PMC apresentou um aumento de menos de duas vezes utilizando a mesma metodologia. No entanto, ao comparar com o UFK, a exatidão demonstrada por ele foi notavelmente alta em relação à rede na curva (b).

4.1.1 Ensaio Online

Foram conduzidos quatro ensaios online para avaliar a resposta dos estimadores. A Figura 21 mostra as quatro curvas em que os estimadores demonstraram uma resposta excepcional.

Figura 21 – Resultado do ensaio online com repouso (a) Saída dos estimadores na segunda bateria do primeiro ensaio.(b) Saída dos estimadores na segunda bateria no segundo ensaio.(c) Saída dos estimadores na segunda bateria no terceiro ensaio.(d) Saída dos estimadores na terceira bateria do terceiro ensaio.



Fonte: Autor, 2024

Durante os ensaios com repouso, as redes apresentaram maior precisão ao estimar os valores da segunda bateria. No primeiro ensaio (a), observa-se que a rede PMC forneceu estimativas muito próximas do valor referencial, divergindo apenas nos momentos de repouso. Em vez de manter constante o valor do SOC, a rede indicou uma queda, comportamento também observado no ensaio offline. Já para o UFK, à medida que a descarga continuou, ocorreu uma divergência entre o valor de referência e a estimativa, o que pode estar relacionado ao modelo gerado.

No segundo ensaio (b), durante o terceiro período de repouso, mesmo com o relé acionado, o robô permaneceu parado, requerendo que o operador desse um leve impulso para frente a fim de retomar a descarga. No entanto, um fato interessante a ser observado é que durante esse período prolongado de repouso, a rede neural conseguiu identificar tal momento e manteve um SOC quase constante. Em contraste, o UFK manteve o mesmo comportamento observado na segunda bateria do primeiro ensaio.

No terceiro ensaio (c e d), é possível observar que a rede durante a fase intermediária da descarga ocorreu uma divergência entre a estimação e o referencial, enquanto nas extremidades nota-se uma convergência. No caso do UFK, a resposta em (d) foi muito próxima ao valor de referência, ao contrário do que foi observado nas curvas anteriores. Isso sugere que a terceira bateria possui características equivalentes ou muito próximas ao modelo, ao contrário da segunda bateria. Para a análise estatística dos melhores resultados dos ensaios online com repouso, as informações de RMSE e MAE estão apresentadas na Tabela 5.

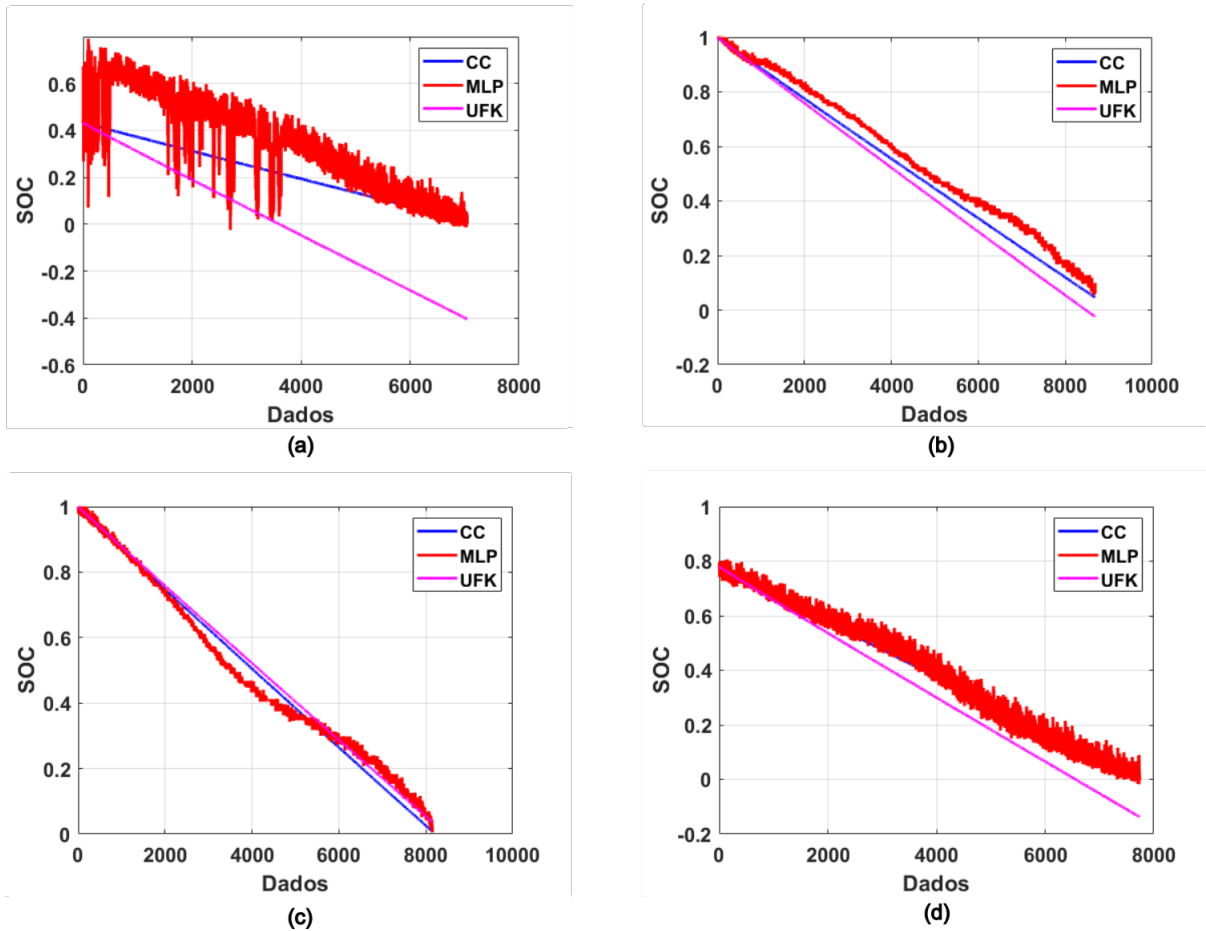
Tabela 5 – Métricas estatísticas para análise do erro durante ensaio online com repouso

Curva	PMC		UFK	
	RMSE	MAE	RMSE	MAE
a	0,0338	0,0261	0,0547	0,0449
b	0,0435	0,0383	0,0344	0,0282
c	0,0482	0,0422	0,0474	0,0413
d	0,0614	0,0459	0,0151	0,0133

Fonte: Autor, 2024

Ao examinar os erros, mesmo que o gráfico possa sugerir que a PMC tem uma resposta igual ou até melhor que o UFK, as métricas revelam que o UFK apresentou resultados superiores, especialmente ao analisar os valores máximos e mínimos. Isso pode estar relacionado ao fato de que a rede PMC tinha dificuldade em identificar corretamente as transições entre os estados de repouso e ação, resultando em variações no SOC, mesmo quando não havia uma variação real. Após os ensaios com repouso, foi realizado o ensaio contínuo, a Figura 22 apresenta a resposta dos estimadores neste ensaio.

Figura 22 – Resultado do ensaio online sem repouso (a) Saída dos estimadores na primeira bateria.(b) Saída dos estimadores na segunda bateria.(c) Saída dos estimadores na terceira bateria.(d) Saída dos estimadores na quarta bateria.



Fonte: Autor, 2024

Ambos os estimadores para a primeira bateria apresentaram respostas inadequadas. A rede, no início da descarga, oscilou entre 65 % e 41 %, enquanto a referência iniciou em 43 %, mesmo seguindo o mesmo procedimento de carga das demais baterias, indicando uma possível falha nesta bateria. Por outro lado, o UFK chegou a apresentar SOC abaixo de 0. Para as demais baterias, os estimadores obtiveram respostas mais satisfatórias, destacando-se a PMC na quarta bateria e o UFK na terceira bateria. É interessante observar que o gráfico (d) da Figura 21, gerado para a terceira bateria, mostra que o modelo consegue representar essa bateria de maneira excelente.

No entanto, para as demais baterias, o modelo não conseguiu alcançar a mesma representatividade observada nesta bateria específica. A Tabela 6 apresenta as métricas resultantes do ensaio realizado.

Tabela 6 – Métricas estatísticas para análise do erro durante ensaio online com descarga contínua

Curva	PMC		UFK	
	RMSE	MAE	RMSE	MAE
a	0,0434	0,0352	0,2436	0,2118
b	0,0570	0,0516	0,0411	0,0356
c	0,0406	0,0339	0,0185	0,0170
d	0,0298	0,0248	0,0818	0,0722

Fonte: Autor, 2024

Ao analisar as métricas, neste ensaio, o UFK apresentou os maiores valores de RMSE e MAE, provenientes da bateria 4. No entanto, é interessante notar que é também o método que oferece o melhor desempenho global. Isso reflete a volatilidade que as baterias podem exibir, indicando que, mesmo produzidas de maneira semelhante e com os mesmos componentes, podem apresentar divergências em suas características.

Caso seja utilizado um modelo que não se adapte conforme a bateria ou ao longo do tempo de uso, o PMC se destaca como uma proposta promissora. Ao ser submetido a ensaios online, demonstrou ser uma possível abordagem eficaz para estimar a capacidade das baterias. Sua capacidade de evoluir com base no banco de dados apresentado, juntamente com a própria topologia, sugere uma perspectiva favorável, permitindo uma generalização eficaz e uma estimativa precisa.

5 CONCLUSÕES DO TRABALHO

O presente trabalho apresentou um estudo comparativo entre dois estimadores para o Estado de Carga de baterias. Realizou-se uma revisão bibliográfica sobre conceitos e estimadores amplamente utilizados, classificando-os por suas características e a demanda requisitado para ser um estimador plausível de ser aplicado. Dentre elas denota-se o baixo consumo computacional, exatidão, versatilidade e realização da estimação mesmo que a bateria esteja em operação (carga ou descarga). A partir destas características foi classificado os estimadores a serem utilizados, sendo eles o Filtro de Kalman Unscented, a Rede Neural Perceptron Multicamadas e por fim o Coulomb Counting para ser o estimador de referência.

Além disto, foi desenvolvida a metodologia para a produção de um banco de dados, onde seria realizado o ensaio offline dos algoritmos e por fim o ensaio online. Como carga foi selecionado um robô aspirador, n qual foi substituído suas baterias por baterias 18650 do modelo INR18540-30Q, o estas baterias foram instrumentadas para captar o tempo, tensão, corrente e temperatura. O ensaio offline foi realizado em um ambiente limitado e foram realizados ensaios onde o robô tinha pausas pré-determinadas e outros com o consumo ininterrupto. O mesmo foi aplicado no ensaio online.

O UFK apresentou respostas bem distintas dependendo da bateria apresentada, assim sendo necessário modelos diferentes ou atualização de parâmetros para garantir exatidão para todas, porém isto acarreta custo computacional. Porém, foi possível verificar que é possível aplicar redes neurais artificiais sem a necessidade de um modelo, sendo este um gargalo devido ao custo computacional.

Ainda, considerando que a rede Perceptron Multimacadas é uma das arquiteturas mais factíveis de ser implementada e com custo computacional compatível para ser implementada em sistemas embarcados, como um BMS por exemplo, isso demonstra que, ao melhorar o banco de dados ao implementar dados de ciclos de condução e novos ensaios, a rede pode se tornar um estimador com altas chances de atender à demanda de um estimador de SOC alternativo ao CC tradicional, porém robusto.

5.1 Limitações de estudo

Algumas limitações foram identificadas no decorrer do estudo. Em primeiro lugar, foi realizada utilizando apenas um modelo concebido para representar as quatro baterias, o que pode restringir a generalização dos resultados. Além disso, o estudo concentrou-se exclusivamente na análise da descarga do pacote de baterias, deixando de considerar outros aspectos que poderiam influenciar seu desempenho. Outra limitação importante é

que todas as baterias foram consideradas como tendo um estado de saúde inicial de 100 %, o que pode não refletir a realidade de todas as situações. Além disso, a pesquisa se restringiu a um único tipo de química de bateria, limitando assim a sua aplicabilidade a outros tipos de baterias disponíveis.

5.2 Perspectivas de trabalhos futuros

Como perspectivas para trabalhos futuros, diferentes modelos de baterias podem ser testados, com a análise do custo computacional de cada estimador em específico. Um ponto relevante seria a implementação de uma metodologia para auxiliar a rede quando o sistema transita entre os modos de repouso e descarga. Isso poderia ser realizado através do uso de CC como entrada da rede ou da incorporação de uma flag para indicar à rede quando a corrente estiver abaixo de um valor mínimo, indicando o modo de repouso. Outro ponto importante seria realizar o estudo para a carga, implementando tanto no de carga quanto no descarga novos ensaios, podendo utilizar ciclos de condução como referência, levando em consideração a dinâmica do veículo. Além disto, efeitos térmicos e de SOH podem ser integrados visando analisar melhor resposta dos algoritmos.

5.3 Trabalhos Publicados em Anais de Eventos

Esta pesquisa foi disseminada em dois eventos científicos de relevância no ano de 2023, sendo eles: IEEE Vehicle Power and Propulsion (IEEE VPPC 2023) e o Simpósio Brasileiro de Automação Inteligente (SBAI). Estes trabalhos auxiliaram a entender melhor as demandas e trouxe contribuições pertinentes da comunidade científica.

5.3.1 Artigo A: Comparative Study Between Unscented Kalman Filter and Multi-Layer Perceptron Applied in an Electric Vehicle Simulation with Pack Parameters Generated from the Database

Este artigo foi desenvolvido em 2022 e 2023, sendo publicado em 2023. O manuscrito inicialmente apresenta alguns conceitos de estimadores e apresenta a necessidade de estudos do SOC levando em consideração *pack* e comportamento do veículo. Assim foi desenvolvido uma metodologia no Matlab/Simulink para realizar o estudo de estimadores, sendo eles o Filtro de Kalman Unscented e Perceptron Multicamadas.

Foi desenvolvido uma simulação, onde é apresentado os componentes do veículo e em especial o *pack*, alterado conforme os parâmetros calculados com base em ensaios reais e com o banco de dados disponibilizados online.

Foi então utilizado como entrada o ciclo de condução FTP-75 e gerados de saída da simulação os dados de tensão, corrente e temperatura que tiveram a adição de ruídos e

foram injetados no UFK e PMC, estes comparados com um SOC de referência fornecido pela própria simulação,

A rede neural apresentou RMSE de 0,0418, enquanto para o UFK o valor foi de 0,0593, enquanto no MAE foram apresentados valores de 0,0344 e 0,0429. A rede neural teve melhor desempenho que o UFK, com valores mais baixos de RMSE e MAE, 29% e 17,7%, respectivamente.

5.3.2 Artigo B: MLP networks applied to State of Charge estimation in electric vehicle simulation with normed driving cycle

Este artigo foi desenvolvido e publicado em 2023. Este documento se inicia apresentando conceitos de estimadores e apresenta a necessidade de apresentar estudos de estimação do SOC levando em consideração o efeito do *pack* e o comportamento do veículo. Após isto é apresentada a metodologia desenvolvida para realização de ensaio no Matlab/Simulink, onde foi comparado os estimadores Filtro de Kalman Unscented, Rede Neural Perceptron Multicamadas e Coulomb Counting.

Foi selecionado um banco de dados da bateria NMC 18650 PF, foi então gerado um modelo RC de segunda ordem que foi implementado em uma simulação de veículo, que operou no ciclo de condução UDDS. Os dados de saída (tensão, corrente e temperatura) tiveram a adição de ruído e posteriormente apresentados aos três estimadores.

Para critério de análise foi utilizado o SOC da simulação como referência e foram aplicadas métricas estatísticas de RMSE e MAE. O CC apresentou melhor resposta com valores de 0,1086 e 0,0931, seguido pela rede neural com 0,3651 e 0,2952. Por fim, o UFK ficou em último lugar com RMSE e MAE de 3,4217 e 2,4137.

REFERÊNCIAS

- ARANHA, W. M. Caracterização de bateria recarregável de lítio de veículos híbridos visando sua reciclagem. 2018.
- BYOUNG-YONG, C. Conversion of a constant phase element to an equivalent capacitor. *J. Electrochem. Sci. Technol*, v. 11, n. 3, p. 318–321, 2020. Disponível em: <<http://www.jecst.org/journal/view.php?number=338>>.
- CASTANHO, D. S. Previsão do estado de carga de bateria aplicada a veículos elétricos usando modelos lineares auto-ajustados através de algoritmos de otimização. Universidade Tecnológica Federal do Paraná, 12 2019. Disponível em: <<http://repositorio.utfpr.edu.br:8080/jspui/handle/1/4758>>.
- CASTRO, B. H. R. de; BARROS, D. C.; VEIGA, S. G. da. Baterias automotivas : panorama da indústria no Brasil , as novas tecnologias e como os veículos elétricos podem transformar o mercado global. *BNDES Setorial*, v. 37, 2013.
- CHAGAS, L. G.; URBANO, A.; SCARMINIO, J. Princípios físicos e químicos de baterias de Íon lítio.
- CHAOUI, H. et al. State-of-charge and state-of-health prediction of lead-acid batteries with genetic algorithms. In: *2015 IEEE Transportation Electrification Conference and Expo (ITEC)*. [S.l.: s.n.], 2015. p. 1–6.
- CHEN, Q. et al. Investigating the environmental impacts of different direct material recycling and battery remanufacturing technologies on two types of retired lithium-ion batteries from electric vehicles in China. *Separation and Purification Technology*, v. 308, p. 122966, 2023. ISSN 1383-5866. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1383586622025230>>.
- CHENG, K. W. et al. Battery-management system (bms) and soc development for electrical vehicles. *IEEE Transactions on Vehicular Technology*, v. 60, p. 76–88, 1 2011. ISSN 00189545.
- ESPEDAL, I. B. et al. Current trends for state-of-charge (soc) estimation in lithium-ion battery electric vehicles. *Energies 2021, Vol. 14, Page 3284*, Multidisciplinary Digital Publishing Institute, v. 14, p. 3284, 6 2021. ISSN 19961073. Disponível em: <<https://www.mdpi.com/1996-1073/14/11/3284/htmlhttps://www.mdpi.com/1996-1073/14/11/3284>>.
- FADLAOUI, E.; ISMAIL, L.; MASAIF, N. Fitting the ocv-soc relationship of a battery lithium-ion using genetic algorithm method. *E3S Web of Conferences*, v. 234, p. 00097, 02 2021.
- GALVÃO, J. R. et al. Hybrid equalization topology for battery management systems applied to an electric vehicle model. *Batteries 2022, Vol. 8, Page 178*, Multidisciplinary Digital Publishing Institute, v. 8, p. 178, 10 2022. ISSN 2313-0105. Disponível em: <<https://www.mdpi.com/2313-0105/8/10/178/htmlhttps://www.mdpi.com/2313-0105/8/10/178>>.

- GAO, D. W. *Interfacing Between an ESS and a Microgrid*. 2015.
- GAZZARRI, J. Battery modeling. *MATLAB Central File Exchange*, 2022. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/15435075.2020.1831511>>.
- GHAEMINEZHAD, N. et al. Review on state of charge estimation techniques of lithium-ion batteries: A control-oriented approach. *Journal of Energy Storage*, v. 72, p. 108707, 2023. ISSN 2352-152X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352152X23021047>>.
- GOEDTEL, A. et al. A comparative study for single and multilayer neural networks applied to speed estimation in induction motors. In: *The XIX International Conference on Electrical Machines - ICEM 2010*. [S.l.: s.n.], 2010. p. 1–6.
- HOSSAIN, M. et al. A parameter extraction method for the thevenin equivalent circuit model of li-ion batteries. In: *2019 IEEE Industry Applications Society Annual Meeting*. [S.l.: s.n.], 2019. p. 1–7.
- HOW, D. N. et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review. *IEEE Access*, Institute of Electrical and Electronics Engineers Inc., v. 7, p. 136116–136136, 2019. ISSN 21693536.
- JEONG, Y. M. et al. Enhanced coulomb counting method with adaptive soc reset time for estimating ocv. *2014 IEEE Energy Conversion Congress and Exposition, ECCE 2014*, Institute of Electrical and Electronics Engineers Inc., p. 4313–4318, 11 2014.
- JUNIOR, P. B. Diagnóstico de curto-circuito no enrolamento de estator em máquinas de indução trifásicas utilizando redes neurais artificiais. *Universidade Tecnológica Federal do Paraná*, 8 2014.
- LI, S. et al. State-of-charge estimation of lithium-ion batteries in the battery degradation process based on recurrent neural network. *Energies 2021, Vol. 14, Page 306*, Multidisciplinary Digital Publishing Institute, v. 14, p. 306, 1 2021. ISSN 19961073. Disponível em: <<https://www.mdpi.com/1996-1073/14/2/306/htmlhttps://www.mdpi.com/1996-1073/14/2/306>>.
- LI, W. et al. Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation. *Journal of Energy Storage*, v. 30, 2020. ISSN 2352152X.
- LIU, S. et al. A novel discharge mode identification method for series-connected battery pack online state-of-charge estimation over a wide life scale. *IEEE Transactions on Power Electronics*, Institute of Electrical and Electronics Engineers Inc., v. 36, p. 326–341, 1 2021. ISSN 19410107.
- MASTALI, M. et al. Battery state of the charge estimation using kalman filtering. *Journal of Power Sources*, Elsevier, v. 239, p. 294–307, 10 2013. ISSN 0378-7753.
- MATHWORKS®. Control system toolbox™ user’s guide. 2022. Retrieved april 10, 2022, from <https://www.mathworks.com/help/pdf_doc/control/control_ug.pdf>.
- MENG, J. et al. *Overview of Lithium-Ion battery modeling methods for state-of-charge estimation in electrical vehicles*. [S.l.]: MDPI AG, 2018.

- MOVASSAGH, K. et al. A critical look at coulomb counting approach for state of charge estimation in batteries. *Energies 2021, Vol. 14, Page 4074*, Multidisciplinary Digital Publishing Institute, v. 14, p. 4074, 7 2021. ISSN 19961073. Disponível em: <<https://www.mdpi.com/1996-1073/14/14/4074/htmlhttps://www.mdpi.com/1996-1073/14/14/4074>>.
- NASCIMENTO, I. F. do. Modelos dinâmicos com estimação via filtro de partículas. *Universidade de Brasília*, 2014.
- PROCHAZKA, P. et al. Li-ion battery deep discharge degradation. *ECS Transactions*, The Electrochemical Society, v. 74, p. 31–36, 12 2016. ISSN 1938-6737. Disponível em: <https://www.researchgate.net/publication/311499287_Li-Ion_Battery_Deep_Discharge_Degradation>.
- QAISAR, S. M. Event-driven coulomb counting for effective online approximation of li-ion battery state of charge. *Energies 2020, Vol. 13, Page 5600*, Multidisciplinary Digital Publishing Institute, v. 13, p. 5600, 10 2020. ISSN 19961073. Disponível em: <<https://www.mdpi.com/1996-1073/13/21/5600/htmlhttps://www.mdpi.com/1996-1073/13/21/5600>>.
- SALKIND, A. J. et al. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. *Journal of Power Sources*, v. 80, n. 1, p. 293–300, 1999. ISSN 0378-7753. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378775399000798>>.
- SHEN, P. et al. The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles. *IEEE Transactions on Vehicular Technology*, Institute of Electrical and Electronics Engineers Inc., v. 67, p. 92–103, 1 2018. ISSN 00189545.
- SILVA, W. Filtro h infinito estendido de segunda ordem e filtro de partículas regularizado com "roughening" aplicados na estimação de atitude de satélites artificiais. 01 2016.
- SIMON, D. Optimal state estimation: Kalman, h, and nonlinear approaches. *Optimal State Estimation: Kalman, H, and Nonlinear Approaches*, Wiley Blackwell, p. 1–526, 1 2006. Disponível em: <<https://onlinelibrary.wiley.com/doi/book/10.1002/0470045345>>.
- SUN, D. et al. An investigation on the role of electric vehicles in alleviating environmental pollution: evidence from five leading economies. *Environmental Science and Pollution Research*, v. 30, 10 2022.
- VERMA, V. et al. Upcycling spent cathode materials from li-ion batteries to precursors: Challenges and opportunities. *Journal of Environmental Chemical Engineering*, Elsevier, v. 11, p. 110216, 8 2023. ISSN 2213-3437.
- VIDAL, C. et al. *Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art*. [S.l.]: Institute of Electrical and Electronics Engineers Inc., 2020. 52796-52814 p.
- WANG, F. et al. Lithium-ion battery soc estimation by integrating electrochemical model with deep learning. In: *2023 3rd New Energy and Energy Storage System Control Summit Forum (NEESSC)*. [S.l.: s.n.], 2023. p. 418–422.

- WEI, M. et al. State of charge estimation for lithium-ion battery using dynamic neural networks. In: *2020 International Conference on Artificial Intelligence and Electromechanical Automation (AIEA)*. [S.l.: s.n.], 2020. p. 23–26.
- WEI, M. et al. State of charge estimation of lithium-ion batteries using lstm and narx neural networks. *IEEE Access*, v. 8, p. 189236–189245, 2020.
- XING, Y. et al. Battery management systems in electric and hybrid vehicles. *Energies 2011, Vol. 4, Pages 1840-1857*, Molecular Diversity Preservation International, v. 4, p. 1840–1857, 10 2011. ISSN 19961073. Disponível em: <<https://www.mdpi.com/1996-1073/4/11/1840/htmhttps://www.mdpi.com/1996-1073/4/11/1840>>.
- YAN, J. et al. Robust state of charge estimation for hybrid electric vehicles: Framework and algorithms. *Energies 2010, Vol. 3, Pages 1654-1672*, Molecular Diversity Preservation International, v. 3, p. 1654–1672, 9 2010. ISSN 19961073. Disponível em: <<https://www.mdpi.com/1996-1073/3/10/1654/htmhttps://www.mdpi.com/1996-1073/3/10/1654>>.
- YANG, S. et al. A parameter adaptive method for state of charge estimation of lithium-ion batteries with an improved extended kalman filter. *Scientific Reports*, Nature Research, v. 11, 12 2021. ISSN 20452322.
- ZHANG, H. et al. On-line measurement of internal resistance of lithium ion battery for ev and its application research. *International Journal of u- and e-Service, Science and Technology*, v. 7, p. 301–310, 08 2014.
- ZOU, Y. et al. Combined state of charge and state of health estimation over lithium-ion battery cell cycle lifespan for electric vehicles. *Journal of Power Sources*, Elsevier, v. 273, p. 793–803, 1 2015. ISSN 0378-7753.