



UFPB



CEAR



Universidade Federal da Paraíba  
Centro de Energias Alternativas e Renováveis  
Programa de Pós-Graduação em Engenharia Elétrica

# Estimação do Estado de Carga em Baterias de Lítio-Íon Baseada em Filtro de Kalman *Unscented*

*(State of Charge Estimation of Lithium-Ion Batteries Using Unscented Kalman Filter)*

Filippe José Gadelha Tertuliano

João Pessoa, Paraíba

Janeiro de 2021

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

T332e Tertuliano, Filipe José Gadelha.

Estimação do estado de carga em baterias de Lítio-Íon baseada em filtro de Kalman Unscented / Filipe José Gadelha Tertuliano. - João Pessoa, 2021.

104 f. : il.

Orientação: Euler Cássio Tavares de Macêdo.

Coorientação: Juan Moisés Maurício Villanueva.

Dissertação (Mestrado) - UFPB/CEAR.

1. Energias renováveis. 2. Filtro de Kalman Estendido (EKF). 3. Filtro de Kalman Unscented (UKF). 4. Estimação de SoC. 5. Modelagem de bateria. 6. Bateria de Lítio-Íon. I. Macêdo, Euler Cássio Tavares de. II. Villanueva, Juan Moisés Maurício. III. Título.

UFPB/BC

CDU 620.91(043)

Filippe José Gadelha Tertuliano

Estimação do Estado de Carga em Baterias de Lítio-Íon Baseada  
em Filtro de Kalman *Unscented*

*(State of Charge Estimation of Lithium-Ion Batteries Using Unscented Kalman Filter)*

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica – PPGEE, da Universidade Federal da Paraíba – UFPB, como requisito final para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Euler Cássio Tavares de Macêdo

João Pessoa, Paraíba

2021

Universidade Federal da Paraíba - UFPB  
Centro de Energias Alternativas e Renováveis - CEAR  
Programa de Pós-Graduação em Engenharia Elétrica – PPGEE

A Comissão Examinadora, abaixo assinada, aprova o Exame de Qualificação

Estimação do Estado de Carga em Baterias de Lítio-Íon Baseada  
em Filtro de Kalman *Unscented*

Elaborado por

Filippe José Gadelha Tertuliano

Como requisito final para obtenção do grau de  
Mestre em Engenharia Elétrica.

Comissão Examinadora



Prof. Dr. Euler Cássio Tavares de Macêdo – UFPB/CEAR/DEE

(Orientador – Presidente da Banca)



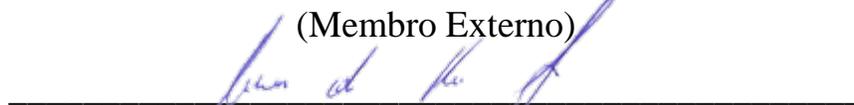
Prof. Dr. Juan Moisés Maurício Villanueva – UFPB/CEAR/DEE

(Coorientador)



Prof. Dr. Lucas Vinícius Hartmann – UFPB/CEAR/DEE

(Membro Externo)



Prof. Dr. Cícero da Rocha Souto – UFPB/CEAR/DEE

(Membro Interno)

João Pessoa – PB, 29 de janeiro de 2021.

À minha mãe e aos outros seres com paciência.

Dedico

## Agradecimentos

Ao Prof. Dr. Euler Cássio Tavares de Macedo, por me acompanhar até aqui nesta jornada, e ao Prof. Dr. Juan Moisés Maurício Villanueva por todo o suporte durante esta pesquisa.

À Secretária da Coordenação, Kelly Oliveira, por sempre atender às minhas demandas com atenção e cordialidade.

À minha mãe pela imensurável paciência e pelo incansável carinho, à minha irmã por sempre me encorajar, e ao meu pai pelo apoio.

Aos meus amigos e às minhas amigas pelas incontáveis conversas e por sempre me empurrarem para a frente, em especial à Danilo Pequeno, engenheiro eletricitista inspirador.

Aos meus colegas de Mestrado por compartilharem anseios e alegrias nesta carreira, sempre segurando um copo de café.

A Deus por colocar cada uma dessas pessoas na minha vida.

“Temos de lembrar que esta é uma estrelinha pequenininha e provavelmente algumas estrelas maiores e mais importantes sejam virtuosas e felizes.”

Albert Einstein

## Sumário

Lista de Ilustrações .....	9
Lista de Tabelas .....	10
Lista de Abreviaturas e Siglas.....	11
Resumo.....	12
Abstract .....	13
1. Introdução .....	14
1.1. Delimitação do Tema .....	14
1.2. Motivação .....	16
1.3. Objetivos .....	17
1.4. Organização do Texto .....	18
2. Fundamentação Teórica.....	19
2.1. Métodos para estimação de SoC .....	19
2.2. Filtros de Kalman.....	23
2.2.1. Filtro de Kalman Padrão .....	23
2.2.2. Filtro de Kalman Estendido .....	25
2.2.3. Filtro de Kalman <i>Unscented</i> .....	28
2.3. Modelagem da Bateria .....	34
2.3.1. Tipos de modelos da bateria.....	34
2.3.2. Processo de modelagem .....	35
3. Revisão Bibliográfica .....	40
3.1. Estudos sobre UKF .....	40
3.2. Resumo das Contribuições.....	48
4. Metodologia.....	50
4.1. Materiais e Equipamentos.....	50
4.1.1. Bateria de Lítio-Íon.....	51
4.1.2. Fonte de Alimentação .....	52
4.1.3. Câmara Climática.....	54
4.1.4. Sistema de aquisição de dados .....	56
4.2. Procedimentos Experimentais.....	59
4.3. Modelagem da Bateria .....	61

4.4.	Implementação dos métodos de estimação .....	69
4.4.1.	Determinação do modelo em espaço de estados .....	69
4.4.2.	Implementação do Filtro de Kalman <i>Unscented</i> (UKF) .....	72
4.4.3.	Implementação do Filtro de Kalman Estendido (EKF).....	73
5.	Resultados e Análises .....	75
5.1.	Determinação da capacidade da bateria .....	75
5.2.	Determinação do modelo da bateria.....	77
5.3.	Estimação do SoC .....	89
5.4.	Comparativo entre UKF e EKF .....	93
6.	Conclusões .....	98
	Referências .....	99

## Lista de Ilustrações

Figura 1 - Fluxograma de implementação do filtro de Kalman Estendido. ....	27
Figura 2 - Fluxograma de implementação do filtro de Kalman <i>Unscented</i> . ....	33
Figura 3 – Modelo de Circuito Equivalente de Thevenin. ....	35
Figura 4 – Ensaio de descarga à corrente pulsada.....	36
Figura 5 – Identificação dos efeitos de cada parâmetro do modelo na tensão de saída. ....	37
Figura 6 – Ajuste de curvas para determinar número de ramos RC. ....	38
Figura 7 – Visualização detalhada do ajuste de curvas para determinar número de ramos RC.....	38
Figura 8 - Bancada Experimental.....	51
Figura 9 - Bateria de lítio-íon 20 Ah.....	51
Figura 10 - Fonte de alimentação Kepco BOP 10-100MG.....	53
Figura 11 - Câmara climática com controle de umidade relativa e temperatura (MA 835/300UR). ....	54
Figura 12 - Painel digital da câmara climática.....	55
Figura 13 - Sistema de aquisição de dados (Datalogger).....	57
Figura 14 - Primeira tela da interface de aquisição de dados.....	58
Figura 15 - Segunda tela da interface de aquisição de dados.....	58
Figura 16 - Sequência de pulsos obtida experimentalmente e SoC simulado.....	62
Figura 17 - Identificação dos pulsos de corrente e das faixas de tensão durante descarga/repouso. ....	63
Figura 18 - Determinação do número de pares RC.....	64
Figura 19 - Estimações iniciais dos parâmetros do modelo.....	66
Figura 20 - Comparativo entre curvas experimental e simulada.....	67
Figura 21 - Parâmetros do modelo da bateria após otimização.....	68
Figura 22 - Comparativo entre curvas experimental e simulada após otimização dos parâmetros.....	68
Figura 23 - Curvas de descarga à corrente contínua sob diferentes temperaturas. ....	76
Figura 24 - Gráfico da capacidade disponível da bateria em função da temperatura de ensaio. ....	77
Figura 25 - Curvas de descarga à corrente pulsada sob diferentes temperaturas.....	78
Figura 26 - Pulsos de corrente aplicados em ensaio de descarga sob diferentes temperaturas.....	79
Figura 27 - Identificação dos pulsos de corrente e das faixas de tensão durante descarga/repouso. ....	79
Figura 28 - Determinação do número de pares RC.....	80
Figura 29 - Processo de otimização de um pulso da curva de descarga.....	81
Figura 30 - Relação entre tensão de circuito aberto ( $V_{oc}$ ), SoC e temperatura.....	83
Figura 31 - Relação entre resistência interna ( $R_0$ ), SoC e temperatura.....	84
Figura 32 – Relação entre elementos entre $R_1$ , SoC e temperatura.....	85
Figura 33 – Relação entre elementos entre $C_1$ , SoC e temperatura.....	86
Figura 34 – Relação entre elementos entre $R_2$ , SoC e temperatura.....	87
Figura 35 – Relação entre elementos entre $C_2$ , SoC e temperatura.....	88
Figura 36 - Simulação da bateria de lítio-íon via Simulink®. ....	90
Figura 37 - Estimação do SoC via UKF sob temperatura de +10 °C com SoC inicial = 100 %. ....	91
Figura 38 - Estimação do SoC via UKF sob temperatura de +10 °C com SoC inicial = 70 %. ....	92
Figura 39 - Comparativo entre UKF e EKF à +10 °C. ....	94
Figura 40 - Comparativo entre UKF e EKF à +20 °C. ....	95
Figura 41 - Comparativo entre UKF e EKF à +30 °C. ....	96

## Lista de Tabelas

Tabela 1 - Especificações da bateria de lítio-íon. ....	52
Tabela 2 - Configurações gerais da fonte de alimentação.....	53
Tabela 3 - Informações técnicas sobre a câmara climática. ....	55
Tabela 4 - Especificações Técnicas do Sistema de Aquisição de Dados. ....	56
Tabela 5 - Comparação da precisão das estimações feitas pelos filtros sob diferentes temperaturas. ....	97

## Lista de Abreviaturas e Siglas

AEKF	<i>Adaptative Extended Kalman Filter</i>
ALS	<i>Autocovariance Least Square</i>
AUKF	<i>Adaptative Unscented Kalman Filter</i>
BMS	<i>Battery Management System</i>
CAN	<i>Controller Area Network</i>
EKF	<i>Extended Kalman Filter</i>
FUDS	<i>Federal Urban Driving Schedules</i>
HPPC	<i>Hybrid Pulse Power Characterization</i>
MAE	<i>Mean Absolute Error</i>
NEDC	<i>New European Driving Cycle</i>
OCV	<i>Open Circuit Voltage</i>
RLS	<i>Recursive Least Square</i>
RMSE	<i>Root-Mean Square Error</i>
SAE	<i>Sistema de Armazenamento de Energia</i>
SKF	<i>Standard Kalman Filter</i>
SoC	<i>State of Charge</i>
SoH	<i>State of Health</i>
SoF	<i>State of Function</i>
SR-UKF	<i>Square Root Unscented Kalman Filter</i>
UDDS	<i>Urban Dynamometer Driving Schedule</i>
UKF	<i>Unscented Kalman Filter</i>

## Resumo

As baterias se tornaram um assunto amplamente estudado em diferentes áreas científicas após o aumento do número de aplicações dependentes de sistemas de energia em diferentes setores da sociedade e indústria. Com o intuito de aumentar a segurança e a eficiência do armazenamento de energia, é necessário monitorar e controlar as baterias continuamente com algoritmos robustos e precisos, baseados em um modelo do sistema. O Estado de Carga (*State of Charge* - SoC) é um dos mais importantes parâmetros da bateria, pois ele representa a sua capacidade restante com relação à sua capacidade nominal. Dentre os algoritmos mais utilizados para este fim, tem-se o método de Filtro de Kalman Estendido (EKF), que permite estimar parâmetros do modelo do sistema dinâmico não-linear da bateria a partir de um processo de linearização complexo, mas eficaz. Contudo, existe o filtro de Kalman *Unscented* (UKF) capaz de estimar os parâmetros do modelo a partir da transformada *Unscented*, apresentando uma maior eficácia computacional do que a linearização feita pelo EKF. Assim, neste trabalho, é realizada a estimação do SoC de baterias de lítio-íon com base no algoritmo UKF para identificar seu desempenho, analisando sua complexidade de implementação e considerando a influência da variação da temperatura durante a operação do sistema. Foi, também, desenvolvido um modelo de bateria com base em um circuito equivalente de segunda ordem, capaz de representar o comportamento do sistema sem comprometer o funcionamento dos métodos de estimação usados. Com o UKF foram obtidas melhores estimativas de SoC do que as feitas pelo EKF, sob todas as diferentes condições de temperatura consideradas neste trabalho, sendo, para o UKF, o Erro Médio Quadrático Máximo de 4,51 % e Erro Médio Absoluto máximo de 3,69 %. Para auxiliar na implementação dos algoritmos e na modelagem da bateria, foram utilizadas ferramentas disponíveis no ambiente Matlab/Simulink®.

**Palavras-chave:** UKF; Estimação de SoC; Modelagem de Bateria; Bateria de Lítio-Íon.

## Abstract

The batteries have become a subject widely studied in different scientific areas after the increase of applications dependent on energy systems in different sectors of society and industry. In order to guarantee the safety and efficiency of energy storage, it is necessary to monitor and control the batteries continuously with robust and accurate algorithms, based on a model of the system. The State of Charge (SoC) is one of the most important parameters of the battery, as it represents its remaining capacity in relation to its nominal capacity. Among the most widely used algorithms there is the Extended Kalman Filter (EKF) method, which estimates parameters of the nonlinear dynamic system model using a complex but effective linearization process. However, there is the Unscented Kalman Filter (UKF) method capable of estimating the model parameters from the Unscented transform, having greater computational efficiency than the linearization performed by EKF. Thus, in this work, SoC lithium-ion battery estimation is performed based on UKF to identify the implementation complexity, considering the influence of temperature variation during the system operation. A battery model was also developed based on a second-order equivalent circuit, capable of representing the system behaviour without compromising the use of the UKF. The SoC estimation using UKF showed better results than the SoC estimation via EKF, under all the different temperature conditions considered in this work, being, for the UKF, the maximum Root-Mean Square Error equals to 4,51 % and maximum Mean Absolute Error equals to 3,69 %. To assist in the implementation of the algorithms and to develop the battery model, the tools available in *Matlab/Simulink*® were used.

**Keywords:** UKF; SoC Estimation; Battery Modelling; Lithium-Ion Batteries.

# 1. Introdução

## 1.1. Delimitação do Tema

Os Sistemas de Armazenamento de Energia (SAE) têm ganhado destaque no mercado tecnológico por estarem diretamente relacionados aos sistemas de mobilidade elétrica, sistemas de geração de energia renováveis e aparelhos eletrônicos portáteis. Esse tipo de sistema permite melhorar o desempenho de operação dos dispositivos, aumentando assim, sua vida útil, e, em maior escala, reduzindo o impacto climático, a partir da não utilização de combustíveis fósseis.

Os SAE são responsáveis por armazenar eletricidade na forma de outro tipo de energia, sendo a eletroquímica a mais comum, e convertê-la em eletricidade novamente quando necessário (ZUBI et al., 2018). Alguns exemplos de baterias empregadas para esse fim incluem composições de chumbo-ácido, íons de lítio, níquel cádmio, entre outros, cada qual com suas especificidades relacionadas à capacidade, densidade de energia, tensões de carga/descarga, entre outras características.

Um dos exemplos mais comuns de SAE, é baseado em baterias de íons de lítio e tem sua importância de acordo com a aplicação final. Esse tipo de bateria é composto por um cátodo (polo positivo) e um ânodo (polo negativo) envoltos pelo eletrólito (composição pela qual existe a troca de elétrons entre os polos) e afastados um do outro pelo separador para evitar o curto-circuito internamente. Estes quatro elementos principais funcionam de maneira que a carga e a descarga da bateria ocorram de forma segura e eficiente. (HANNAH et al., 2018).

Contudo, diferentes fatores podem colocar em risco o bom funcionamento da bateria. Dentre eles, destacam-se a temperatura de operação, a descarga excessiva e a sobrecarga. Adicionalmente, verifica-se uma queda drástica na durabilidade da bateria quando ela é submetida a temperaturas fora dos limites estabelecidos pelo fabricante. Já com a descarga excessiva, ocorre degradação dos compostos químicos internos afetando diretamente o seu funcionamento. O mesmo ocorre com a sobrecarga, formando compostos danosos não só para o funcionamento como também para a segurança de operação do sistema (BALAGOPAL; CHOW, 2015).

Apesar da bateria ser um dispositivo seguro e estar aliada na redução de impactos ambientais, é necessário que ela seja constantemente monitorada e controlada por um usuário ou

um sistema supervisorio automático, também conhecido como Sistema de Gerenciamento de Bateria (do inglês, *Battery Management System* – BMS) (PURWADI et al., 2014).

O BMS é responsável por prevenir que a bateria descarregue abaixo de um valor de tensão pré-determinado (*cut-off voltage*) e de evitar que haja o recebimento contínuo de carga após ela estar completamente carregada, ou seja, mantém a carga ou descarga dentro de uma faixa segura de operação respeitando os limites operacionais da bateria. Ele controla o fluxo de energia através da bateria, assegurando uma vida útil mais longa (CHEN et al., 2016).

Alguns parâmetros, conhecidos também como estados de operação, são usados para representar a condição atual da bateria. Um dos mais importantes é o Estado de Carga (do inglês, *State of Charge* – SoC), que representa a capacidade atual da bateria como uma porcentagem da sua capacidade máxima. Porém, o SoC não pode ser medido, apenas estimado com base nas medições de corrente, de tensão e de temperatura presentes no sistema. Outros parâmetros também estimados são o Estado de Saúde (do inglês, *State of Health* – SoH) e o Estado de Função (do inglês, *State of Function* – SoF) (JOKIĆ et al., 2018).

As variações espaço-temporais sob as quais a bateria está submetida dificultam a estimação dos parâmetros usados para representá-la. Sendo assim, faz-se necessário construir um modelo da bateria capaz de englobar o seu comportamento dinâmico para que haja uma otimização nas estimações, melhorando o funcionamento do dispositivo ao qual ela está associada (HAASE et al., 2017). Existem diferentes métodos utilizados na modelagem da bateria, cada qual com suas vantagens e peculiaridades. Porém, por causa do comportamento altamente não-linear do sistema em questão, são exigidos modelos com elevada complexidade matemática, visando precisão nas estimações dos parâmetros independentemente dos fatores estáticos e dinâmicos envolvidos no processo. Com isso, quanto maior a complexidade do modelo, maior a dificuldade de sua aplicação (BALASINGAM; PATTIPATI, 2018).

Para realizar a estimação dos parâmetros como SoC e SoH, além de um modelo de bateria preciso, é necessário aplicar os dados, obtidos a partir das medições, em algoritmos robustos e confiáveis. Dentre eles, o Filtro de Kalman se destaca como uma solução poderosa e eficiente. Em 1960, Rudolf Emil Kalman sugeriu um método fortemente baseado na teoria de probabilidade, mas que hoje, em aplicações digitais, pode ser implementado de maneira simples e eficiente (AUGER et al., 2013). O método é amplamente empregado em diferentes áreas com destaque para controle de sistemas dinâmicos, comunicações e estimação de desempenho de baterias.

O Filtro de Kalman utiliza equações recursivas, que são verificadas repetidamente no decorrer da operação do sistema, para estimar os estados presentes considerando os impactos das variáveis no instante anterior, gerando assim, o mínimo erro quadrático possível. Nele, são aplicadas como entrada as medições de grandezas físicas como, por exemplo, corrente e tensão, para estimar parâmetros que não podem ser medidos diretamente, como SoC, considerando a influência de ruídos de processo e de medição (PLETT, 2004).

Durante a operação do filtro, há duas etapas principais: a Predição e a Atualização. Na Predição, o estado é obtido com base na estimação do estado proveniente no instante anterior. Assim, são estimados os valores preditos do estado, da saída do sistema e dos erros de covariância envolvidos na utilização do filtro. Na Atualização, o estado predito e o erro de covariância são corrigidos com base nas medições de saída do sistema físico e no valor de ganho de Kalman, sendo o resultado desta etapa utilizado na predição do intervalo seguinte (PLETT, 2004).

Diferentes versões do Filtro de Kalman podem ser utilizadas na estimação de parâmetros. O filtro de Kalman Padrão (do inglês, *Standard Kalman Filter* - SKF) é um ótimo estimador de estados em sistemas lineares sob efeito dos ruídos de processo e de medição. O filtro de Kalman Estendido (do inglês, *Extended Kalman Filter* – EKF) pode ser utilizado em sistemas não lineares, necessitando de aproximações lineares das funções do sistema, com base na expansão em séries de Taylor, em torno do mais recente estado estimado. O Filtro de Kalman Unscented (do inglês, *Unscented Kalman Filter* – UKF) também é empregado em sistemas não lineares, porém, baseia-se na Transformada *Unscented* durante o processo de estimação (SCARDUA, 2015).

A bateria apresenta um comportamento não linear durante sua operação em função da influência de elementos internos e externos, como autodescarregamento e temperatura ambiente (LIU et al., 2017). Visando diminuir a influência desses fatores e atenuar os impactos dos ruídos inerentes à estimação de estados, os filtros de Kalman se apresentam como uma excelente solução para a análise de desempenho de baterias.

## 1.2. Motivação

A geração de eletricidade baseada em fontes renováveis ocorre de maneira intermitente, exigindo o suporte operacional de sistemas de armazenamento de energia para promover a integração da eletricidade gerada à rede elétrica. O aumento de *smart grids*, também, demanda

uma maior participação de SAE no mercado, visando melhorar o desempenho da operação de sistemas de comunicação, computacional e de controle intrínsecos a essas redes, além de permitir a postergação de investimentos de repotencialização. O mesmo ocorre com a eletrificação dos sistemas automotivos, que utilizam bancos de baterias capazes de atender aos requisitos de potência e de densidade energética exigidos pelo sistema de *powertrain* dos veículos. Assim, estudos a respeito de baterias são necessários para viabilizar o aperfeiçoamento na estimação de seus parâmetros e, conseqüentemente, melhorar o desempenho do BMS, tornando-o mais seguro e confiável (Rahimi-Eichi et al. 2013).

As transformações químicas internas e efeitos externos sobre a bateria dificultam a estimação dos seus estados. Apesar da temperatura ser um dos principais efeitos externos e exercer forte influência no funcionamento do sistema de energia, a maioria da construção de modelos e da estimação de SoC não considera seus impactos no funcionamento da bateria (Wu et al. 2018). Sendo assim, é necessário incluir a temperatura nos processos de modelagem da bateria e de estimação de seus parâmetros para que haja uma otimização nas estimações, melhorando assim, o funcionamento do dispositivo ao qual ela está associada (Haase et al. 2017).

Neste trabalho, busca-se contribuir com uma análise sobre a bateria de lítio-íon para o conseqüente aperfeiçoamento do setor energético e de outras áreas cada vez mais dependentes de sistemas de armazenamento de energia. Será detalhado o processo de estimação do SoC de uma bateria de lítio-íon com base não somente nas medições de corrente e de tensão como também, de temperatura, utilizando o filtro de Kalman *Unscented*.

### 1.3. Objetivos

Neste trabalho, têm-se como objetivos principais apresentar uma metodologia para modelagem de baterias baseada em dados experimentais e realizar a estimação do estado de carga de baterias de lítio-íon utilizando filtro de Kalman *Unscented* sob diferentes condições de temperatura.

Especificamente, será apresentada uma bancada experimental desenvolvida para a realização dos ensaios de carga/descarga de baterias; assim como, será detalhada a construção do modelo de circuito elétrico equivalente da bateria de lítio-íon capaz de representar o comportamento dinâmico desse sistema não-linear; na seqüência, será feita a comparação dos

resultados de estimação de SoC feita com o uso do UKF e outros métodos também usados para a estimação de estados; por fim, serão avaliados os efeitos da temperatura no desempenho do sistema de armazenamento de energia.

## 1.4. Organização do Texto

Este trabalho está organizado da seguinte maneira:

- No Capítulo 2, será apresentada a fundamentação teórica necessária para o entendimento deste trabalho de maneira simples. Dentre os conceitos abordados, será descrito o processo de modelagem de bateria utilizado. Serão, também, descritos os principais métodos de estimação do Estado de Carga de baterias, com destaque para as variações do Filtro de Kalman (UKF e EKF);
- No Capítulo 3, será apresentada a metodologia do trabalho, relatando os procedimentos experimentais adotados nos ensaios de carga e descarga das baterias, além dos materiais e equipamentos utilizados na modelagem do sistema;
- No Capítulo 4, serão exibidos e analisados os resultados obtidos com a modelagem da bateria e a implementação do filtro de Kalman *Unscented* considerado nesta pesquisa;
- No Capítulo 5, serão apresentadas as considerações finais deste trabalho.

## 2. Fundamentação Teórica

Neste capítulo, serão abordados os principais conceitos relacionados à modelagem da bateria e aos métodos empregados na estimação de estados em sistemas não-lineares dinâmicos, objetivando assim, melhorar a compreensão sobre o tema.

### 2.1. Métodos para estimação de SoC

A estimação do estado de carga em uma bateria é fundamental para otimizar o gerenciamento de energia dos dispositivos aos quais esse sistema está associado. Contudo, é necessário que esse processo seja realizado de maneira precisa para que, além de indicar a carga armazenada disponível em comparação com a carga total da bateria, sejam evitadas descargas profundas ou sobrecargas, que possam danificar o sistema (MISYRIS et al., 2019). Portanto, uma boa estimação aumenta a durabilidade e melhora o desempenho da bateria, evitando situações que põem em risco usuários e dispositivos.

Ao contrário de outras grandezas presentes na bateria que podem ser medidas por sensores, como, por exemplo, tensão de saída, corrente de descarga e temperatura, o SoC não pode ser obtido diretamente, exigindo o uso de métodos indiretos que viabilizem a sua estimação de maneira precisa e confiável (RAHIMI-EICHI et al., 2013). Assim, a partir de medições diretas, o SoC é determinado indiretamente.

Existe uma série de técnicas empregadas na estimação de SoC em sistemas de armazenamento de energia, disponibilizadas na bibliografia científica, variando principalmente em relação à precisão de estimação ou na complexidade de implementação.

(ZHANG et al., 2018) realizaram uma revisão detalhada sobre o tema. No estudo, os autores organizaram os métodos em cinco categorias principais, sendo elas: convencional, filtro adaptativo, inteligência artificial adaptativa, observador não-linear e algoritmo híbrido. A seguir, são descritos alguns desses métodos de acordo com suas categorias, ressaltando as vantagens e as desvantagens de cada um.

## 1) Convencional

- Contagem Ampère-hora (*Coulomb Counting*)

Consiste no uso da integral da corrente de carga/descarga no cálculo da capacidade restante na bateria. É de fácil implementação e baixa complexidade computacional. Porém, exige conhecimento do estado inicial de carga e apresenta baixa precisão, além de depender de parâmetros sujeitos a erros de medição (PURWADI et al., 2014).

- *Open Circuit Voltage* - OCV

Usa a relação entre força eletromotriz e SoC na estimação do estado. Tem alta precisão e baixa complexidade computacional. Contudo, apresenta uma limitação no número de aplicações devido a necessidade, por exemplo, de sensores de tensão com alta resolução (ZHANG et al., 2018).

- Impedância e Resistência Interna

A partir dos estados e temperatura com valores fixos, usa-se os valores de impedância e resistência interna da bateria no processo de estimação. É baseada em características intrínsecas à bateria sob qualquer excitação de corrente. Porém, a difícil medição da impedância e da resistência interna elevam o custo de implementação, além de apresentar relação entre SoC e impedância não estável (ZHANG et al., 2018).

- Eletroquímico

Identifica a quantidade de lítio nos eletrodos e emprega equações diferenciais parciais na estimação do SoC. Tem alta precisão na estimação teórica e é aplicável em estimacões com o equipamento fora de operação (*offline*). Contudo, tem alta complexidade de implementação e alta dificuldade para realizar a estimação com o sistema em operação (*online*) (XIONG et al., 2018).

- Baseado no modelo da bateria

Usa elementos de circuito elétrico para modelar a bateria e, a partir deles, estimar o SoC. Tem boa precisão na estimação dos estados com o sistema em operação (*online*). Porém, não representa algumas características da bateria, como efeitos de histerese (XIONG et al., 2018).

## 2) Filtro Adaptativo

- Filtro de Kalman Padrão

Usa equações recursivas para estimar estados atuais com base nos obtidos em instantes anteriores. Apresenta excelente desempenho em sistemas lineares e promove a autocorreção dos erros durante operação do sistema, mas tem péssimo desempenho em sistemas não-lineares (PLETT, 2004).

- Filtro de Kalman Estendido

A partir do processo de linearização com base em série de Taylor, usa-se equações recursivas para estimar estados atuais com base nos estados obtidos em um instante prévio. É aplicável em sistemas não-lineares. Porém, tem baixa precisão em sistemas altamente não-lineares (LOUKIL et al., 2017).

- Filtro de Kalman *Unscented*

Após processo de linearização com base em transformada *Unscented*, são empregadas equações recursivas para estimar estados atuais com base nos obtidos em instante anterior. É aplicável em sistemas altamente não-lineares. Porém, exige sintonia de parâmetros usados na linearização do sistema (JULIER; UHLMANN, 1997).

### 3) Inteligência artificial adaptativa

- Rede Neural Artificial

Emprega unidades de processamento conectadas para representar um modelo não-linear complexo. É altamente adaptável e pode ser aplicável em diferentes problemas. Não necessita de conhecimento físico sobre parâmetros internos da bateria. Porém, tem como requisito um extenso banco de dados para ser usado no treinamento da rede, exigindo assim, capacidade computacional elevada, em especial, de memória do sistema (MOURA, 2019).

- Algoritmo Genético

Inspirado no processo genético biológico, o algoritmo busca encontrar soluções aproximadas para problemas de otimização. É considerado robusto e aplicável em diferentes tipos de problemas, mas exige exatidão de elementos específicos e grande número de avaliações de funções internas (ZINI, 2009).

- Lógica *Fuzzy*

Com base em um banco de dados adequado, é capaz de representar um modelo não-linear complexo baseando-se em diferentes patamares (regras). Apresenta uma alta adaptabilidade e

fornece rapidamente um protótipo do sistema. Contudo, tem maior necessidade de verificação das variáveis utilizadas e exigem um elevado número de simulações e testes (DA SILVA et al., 2019).

#### 4) Observador não-linear

- Observador Proporcional-Integral

Controlador capaz de estimar estados e entradas desconhecidas simultaneamente sem considerar ruídos estatísticos de processo e de medição. Apresenta estrutura simples e de fácil implementação, possuindo alta precisão e eficiência durante sua aplicação. Porém, leva em consideração não-linearidades do sistema e outros aspectos, como por exemplo, entradas desconhecidas do modelo, podendo assumir os impactos de tais partes no sistema de maneira incorreta (LIU, 2011).

- Observador *Slide Mode*

Garante a estabilidade e a robustez do sistema contra incertezas do modelo ao usar um ganho de realimentação e outras táticas no controle do regime. Apresenta rápida taxa de convergência e boa precisão de estimação quando comparado a outros métodos. Porém, é altamente afetado pela variação de ruídos externos (ZHANG et al., 2009).

#### 5) Método híbrido

- EKF combinado a Contagem Ampère-hora

Combina dois métodos para aumentar a precisão de estimação dos estados, compensando as desvantagens de um com as vantagens de outro. No caso, o alto erro acumulado pelo Contagem Ampère-hora durante a operação do sistema é corrigido automaticamente pelo filtro de Kalman Estendido. Porém, ainda conta com a baixa precisão de estimação em sistemas altamente não-lineares e exige esforço computacional elevado.

Após avaliar as vantagens e as desvantagens de cada método de estimação de estados e considerar os requisitos do sistema não-linear da bateria, verificou-se que o método híbrido é capaz de estimar o SoC da bateria com maior exatidão ao considerar os impactos de ruídos externos sobre o sistema e ajustar automaticamente os erros inerentes ao processo de estimação. Portanto, neste

trabalho, foi analisado o desempenho do método híbrido gerado a partir da combinação do método UKF com o método Ampère-Hora, assim como foi realizada e analisada a comparação da combinação entre os métodos EKF e Ampère-hora na estimação. Nas seções seguintes, os filtros de Kalman serão descritos com maior profundidade, visando situar o leitor acerca dos conceitos básicos sobre o tema.

## 2.2. Filtros de Kalman

O Filtro de Kalman engloba uma série de métodos largamente empregados na estimação de parâmetros variantes com o tempo, que não podem ser obtidos de maneira direta, em sistemas dinâmicos. Para sua implementação, são aplicadas equações recursivas ao longo da operação do sistema que permitem estimar parâmetros atuais a partir de valores anteriores e de dados de entrada e saída do sistema. Esse comportamento regressivo permite uma maior tolerância a distúrbios externos por sempre autocorrigir os erros durante a execução do sistema (CHEN et al., 2012).

Nesta seção, serão apresentados os algoritmos dos métodos baseados em Filtro de Kalman utilizados na estimação de estados em sistemas dinâmicos lineares e não-lineares, assim como, também, as suas vantagens e desvantagens.

### 2.2.1. Filtro de Kalman Padrão

O Filtro de Kalman Padrão (do inglês *Standard Kalman Filter – SKF*), é considerado uma excelente ferramenta para estimação de estados em sistemas dinâmicos lineares. Para sua implementação, é necessário realizar a discretização do sistema no domínio do tempo, como apresentado, de maneira genérica, no modelo de espaço de estados em (1) e (2) (PLETT, 2004).

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

$$y_k = C_k x_k + D_k u_k + r_k \quad (2)$$

A Equação (1) é conhecida como a equação do processo ou modelo dinâmico. Nela,  $x_k$  corresponde ao vetor de estados do sistema no instante  $k$ ;  $u_k$  é a entrada do sistema;  $q_k$  corresponde

ao ruído inerente do processo. A Equação (2) é conhecida como equação de saída. Nela,  $y_k$  corresponde à saída do sistema e  $r_k$  é o ruído inerente de medição. No modelo, as matrizes  $A_k$ ,  $B_k$ ,  $C_k$  e  $D_k$  descrevem as condições dinâmicas do sistema.

A seguir, são destacadas as etapas envolvidas no processo de estimação utilizando o SKF:

### 1) Inicialização

A inicialização do vetor de estado do sistema ( $x_0$ ) é baseada nos valores iniciais da média ( $x_0^+$ ) e da matriz de covariância ( $P_0$ ), sendo  $E(\cdot)$  a esperança do valor médio.

$$x_0^+ = E[x_0] \quad (3)$$

$$P_0^+ = E[(x_0 - x_0^-)(x_0 - x_0^-)^T] \quad (4)$$

### 2) Predição

Na Predição, ocorre o cálculo dos valores preditos dos estados, no instante  $k + 1$ , a partir do vetor  $x_k^+$  do instante anterior, como expresso em (5). Nesta etapa, há, também, o cálculo da matriz de covariância de acordo com (6), sendo  $Q_k$  a matriz de covariância do ruído do processo.

$$x_{k+1}^- = A_k x_k^+ + B_k u_k \quad (5)$$

$$P_{k+1}^- = A_k P_k^+ A_k^T + Q_k \quad (6)$$

### 3) Atualização

Na Atualização, ocorre o cálculo do ganho de Kalman ( $K_{k+1}$ ), como apresentado em (7), e, conseqüentemente, a correção do vetor de estados e da matriz de covariância preditos anteriormente, de acordo com as expressões (8) e (9), sendo  $R_k$  a matriz de covariância do ruído de medição.

$$K_{k+1} = P_{k+1}^- C_{k+1}^T (C_{k+1} P_{k+1}^- C_{k+1}^T + R_k)^{-1} \quad (7)$$

$$x_{k+1}^+ = x_{k+1}^- + K_k (y_k - C_k x_{k+1}^- - D_k u_k) \quad (8)$$

$$P_{k+1}^+ = P_{k+1}^- - K_k C_k P_{k+1}^- \quad (9)$$

Apesar da correção automática de erro, o SKF não deve ser aplicado na estimação de variáveis em sistemas dinâmicos não-lineares. Para essa finalidade, há dois outros métodos da mesma família de filtros, o Filtro de Kalman Estendido e o Filtro de Kalman *Unscented*.

### 2.2.2. Filtro de Kalman Estendido

Para a estimação de sistemas dinâmicos não-lineares, é comum utilizar o filtro de Kalman Estendido (do inglês *Extended Kalman Filter – EKF*). Com ele, ocorre um processo de linearização, durante cada passo de tempo, das funções não-lineares que definem o sistema.

A linearização usa derivadas parciais para calcular matrizes Jacobianas e expansões em séries de Taylor de primeira ordem. Após ela, o sistema linearizado é agregado ao Filtro de Kalman Padrão (SKF) para estimar os estados desejados. Para melhor compreender o funcionamento desse filtro, considere a dinâmica do estado e as observações do sistema não-linear discretizado representadas em (10) e (11) (PLETT, 2004).

$$x_{k+1} = f(x_k, u_k) + q_k \quad (10)$$

$$y_k = g(x_k, u_k) + r_k \quad (11)$$

sendo  $q_k$  e  $r_k$  os ruídos de processo e de medição, respectivamente;  $f(x_k, u_k)$  é a função de estados não-linear ou modelo dinâmico;  $g(x_k, u_k)$  é a função de medição ou modelo de medidas;  $k$  representa o índice de tempo discreto;  $x_k$  corresponde ao vetor de estados;  $u_k$  e  $y_k$  correspondem, respectivamente, às matrizes de entrada e de saída do sistema.

A implementação do EKF ocorre em duas etapas principais, a predição e a atualização. Porém, para que o SKF seja utilizado na estimação, é necessária uma etapa de linearização das equações de estado e de medição. A seguir, são destacadas as etapas envolvidas no processo de estimação pelo EKF:

#### 1) Linearização

Na linearização,  $f(x_k, u_k)$  e  $g(x_k, u_k)$  são linearizadas por expansão em série de Taylor de primeira ordem em cada passo de tempo, resultando nas expressões (12) e (13) e sendo as matrizes do modelo em espaço de estados obtidas de acordo com (14)-(17).

$$x_{k+1} = A_k x_k + f(\hat{x}_k, u_k) - A_k \hat{x}_k + q_k = A_k x_k + B_k u_k + q_k \quad (12)$$

$$y_k = C_k x_k + g(\hat{x}_k, u_k) - C_k \hat{x}_k + r_k = C_k x_k + D_k u_k + r_k \quad (13)$$

$$A_k = \frac{\partial f(x_k, u_k)}{\partial x_k} \quad (14)$$

$$B_k = \frac{\partial f(x_k, u_k)}{\partial u_k} \quad (15)$$

$$C_k = \frac{\partial g(x_k, u_k)}{\partial x_k} \quad (16)$$

$$D_k = \frac{\partial g(x_k, u_k)}{\partial u_k} \quad (17)$$

## 2) Inicialização

A inicialização do vetor de estado do sistema é baseada nos valores iniciais da média ( $x_0^+$ ) e da matriz de covariância ( $P_0$ ), sendo  $E(\cdot)$  a esperança do valor médio, de acordo com (18) e (19).

$$x_0^+ = E[x_0] \quad (18)$$

$$P_0^+ = E[(x_0 - x_0^-)(x_0 - x_0^-)^T] \quad (19)$$

## 3) Predição

Na Predição, ocorre o cálculo dos valores preditos dos estados, no instante  $k$ , a partir do vetor  $x^+$  no instante anterior, como expresso em (20). Nela também é realizado o cálculo da matriz de covariância de acordo com (21), sendo  $Q_k$  a matriz de covariância do ruído do processo.

$$x_{k+1}^- = A_k x_k^+ + B_k u_k \quad (20)$$

$$P_{k+1}^- = A_k P_k^+ A_k^T + Q_k \quad (21)$$

## 4) Atualização

Na Atualização, ocorre o cálculo do ganho de Kalman ( $K_{k+1}$ ), como apresentado em (22), e, conseqüentemente, a correção do vetor de estados e da matriz de covariância preditos anteriormente, de acordo com as expressões (23) e (24), sendo  $R_k$  a matriz de covariância do ruído de medição.

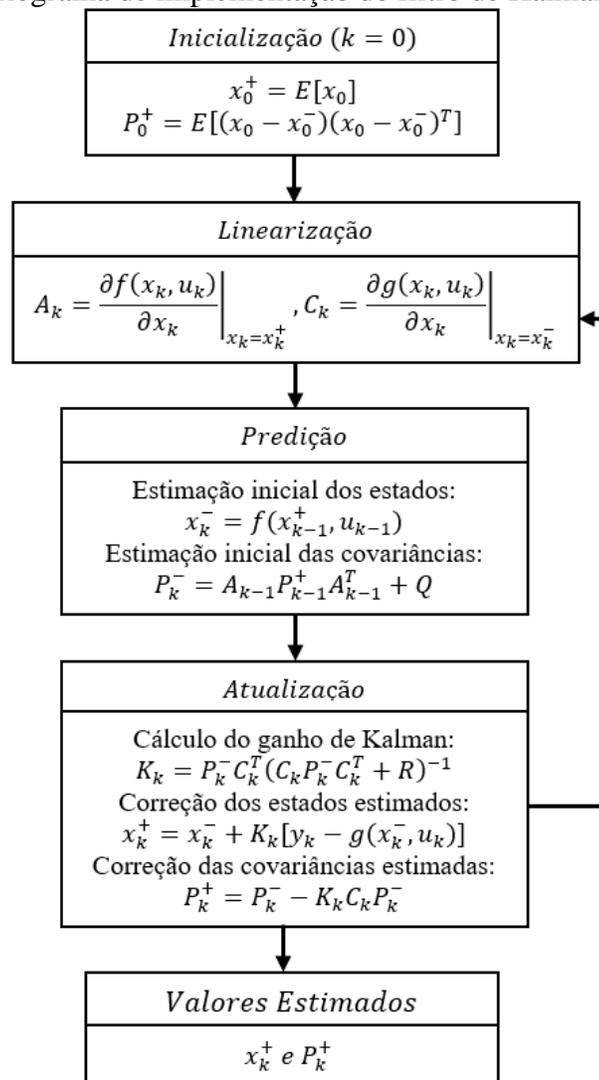
$$K_{k+1} = P_{k+1}^- C_{k+1}^T (C_{k+1} P_{k+1}^- C_{k+1}^T + R_k) \quad (22)$$

$$x_{k+1}^+ = x_{k+1}^- + K_k (y_k - C_k x_{k+1}^- - D_k u_k) \quad (23)$$

$$P_{k+1}^+ = P_{k+1}^- - K_k C_k P_{k+1}^- \quad (24)$$

Na Figura 1, apresenta-se um fluxograma contendo as principais etapas envolvidas na estimação de estados feita pelo EKF.

Figura 1 - Fluxograma de implementação do filtro de Kalman Estendido.



Fonte: Autor (2020).

### 2.2.3. Filtro de Kalman *Unscented*

Assim como o EKF, o Filtro de Kalman *Unscented* (UKF) é uma excelente opção para estimar variáveis relacionadas a sistemas não-lineares. Portanto, pode ser empregado para a estimação do estado de carga e de outros parâmetros de baterias.

Ao invés de realizar aproximações lineares em funções não lineares do sistema dinâmico, este método utiliza a Transformada *Unscented* (do inglês, *Unscented Transform* – UT), durante cada passo de tempo, nas funções que definem o sistema. Com ela é possível estimar média e erro de covariância dos estados do sistema de maneira mais precisa do que os outros métodos da família de filtros (PARTOVIBAKHSH; LIU, 2015).

Com a UT é possível escolher, de maneira determinística, amostras em torno do espaço de estados do sistema dinâmico. Tais amostras, conhecidas como pontos sigma ( $S$ ), são posteriormente propagadas através do modelo dinâmico e, assim, a média e a covariância relacionadas à saída do sistema são estimadas (SCARDUA, 2011).

Com o UKF, a derivação de matrizes Jacobianas, que ocorre no EKF, é evitada, diminuindo as dificuldades de implementação do filtro. Outras vantagens englobam a possibilidade de aplicação em funções não deriváveis e a validade para expansões de ordem superior à do EKF (GARCIA et al., 2013). Porém, o funcionamento do UKF está diretamente relacionado à inicialização de parâmetros específicos aplicados na obtenção dos pontos sigma e dos respectivos pesos. Assim, a sintonia de tais parâmetros, pode gerar erros de estimação quando não cumprida de maneira adequada, sendo considerada uma desvantagem deste filtro (SCARDUA, 2011). Outra exigência, intrínseca a outros filtros de Kalman, é a utilização de um modelo do sistema altamente preciso, resultando em estimativas falhas em caso contrário.

Para o entendimento do seu funcionamento, considere as equações de estados e de observação referentes a um sistema não linear discretizado, apresentadas em (25) e (26), respectivamente. Nelas, novamente,  $k$  representa o índice de tempo discreto;  $f(x_k, u_k)$  corresponde à função não linear do modelo dinâmico;  $g(x_k, u_k)$  corresponde à função não-linear do modelo de medidas;  $x_k$  corresponde à matriz de estados;  $u_k$  e  $y_k$  correspondem, respectivamente, às matrizes de entrada e de saída do sistema;  $q_k$  e  $r_k$  representam, respectivamente, os ruídos de processo e de medição, ambos ruídos brancos gaussianos independentes.

$$x_{k+1} = f(x_k, u_k) + q_k \quad (25)$$

$$y_k = g(x_k, u_k) + r_k \quad (26)$$

Assim como ocorre em outros métodos, o UKF é composto por duas etapas principais, a predição e a atualização. Porém, a Transformada *Unscented* desempenha um papel crucial na estimação dos estados. As descrições sobre cada uma dessas etapas são apresentadas a seguir:

### 1) Inicialização

A inicialização da matriz de estado do sistema ( $x_0$ ) é baseada nos valores iniciais da média ( $\bar{x}_0$ ) e da matriz de covariância ( $P_0$ ), sendo  $E(\cdot)$  a esperança do valor médio.

$$\bar{x}_0 = E[x_0] \quad (27)$$

$$P_0 = E[(x_0 - \bar{x}_0)(x_0 - \bar{x}_0)^T] \quad (28)$$

### 2) Determinação dos pontos sigma

A UT é iniciada com a geração de  $2L + 1$  vetores formados por pontos sigma ( $S$ ), sendo  $L$  a quantidade de estados do sistema, de acordo com as expressões (29) – (31).

$$S_{0,k} = \bar{x}_{k-1} \quad (29)$$

$$S_{i,k} = \bar{x}_{k-1} + \left( \sqrt{(L + \lambda)P_i} \right)_i, i = 1, 2, \dots, L \quad (30)$$

$$S_{i,k} = \bar{x}_{k-1} - \left( \sqrt{(L + \lambda)P_i} \right)_i, i = L + 1, L + 2, \dots, 2L, \quad (31)$$

com  $\left( \sqrt{(L + \lambda)P_i} \right)_i$  sendo a  $i$ -ésima coluna da matriz  $\sqrt{(L + \lambda)P_i}$ ;  $\lambda$  um parâmetro de escalonamento obtido a partir da Equação (32) na qual  $\alpha$  é um parâmetro responsável por definir o espelhamento dos pontos sigma em torno do valor médio dos estados e  $\kappa$  é um parâmetro de escalonamento secundário.

$$\lambda = \alpha^2(L + \kappa) - L \quad (32)$$

Durante o cálculo UT, é realizado, também, o cálculo dos pesos  $w^{(m)}$  e  $w^{(c)}$ , relacionados aos pontos sigma, de acordo com as expressões em (33)-(36), sendo  $\beta$  um parâmetro usado para incorporar conhecimento prévio sobre a distribuição dos estados.

$$w_0^{(m)} = \frac{\lambda}{\lambda + L} \quad (33)$$

$$w_0^{(c)} = \frac{\lambda}{\lambda + L} + (\beta - \alpha^2 + 1) \quad (34)$$

$$w_i^{(m)} = \frac{1}{2(L + \lambda)}, i = 1, 2, \dots, 2L \quad (35)$$

$$w_i^{(c)} = \frac{1}{2(L + \lambda)}, i = 1, 2, \dots, 2L \quad (36)$$

### 3) Predição

Na predição, os pontos sigma encontrados anteriormente são propagados através da função não-linear que representa o modelo dinâmico, como expresso em (37).

$$\hat{S}_{i,k} = f(S_{i,k-1}, u_k), i = 0, 1, \dots, 2L \quad (37)$$

Assim, com os resultados obtidos em (37), é possível estimar os valores da média ( $\hat{x}$ ) e do erro de covariância ( $\hat{P}$ ) preditos dos estados do sistema de acordo com as Equações (38) e (39). Nesta etapa,  $Q$  corresponde à matriz de covariância do ruído do processo.

$$\hat{x}_k = \sum_{i=0}^{2L} w_i^{(m)} \hat{S}_{i,k} \quad (38)$$

$$\hat{P}_k = \sum_{i=0}^{2L} w_i^{(c)} (\hat{S}_{i,k} - \hat{x}_k)(\hat{S}_{i,k} - \hat{x}_k)^T + Q_{k-1} \quad (39)$$

### 4) Atualização

A partir dos valores da média e da covariância preditos em (38) e (39), respectivamente, são determinados novos pontos sigma de acordo com as expressões de (40) – (42).

$$\vec{S}_{0,k} = \hat{x}_k \quad (40)$$

$$\vec{S}_{i,k} = \hat{x}_k + \left( \sqrt{(L + \lambda) \hat{P}_{i,k}} \right)_i, i = 1, 2, \dots, L \quad (41)$$

$$\vec{S}_{i,k} = \hat{x}_k - \left( \sqrt{(L + \lambda) \hat{P}_{i,k}} \right)_i, i = L + 1, L + 2, \dots, 2L \quad (42)$$

Em seguida, os pontos sigma atualizados ( $\vec{S}_{i,k}$ ) são propagados através da função não linear  $g$ , que corresponde ao modelo de medidas do sistema, de acordo com a expressão (43).

$$Y_{i,k} = g(\vec{S}_{i,k}), i = 0, 1, \dots, 2L \quad (43)$$

Assim, com os resultados obtidos anteriormente, é possível estimar os valores da média e da covariância da tensão de saída predita de acordo com as expressões (44) e (45), sendo  $R$  a matriz de covariância do ruído de medição. É calculado, também, a covariância cruzada entre as previsões dos estados e da tensão de saída do sistema, como apresentado em (46).

$$\hat{Y}_k = \sum_{i=0}^{2L} w_i^{(m)} \vec{S}_{i,k} \quad (44)$$

$$C_k = \sum_{i=0}^{2L} w_i^{(c)} (Y_{i,k} - \hat{Y}_k)(Y_{i,k} - \hat{Y}_k)^T + R_{k-1} \quad (45)$$

$$D_k = \sum_{i=0}^{2L} w_i^{(c)} (\vec{S}_{i,k} - \hat{x}_k)(Y_{i,k} - \hat{Y}_k)^T \quad (46)$$

A partir das matrizes  $C_k$  e  $D_k$ , calcula-se o valor do ganho de Kalman ( $K_k$ ), como apresentado em (47), e, conseqüentemente, obtém-se a média e a covariância atualizadas dos estados em análise, como expresso em (48) e (49), respectivamente.

$$K_k = D_k C_k^{-1} \quad (47)$$

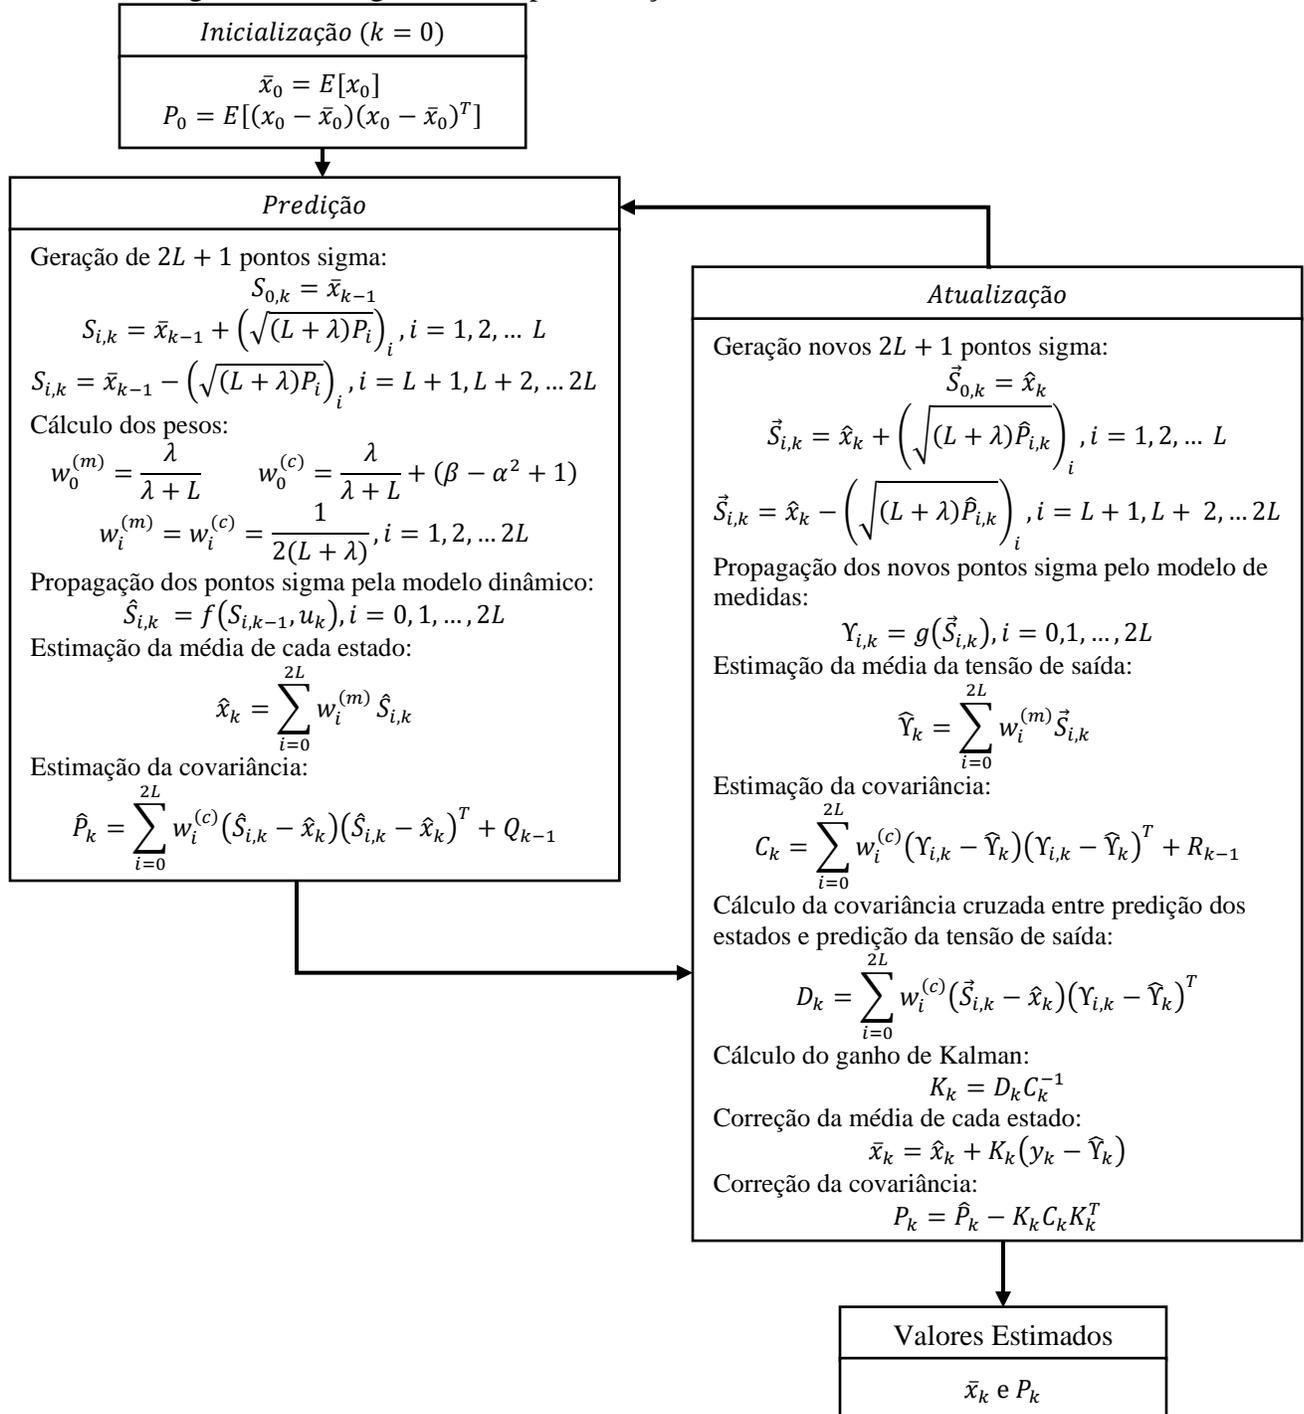
$$\bar{x}_k = \hat{x}_k + K_k (y_k - \hat{Y}_k) \quad (48)$$

$$P_k = \hat{P}_k - K_k C_k K_k^T \quad (49)$$

Na Figura 2, é apresentado um fluxograma contendo as principais etapas envolvidas na estimação de estados feita pelo UKF.

No estudo em questão, o UKF será aplicado na estimação do SoC da bateria e em outros estados, relacionados às tensões sobre os ramos RC empregados no modelo de circuito equivalente do sistema. Assim, é necessário analisar a quantidade de ramos RC necessária para tornar o modelo mais próximo do sistema real e, de preferência, com baixa complexidade computacional, permitindo assim, identificar o número total de estados estimados pelo filtro.

Figura 2 - Fluxograma de implementação do filtro de Kalman *Unscented*.



Fonte: Autor (2020).

## 2.3. Modelagem da Bateria

Nesta seção, serão introduzidos conceitos fundamentais sobre a modelagem de baterias com base no Modelo de Circuito Equivalente, ressaltando às vantagens e desvantagens desta escolha. Serão, também, descritas algumas das ferramentas disponíveis no ambiente computacional *Matlab*®, que permitem facilitar o processo de construção e análise do modelo.

### 2.3.1. Tipos de modelos da bateria

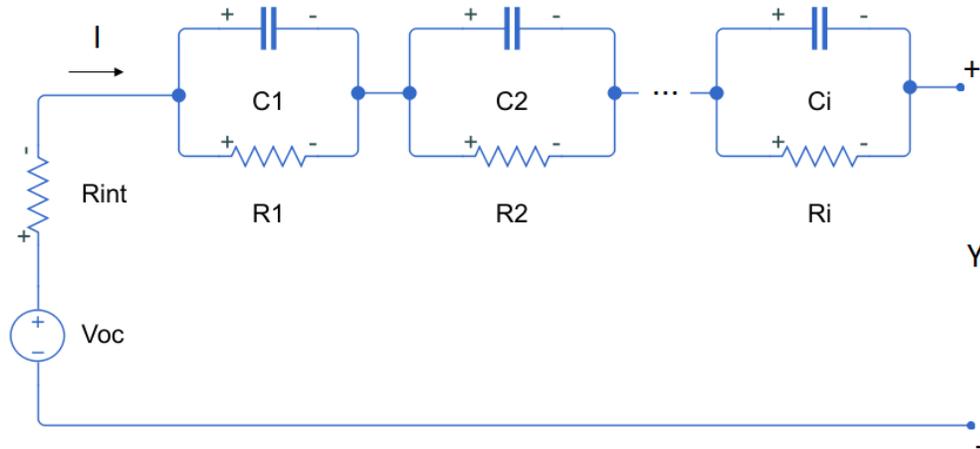
A modelagem de baterias se tornou um assunto amplamente estudado em diferentes áreas científicas, como consequência do aumento de aplicações dependentes de sistemas de energia em diferentes setores da sociedade. Porém, apesar de ser uma excelente fonte de energia elétrica, a bateria apresenta uma série de limitações ligadas à sua composição eletroquímica complexa, efeitos internos relacionados às condições de trabalho e de operação. Assim, com o objetivo de representar o comportamento da bateria de maneira precisa e não complexa, é realizada a modelagem do sistema (HU et al., 2012).

Segundo BOCA et al. (2018), os modelos podem ser agrupados em três categorias principais: matemático, eletroquímico e elétrico. O modelo matemático é capaz de prever o funcionamento da bateria a partir de um conjunto específico de parâmetros aplicados em equações obtidas experimentalmente ou aproximações estocásticas, fornecendo resultados menos precisos e viáveis apenas em certas aplicações. No modelo eletroquímico, são usadas equações diferenciais parciais para descrever o comportamento físico-químico da bateria, resultando em uma alta precisão nos resultados, porém com elevada complexidade de solução. No modelo elétrico, é apresentado um melhor equilíbrio entre precisão e complexidade computacional requerida de modo que o modelo possa ser empregado em microprocessadores sem comprometer a precisão das estimativas.

Neste estudo, a modelagem da bateria de lítio-íon foi feita com base em um subtipo do modelo elétrico conhecido como modelo de circuito equivalente de Thévenin. Ele simula o comportamento da bateria a partir de elementos resistivos e capacitivos associados à tensão de circuito, conforme apresentado na Figura 3. Nela,  $R_{int}$  representa a resistência interna da bateria;

$R_i$  e  $C_i$  em paralelo representam a resposta transitória da bateria;  $V_{oc}$  é a tensão de circuito aberto;  $Y$  e  $I$  são a tensão de saída e a corrente do sistema, respectivamente (BRONDANI, 2015).

Figura 3 – Modelo de Circuito Equivalente de Thevenin.



Fonte: Autor (2020).

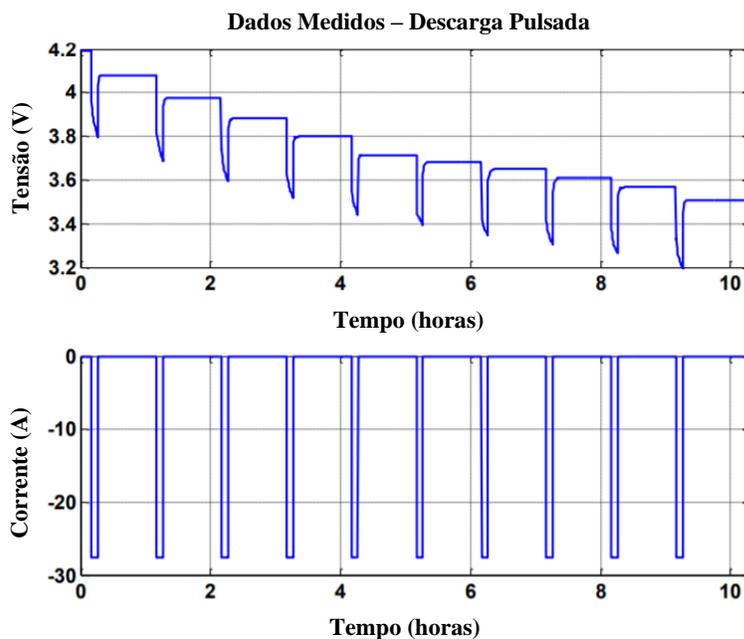
Para ajustar o modelo de circuito equivalente de acordo com o sistema real, é necessário estimar os parâmetros apresentados na Figura 3. Dentre as várias alternativas empregadas com essa finalidade, neste trabalho, a estimação dos parâmetros foi realizada com base no trabalho de (JACKEY et al., 2013) e em um conjunto de funções disponibilizadas pelo *Matlab/Simulink*®.

### 2.3.2. Processo de modelagem

Inicialmente, (JACKEY et al., 2013) realizaram a aquisição de dados de tensão e corrente de um ensaio de descarga em uma bateria de lítio-íon à corrente pulsada, conforme padrão apresentado na Figura 4. O número e a largura dos pulsos aplicados durante o ensaio têm influência direta sobre a resolução dos dados coletados uma vez que cada pulso representa um estado de carga e de cada um são extraídas informações sobre os parâmetros do modelo elétrico da bateria.

Com o número e a largura dos pulsos estabelecidos, os autores realizaram a estimação dos parâmetros do modelo. Durante os instantes de corrente igual a zero, conhecido como período de descanso da bateria, a tensão de saída é semelhante à curva de carga em um circuito RC. Assim, tal curva pode ser ajustada com base na expressão (50) (SANTOS, 2017).

Figura 4 – Ensaio de descarga à corrente pulsada.



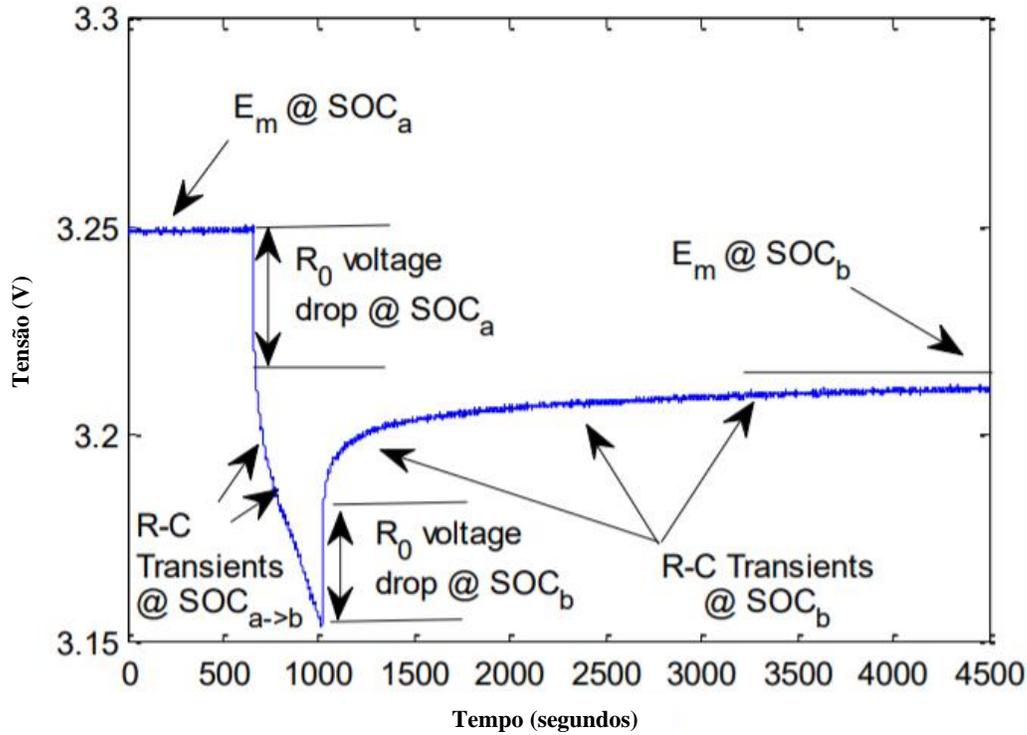
Fonte: Adaptado de (JACKEY et al., 2013).

$$Y(t) = V_{oc} + V_1 \left( 1 - e^{-\frac{t}{R_1 C_1}} \right) + \dots + V_i \left( 1 - e^{-\frac{t}{R_i C_i}} \right) \quad (50)$$

Em seguida, cada curva de tensão foi analisada separadamente, pois cada uma representa valores de parâmetros específicos para aquele estado de carga da bateria, obtidos a partir do ajuste de curva com a expressão (50).

Na Figura 5, é apresentado o comportamento transitório do sistema durante um período de descanso. Nela é possível identificar a transição de um Estado de Carga para outro e o papel de cada elemento do circuito equivalente na geração dessa curva: as resistências internas representadas por  $R_0 \text{ voltage drop @ } SOC_a$  e por  $R_0 \text{ voltage drop @ } SOC_b$  são responsáveis pela variação instantânea da tensão de saída no Estado de Carga  $a$  e  $b$ , respectivamente; o ramo RC, representado por  $R - C \text{ Transients @ } SOC_{a \rightarrow b}$ , por sua vez, é responsável pelo comportamento dinâmico do sistema sob efeito da corrente de descarga;  $R - C \text{ Transients @ } SOC_b$  é responsável pelo comportamento dinâmico do sistema durante o período de descanso da bateria no  $SOC_b$ . Já as siglas  $E_m @ SOC_a$  e  $E_m @ SOC_b$  correspondem às tensões de circuito aberto nos Estados de Carga  $a$  e  $b$ , respectivamente.

Figura 5 – Identificação dos efeitos de cada parâmetro do modelo na tensão de saída.

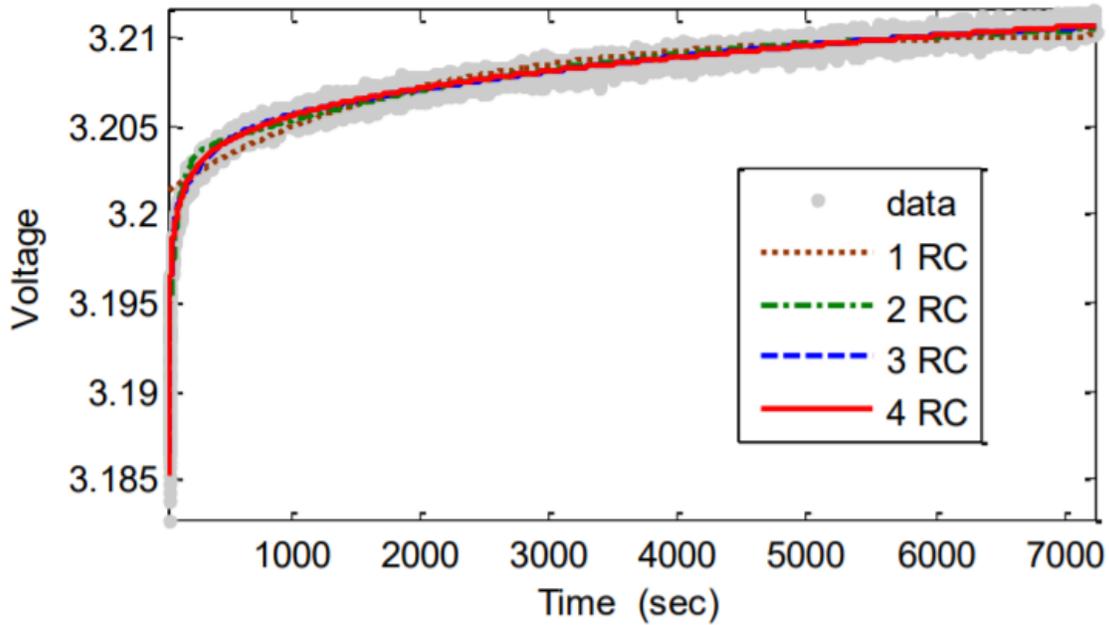


Fonte: Adaptado de (JACKEY et al., 2013).

Para determinar o número de ramos RC empregados no modelo, os autores examinaram novamente a curva de tensão durante o período de descanso da bateria. Um número inadequado de ramos RC pode prejudicar o comportamento do modelo durante a estimação dos estados. A expressão (50) foi aplicada no ajuste da curva considerando a existência de até quatro ramos RC no circuito, conforme exibido na Figura 6.

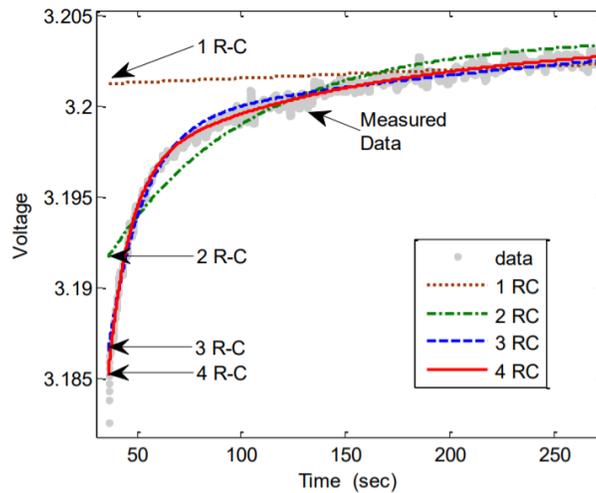
A partir da visualização mais detalhada no trecho inicial da curva, conforme apresentada na Figura 7, demonstra-se que, para o trabalho de (JACKEY et al., 2013), os modelos com até dois ramos não se ajustaram adequadamente à curva de referência. Portanto, o circuito com três ramos foi escolhido por eles por haver proximidade suficiente com a curva de referência, além de evitar o aumento da complexidade computacional causada pelo circuito com quatro ramos.

Figura 6 – Ajuste de curvas para determinar número de ramos RC.



Fonte: (JACKEY et al., 2013).

Figura 7 – Visualização detalhada do ajuste de curvas para determinar número de ramos RC.



Fonte: (JACKEY et al., 2013).

A partir do trabalho de (JACKEY et al., 2013), foi possível identificar etapas fundamentais para a estimação dos parâmetros do modelo da bateria: após determinar o número e a largura dos pulsos da corrente, determinar o número de ramos RC, e analisar as curvas de tensão durante os

períodos de descanso, é preciso extrair os valores dos parâmetros. Para isso, nesta dissertação, foi utilizado um algoritmo composto por um conjunto de funções, disponibilizado pela *Mathworks*®, capaz de realizar a identificação dos parâmetros do modelo de maneira otimizada.

A seguir, no Capítulo 4, será apresentada a metodologia empregada na modelagem da bateria e como foram implementados os algoritmos do filtro de Kalman *Unscented* e do filtro de Kalman Estendido, sendo os resultados obtidos apresentados no Capítulo 5.

## 3. Revisão Bibliográfica

O estado de carga é um indicador da capacidade de energia disponível em uma bateria. Portanto, é fundamental estimá-lo de maneira precisa para assegurar um bom funcionamento do sistema de armazenamento e reduzir danos internos, assim como, ao sistema a ele vinculado. O filtro de Kalman *Unscented*, por sua vez, é considerado uma excelente técnica utilizada na estimação do SoC. Todavia, seu algoritmo padrão pode exigir algumas adaptações para promover melhores resultados.

O uso de métodos de estimação de SoC a partir de valores medidos de corrente e tensão é consolidado. Porém, a determinação de parâmetros relacionados ao modelo da bateria, dos ruídos estatísticos e a influência de fatores externos, como a temperatura, sobre o desempenho da bateria ainda requer estudos. Assim, a estimação confiável dos elementos elétricos representativos do comportamento dinâmico da bateria e dos ruídos de processo e de medição inerentes ao sistema têm se tornado cada vez mais importante na potencialização do funcionamento do UKF. Assim, neste capítulo, será apresentada uma revisão bibliográfica sobre a estimação do SoC e de outros estados por meio do UKF.

### 3.1. Estudos sobre UKF

Após verificar as limitações presentes na estimação e filtragem do EKF, Julier e Uhlmann (1997) escreveram um dos primeiros artigos sobre o UKF. Na época, nomeado como “*Unscented filter*”, o novo filtro foi proposto como um estimador linear com desempenho semelhante ao do Filtro de Kalman Padrão (SKF) em sistemas lineares, mas que era aplicável também em sistemas não-lineares sem a necessidade de etapas de linearização como as presentes no EKF. Para eles, diante das desvantagens inerentes do EKF, o novo método seria mais fácil de ser implementado e teria uma maior precisão na estimação de parâmetros em diferentes tipos de aplicações.

Eles apresentaram o problema base de aplicar o SKF em um sistema de tempo discreto não-linear, ressaltando a dificuldade em calcular as estatísticas de uma variável aleatória. Exemplificaram as inconsistências da transformação linear quando aplicada em sistemas não-

lineares, expondo a necessidade de se introduzir ruído estabilizador em um EKF apesar de nem sempre a estimação transformada se manter confiável. Assim, sugeriram a Transformada *Unscented* (UT) como solução para calcular as estatísticas de uma variável aleatória sob transformação não-linear. Nela, uma pequena quantidade de pontos sigma, obtidos deterministicamente, seria suficiente para conseguir informações de alto nível sobre a distribuição estatística. Eles descreveram os procedimentos dessa transformada e apresentaram um resumo das propriedades do algoritmo. Ao associarem a UT com o KF, eles desenvolveram o filtro *Unscented*.

Julier e Uhlmann (1997) encerraram o trabalho com uma aplicação do filtro desenvolvido por eles e do já consagrado EKF em um exemplo de rastreamento de veículo, comparando os resultados obtidos por ambos os métodos. Eles comprovaram a facilidade de implementação e a maior precisão na estimação do método, abrindo espaço para uma nova e confiável maneira de estimar variáveis em sistemas altamente não-lineares.

Quando o UKF surgiu no meio científico, suas vantagens em relação aos outros métodos se destacaram em aplicações de sistemas altamente não-lineares. Assim, o filtro logo se consolidou no rastreamento de objetos e na estimação de trajetórias. Nestes cenários, a comparação entre o UKF e o EKF era comumente estabelecida. Com o aumento dos estudos sobre veículos elétricos e geração renovável de energia, no início do século XXI, o UKF passou a ser uma opção na estimação de estados e parâmetros relacionados à bateria. Mesmo com as vantagens do UKF já representadas em trabalhos sobre rastreamento de objetos e comunicações, a nova aplicabilidade exigiu novas comparações entre o UKF e o EKF, sempre buscando o método com menor erro e maior precisão.

Zhang, Liu e Fang (2009) propuseram a estimação de SoC, resistência interna e da capacidade de uma bateria usando o UKF. Eles utilizaram o modelo de circuito equivalente com dois ramos RC, sendo o ramo formado pelo resistor em série com o capacitor, para representar o comportamento dinâmico da bateria. O modelo genérico desenvolvido por eles foi aplicado na análise de comportamento de uma bateria de lítio-íon. Os autores descreveram a implementação do UKF e validaram o método empregado com a aplicação de um protótipo de um robô em ensaios experimentais. Com o UKF foram obtidos resultados satisfatórios. Contudo, fatores externos capazes de afetar o desempenho da bateria, como a temperatura, não foram considerados.

Os autores (PIAO et al., 2010) propuseram a utilização do UKF na estimação de SoC em uma bateria de chumbo-ácido. Na equação de estado (cálculo do SoC), consideraram a variação

da capacidade de carga da bateria assim como a do coeficiente de Coulomb, considerando os impactos da temperatura e da taxa de descarga. A equação de medição foi baseada no modelo combinado. Após comparar os resultados estimados com os experimentais, obtiveram erro absoluto inferior a 7,05%. Para verificar o desempenho do filtro, foram feitos também ensaios experimentais sob correntes de ensaio variadas.

Sun et al. (2011) propuseram uma abordagem diferente. Eles adaptaram o filtro de Kalman *Unscented* (do inglês, *Adaptive Unscented Kalman Filter – AUKF*) para obter melhores resultados e aplicaram-no em um modelo *zero-state hysteresis*. Fizeram também um comparativo com outros métodos para comprovar a superioridade do método proposto por eles. Na bancada experimental, os autores utilizaram um sistema de teste em baterias disponível comercialmente, e um conjunto de outros materiais e equipamentos associado a um banco de baterias de lítio-íon (100 Ah/célula) formado por 16 células. A adaptação por eles sugerida acontece no cálculo dos valores de covariância do processo e do ruído de medição. Assim, o algoritmo deles, além das etapas de Inicialização, Predição e Atualização intrínsecas ao filtro de Kalman, ainda conta com uma etapa final de Ajuste. Os autores, apesar de considerarem a estimação dos ruídos estatísticos importante, omitiram os impactos da temperatura na estimação do SOC e sugeriram como trabalho futuro a análise do efeito de relaxação na bateria.

Liu et al. (2012) apresentaram uma variante do UKF, conhecida como *Square Root UKF* (SR-UKF), para estimar não só o estado de carga da bateria de lítio-íon como também seu valor de resistência interna, empregando um filtro para cada estimação. Eles representaram o comportamento dinâmico da bateria matematicamente, utilizando uma equação proveniente de um modelo combinado. Para validação do método empregado, utilizaram um ciclo de teste padrão para simular a bateria em uma situação real. Os resultados obtidos foram satisfatórios, com tempo de convergência reduzido. Porém, não consideraram os efeitos de fatores externos sobre o funcionamento da bateria nem a estimação dos ruídos estatísticos presentes no sistema.

Apesar de uma estimação precisa e confiável do SoC exigir um bom modelo da bateria, He et al. (2013) utilizaram o UKF na estimação do estado de carga de baterias de lítio-íon com base em um modelo extremamente simplificado. O UKF foi escolhido, pois, segundo os autores, apresenta melhores resultados do que o EKF na estimação de parâmetros em sistemas não lineares. Porém, eles não apresentaram comparações entre o UKF e o EKF. O SoC e a resistência interna do modelo da bateria foram considerados estados. Contudo, eles não apresentaram importantes

elementos na modelagem da bateria, como o ramo RC, baseando o trabalho em um modelo pouco confiável. Para testar o método desenvolvido, foram utilizados os bancos de dados norte-americanos. Assim, eles obtiveram estimações com erro quadrático mínimo (RMS) de até 4%, mesmo sem considerar as variações internas das células ou das diferentes condições de teste para o UKF.

Com um modelo de bateria mais completo, Zhao et al. (2013) propuseram a estimação do SoC de uma bateria de lítio-íon com base no UKF comparando os resultados com os obtidos via EKF. Eles utilizaram um modelo de circuito equivalente com apenas um ramo RC para representar o comportamento dinâmico da bateria. Fizeram ensaios à corrente constante de carga e descarga para obter cinco diferentes funções para representar a relação OCV-SoC, em temperatura ambiente, cujos parâmetros foram extraídos a partir dos ensaios. Para verificar a superioridade do UKF sobre o EKF, foram realizadas cinco simulações nas quais houve a inicialização imprecisa do SoC e o acréscimo de um ruído gaussiano artificial na corrente de entrada do sistema. Em todos os cenários, obtiveram uma maior precisão e um menor tempo de convergência na estimação do SoC quando utilizaram o UKF. Apesar de estimarem os ruídos estatísticos, os autores não consideraram os impactos da temperatura no desempenho da bateria.

Tian et al. (2014), por sua vez, apresentaram a estimação de SoC usando UKF em um modelo de bateria diferente, formado por um circuito equivalente com dois ramos RC adaptado com uma fonte de tensão *offset* para corrigir erros entre OCV estimado e medido. Para o cálculo do SoC, foi considerado o conhecido método de *Coulomb Counting*, porém, com o acréscimo de duas variáveis associadas à capacidade nominal da bateria:  $Q_r$  referente à capacidade prática e  $Q_t$  referente à capacidade influenciada diretamente pela temperatura. Eles, também, utilizaram um veículo elétrico com um banco de baterias robusto, sob o qual foram aplicados o modelo da bateria e o UKF para verificar a precisão e a sua estabilidade. O SoC estimado foi comparado com o SoC proveniente da unidade de monitoramento do veículo. O erro encontrado foi inferior à 3%. Para analisar o desempenho do UKF sob péssimas condições de operação, foi acrescentado ruído à corrente medida. Mesmo assim, foram obtidos resultados satisfatórios para o SOC estimado. Apesar da proposta significativa, os ruídos estatísticos foram considerados constantes.

No trabalho desenvolvido por Partovibakhsh e Liu (2015) foi utilizado um AUKF para estimar não só os parâmetros da bateria de lítio-íon e o estado de carga dela, como também as covariâncias de processo e de medição, visando aplicações em robótica. Na modelagem da bateria,

construíram o modelo em espaço-estados do circuito elétrico, e consideraram como variáveis de estado todos os elementos de tensão, capacitância e resistência presentes no circuito. Em laboratório, conduziram experimentos na bateria utilizando um robô como plataforma de teste, coletando dados de tensão e corrente para identificação dos parâmetros da bateria e atualizando o modelo em tempo real. Os resultados obtidos com AUKF foram comparados com os gerados por outros métodos de estimação e com cálculos *offline*, para comprovar o melhor desempenho do método proposto. Os autores, porém, não consideraram os efeitos da temperatura sobre a bateria.

Zhang et al. (2016) aplicaram o UFK padrão na estimação do SOC em uma bateria de lítio-íon. O modelo de circuito equivalente com dois ramos RC foi utilizado na modelagem da bateria. Os parâmetros do modelo foram obtidos de maneira complexa via dados experimentais complementados com o algoritmo dos mínimos quadrados recursivos com memória limitada. Para validar o método proposto, utilizaram uma plataforma de simulação feita em ambiente do *Matlab*®. Os autores observaram as variações presentes nos valores dos parâmetros do modelo, evidenciando a necessidade de atualização dos parâmetros durante a estimação. Eles implementaram também o método de *Coulomb Counting* para servir de referencial na comparação com a curva gerada pelo UKF. Com o filtro, foram obtidos resultados satisfatórios para simulação com correntes constante e variada. O diferencial do trabalho está no cálculo dos parâmetros do modelo. Porém, os impactos da temperatura no desempenho da bateria e a variação dos ruídos estatísticos foram ignorados.

Guo et al. (2017) propuseram utilizar um UKF adaptado (AUKF) para estimar a resistência interna, SOC e os ruídos estatísticos presentes em baterias de lítio-íon. Eles optaram pelo modelo de circuito equivalente com apenas um ramo RC para simular o comportamento dinâmico da bateria. Os parâmetros do modelo foram obtidos a partir de experimentos e considerados constantes, exceto os valores de resistência interna, que foram obtidos via AUKF. Para validar o método proposto, realizaram ensaios em uma plataforma de testes com um banco de baterias, coletando dados de tensão e de corrente. O SoC de referência foi gerado a partir do método *Coulomb Counting* usando corrente medida por um sensor de alta precisão. Com o AUKF proposto, foram obtidos resultados satisfatórios e precisos na estimação do SoC. Não houve comparações com outras técnicas de estimação. A temperatura, também, não foi considerada como fator impactante no processo de estimação.

Peng et al. (2017) apresentaram um AUKF com estimador estatístico de ruído para estimar o estado de carga de sistemas de armazenamento de energia com baterias. Para representar o comportamento dinâmico do banco de baterias, foi adotado o modelo de circuito equivalente com dois ramos RC, considerando seus parâmetros dependentes do SoC. Eles descreveram a implementação do UKF padrão e, posteriormente, apresentaram a etapa de adaptação do método empregado por eles, que consiste na estimação das médias e das covariâncias relacionadas aos ruídos de processo e de medição. Com o objetivo de validar o modelo desenvolvido, fizeram comparações entre os dados simulados e os experimentais. Os resultados obtidos com o método adaptado se sobressaíram em comparação ao padrão. Os erros obtidos e o tempo de convergência foram extremamente satisfatórios independentemente dos ruídos estatísticos e das inicializações considerados. Apesar dos excelentes resultados, os autores não analisaram a influência da temperatura sobre a estimação do SoC.

Sem estimar os ruídos estatísticos ou considerar os efeitos da temperatura no funcionamento da bateria, Jokić et al. (2018) propuseram a comparação entre UKF e EKF padrões com base na estimação do SoC em uma bateria de lítio-íon sob cenários diferentes de simulação. Para representar o comportamento dinâmico da bateria, foi utilizado o modelo de circuito equivalente com dois ramos RC. Em um primeiro cenário simulado, foi considerado o ensaio de descarga da bateria à corrente constante sem ruído. Com o EKF, foi obtido menor erro no início da estimação, porém, com o UKF foi observado menor erro na maior parte do ensaio. Em um segundo cenário simulado, foi considerado uma corrente constante de descarga com ruído. Com o UKF foram obtidos melhores resultados.

Huang et al. (2018) propuseram a comparação entre o UKF e o EKF na estimação do SoC em uma bateria de lítio-íon sob diferentes cenários. Os autores se basearam em dois tipos de modelo para representar o comportamento dinâmico da bateria. Um deles foi o modelo de circuito equivalente com apenas um ramo RC no qual os parâmetros são independentes do SOC e dependentes da temperatura e foram obtidos de duas maneiras: com algoritmo *Recursive Least Square* (RLS) e com o *Multi-Swarm Particle Swarm Optimization* (MPSO); com o MPSO, a estimação dos parâmetros foi melhor. O outro modelo foi o modelo combinado no qual os parâmetros foram calculados com base no algoritmo *Linear Least Square* (LLS) sob diferentes temperaturas. Os parâmetros do modelo da bateria foram obtidos a partir de dados extraídos de ensaios experimentais. Para verificar a precisão e estabilidade dos filtros, foram feitas simulações.

Os autores não destacaram superioridade de nenhum dos métodos ao considerar os efeitos da temperatura na estimação dos estados. Ambos os filtros apresentaram um bom desempenho, porém, os ruídos estatísticos não foram analisados como variantes no tempo.

Uma abordagem robusta sobre estimação e filtragem foi proposta por El Din et al. (2018) Os autores aplicaram o UKF associado à técnica *Autocovariance Least Square* (ALS) para estimar o SoC e o ruído de medição presente no sistema. Eles utilizaram um modelo de circuito equivalente com um ramo RC para representar o comportamento dinâmico da bateria, considerando os parâmetros como variáveis dependentes de SoC e da temperatura. Assim, empregaram uma rede neural artificial para estimar tais parâmetros dinamicamente, construindo, a partir dos dados, uma tabela de referência (*look-up table*). Apenas o SoC foi considerado como estado do sistema.

Além da estimação dos parâmetros do modelo da bateria via rede neural artificial, outro diferencial do trabalho está na estimação da matriz de covariância de medição ( $R_v$ ) com base na técnica ALS, agregando uma complexa abordagem estatística ao trabalho. Para validar o método proposto, diferentes ensaios foram realizados tanto em uma única célula quanto em um banco de baterias sob diferentes temperaturas. Foram executados três tipos de teste nos quais o SoC foi estimado com UKF e EKF padrões e com o UKF e EKF associados à técnica ALS. O SoC de referência foi obtido a partir do método *Coulomb Counting*. Os menores valores de erro foram obtidos com o ALS-UKF. Os autores também aplicaram os métodos de estimação em um outro tipo de bateria, com dados fornecidos pela NASA, para analisar o desempenho do método proposto. Novamente, o menor erro médio absoluto foi obtido com o ALS-UKF. A abordagem deste trabalho contempla a estimação dos ruídos estatísticos e os impactos da temperatura no desempenho da bateria de maneira extremamente complexa.

Com uma abordagem maior sobre a influência da temperatura no desempenho da bateria, Wu et al. (2018) propuseram a estimação do SoC com o auxílio do UKF, considerando uma larga faixa de temperatura. Eles utilizaram um modelo de circuito equivalente com um ramo RC para simular o comportamento dinâmico da bateria, sendo os parâmetros do modelo dependentes do SoC e da temperatura. Para obtê-los, realizaram diferentes tipos de ensaios em uma bancada experimental. Assim, os parâmetros foram extraídos com o auxílio do método dos mínimos quadrados recursivos.

Após validar e estabelecer um modelo confiável, os autores aplicaram o UKF na estimação de dois estados do sistema: o SoC e a tensão sobre o ramo RC. Eles compararam o desempenho

do UKF padrão sem influência da temperatura com o UKF desenvolvido por eles (T-UKF). Com a estimação proposta no trabalho, foram coletados melhores resultados. O trabalho deles não considerou a estimação dos ruídos estatísticos.

Xiao et al. (2019) utilizaram o UKF e o EKF para estimar o SoC de uma bateria de lítio-íon. Foram realizadas apenas simulações considerando a carga/descarga da bateria com corrente contínua e alternada, além do ciclo de teste *New European Driving Cycle* (NEDC). Para o modelo dinâmico da bateria, foi considerado um circuito com dois ramos RC. As variáveis de estado incluídas foram o SoC e as tensões sobre os ramos RC. Os dados analisados da bateria foram obtidos por simulação (*Matlab*®) e contaminados posteriormente com ruído antes de serem aplicados nos filtros. Em seguida, foram comparadas a precisão e a robustez de ambos os métodos utilizados para diferentes condições iniciais e correntes de carga. Ambos os filtros apresentaram boa convergência independentemente do SoC inicial em todos os cenários aplicados. Para simular os impactos da temperatura e outros fatores externos sobre a bateria, foram realizados desvios nos parâmetros do modelo (capacidade e resistência interna). A robustez de ambos os métodos foi semelhante.

Sem construir um modelo de bateria, Qin et al. (2019) se basearam em uma rede neural não linear autorregressiva com entradas exógenas (NARXNN) associada ao UKF na estimação do SoC de uma bateria de lítio-íon. A preparação dos dados foi feita com ensaio em uma bateria de lítio-íon sob três diferentes temperaturas e diferentes ciclos de teste. Parte dos dados obtidos foram utilizados no treinamento da rede neural enquanto a outra parte foi utilizada para verificar o funcionamento do modelo treinado. As entradas da rede foram a corrente e a tensão sob temperatura específica e os parâmetros de entrada foram escolhidos de maneira a minimizar os erros entre estimação e medição. A rede foi treinada no ambiente do *Matlab*®. Os valores medidos foram calculados a partir do método de *Coulomb Counting* e os estimados, obtidos da saída da rede neural. Os resultados do teste corroboraram para uma precisa, mas não estável estimação do SoC. Assim, o UKF foi inserido no processo de estimação, tendo a corrente e a saída da rede neural como as variáveis de entrada, a equação de estado baseada no *Coulomb Counting* e a equação de medição obtida da saída da rede neural. Com o método proposto da NARXNN associada ao UKF, foram obtidos melhores resultados do que os calculados somente com a rede neural.

Mediouni et al. (2019) buscaram comparar a robustez e o desempenho do UKF com o EKF na estimação do SoC de uma bateria de lítio-íon baseados no modelo de degradação de sua

capacidade. Para o modelo de circuito equivalente da bateria, foi considerado apenas um ramo RC. Todos os elementos são funções dependentes do SoC e da temperatura. O modelo de degradação da capacidade da bateria envolveu o tipo de estresse aplicado sobre a bateria, o número de ciclos de carga/descarga e os efeitos da temperatura diretamente. Para simulação, os autores consideraram o ciclo *Urban Dynamometer Driving Schedule* (UDDS) e outros ciclos de carga/descarga sob diferentes valores de temperatura após uma série de ciclos de degradação na bateria. A comparação entre UKF e EKF ocorreu em dois cenários: um em condições normais de trabalho sob diferentes valores de temperatura e outro com corrente e tensão sob efeito de ruídos. Em ambos os cenários, consideraram o erro médio absoluto e o erro máximo como variáveis comparativas. Os resultados obtidos com UKF foram melhores do que com EKF. Não houve estimação dos ruídos estatísticos do sistema, considerados constantes no trabalho.

## 3.2. Resumo das Contribuições

O filtro de Kalman *Unscented* vem sendo pesquisado desde a década de 1990. Assim, observou-se a existência de uma enorme variedade de estudos sobre esse tema. Inicialmente, o UKF era mais utilizado no rastreamento de objetos e outras aplicações relacionadas ao posicionamento e comunicações. Nos últimos anos, porém, com a inserção da mobilidade elétrica na sociedade e com o aumento da geração de energia a partir de fontes renováveis, muitos estudos sobre UKF passaram a ser aplicados na análise do comportamento dinâmico da bateria, um importante elemento nos sistemas de armazenamento de energia.

Com a revisão bibliográfica realizada, observou-se que, de forma geral, os trabalhos sobre estimação de estados na bateria envolvem o SoC como o principal tópico. Alguns consideram a necessidade de estimar em tempo real os parâmetros dos modelos da bateria, outros os consideram aplicações invariantes no tempo. A maioria ignora a influência da temperatura nos cálculos, diminuindo assim, a confiabilidade dos modelos. Para alguns autores, o algoritmo padrão do UKF é suficiente para a estimação enquanto outros modificam-no para incluir as variações dos ruídos de processo e de medição presentes no sistema não linear, objetivando viabilizar melhores resultados.

Com o levantamento das pesquisas, verificou-se que alguns dos trabalhos destacaram a superioridade do desempenho do UKF sobre outros métodos, como, por exemplo, o EKF,

demonstrando facilidade de implementação e a maior precisão do método sugerido por seus desenvolvedores (JULIER; UHLMANN; 1997). Já outros optaram pela escolha do EKF como melhor solução para estimação dos estados. Boa parte dos estudos envolveu uma abordagem experimental na extração de dados sobre a bateria. Contudo, poucos foram os que tiveram uma aplicação direta na análise de veículos elétricos reais, ou seja, limitam-se a investigar o comportamento de uma única bateria e não de um banco.

A partir da revisão bibliográfica apresentada e da definição do estado da arte, foi possível observar que a maioria das pesquisas considera modelos de baterias simples com apenas um ramo RC ou modelos combinados complexos; não consideram também os impactos da temperatura na estimação do SoC nem na determinação dos parâmetros do modelo. Os trabalhos comparativos entre UKF e outros métodos aplicados a baterias se destacaram nos últimos anos, sendo ainda, um campo aberto para novas análises e estudos.

Portanto, este trabalho surge como uma aglutinação das contribuições de diferentes pesquisas, propondo uma nova forma de análise experimental e considerando modelo de bateria mais robusto - mas ainda implementável – na modelagem do sistema de energia. Serão investigados, em especial, a inclusão dos impactos da temperatura na estimação de SoC e feita a estimação dos parâmetros da bateria constantemente durante a operação do sistema. A escolha do UKF e do EKF para este tipo de aplicação se deu pelo fato comprovado em várias pesquisas de que ambos são bons métodos de estimação de estados em sistemas não lineares. Porém, um estudo comparativo será apresentado, com o objetivo de verificar a superioridade recorrente do UKF sobre o EKF.

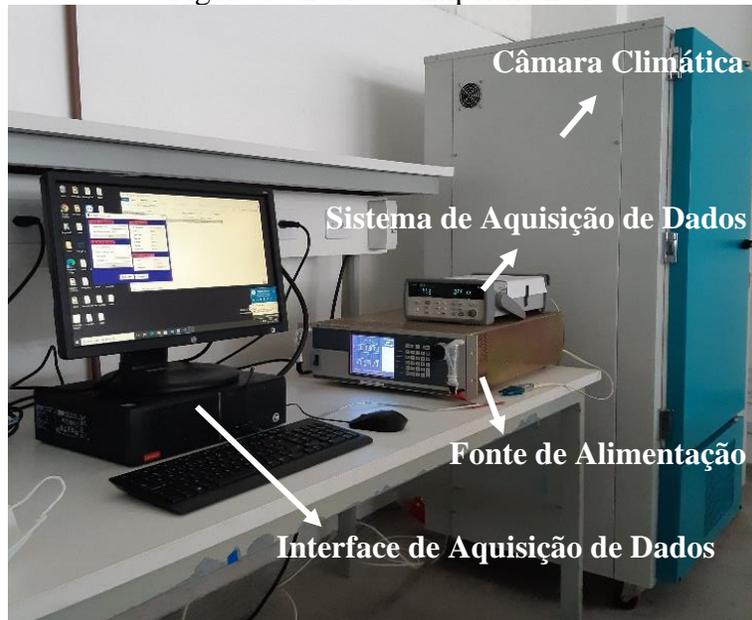
## 4. Metodologia

Neste capítulo, serão descritos a metodologia, os materiais, e os equipamentos utilizados nos ensaios de carga/descarga da bateria de lítio-íon realizados em laboratório, assim como os procedimentos adotados para viabilizar a construção do banco de dados utilizado no desenvolvimento do modelo da bateria. Em seguida, serão detalhadas as etapas de modelagem do sistema e as ferramentas utilizadas para a otimização dos seus parâmetros. Serão apresentados, também, os procedimentos necessários para a implementação efetiva do algoritmo do filtro de Kalman *Unscented* e do filtro de Kalman Estendido.

### 4.1. Materiais e Equipamentos

Para a realização deste trabalho, uma bancada experimental foi montada para realizar os ensaios de carga/descarga em sistemas de armazenamento de energia. Ela é formada por uma fonte de alimentação KEPCO BOP 10-100MG, um sistema de aquisição de dados Agilent 34972A, uma interface de aquisição de dados desenvolvida em linguagem C# e uma câmara climática MA 835/300UR. Todos os materiais e equipamentos estão disponíveis no Grupo de Inteligência Computacional Aplicada (GICA), laboratório da Universidade Federal da Paraíba (UFPB). Foram realizados ensaios em baterias de lítio-íon com capacidade de 20Ah. Na Figura 8, apresenta-se a bancada experimental utilizada e, na sequência, detalha-se cada material/equipamento empregado.

Figura 8 - Bancada Experimental.



Fonte: Autor (2020).

#### 4.1.1. Bateria de Lítio-Íon

Para implementar a modelagem do sistema e analisar o funcionamento dos algoritmos de estimação de carga, foi utilizada a bateria de lítio-íon, fabricada pela empresa A123 Systems, com capacidade nominal de 20 Ah e com composição química baseada em tecnologia de nanofosfato (A123 Systems, 2014). Na Figura 9, apresenta-se a bateria utilizada neste trabalho. Na Tabela 1, estão disponíveis algumas das especificações fornecidas pelo fabricante.

Figura 9 - Bateria de lítio-íon 20 Ah.



Fonte: Autor (2020).

Tabela 1 - Especificações da bateria de lítio-íon.

Especificação	Valor	Notas/Comentários
Capacidade Nominal	20 Ah	-
Capacidade Mínima	19,5 Ah	25 °C, 6 A de descarga, de 3,6 V até 2,0 V no BOL
Tensão Nominal	3,3 V	Com 50 % SoC
Faixa de Tensão	2,0 V até 3,6 V	Completamente descarregada até completamente carregada.
Tensão Máxima Absoluta	4,0 V	Acima deste valor, haverá danos à bateria.
Tensão Máxima de Carga	3,6 V	-
Tensão Final de Descarga	2,0 V	-
Corrente de Carga Padrão	20 A	Até 3,6 V
Corrente Máxima de Carga	100 A	Até 3,6 V, temperatura < 85 °C
Peso	495 gramas	+/- 10 gramas
Temperatura de Operação	-30 °C até +60 °C	Ambiente envolta da bateria.
Temperatura de Armazenamento	-40 °C até +65 °C	-

Fonte: (A123 Systems, 2014).

#### 4.1.2. Fonte de Alimentação

A fonte de alimentação utilizada foi do modelo BOP 10-100MG da empresa Kepco Inc., apresentada na Figura 10. Ela é uma fonte de quatro quadrantes capaz de operar como fonte de tensão ou como fonte de corrente, fornecendo ou drenando energia elétrica de um sistema. Seus limites de operação envolvem uma faixa de corrente de -100 A até 100 A, e uma faixa de tensão que pode variar de -10 V até 10 V. Ela também pode ser controlada digitalmente por meio de um menu presente em seu painel frontal, ou por meio de uma interface digital padrão de acesso remoto.

Neste trabalho, a fonte de alimentação foi configurada como fonte de tensão. Assim, ela foi capaz de fornecer a tensão de saída programada dentro dos limites estabelecidos pelo usuário. Outro ajuste importante está relacionado ao tipo de carga que será associada à fonte. Neste caso, a carga foi definida como bateria. A interface de acesso remoto escolhida para controle e

monitoramento remoto deste equipamento foi via porta serial RS-232. Na Tabela 2, estão disponíveis as configurações gerais aplicadas à fonte. Nela, são apresentados os limites de tensão e de corrente que foram definidos de acordo com o estabelecido pelo fabricante da bateria.

Figura 10 - Fonte de alimentação Kepco BOP 10-100MG



Fonte: Autor (2020).

Tabela 2 - Configurações gerais da fonte de alimentação.

Configurações de Interface (RS-232)	
<i>Data Format</i>	SCPI
<i>*RST sets Output</i>	Desligado
<i>Serial BaudRate</i>	19200
<i>X<sub>on</sub>/X<sub>off</sub></i>	Habilitado
<i>Prompt</i>	Desabilitado
Configurações de Limites (Modo Fonte de Tensão)	
<i>Protect Entry</i>	Independente
+Tensão Máxima	3,6
-Tensão Mínima	2,0
+C Proteção Máxima	20,0
+C Proteção Mínima (padrão)	0,2187
-C Proteção Máxima (padrão)	0,2127
-C Proteção Mínima	20,0
Configurações do Tipo de Carga	
Tipo de Carga	Bateria

Fonte: Autor (2020).

### 4.1.3. Câmara Climática

A câmara climática utilizada nos ensaios foi do modelo personalizado MA 835/300UR da empresa Marconi Equipamentos para Laboratórios Ltda, apresentada na Figura 11. A função desse equipamento é garantir o controle da temperatura e da umidade relativa do ambiente no qual a bateria está inserida uma vez que esses parâmetros exercem forte impacto no desempenho e na capacidade da bateria. Dentro da câmara, a bateria fica envolta pelo ar, que é resfriado ou aquecido de acordo com a configuração estabelecida pelo usuário, podendo a temperatura de trabalho variar de -10 °C até 80 °C e a umidade relativa de 20 % até 95 %.

Figura 11 - Câmara climática com controle de umidade relativa e temperatura (MA 835/300UR).



Fonte: Autor (2020).

A câmara climática utiliza uma resistência blindada em aço inox AISI 304 com potência de 1500 W para realizar o aquecimento, um umidificador com micropartículas de água para a manutenção da umidade relativa, e uma unidade selada para refrigeração, baseada em um sistema

de abastecimento e escoamento de água. A medição de temperatura é feita por um sensor PT100, que varia o valor de sua resistência de acordo com a temperatura. O isolamento é feito por isopor de alta densidade tipo P2, porta interna de vidro e porta externa de aço. Outras especificações técnicas relacionadas à câmara climática estão apresentadas na Tabela 3.

Tabela 3 - Informações técnicas sobre a câmara climática.

Informação Técnica	Valor
Modelo	MA 835/300UR (personalizado)
Volume Útil	300 litros
Tensão	220 V
Corrente	20 A
Frequência	20 Hz
Potência	4500 W
Peso Aproximado	300 kg
Dimensões LxPxA (mm)	1180 x 860 x 1600

Fonte: Manual.

No painel digital exibido na Figura 12, é possível observar na interface digital do equipamento, os indicadores de temperatura e de umidade relativa inseridos pelo usuário no menu “Ajuste de Controle”, em vermelho, e os valores atuais dentro do equipamento, em preto. Por meio dele, é também possível identificar a ação (aquecimento/refrigeração/umidificação) que ocorre naquele instante de tempo, representado por imagens (fogo, cristal de gelo, gotas de água).

Figura 12 - Painel digital da câmara climática.



Fonte: Autor (2020).

#### 4.1.4. Sistema de aquisição de dados

O sistema de aquisição de dados utilizado neste trabalho foi o Agilent 34972A, uma unidade de aquisição, comutação e registro de dados LXI fabricada pela empresa Keysight Technologies, conforme apresentado na Figura 13. Esse equipamento é composto por um *mainframe* de três *slots* associado a um multímetro digital com resolução de 6 ½ dígitos (22 bits), apresentando, assim, um bom desempenho de medição com um baixo custo de operação. A conexão com o computador pode ser feita por meio das interfaces LAN ou USB. Na Tabela 4, são apresentadas algumas das especificações técnicas do equipamento.

Neste trabalho, o sistema de aquisição de dados foi utilizado para realizar as medições de tensão da bateria e temperatura de ensaio. O equipamento, contudo, não permite medições de corrente acima de 1 A, sendo tal medição obtida dos valores de corrente fornecidos pela fonte de alimentação. A interface de comunicação com o computador escolhida foi a LAN por viabilizar uma fácil configuração de medição, monitoramento e controle dos resultados de maneira remota.

Tabela 4 - Especificações Técnicas do Sistema de Aquisição de Dados.

Informações Técnicas Gerais	
Módulo	34901A
Número de canais	20 canais de dois fios
Número de funções	11
Medições analógicas	Tensão, corrente, resistência, frequência e temperatura.
Comando de controle	SCPI
Interfaces de comunicação	LAN (Gigabit LAN) e USB (USB 2.0)
Resolução	dcV: 6 ½ dígitos; Termopar: 0,1 °C; RTD, termistor: 0,01 °C; Freq.: 6 ½ dígitos.
Precisão (anual)	dcV: 0,0035+0,0005 (% leitura + % faixa) Termopar (tipo J): 1,0 °C; RTD: 0,06 °C Termistor: 0,08 °C

Fonte: Manual, 2020.

Figura 13 - Sistema de aquisição de dados (*Datalogger*).



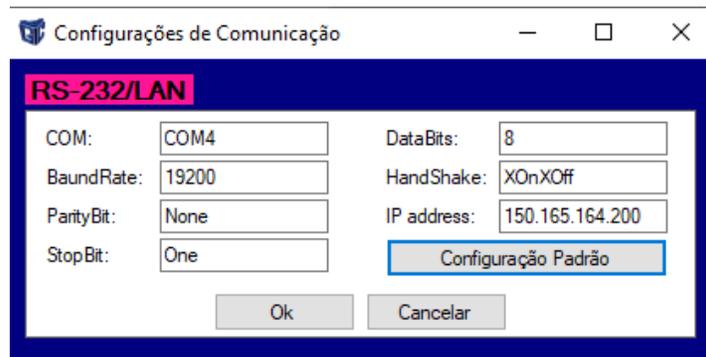
Fonte: Autor (2020).

#### 4.1.5. Interface de Aquisição de Dados

A interface de aquisição de dados utilizada neste trabalho foi implementada usando linguagem C# no ambiente do *IDE Visual Studio*. Por meio dela, o usuário é capaz de controlar os demais equipamentos (fonte de alimentação e *datalogger*) de maneira remota, além de monitorar e coletar os dados obtidos com as medições.

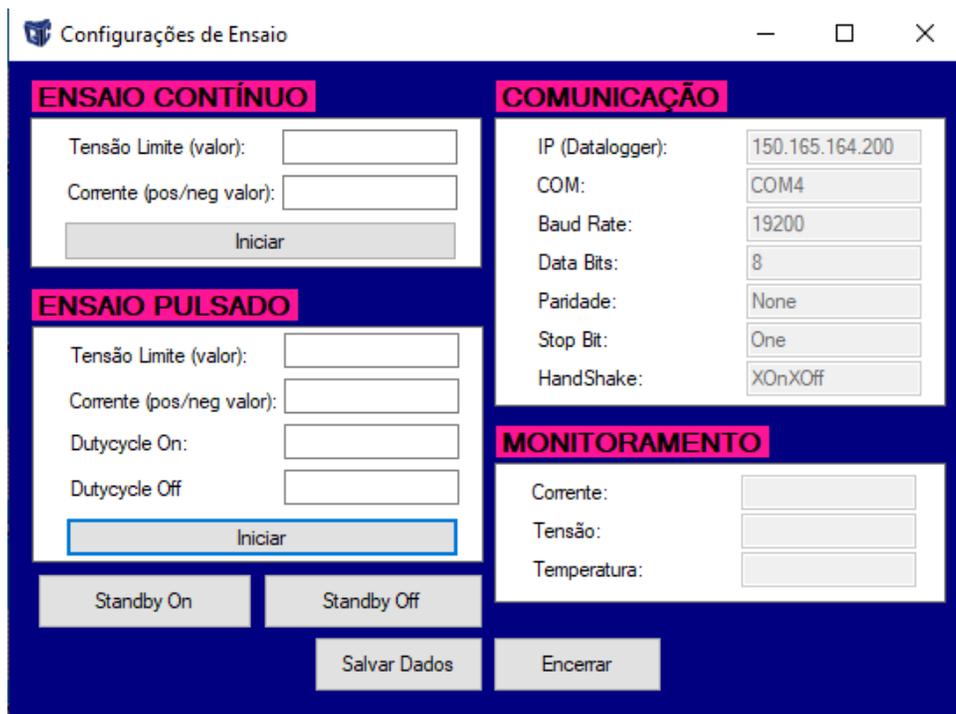
A interface apresenta duas telas de interação com o usuário. Na primeira tela, exibida na Figura 14, são realizadas configurações iniciais, com a identificação da porta serial da fonte de alimentação e do endereço IP do sistema de aquisição de dados, além da inicialização da fonte de tensão. Na segunda tela, apresentada na Figura 15, é possível ajustar os valores de tensão e de corrente de acordo com o ensaio (contínuo ou pulsado), monitorar os valores medidos pelo *datalogger* (tensão e temperatura) e pela fonte de alimentação (corrente), e gerar o arquivo de texto (.txt) contendo os dados obtidos com a medição.

Figura 14 - Primeira tela da interface de aquisição de dados.



Fonte: Autor (2020).

Figura 15 - Segunda tela da interface de aquisição de dados.



Fonte: Autor (2020).

## 4.2. Procedimentos Experimentais

Inicialmente, a bateria foi posicionada dentro da câmara climática, sendo mantida sob temperatura controlada, e conectada à fonte de alimentação e ao sistema de aquisição de dados. Um sensor de temperatura associado ao *datalogger* também foi introduzido na câmara climática para medir a temperatura do ensaio. Neste trabalho, as etapas preparatórias e os procedimentos experimentais realizados foram determinados com base na Norma Brasileira ABNT NBR IEC 62660-1 e no trabalho realizado por (SANTOS, 2018).

Os ensaios experimentais foram inicializados a partir de duas etapas preparatórias fundamentais: a climatização do ensaio e o carregamento completo da bateria. Na etapa de climatização, ocorre o ajuste da temperatura na câmara climática na qual a bateria será alocada. Na etapa de carregamento completo, ocorre a preparação da bateria antes dela ser descarregada. As duas etapas foram realizadas da seguinte maneira:

- Etapa 1 – Climatização do ensaio
  - A câmara climática é ajustada para a temperatura desejada de ensaio. Após a temperatura interna da câmara atingir a estabilidade (processo com duração de cerca de 1 hora), a bateria é mantida em repouso sob essa temperatura por 2 horas antes de ser completamente carregada.
- Etapa 2 – Carregamento completo da bateria
  - A bateria é carregada à corrente constante de 20 A (valor padrão recomendado pelo fabricante da bateria para carga) até a tensão de 3,6 V (tensão máxima recomendada pelo fabricante). Ao atingir o valor máximo de tensão, a corrente começa a decair. A bateria estará completamente carregada quando o valor de corrente for menor ou igual à 0,2 A (valor  $\leq 1\%$  da capacidade nominal).

Após as etapas preparatórias, foram realizados dois procedimentos experimentais: descarga à corrente constante e descarga à corrente pulsada. O ensaio à corrente constante foi feito com o objetivo de analisar o impacto da temperatura no desempenho nominal da bateria. O ensaio à corrente pulsada serviu como base para a obtenção dos parâmetros relacionados ao modelo de circuito elétrico equivalente da bateria. Considerando a bateria de lítio-íon com capacidade de 20

Ah sob temperatura em torno de 25 °C, os procedimentos experimentais são realizados da seguinte maneira:

- Procedimento 1 - Ensaio de descarga à corrente constante
  - Com a bateria completamente carregada (tensão = 3,6 V e corrente  $\leq 0,2$  A), aplica-se uma corrente constante de 20 A até atingir a tensão de 2,0 V (tensão final de descarga recomendada pelo fabricante);
  - A duração deste procedimento irá depender do tempo de vida da bateria e da temperatura de ensaio. Por exemplo, para uma bateria nova, com capacidade nominal ideal de 20 Ah sob temperatura em torno de 25 °C, este procedimento irá demorar 1 hora para ser concluído, teoricamente. Para outras condições de temperatura de ensaio, a duração do procedimento será diferente, pois a temperatura afeta as características da bateria.
- Procedimento 2 - Ensaio de descarga à corrente pulsada
  - Com a bateria completamente carregada (tensão = 3,6 V e corrente  $\leq 0,2$  A), aplica-se uma corrente constante de descarga no valor de 20 A durante  $t$  segundos, ocasionando um descarregamento de 10 % da capacidade nominal da bateria. Em seguida, a fonte de alimentação deve ser configurada no modo *standby*, ou fornecer corrente igual a 0 A, durante 2 horas, para que haja o equilíbrio térmico e eletroquímico da bateria, etapa conhecida como repouso;
  - O valor de  $t$  será determinado de acordo com a duração do Procedimento 1 devendo corresponder a 10 % do tempo total de ensaio à corrente contínua. Por exemplo, se o ensaio de descarga à corrente constante durar 1 hora,  $t$  será igual à 360 segundos (6 minutos ou 10 % do tempo total de ensaio);
  - A aplicação de uma corrente de descarga de 20 A durante  $t$  segundos e o período de repouso de 2 horas devem ocorrer até que a bateria atinja a tensão de 2,0 V (valor de tensão final de descarga recomendado pelo fabricante). Serão necessários, portanto, 10 pulsos de corrente de descarga para que isso ocorra.

Nesta Seção, as etapas preparatórias e os procedimentos experimentais apresentados foram aplicados para as temperaturas de 0 °C, 10 °C, 20 °C, 30 °C e 40 °C, garantindo uma análise do funcionamento da bateria dentro de uma larga faixa de temperatura. Com os dados coletados no Procedimento 1, pode-se observar a variação da duração de tempo de ensaio em decorrência da

variação da capacidade da bateria de acordo com a temperatura. Com os dados coletados no Procedimento 2, a modelagem da bateria pode ser realizada.

### 4.3. Modelagem da Bateria

Neste trabalho, a modelagem da bateria de lítio-íon será feita com base no modelo de circuito equivalente. Esse tipo de modelo elétrico é capaz de simular o comportamento da bateria a partir de elementos resistivos e capacitivos associados à tensão de circuito, apresentando um melhor equilíbrio entre exatidão e complexidade computacional do que outros tipos de modelo (Boca et al. 2018). Contudo, um dos grandes desafios encontrado ao utilizá-lo é a determinação dos parâmetros que o compõem, geralmente feita com base em ensaios à corrente pulsada.

Como apresentado por (JACKEY et al., 2013), a modelagem da bateria envolve algumas etapas principais, sendo elas: definição do número e da largura dos pulsos da corrente de ensaio; realização do ensaio com a coleta dos dados de tensão de saída e de corrente; identificação do número de ramos RC empregados no modelo; análise individual das curvas de tensão nos períodos de descanso da bateria para ajuste da curva simulada, e extração dos parâmetros do modelo.

Assim, a partir do banco de dados construído experimentalmente, de técnicas de estimação e de otimização de dados, e de ferramentas disponibilizadas pela *Mathworks*®, foi determinado o modelo de circuito elétrico equivalente da bateria de lítio-íon, incluindo a determinação da complexidade do modelo e a construção de *lookup tables* para cada parâmetro com valores dependentes do SoC e da temperatura de ensaio.

Os passos utilizados para obtenção dos parâmetros utilizam técnicas de otimização para determinar o número de ramos RC do modelo, fornecem estimativas iniciais para os parâmetros, e estimam valores de parâmetros otimizados para ajustar o modelo aos dados experimentais. No final, há a identificação da tensão de circuito aberto, da resistência em série, e dos ramos RC que melhor se encaixam ao modelo de circuito elétrico equivalente (Mathworks, 2020).

Os passos utilizados na modelagem da bateria podem ser resumidos da seguinte maneira:

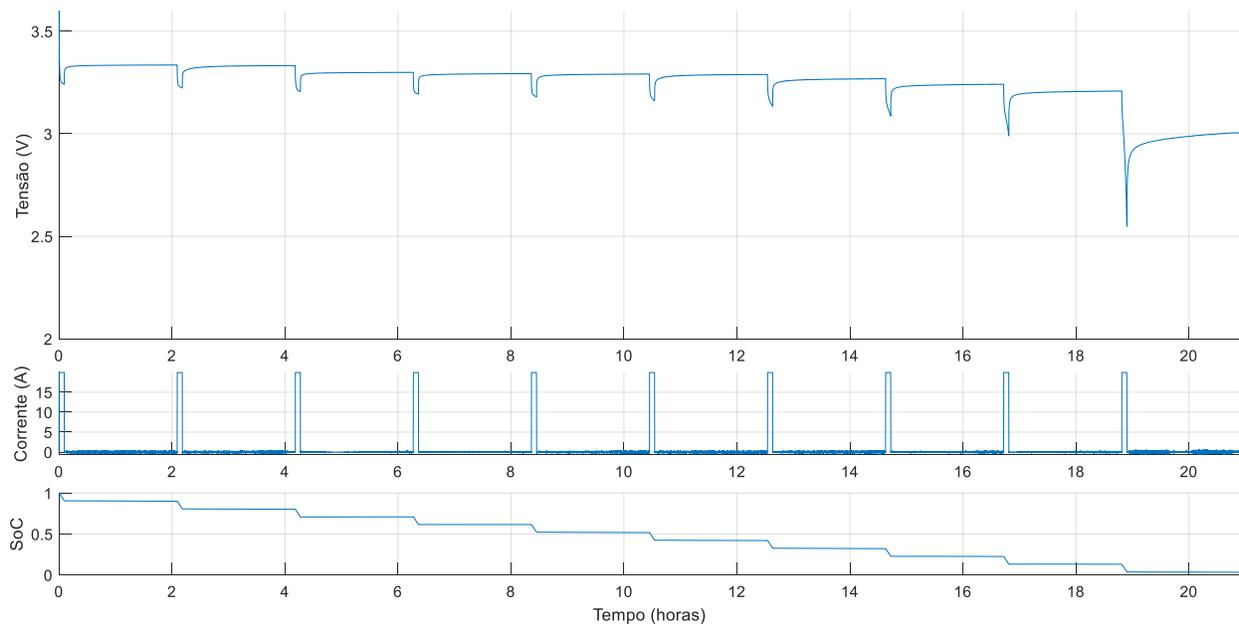
- Carregamento e pré-processamento dos dados experimentais;
- Determinação do número de ramos RC;
- Estimação dos parâmetros;

- Definição dos parâmetros otimizados em função do SoC e da temperatura (construção de *lookup tables*).

No passo de carregamento e pré-processamento dos dados experimentais, existem alguns requisitos para que haja a sua implementação. É necessário utilizar dados de tempo, tensão e corrente provenientes de ensaios de descarga à corrente pulsada, sendo a temperatura considerada constante; a taxa de amostragem utilizada na coleta dos dados deve ser de no mínimo de 1 Hz; deve-se haver um período de repouso da bateria suficiente para que haja seu equilíbrio eletroquímico e térmico. Neste trabalho, foi utilizada uma taxa de amostragem de 1 Hz em ensaios de descarga à corrente pulsada com período de repouso da bateria de 2 horas.

Em seguida, os dados de tempo, tensão e corrente são inseridos, lidos e adicionados à classe *Battery*, para que sejam extraídos dela diferentes objetos. Neste passo, a sequência de pulsos provenientes dos dados experimentais é apresentada, juntamente com uma estimativa simulada de SoC, como pode ser visto na Figura 16.

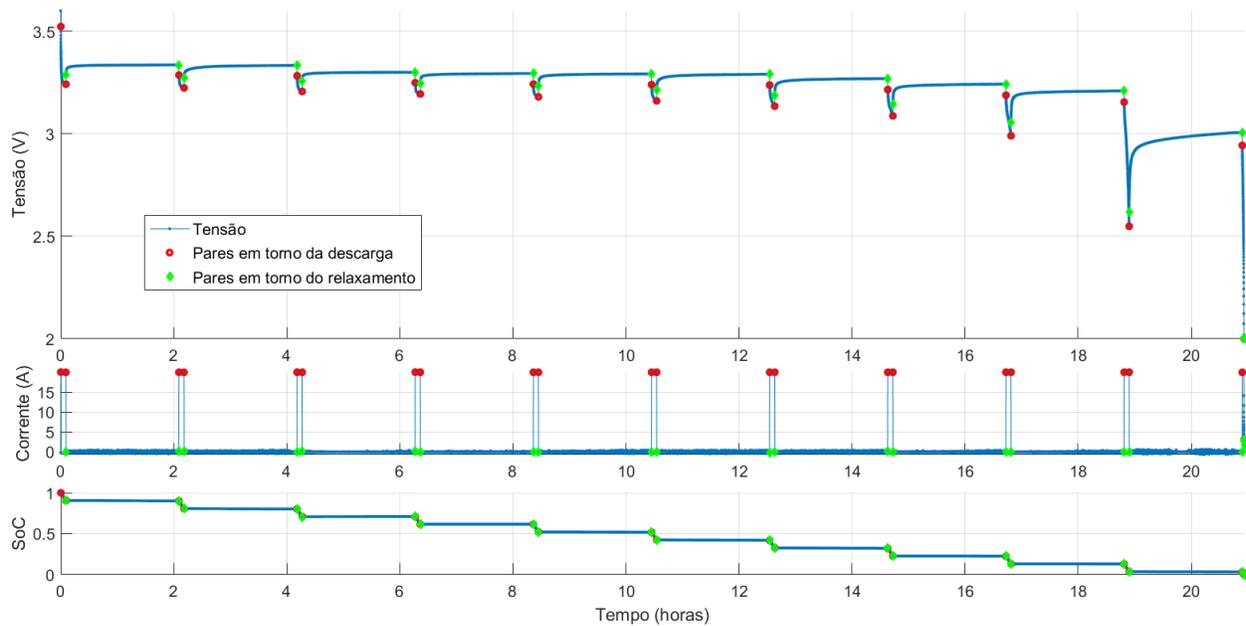
Figura 16 - Sequência de pulsos obtida experimentalmente e SoC simulado.



Fonte: Autor (2020).

Para a identificação de cada pulso, o algoritmo identifica quando a bateria está sendo descarregada e quando está em repouso com base em um valor de corrente definido em código, ou seja, quando ocorre uma variação de corrente acima daquele valor pré-definido, há o início do período de repouso e quando ocorre o inverso, há o início do período de descarga. A identificação dos pulsos é uma etapa fundamental na modelagem da bateria, pois é a partir das curvas de tensão geradas durante o período de repouso que serão extraídos os parâmetros do modelo. Na Figura 17, são apresentados os resultados do processo de identificação dos pulsos pelo algoritmo, sendo os pontos verdes limitantes do período de repouso enquanto os vermelhos limitam os períodos de descarga do sistema.

Figura 17 - Identificação dos pulsos de corrente e das faixas de tensão durante descarga/repouso.



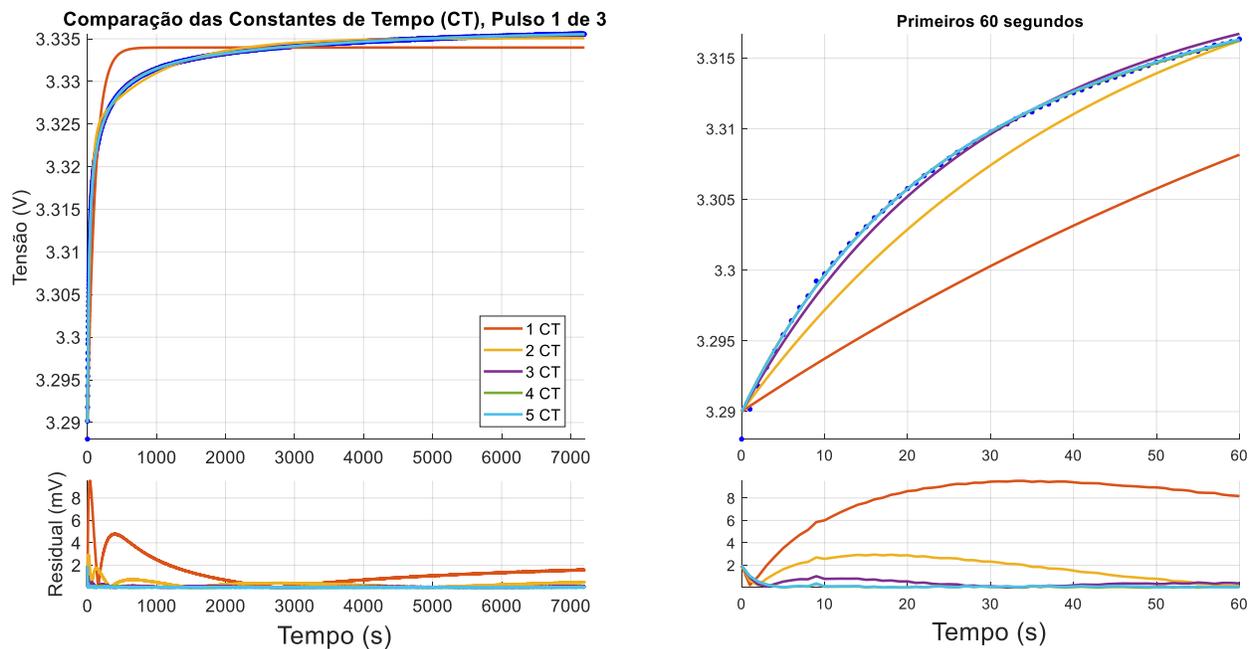
Fonte: Autor (2020).

No passo seguinte do processo de modelagem, ocorre a determinação do número de constantes de tempo necessárias para a estimação, ou seja, a quantidade de ramos RC no modelo. Esse número irá determinar a exatidão e a complexidade do modelo. Quanto mais ramos RC forem considerados, maior será o esforço computacional nas estimações dos parâmetros do modelo e, conseqüentemente, do SoC da bateria. Quanto menor o número de ramos RC, maior será o erro de

ajuste do modelo. Assim, o algoritmo faz uma análise comparativa entre cinco constantes de tempo para diferentes pulsos, cada qual com um erro residual inerente, sujeitos à escolha do usuário ou da aplicação. A ferramenta *Curve Fitting Toolbox* é utilizada neste passo para auxiliar no ajuste das curvas geradas a partir dos dados experimentais.

Na Figura 18, é apresentado um dos resultados deste procedimento. Nela é possível observar, no gráfico à esquerda, cinco curvas, cada uma referente a um número de ramos RC, variando de 1 até 5. No gráfico à direita, é exibida uma visão detalhada dos primeiros 60 segundos da simulação na qual observa-se com maior detalhamento qual das curvas está mais próxima do referencial (curva experimental), ou seja, qual delas apresenta menor erro residual, o que pode ser feito com base curvas de erro residual localizadas abaixo dos gráficos de tensão.

Figura 18 - Determinação do número de pares RC.



Fonte: Autor (2020).

No terceiro passo do processo de modelagem, ocorre a estimação dos parâmetros referentes ao modelo da bateria. Primeiramente, os valores iniciais da tensão de circuito aberto ( $V_{oc}$ ) e da resistência em série ( $R_0$ ) são estimados. Isso ocorre com uma análise da tensão imediatamente antes e depois da aplicação e da remoção da corrente no começo e no fim de cada pulso.

Em seguida, os valores iniciais das constantes de tempo do modelo são estimados durante os períodos de relaxamento da bateria para cada valor de SoC, utilizando a ferramenta *Curve Fitting Toolbox*, que considera uma equação exponencial para representar o comportamento das constantes de tempo.

Após as estimativas iniciais, o algoritmo utiliza os dados de cada pulso e os trata como um sistema linear, objetivando identificar os valores de resistência de cada ramo RC. Na Figura 19, é possível observar os valores identificados inicialmente de todos os parâmetros do modelo para cada nível de SoC, considerando um modelo de bateria com 2 ramos RC. Essa estimação inicial também pode ser realizada aplicando-se a função  $fit(x,y,'fitType')$ , disponibilizada pelo *Matlab*®, na qual é ajustada uma curva com base nos dados de  $x$  e  $y$  e no tipo de expressão estabelecida pelo usuário ( $'fitType'$ ). Para o modelo elétrico com 2 ramos RC, foi considerada uma expressão exponencial de segunda ordem, exposta em (51).

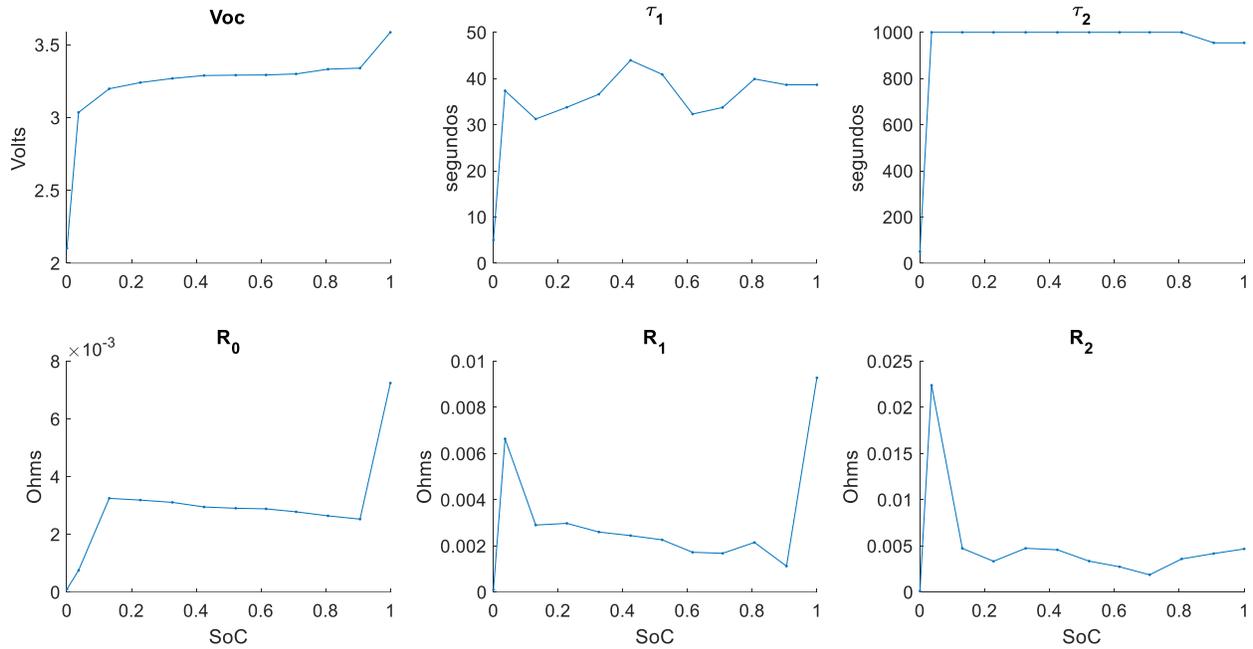
$$fitType = Voc + V_1 * (1 - \exp(-x/\tau_1)) + V_2 * (1 - \exp(-x/\tau_2)) \quad (51)$$

com  $V_1$  e  $V_2$  sendo as tensões sobre os ramos RC;  $Voc$  representa a tensão de circuito aberto do modelo;  $\tau_1$  e  $\tau_2$  são as constantes de tempo;  $x$  corresponde aos dados de tempo. Assim, os valores das resistências e capacitâncias de cada ramo RC podem ser extraídos de  $V_1$ ,  $V_2$ ,  $\tau_1$  e  $\tau_2$ , presentes na expressão (51) de acordo com as expressões (52) e (53).

$$R_1 = \frac{V_1}{I} \quad C_1 = \frac{\tau_1}{R_1} \quad (52)$$

$$R_2 = \frac{V_2}{I} \quad C_2 = \frac{\tau_2}{R_2} \quad (53)$$

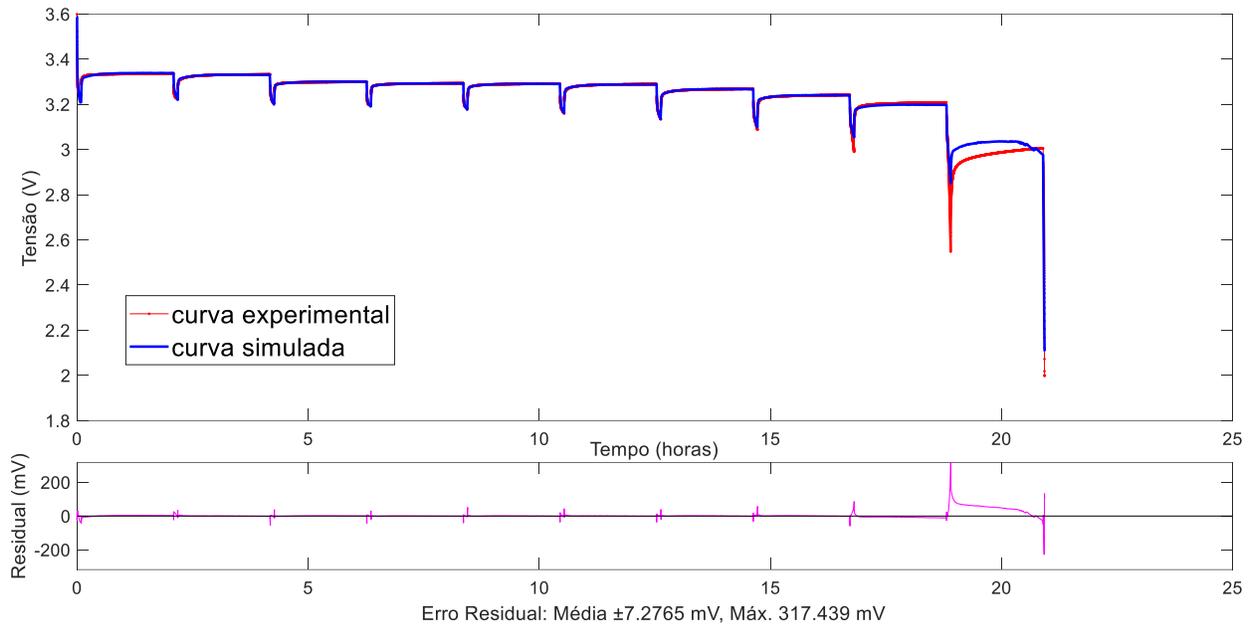
Figura 19 - Estimações iniciais dos parâmetros do modelo



Fonte: Autor (2020).

Com os valores identificados, é possível simular o comportamento do modelo para o mesmo sinal de entrada do sistema. O resultado dessa simulação pode ser visto na Figura 20, na qual é apresentado um comparativo entre a curva de tensão experimental e a simulada pelo algoritmo baseado nos valores iniciais dos parâmetros.

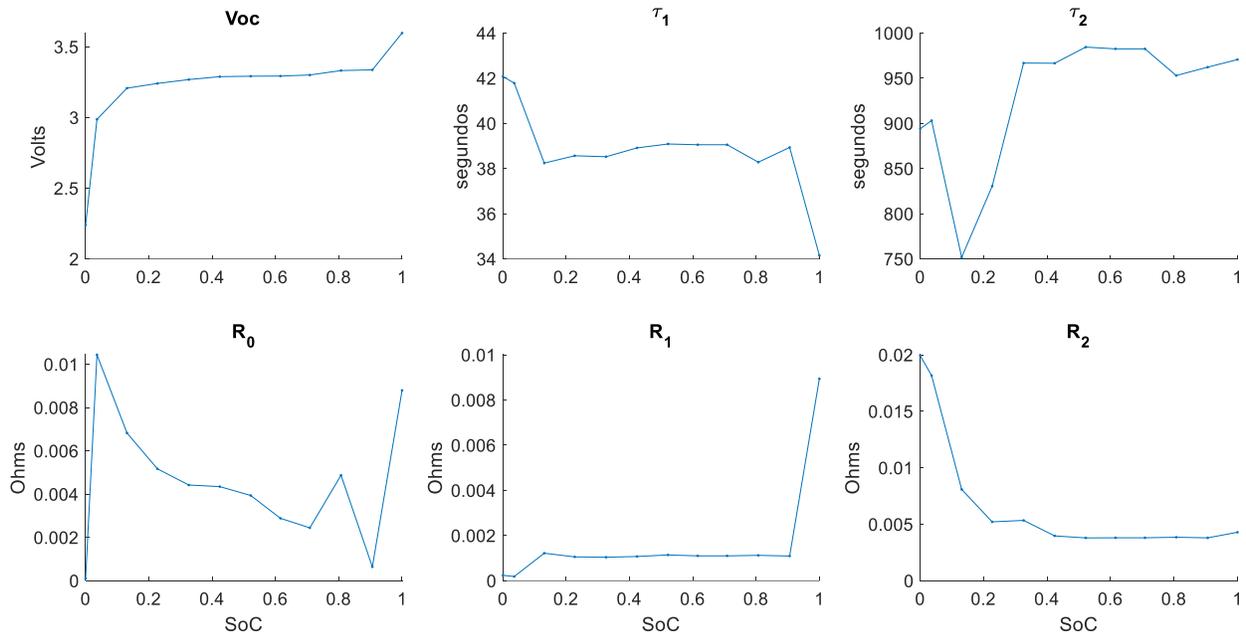
Figura 20 - Comparativo entre curvas experimental e simulada.



Fonte: Autor (2020).

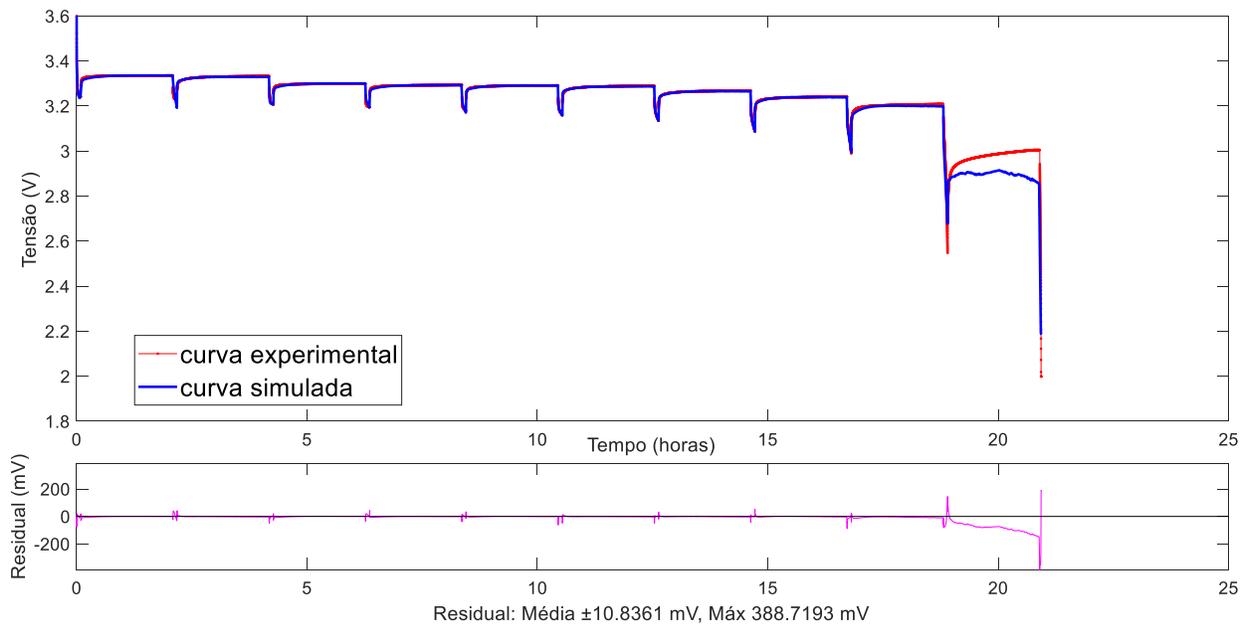
Em seguida, o algoritmo utiliza a ferramenta *Simulink Design Optimization* (SDO) para otimizar as estimações iniciais dos parâmetros do modelo da bateria, visando diminuir o erro residual inerente ao processo e aumentar a exatidão do modelo. Nas Figuras 21 e 22, estão apresentadas as estimações otimizadas dos parâmetros do modelo e o comparativo entre a curva experimental e a simulada após o processo de otimização dos parâmetros, respectivamente. Com uma visualização mais detalhada das curvas simuladas de tensão no início e no final do processo de modelagem, é possível notar a redução do erro residual decorrente delas após o processo de otimização.

Figura 21 - Parâmetros do modelo da bateria após otimização.



Fonte: Autor (2020).

Figura 22 - Comparativo entre curvas experimental e simulada após otimização dos parâmetros.



Fonte: Autor (2020).

## 4.4. Implementação dos métodos de estimação

### 4.4.1. Determinação do modelo em espaço de estados

Para que o filtro de Kalman seja empregado, o modelo da bateria deve estar representado na forma de espaço de estados em tempo discreto. Portanto, após a modelagem do sistema, é necessário determinar as equações de processo e de saída que representam seu comportamento. Neste trabalho, serão considerados como estados do sistema o SoC e as tensões sobre os ramos RC,  $V_1$  e  $V_2$ , existentes no modelo elétrico. Assim, é preciso definir as equações que representam o comportamento desses estados do sistema em tempo contínuo para posterior processo de discretização.

O estado de carga da bateria é o estado mais importante do modelo e geralmente é definido pelo método *Coulomb Counting*. A equação que define o SoC da bateria, em tempo contínuo, está expressa em (54). Nela, a corrente de entrada  $I$  do sistema é integrada ao longo do tempo, sendo  $SoC(t_1)$  o estado de carga da bateria em um instante inicial;  $C_n$  a capacidade da bateria (que irá depender da temperatura do ensaio);  $\eta$  é a constante de Coulomb (geralmente igual à 0,98).

$$SoC(t_2) = SoC(t_1) + \frac{\eta}{C_n} \int_{t_1}^{t_2} I(\tau) d\tau \quad (54)$$

O método de *Coulomb Counting* necessita de medições precisas da corrente e uma boa inicialização do estado para diminuir os impactos de erros no processo de estimação. Assim, esse método será usado em conjunto com um filtro de Kalman, conhecido por sua autocorreção do erro de covariância durante a operação do sistema. Assim, a Equação (54) deve estar discretizada de acordo com a expressão (55), com  $t_1 = k\Delta t$  e  $t_2 = (k + 1)\Delta t$  sendo  $\Delta t$  o período de amostragem. A equação que define o SoC da bateria, em tempo discreto, está expressa em (56).

$$SoC((k + 1)\Delta t) = SoC(k\Delta t) + \frac{\eta\Delta t}{C_n} I(k\Delta t) \quad (55)$$

$$SoC[k + 1] = SoC[k] + \frac{\eta\Delta t}{C_n} I[k] \quad (56)$$

Neste trabalho, as tensões sobre os ramos RC também são consideradas estados do sistema, sendo necessário determinar as expressões que regem seus comportamentos. Assim, com base no modelo elétrico, nas leis de Kirchhoff e nas características transitórias do modelo, a tensão de saída do sistema  $Y$  e a corrente  $I$  que circula através dele podem ser expressas, em tempo contínuo, de acordo com (57) e (58), respectivamente.

$$Y = V_{oc} - V_1 - V_2 - R_{int}I \quad (57)$$

$$I = \frac{V_1}{R_1} + C_1 \frac{dV_1}{dt} = \frac{V_2}{R_2} + C_2 \frac{dV_2}{dt} \quad (58)$$

Portanto, as tensões sobre os ramos RC podem ser expressas na forma de equações diferenciais como apresentado em (59) e (60) (TOPAN et al., 2016).

$$\frac{dV_1}{dt} = -\frac{V_1}{R_1 C_1} + \frac{I}{C_1} \quad (59)$$

$$\frac{dV_2}{dt} = -\frac{V_2}{R_2 C_2} + \frac{I}{C_2} \quad (60)$$

Reorganizando as equações (59) e (60), é possível representar as derivadas desses estados do sistema de maneira matricial em tempo contínuo de acordo com (61), sendo  $x_V$  o vetor transposto formado pelas tensões sobre os ramos RC.

$$\dot{x}_V = Ax_V + BI = \begin{bmatrix} -\frac{1}{R_1 C_1} & 0 \\ 0 & -\frac{1}{R_2 C_2} \end{bmatrix} \begin{bmatrix} V1 \\ V2 \end{bmatrix} + \begin{bmatrix} \frac{1}{C_1} \\ \frac{1}{C_2} \end{bmatrix} I \quad (61)$$

De forma geral, o processo de discretização é iniciado de acordo (62) e (63), considerando  $t = k\Delta t$  no qual  $\Delta t$  representa o período de amostragem.

$$x((k + 1)\Delta t) = M(\Delta t)x(k\Delta t) + N(\Delta t)u(k\Delta t) \quad (62)$$

$$y(k\Delta t) = H(x(k\Delta t), u(k\Delta t)) \quad (63)$$

Ainda para determinar o modelo discreto, são utilizadas as igualdades expressas em (64) e (65).

$$M(\Delta t) = e^{A\Delta t} \quad (64)$$

$$N(\Delta t) = (e^{A\Delta t} - I)BA^{-1} \quad (65)$$

Assim, após a discretização, é possível representar o sistema em espaço de estados de acordo com (66) e (67) e, de forma mais detalhada, como apresentado em (68) e (69) (PENG et al., 2017). Nelas,  $q$  e  $r$  correspondem aos ruídos de processo e de medição do sistema, respectivamente;  $\Delta t$  é o período de amostragem;  $\tau_1$  e  $\tau_2$  correspondem às constantes de tempo do primeiro e do segundo ramos, respectivamente, calculadas pela multiplicação entre os valores de resistência e capacitância presentes no ramo.

$$x(k + 1) = Mx(k) + NI(k) + q(k) \quad (66)$$

$$y(k) = H(x(k), u(k)) + r(k) \quad (67)$$

$$\begin{bmatrix} SoC(k+1) \\ V_1(k+1) \\ V_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{\Delta t}{\tau_1}} & 0 \\ 0 & 0 & e^{-\frac{\Delta t}{\tau_2}} \end{bmatrix} \begin{bmatrix} SoC(k) \\ V_1(k) \\ V_2(k) \end{bmatrix} + \begin{bmatrix} \frac{\eta \Delta t}{3600 C_n} \\ R_1 [1 - e^{-\frac{\Delta t}{\tau_1}}] \\ R_2 [1 - e^{-\frac{\Delta t}{\tau_2}}] \end{bmatrix} I(k) + q(k) \quad (68)$$

$$Y(k) = H(x(k), u(k)) = V_{oc}(k) - V_1(k) - V_2(k) - R_{int} I(k) + r(k) \quad (69)$$

#### 4.4.2. Implementação do Filtro de Kalman *Unscented* (UKF)

No filtro de Kalman *Unscented*, os pontos sigma e os pesos relacionados a eles são calculados com base em um conjunto de parâmetros de escalonamento responsáveis por influenciar a distância entre esses pontos sigma da média do estado. Esses parâmetros podem ser especificados livremente, possibilitando uma infinidade de resultados da Transformada *Unscented*. Contudo, eles devem respeitar alguns critérios, como descrito a seguir (WAN AND VAN DER MERWE, 2000):

- $\alpha$  é responsável por determinar a distância entre os pontos sigma da média do estado. Geralmente,  $0 < \alpha \leq 1$ ;
- $\kappa$  atua secundariamente no espelhamento dos pontos sigma em torno da média do estado. Idealmente,  $\kappa \geq 0$ ;
- $\beta$  é responsável por incorporar conhecimento prévio sobre a distribuição do estado. Para distribuições gaussianas, assume-se como ideal  $\beta = 2$ ;
- $\lambda$  é outro parâmetro de escalonamento, sendo determinado por  $\lambda = \alpha^2(L + \kappa) - L$  no qual  $L$  representa a quantidade de estados analisados.

Com o emprego do UKF, não há necessidade de construir matrizes Jacobianas após a discretização do sistema como ocorre com o EKF. Após a sintonia do filtro, ou seja, a inicialização dos seus parâmetros de escalonamento, é necessário apenas inicializar os valores médios dos estados e a matriz de covariância de acordo com (70) e (71), respectivamente.

$$\bar{x}_0 = \begin{bmatrix} SoC(0) \\ V_1(0) \\ V_2(0) \end{bmatrix} \quad (70)$$

$$P_0 = \begin{bmatrix} P_{SoC} & 0 & 0 \\ 0 & P_{V_1} & 0 \\ 0 & 0 & P_{V_2} \end{bmatrix} = \begin{bmatrix} \sigma_{SoC}^2 & 0 & 0 \\ 0 & \sigma_{V_1}^2 & 0 \\ 0 & 0 & \sigma_{V_2}^2 \end{bmatrix} \quad (71)$$

Após a modelagem do sistema, foram obtidos os valores dos parâmetros do modelo elétrico para cada estado de carga da bateria. Assim, foi possível determinar as funções que representam a relação entre SoC/temperatura com cada parâmetro. Essas funções foram, conseqüentemente, aplicadas ao UKF, implementado com base no algoritmo conforme apresentado na Figura 2, ou seja, foi realizado o cálculo da Transformada *Unscented*, com a geração dos pontos sigma e a conseqüente aplicação dos valores obtidos na equação de processo do sistema; na seqüência, novos valores médios e de covariância dos estados foram calculados e aplicados na equação de saída do modelo, resultando, em seguida, na obtenção do ganho de Kalman e na estimação dos estados e da matriz do erro de covariância.

#### 4.4.3. Implementação do Filtro de Kalman Estendido (EKF)

Com o intuito de analisar o desempenho do UKF, foi feita uma análise comparativa com os resultados obtidos da implementação do Filtro de Kalman Estendido com base no erro médio absoluto e na raiz do erro quadrático médio. Inicialmente, foram seguidos os mesmos procedimentos adotados no UKF, ou seja, na implementação do EKF também foram estimados três estados do sistema (SoC e tensões sobre os ramos RC). A discretização do sistema também ocorreu da mesma maneira que a realizada na Seção 4.2, representada em (68) e (69). O diferencial desta implementação está na etapa de linearização, na qual as matrizes representantes do comportamento dinâmico da bateria são obtidas de acordo com (72)-(75) (SANTOS et al., 2017).

$$A_k = \frac{\partial f}{\partial x} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-\frac{\Delta t}{\tau_1}} & 0 \\ 0 & 0 & e^{-\frac{\Delta t}{\tau_2}} \end{bmatrix} \quad (72)$$

$$B_k = \frac{\partial f}{\partial u} = \begin{bmatrix} \frac{\eta \Delta t}{3600 C_n} \\ R_1 [1 - e^{-\frac{\Delta t}{\tau_1}}] \\ R_2 [1 - e^{-\frac{\Delta t}{\tau_2}}] \end{bmatrix} \quad (73)$$

$$C_k = \frac{\partial g}{\partial x} = \begin{bmatrix} \frac{\partial V_{oc}}{\partial SOC} & -1 & -1 \end{bmatrix} \quad (74)$$

$$D_k = \frac{\partial g}{\partial u} = [-R_{int}] \quad (75)$$

# 5. Resultados e Análises

Neste Capítulo, serão apresentados os resultados obtidos com a implementação da metodologia proposta. Podem ser destacados como os principais resultados, a obtenção de um modelo de bateria baseado em um circuito elétrico equivalente e a estimação dos seus parâmetros, gerando respostas semelhantes às produzidas pelo sistema real. Em seguida, serão exibidos e comparados, por meio de gráficos e tabelas, os resultados obtidos com os métodos de estimação do estado de carga baseados em filtros de Kalman. Sabendo-se do impacto da temperatura no desempenho da bateria, a modelagem do sistema e estimação do SoC foram realizados para diferentes bancos de dados, levando em consideração a variação da temperatura ambiente na qual a bateria estava inserida.

## 5.1. Determinação da capacidade da bateria

O funcionamento da bateria é significativamente afetado pela variação de temperatura ambiente em decorrência das reações químicas que ocorrem dentro do sistema. Para analisar esse impacto, a bateria de lítio-íon foi submetida à ensaios de descarga à corrente contínua (20 A) sob diferentes temperaturas (0° C, 10° C, 20° C, 30° C, 40° C) de acordo com o Procedimento 1 já detalhado no Capítulo 4.

Os resultados desses ensaios estão apresentados na Figura 23. Nela é possível observar que quanto menor a temperatura interna da câmara climática, mais rápido é o descarregamento da bateria, ou seja, menor o tempo de ensaio. Isso indica uma redução da capacidade da bateria. Para analisar o valor da capacidade disponível da bateria, basta-se aplicar a expressão (76) aos resultados do ensaio de descarga à corrente constante.

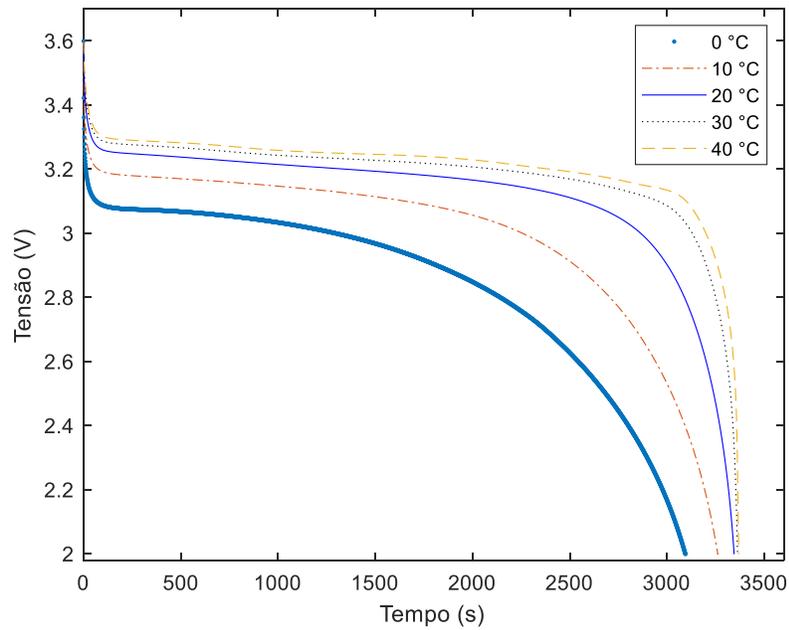
$$capacidade = \frac{tempo \times corrente}{3600} \quad (76)$$

Com isso, o gráfico da capacidade disponível em função da temperatura foi construído, como apresentado na Figura 24. Com o auxílio da ferramenta *Curve Fitting Toolbox*,

disponibilizada pelo *Matlab*®, foi possível extrair a expressão exponencial (77) que permite calcular o valor da capacidade disponível  $C_d$  em função da temperatura  $T$ .

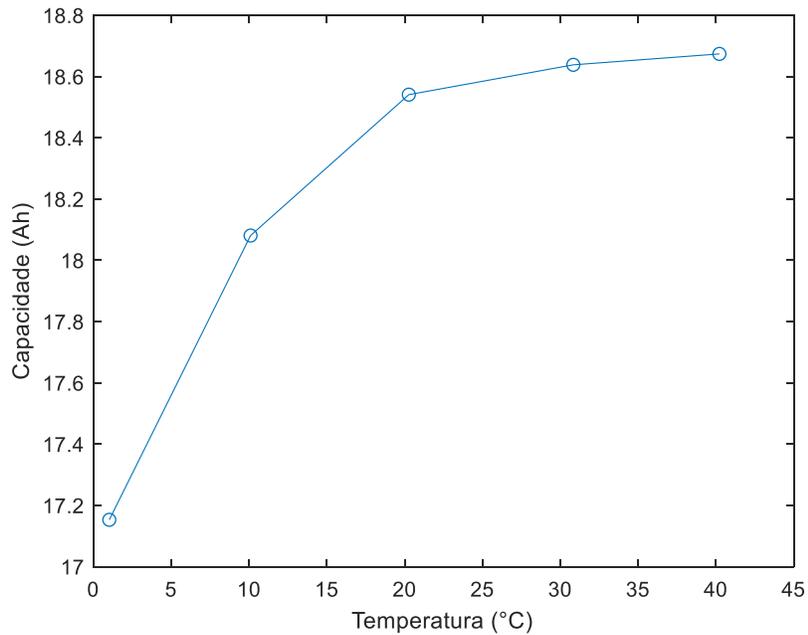
$$C_d = 19,1 \times e^{-0,0004657 \times T} - 2,105 \times e^{-0,08227 \times T} \quad (77)$$

Figura 23 - Curvas de descarga à corrente contínua sob diferentes temperaturas.



Fonte: Autor (2020).

Figura 24 - Gráfico da capacidade disponível da bateria em função da temperatura de ensaio.



Fonte: Autor (2020).

Idealmente, a bateria de lítio-íon utilizada nos ensaios deveria ter uma capacidade nominal de 20 Ah, ou seja, o ensaio de descarga à corrente contínua de 20 A deveria durar 1 h. Com base nos resultados apresentados na Figura 24, nota-se uma capacidade em torno de 18,6 Ah para temperatura ambiente. Isso ocorre devido a célula já possuir algum tempo de fabricação. Quanto maior o tempo de vida da célula, mais deteriorada se torna sua composição interna e, conseqüentemente, menor sua capacidade disponível, mesmo sem ter sido utilizada anteriormente. Esse fato, contudo, não afeta o estudo da modelagem da bateria e da estimação do seu estado de carga, desde que sejam consideradas essas mudanças no decorrer do trabalho.

## 5.2. Determinação do modelo da bateria

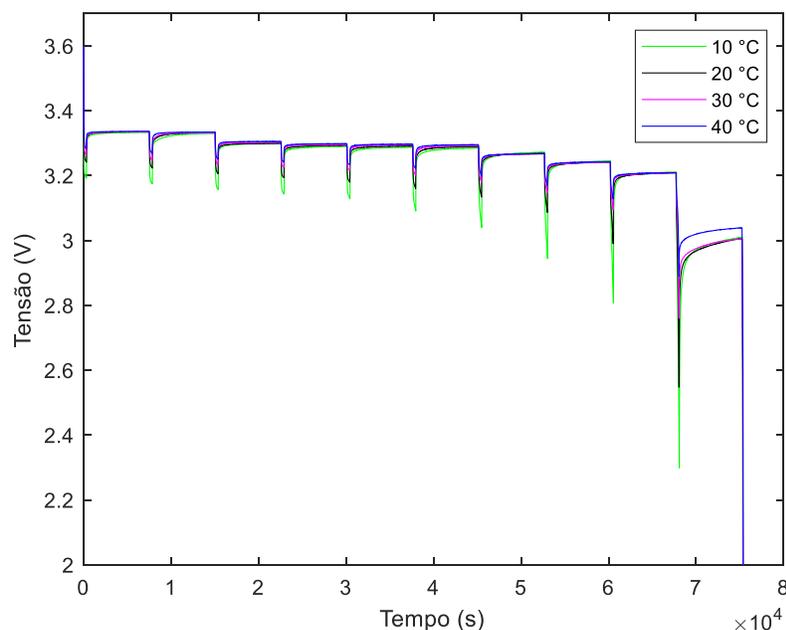
Inicialmente, para realizar a modelagem da bateria, é necessário analisar as curvas de tensão obtidas durante os períodos de relaxamento do sistema em ensaios à corrente pulsada. Assim, ensaios experimentais foram feitos de acordo com o Procedimento 2 descrito no Capítulo 4. As curvas de tensões de saída da bateria medidas sob diferentes condições de temperatura (10°

C, 20° C, 30° C, 40° C) estão apresentadas na Figura 25. Optou-se, em todos os ensaios, realizar a descarga de 10 % do SoC da bateria durante cada pulso de corrente (20 A). Sendo assim, todos os ensaios apresentaram 10 períodos de relaxamento, ou seja, 10 níveis de SoC.

Na Figura 26, são apresentados os pulsos de corrente aplicados durante o ensaio de descarga. Nela, observa-se um ruído durante o período de repouso da bateria. Esse fato ocorreu devido às configurações da fonte de alimentação no momento que era utilizada no modo *standby*, pois verificou-se que a mesma era incapaz de fornecer corrente igual à 0 A. Isso resultou em sinais ruidosos durante a medição. Contudo, tais ruídos de corrente não afetam significativamente o período de relaxamento da bateria por serem majoritariamente valores inferiores à 0,2 A.

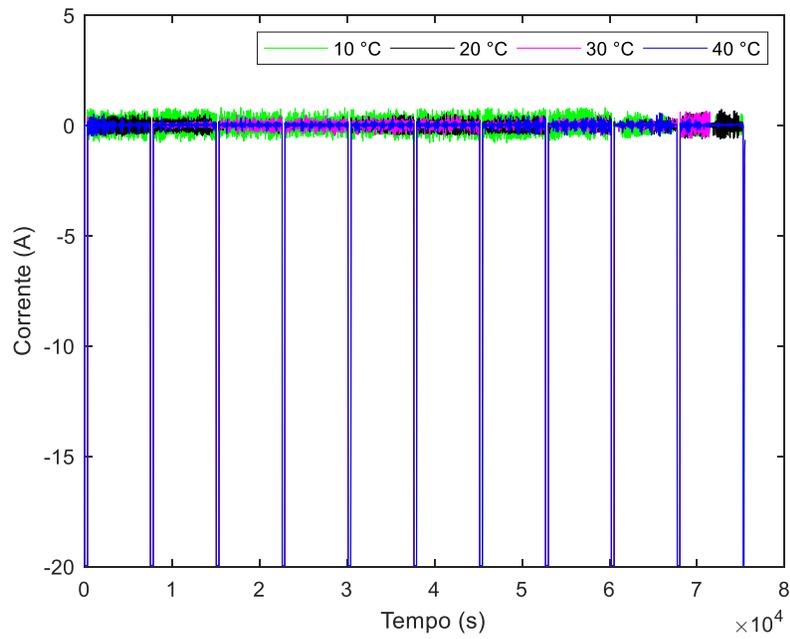
Em seguida, os dados experimentais coletados em laboratório foram aplicados ao algoritmo, disponibilizado pela *Mathworks*®, capaz de estimar os parâmetros do modelo de maneira automática em quatro passos principais. Inicialmente, ocorreu a identificação dos pulsos de corrente, com o isolamento das curvas de tensão durante os períodos de descanso da bateria, como está representado na Figura 27. Nela, estão apresentados os resultados do primeiro passo da modelagem da bateria para a temperatura de 20 °C. Todas os dados obtidos para as outras temperaturas também passaram pelo mesmo processo de modelagem.

Figura 25 - Curvas de descarga à corrente pulsada sob diferentes temperaturas.



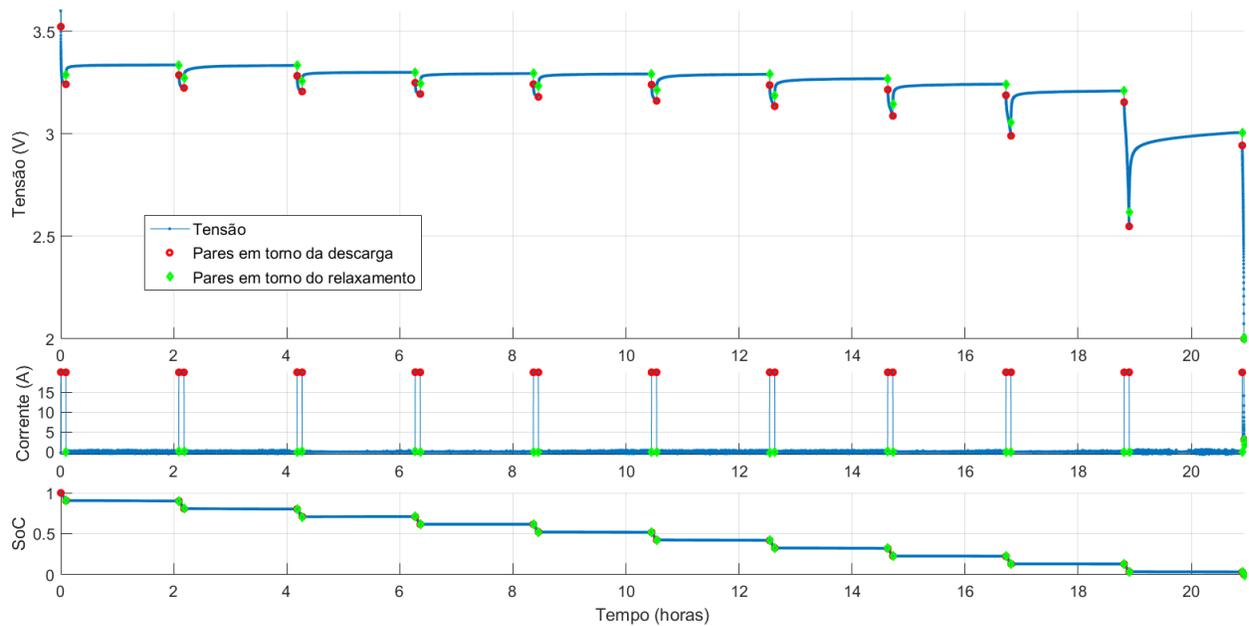
Fonte: Autor (2020).

Figura 26 - Pulsos de corrente aplicados em ensaio de descarga sob diferentes temperaturas.



Fonte: Autor (2020).

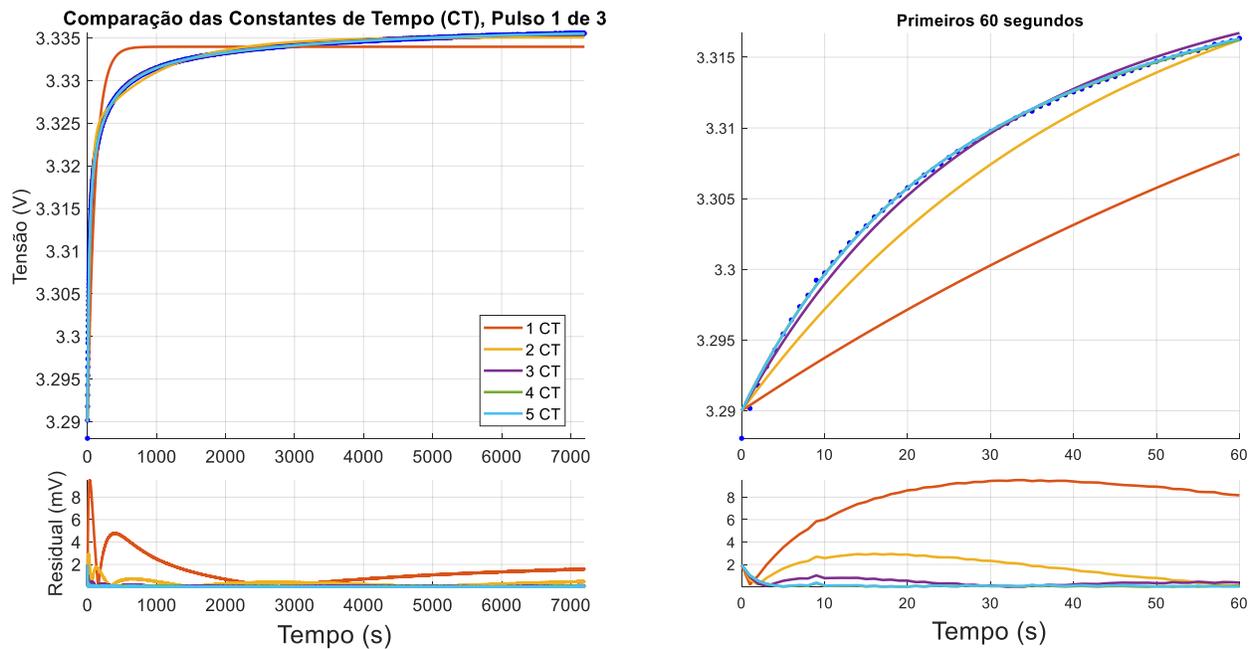
Figura 27 - Identificação dos pulsos de corrente e das faixas de tensão durante descarga/repouso.



Fonte: Autor (2020).

Em seguida, durante o segundo passo de execução do algoritmo, ocorreu a determinação do número de pares RC que farão parte do modelo do sistema. Sabe-se que quanto maior o número de pares RC, mais próximo será o modelo do sistema real. Contudo, um número elevado de constantes de tempo irá exigir um esforço computacional também maior. Assim, após analisar os gráficos produzidos pelo algoritmo da *Mathworks*® para modelagem da bateria, apresentados na Figura 28, optou-se por considerar dois ramos RC, pois o erro residual é significativamente menor do que o modelo com um ramo e próximo ao modelo com três ramos RC, exigindo, porém, um menor requisito computacional e tempo de processamento.

Figura 28 - Determinação do número de pares RC.



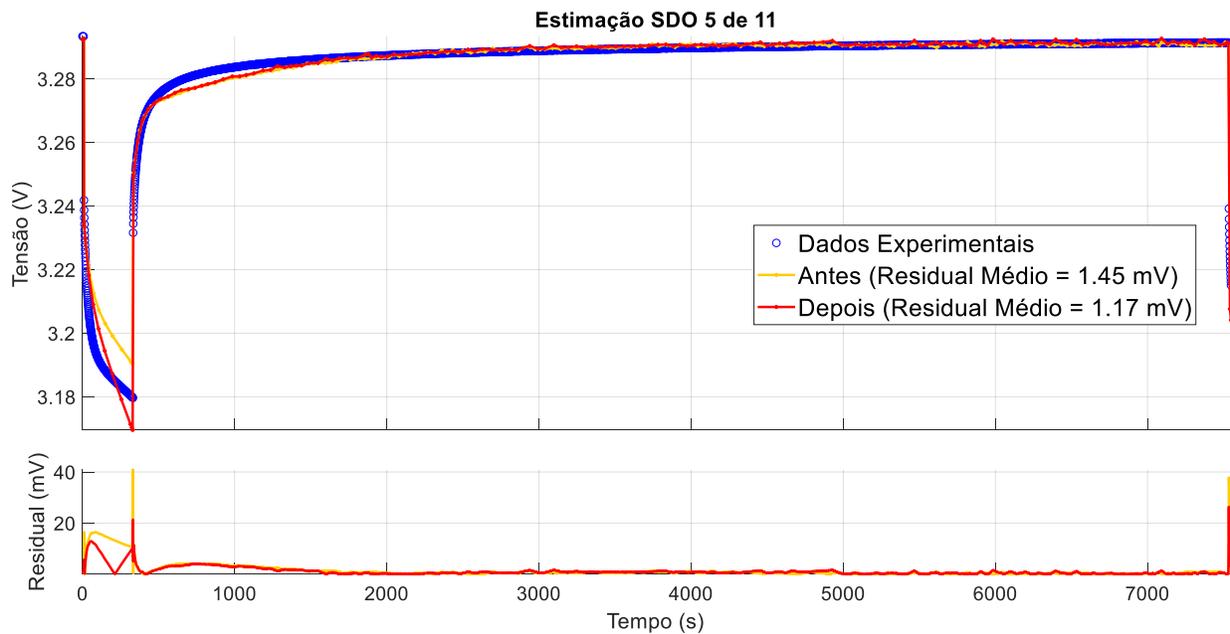
Fonte: Autor (2020).

No terceiro passo do processo de modelagem, foram extraídos os valores iniciais dos parâmetros do modelo a partir de cada curva de tensão resultante do período de relaxamento da bateria, ou seja, são estimados os parâmetros para cada nível de SoC. Com esses valores, já é possível gerar uma simulação do comportamento do modelo. Porém, visando aperfeiçoar os resultados de estimação, o algoritmo aplica um processo de otimização, com auxílio da ferramenta

*Simulink Design Optimization*, tornando o comportamento do modelo ainda mais próximo do sistema real.

Na Figura 29, é possível observar a diminuição do erro residual ao se realizar a otimização durante um período de descanso da bateria. Nesse gráfico, a curva em amarelo corresponde à resposta do modelo baseada nos parâmetros iniciais, antes da otimização; já a curva em vermelho corresponde à resposta do modelo considerando os valores dos parâmetros otimizados. Com esse processo, o erro residual foi reduzido de 1,45 mV para 1,17 mV para esse nível de SoC. Com as demais curvas de repouso também ocorre reduções significativas do erro residual.

Figura 29 - Processo de otimização de um pulso da curva de descarga.



Fonte: Autor (2020).

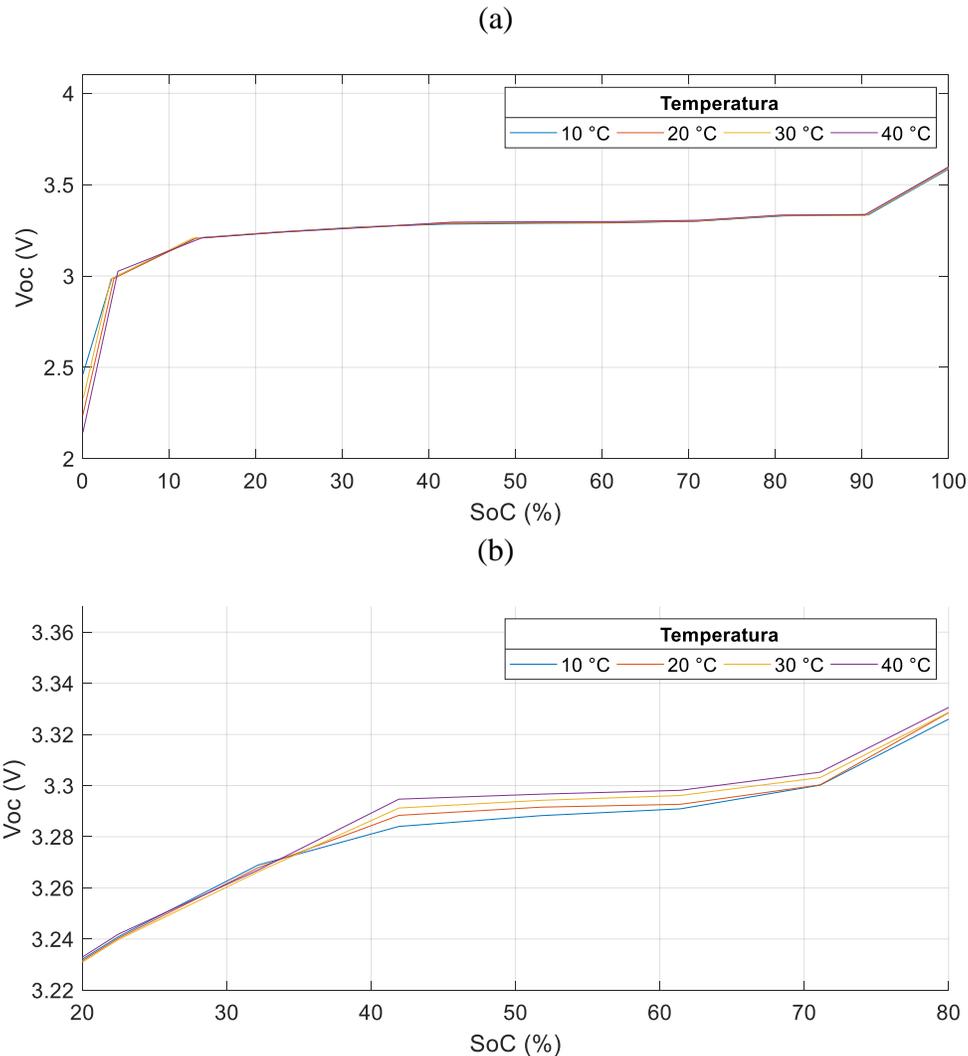
Com a obtenção dos valores dos parâmetros otimizados para cada nível de SoC, foram extraídas expressões que representam o comportamento desses parâmetros para cada condição de temperatura. Essas expressões foram obtidas utilizando a função *fit*, disponibilizada pelo *Matlab*®, com base no método de *'linearinterp'*, que corresponde à interpolação linear. Com esse método, é possível gerar uma curva ou superfície pela qual passam todos os pontos de dados fornecidos enquanto os demais pontos não fornecidos são calculados por interpolação linear. Assim, obteve-

se um conjunto de expressões para cada temperatura utilizada nos ensaios experimentais à corrente pulsada (10 °C, 20 °C, 30 °C e 40 °C).

Os extremos de operação da bateria, totalmente carregada ou totalmente descarregada, são as áreas mais instáveis do sistema nas quais ocorre forte influência das transformações químicas na estimação dos parâmetros do modelo, podendo gerar resultados significativamente divergentes dos ideais. Neste trabalho, portanto, a análise dos parâmetros do modelo da bateria será baseada nos valores dentro de uma faixa mais estável, ou seja, mais segura de operação do filtro de Kalman, considerada aqui como sendo entre 20 % e 80 % do SoC, excluindo, assim, os valores potencialmente descompensados dos parâmetros nos extremos de operação da bateria.

Na Figura 30, são apresentados dois gráficos correspondentes aos dados de tensão de circuito aberto ( $V_{oc}$ ), SoC e temperatura. Na Figura 30a, observa-se que não há diferenças significativas das curvas de  $V_{oc}$  para diferentes temperaturas, todas variam não linearmente de 3,6 V até cerca de 2 V, durante o funcionamento completo da bateria. Uma visão aproximada da faixa de operação segura ( $20\% \geq SoC \leq 80\%$ ), exibida na Figura 30b, demonstra com maiores detalhes a proximidade dos valores de  $V_{oc}$ , sendo eles menores quanto menor for a temperatura.

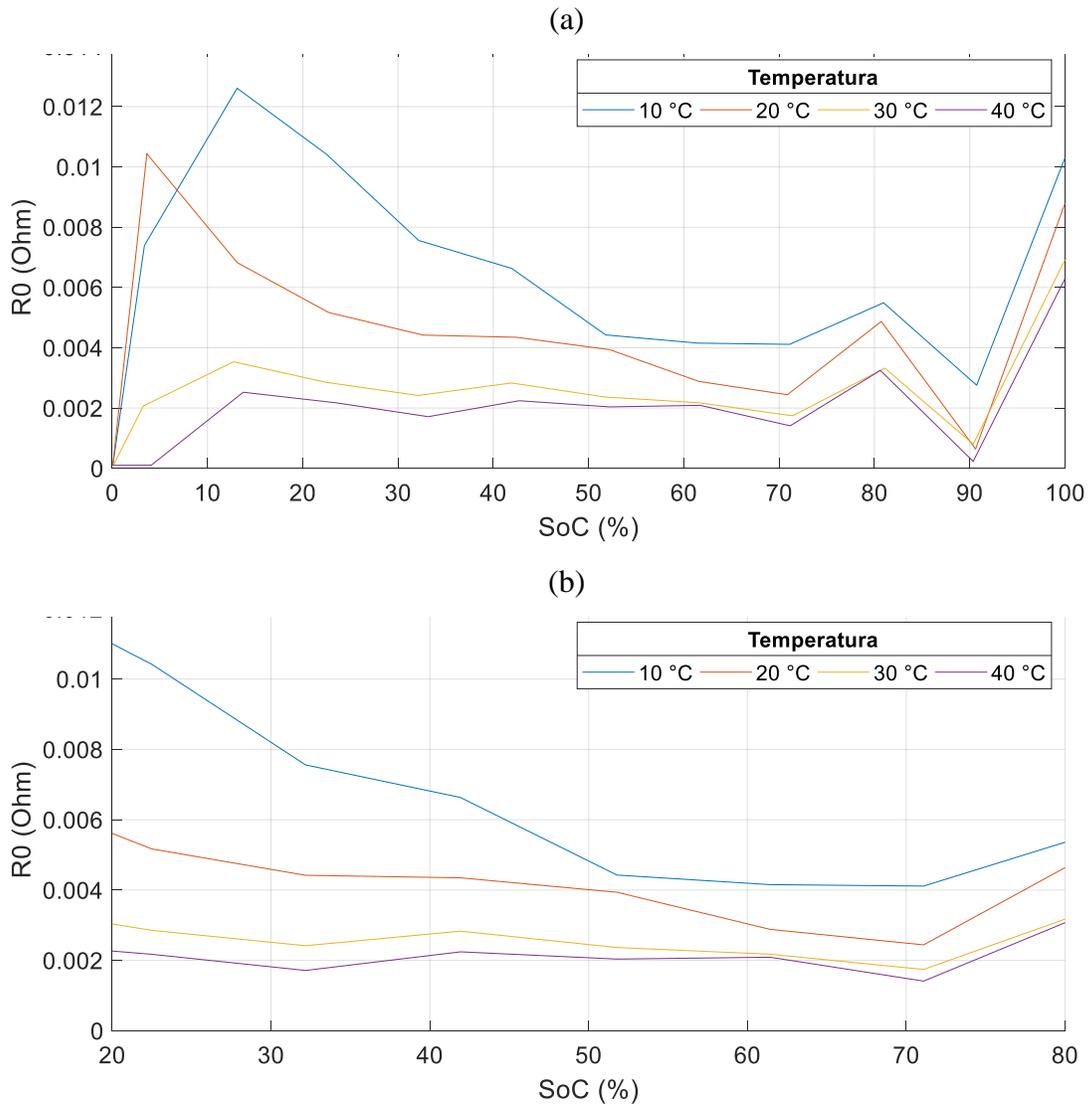
Figura 30 - Relação entre tensão de circuito aberto ( $V_{oc}$ ), SoC e temperatura.



Fonte: Autor (2020).

Na Figura 31, são apresentados dois gráficos correspondentes aos dados de resistência interna da bateria ( $R_0$ ), SoC e a temperatura. Na Figura 31a, nota-se um aumento significativo da resistência interna com a diminuição da temperatura, uma queda nos valores de resistência à medida que o SoC aumenta e um crescimento irregular nos extremos de operação. Uma visão aproximada da faixa de operação segura ( $20 \% \geq SoC \leq 80\%$ ), exibida na Figura 31b, demonstra com maiores detalhes o comportamento da resistência interna com base na temperatura e na variação do SoC, sendo o comportamento para altas temperaturas ( $30\text{ }^{\circ}\text{C}$  e  $40\text{ }^{\circ}\text{C}$ ) aproximadamente linear.

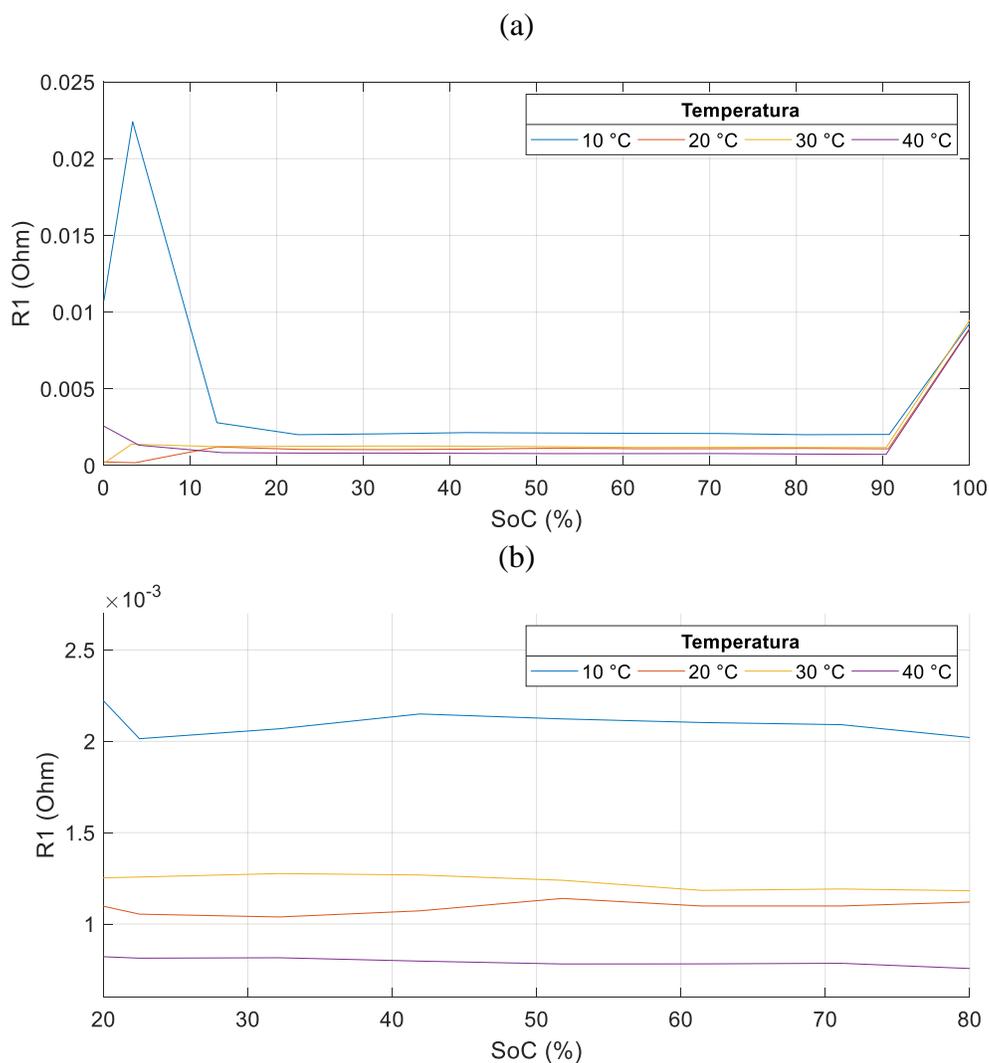
Figura 31 - Relação entre resistência interna ( $R_0$ ), SoC e temperatura.



Fonte: Autor (2020).

Na Figura 32, são apresentados dois gráficos correspondentes aos dados de resistência  $R_1$ , presente no primeiro par RC, o SoC e a temperatura. Na Figura 32a, observa-se que os valores de  $R_1$  são ligeiramente maiores em baixas temperaturas, praticamente não havendo variações com a mudança de SoC, e há valores de  $R_1$  significativamente divergentes nos extremos. Uma visão aproximada da faixa de operação segura ( $20\% \geq SoC \leq 80\%$ ), exibida na Figura 32b, demonstra com maiores detalhes o comportamento da resistência  $R_1$  com base na temperatura e na variação do SoC, sendo o comportamento de todas as curvas de temperatura aproximadamente linear.

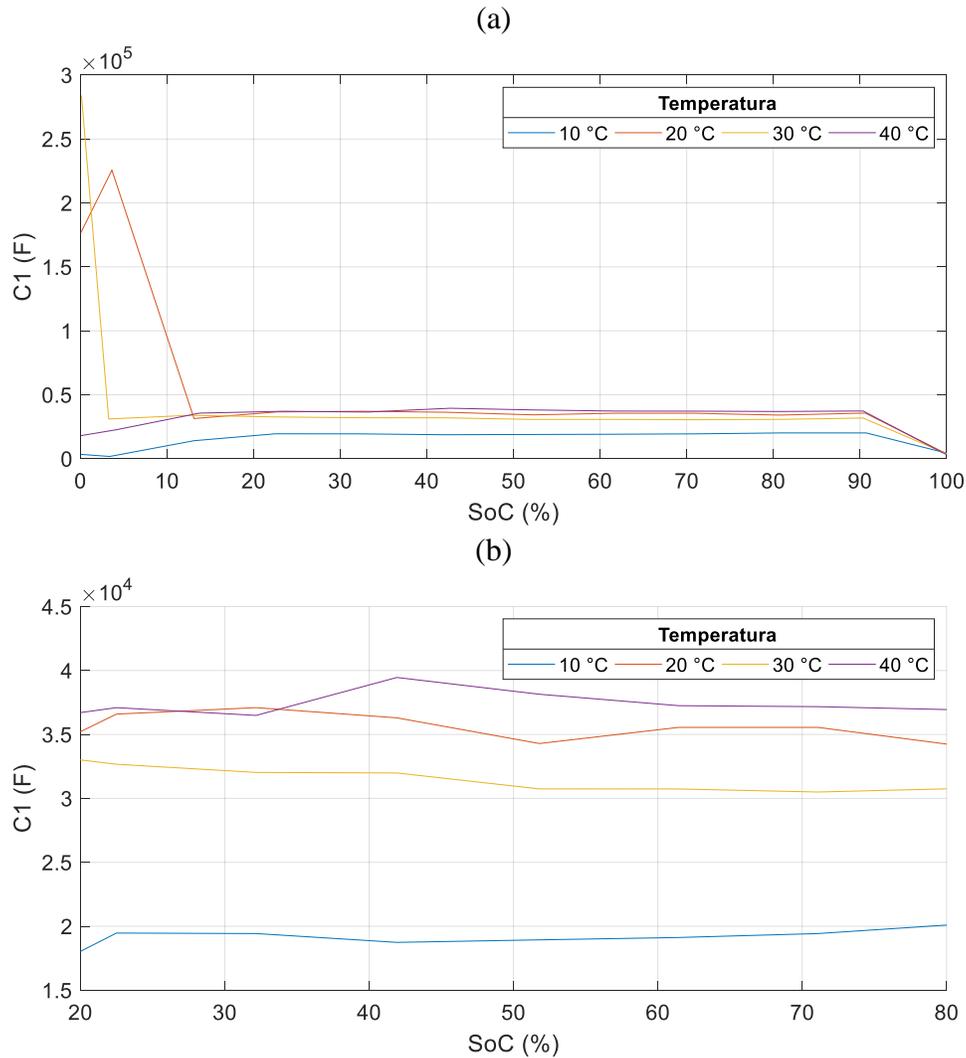
Figura 32 – Relação entre elementos entre  $R_1$ , SoC e temperatura.



Fonte: Autor (2020).

Essa estabilidade apresentada por  $R_1$  também é possível ser observada nos gráficos da Figura 33 nos quais são exibidos os dados relacionados à capacitância  $C_1$  presente no primeiro par RC, da temperatura e do SoC. Na Figura 33a, observa-se que quanto maior a temperatura, maior será a capacitância  $C_1$ . Uma visão aproximada da faixa de operação segura ( $20\% \geq SoC \leq 80\%$ ), exibida na Figura 33b, demonstra com maiores detalhes o comportamento de  $C_1$  com base na temperatura e na variação do SoC, sendo o comportamento de todas as curvas de temperatura aproximadamente linear novamente.

Figura 33 – Relação entre elementos entre  $C_1$ , SoC e temperatura.

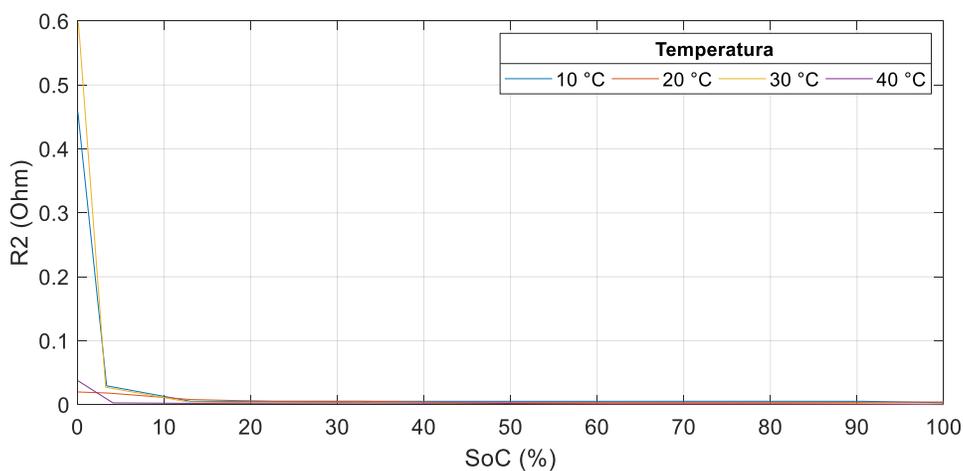


Fonte: Autor (2020).

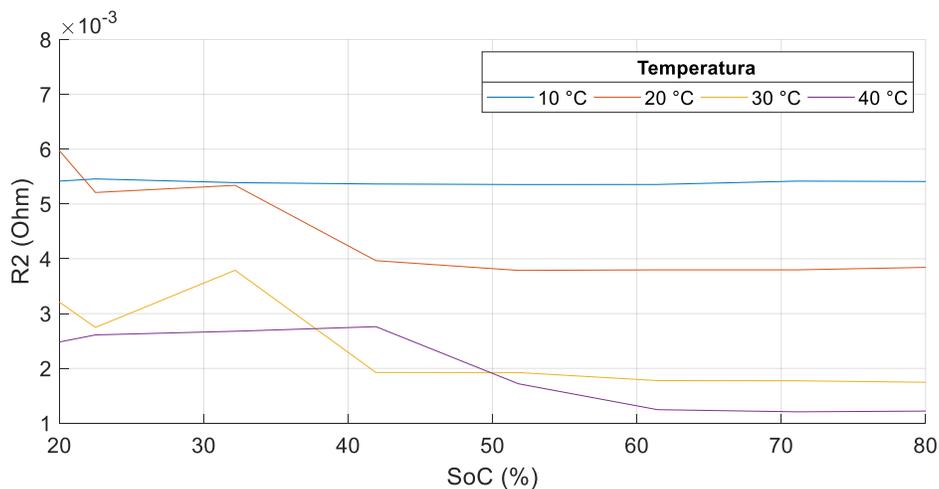
Na Figura 34, são exibidos dois gráficos correspondentes aos dados da resistência  $R_2$ , presente no segundo par RC, do SoC e da temperatura. Na Figura 34a, observa-se que os valores de  $R_2$  são extremamente maiores (atingem 0,6 Ohm) para  $SoC = 0\%$ , sendo, possivelmente, resultados afetados pelas transformações químicas internas da bateria. Uma visão aproximada da faixa de operação segura ( $20\% \geq SoC \leq 80\%$ ), exibida na Figura 34b, demonstra que quanto menor a temperatura, maior será o valor de  $R_2$ .

Figura 34 – Relação entre elementos entre  $R_2$ , SoC e temperatura.

(a)



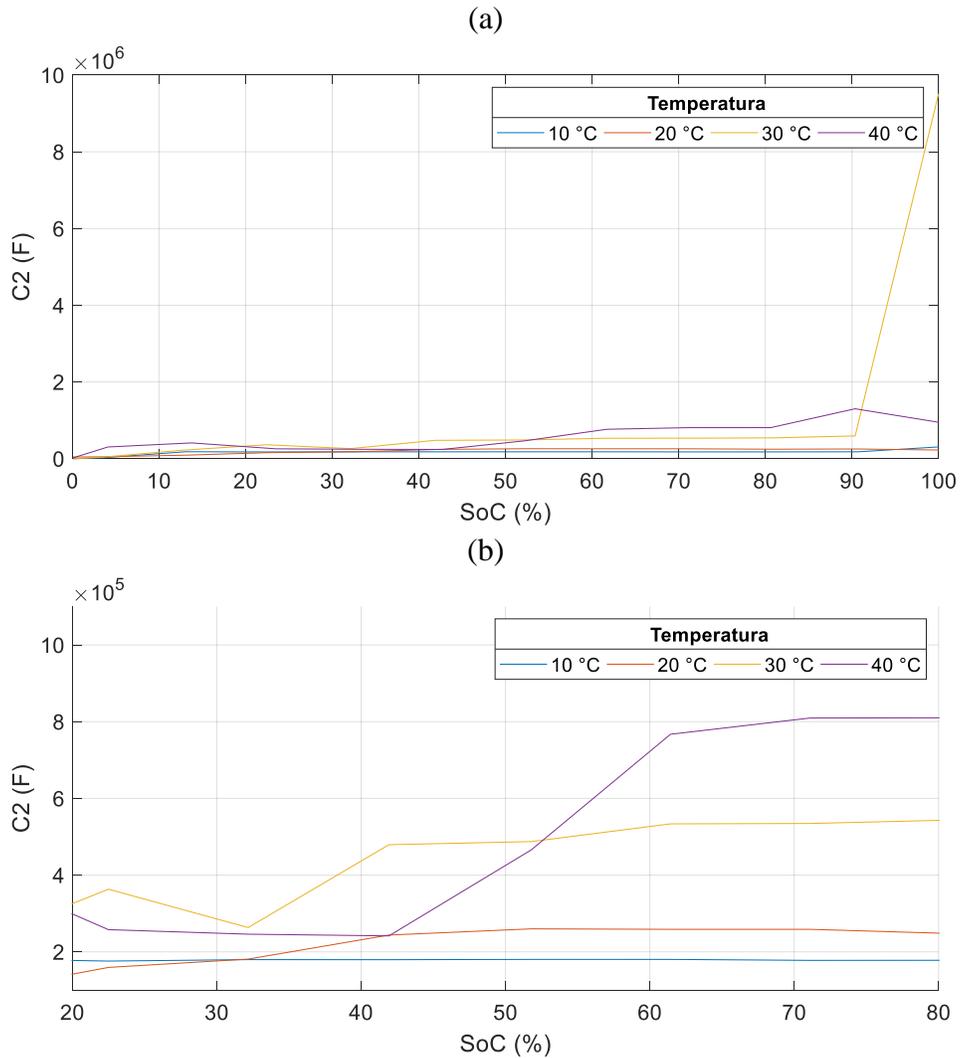
(b)



Fonte: Autor (2020).

Na Figura 35, são exibidos dois gráficos correspondentes aos dados da capacitância  $C_2$ , presente no segundo par RC, do SoC e da temperatura. Na Figura 35a, observa-se que os valores de  $C_2$  são maiores para  $SoC = 100\%$  (atingindo  $9 \times 10^6$  F para  $30\text{ °C}$ ), divergindo da estabilidade presente na faixa de operação segura ( $20\% \leq SoC \leq 80\%$ ), exibida na Figura 35b, que demonstra que quanto menor a temperatura, menor será o valor de  $C_2$ .

Figura 35 – Relação entre elementos entre  $C_2$ , SoC e temperatura.



Fonte: Autor (2020).

A partir da avaliação dos gráficos dos parâmetros do modelo relacionados ao nível de SoC e à temperatura, é possível observar discrepâncias recorrentes nos valores dos parâmetros próximos aos extremos de SoC, ou seja, fora da faixa segura de operação, comprovando o comportamento altamente não-linear da bateria e sua instabilidade, quando totalmente carregada ou totalmente descarregada, decorrente dos fatores químicos internos.

### 5.3. Estimação do SoC

Inicialmente, para verificar seu funcionamento, o algoritmo do UKF foi implementado no ambiente do *Matlab*® e utilizado na estimação do SoC de uma bateria de lítio-íon. Foram considerados como estados do sistema o SoC e as tensões sobre os ramos RC ( $V_1$  e  $V_2$ ). Em um primeiro cenário, sob temperatura de +10 °C, foram considerados os seguintes valores na etapa de inicialização:

- Para o vetor de estados  $x$  foi assumido  $x = [1; 0; 0]$ , considerando a bateria totalmente carregada ( $SoC = 100\%$ ) enquanto os demais estados são desconhecidos ( $V_1 = 0\text{ V}$  e  $V_2 = 0\text{ V}$ );
- Sabe-se que quanto maior a confiança na estimação inicial dos estados, menores podem ser os valores da diagonal da matriz de covariância do filtro. Assim, para a matriz de covariância  $P$  do filtro, foi considerada uma matriz identidade, assumindo a independência entre os estados do sistema e a incerteza elevada em suas situações iniciais;
- Os ruídos estatísticos ( $R$  e  $Q$ ) relacionados ao sistema foram considerados constantes quando aplicados ao filtro. Para a matriz de covariância do ruído de processo  $Q$ , foi assumido arbitrariamente o valor de  $10^{-5}$  para todos os estados, pois foi considerada uma variação pequena do valor de SoC. Já a covariância do ruído de medição  $R$  foi obtida com base no resultado da função  $std(y)$ , disponibilizada pelo *Matlab*®, sendo  $y$  o vetor com os dados de tensão de saída dos ensaios, resultando em  $R = 0,225$ ;
- Na sintonia do UKF, foram considerados os valores dos parâmetros  $\alpha = 0,0001$ ,  $\beta = 2$ ,  $\kappa = 0$ , definidos arbitrariamente dentro da faixa aceitável por cada um deles.

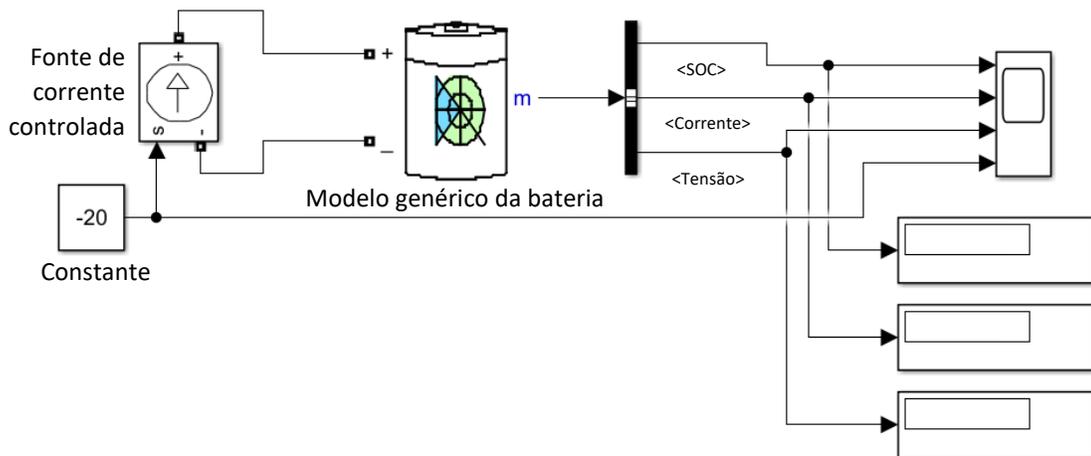
Em seguida, foram agregadas ao algoritmo as expressões representantes do comportamento de cada parâmetro presente no modelo elétrico da bateria ( $VOC$ ,  $R_0$ ,  $R_1$ ,  $R_2$ ,  $C_1$  e  $C_2$ ), ou seja, o conjunto de expressões referentes à temperatura de +10 °C. Assim, os valores dos parâmetros do modelo no instante atual são determinados em função do valor estimado de SoC obtido no instante anterior. Com os parâmetros atualizados, reinicia-se o ciclo de estimação (Predição e Atualização dos estados).

A influência da temperatura na estimação do SoC está diretamente associada à capacidade atual da bateria. Portanto, na expressão utilizada para calcular o SoC, proveniente do método de *Coulomb Counting*, é empregado o valor da capacidade disponível  $C_d$  da bateria obtida da expressão (77), gerando a expressão apresentada em (78). Logo, a estimação de SoC ocorre em função do seu estado anterior e da capacidade disponível/temperatura atual.

$$SoC[k + 1] = SoC[k] + \frac{\eta \Delta t}{19,1 \times e^{-0,0004657 \times T} - 2,105 \times e^{-0,08227 \times T}} I[k] \quad (78)$$

Para comparar os resultados da estimação usando o UKF, foi utilizado um sinal de referência gerado pelo bloco de simulação de bateria disponibilizado pelo *software Simulink®*, que utiliza somente o método *Coulomb Counting* para determinar o SoC. Esse bloco corresponde a um modelo genérico da bateria de lítio-íon e utiliza parâmetros extraídos da folha de dados (*datasheet*) para calcular o SoC e a tensão de saída do sistema sob efeito de uma corrente de entrada e da temperatura especificadas pelo usuário. Na Figura 36, é exibida o conjunto de blocos utilizado na simulação do SoC.

Figura 36 - Simulação da bateria de lítio-íon via *Simulink®*.

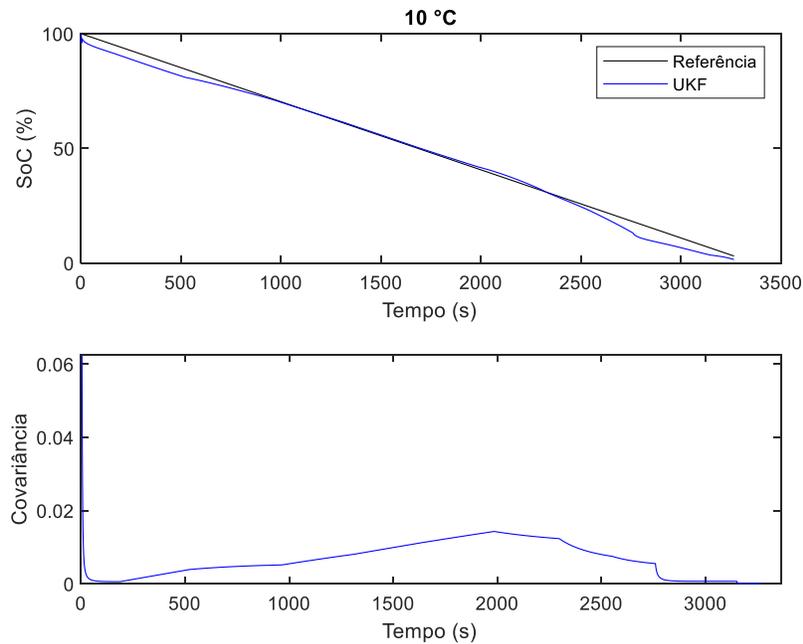


Fonte: Autor (2020).

Na Figura 37, é possível observar, no gráfico superior, a curva de SoC resultante da estimação feita pelo UKF para um ensaio à descarga contínua com corrente de aproximadamente 20 A sob temperatura de +10 °C. A curva estimada segue o comportamento da curva ideal

proveniente da simulação, se mantendo próxima durante toda a operação. Na mesma figura, no gráfico inferior, é apresentada a curva da covariância  $P$  referente ao SoC. Observa-se que ela decaiu no início de operação do filtro o que demonstra convergência do método empregado, se mantendo com valores menores do que 0,02 durante o restante da operação.

Figura 37 - Estimação do SoC via UKF sob temperatura de +10 °C com SoC inicial = 100 %.



Fonte: Autor (2020).

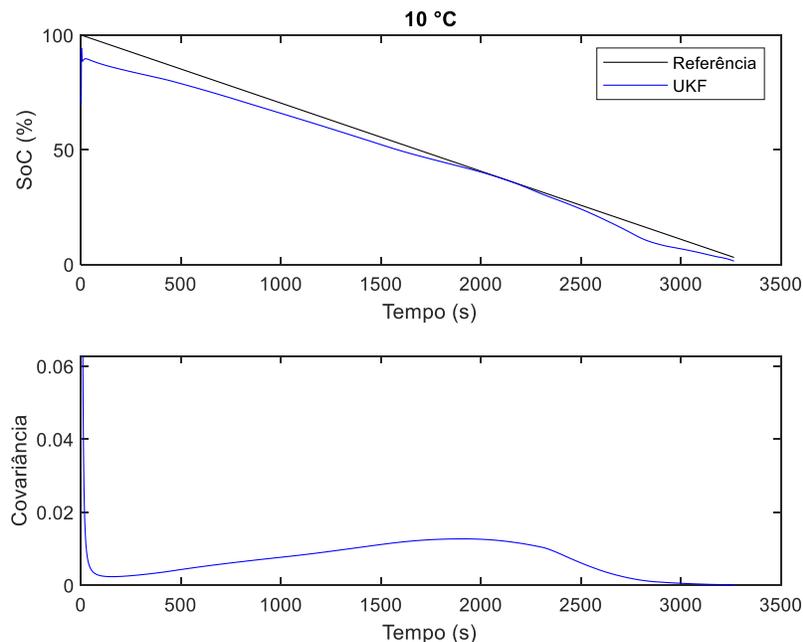
Em um segundo cenário, sob temperatura de +10 °C, foram considerados os seguintes valores na etapa de inicialização:

- Para o vetor de estados  $x$  foi assumido  $x = [0,7; 0; 0]$ , considerando a bateria com 70 % da carga total ( $SoC = 70\%$ ) enquanto os demais estados são desconhecidos ( $V_1 = 0\text{ V}$  e  $V_2 = 0\text{ V}$ );
- Novamente, para a matriz de covariância do filtro  $P$ , foi considerada uma matriz identidade, assumindo a independência entre os estados do sistema e a incerteza elevada em suas situações iniciais;

- Para a matriz de covariância do ruído de processo  $Q$ , foi assumido, novamente, o valor de  $10^{-5}$  para todos os estados, pois foi considerada uma variação pequena do valor de SoC. Já para a covariância do ruído de medição  $R$ , utilizou-se  $R = 0,225$ ;
- Na sintonia do UKF, foram considerados os valores dos parâmetros  $\alpha = 1$ ,  $\beta = 2$ ,  $\kappa = 0$ , definidos arbitrariamente dentro da faixa aceitável por cada um deles.

Na Figura 38, é possível observar, no gráfico superior, a curva de SoC resultante da estimação feita pelo UKF para um ensaio à descarga contínua com corrente de aproximadamente 20 A sob temperatura de +10 °C e SoC inicial de 70 %. Após uma rápida subida na tentativa de se aproximar do referencial nos primeiros segundos, a curva estimada segue o comportamento da curva ideal proveniente da simulação, se mantendo próxima durante toda a operação. Na mesma figura, no gráfico inferior, é apresentada a curva da covariância  $P$  referente ao SoC. Como no cenário anterior, observa-se que ela decaiu no início de operação do filtro o que demonstra convergência do método empregado, se mantendo com valores menores do que 0,02 durante o restante da operação.

Figura 38 - Estimação do SoC via UKF sob temperatura de +10 °C com SoC inicial = 70 %.



Fonte: Autor (2020).

## 5.4. Comparativo entre UKF e EKF

Assim como o UKF, o EKF foi implementado com base no algoritmo apresentado no Capítulo 2, resultando em um código de estimação de estados no ambiente do *Matlab*. Nele foram agregadas as expressões representativas do comportamento de cada parâmetro presente no modelo do sistema. Assim, na estimação dos estados feita pelos filtros, são considerados os impactos da temperatura sobre a bateria. Com o EKF, foram também considerados como estados do sistema o *SoC* e as tensões sobre os ramos RC ( $V_1$  e  $V_2$ ).

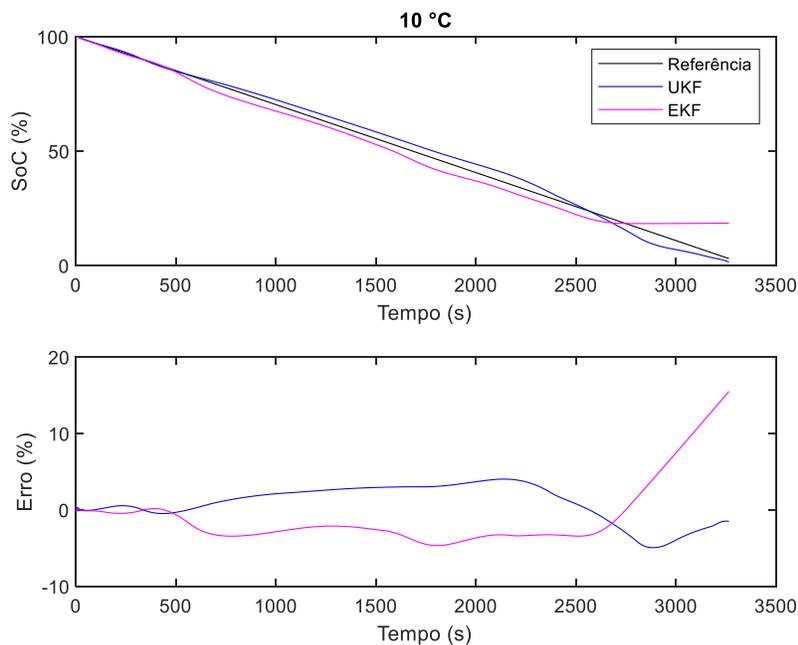
Em seguida, as curvas obtidas com o UKF foram comparadas com o EKF, visando analisar o comportamento de ambos os filtros sob novas configurações e sob diferentes temperaturas, identificando, conseqüentemente, o método com os melhores resultados baseado no esforço computacional empregado e na proximidade com os resultados de simulação. Novamente, o sinal de referência para ambos os filtros foi o *SoC* proveniente do modelo de bateria disponibilizado pelo *software Simulink®*.

Para todos os cenários, foram considerados os seguintes valores na etapa de inicialização:

- Para o vetor de estados  $x$  foi assumido  $x = [1; 0; 0]$ , considerando a bateria totalmente carregada ( $SoC = 100\%$ ) enquanto os demais estados são desconhecidos ( $V_1 = 0$  e  $V_2 = 0$ );
- Para a matriz diagonal de covariância  $P$ , foi considerado  $P_{SoC} = 0,001$  para a covariância referente ao *SoC*, indicando segurança no valor de inicialização do estado ( $P < 1$ ) enquanto para os demais estados, a covariância foi inicializada com  $P_{V_1} = 1$  e  $P_{V_2} = 1$ , indicando incerteza em suas inicializações;
- Para a matriz de covariância do ruído de processo  $Q$ , foi assumido, arbitrariamente, na diagonal o valor de  $10^{-5}$  para todos os estados. Já para a covariância do ruído de medição,  $R = 0,225$ .
- A sintonia do UKF contou com os valores dos parâmetros  $\alpha = 1$ ,  $\beta = 2$ ,  $\kappa = 0$ , definidos arbitrariamente dentro da faixa aceitável por cada um deles.

Na Figura 39, é possível observar que a variável SoC foi estimada pelos métodos EKF e UKF de maneira satisfatória sob temperatura de +10 °C, pois ambas as curvas de estimação ficaram próximas do SoC de referência com erro absoluto inferior a 8 % na maior parte do funcionamento dos filtros. Os resultados divergiram significativamente da referência somente ao final do processo de estimação, para valores de SoC abaixo de 20 %, indicando os impactos das transformações químicas fora da faixa segura de operação. Contudo, mesmo diante dessa situação, a divergência do UKF foi menor do que a apresentada pelo EKF.

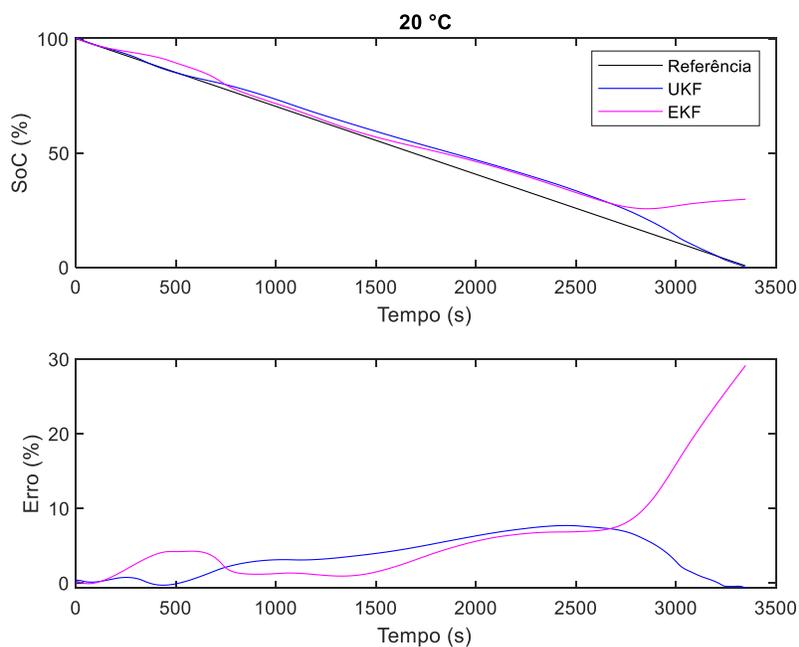
Figura 39 - Comparativo entre UKF e EKF à +10 °C.



Fonte: Autor (2020).

Na Figura 40, nota-se que ambos os métodos apresentaram um bom funcionamento à +20 °C, pois as curvas de estimação ficaram próximas do SoC de referência, com erro absoluto inferior a 10 %, durante a maior parte da operação dos filtros. Contudo, com o EKF foram obtidos resultados de estimação divergentes do sinal de referência ao final do processo, para valores de SoC em torno de 20 %, região na qual os valores dos parâmetros do modelo não são confiáveis por causa dos impactos químicos internos da bateria. Com o UKF, sob os mesmos ruídos, obteve-se uma estimação mais estável, próxima do referencial, corroborando em seu melhor desempenho.

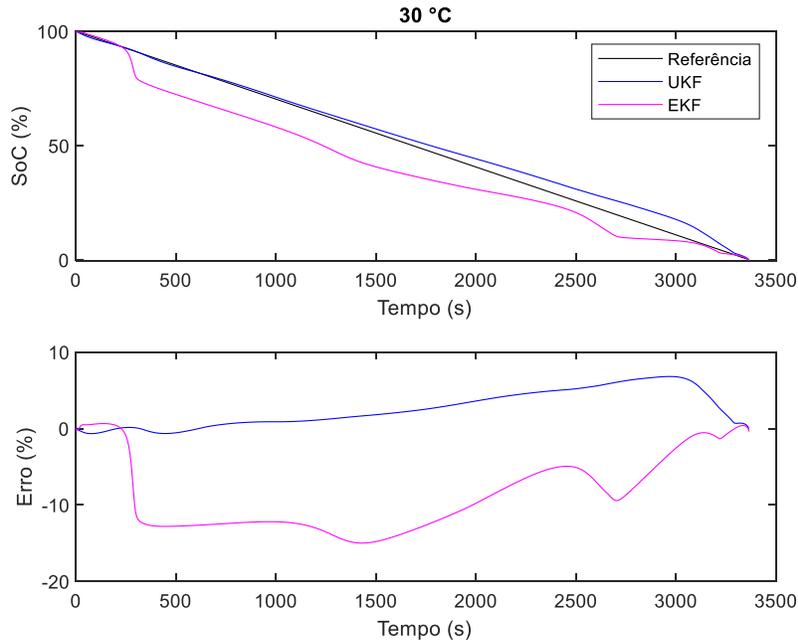
Figura 40 - Comparativo entre UKF e EKF à +20 °C.



Fonte: Autor (2020).

Como nos cenários anteriores, sob a temperatura de +30 °C, os resultados obtidos pelos métodos de Kalman em análise também foram próximos do SoC estimado pelo modelo de bateria do *Simulink*® como apresentado na Figura 41. Contudo, não houve divergências nos extremos, apenas uma aproximação maior do UKF com relação à referência enquanto o EKF manteve-se mais afastado e instável durante a operação da bateria.

Figura 41 - Comparativo entre UKF e EKF à +30 °C.



Fonte: Autor (2020).

Constata-se, portanto, que ambas as estimações se mantiveram próximas do SoC de referência. Porém, os resultados obtidos com o UKF foram ligeiramente melhores do que os obtidos com o EKF. Na Tabela 5, são apresentados os valores do erro médio absoluto (do inglês, *Mean Absolute Error* – MAE), gerado com base na expressão (79), e da raiz do erro quadrático médio (do inglês, *Root-Mean Square Error* – RMSE), obtido com base na expressão (80), calculados para verificar numericamente as acurácias do UKF e do EKF. Nelas,  $n$  corresponde ao total de amostras consideradas. É possível notar que, independentemente do valor de temperatura e do erro analisado, os erros relacionados ao UKF foram sempre menores que 5 % enquanto, para o EKF, observou-se um aumento do erro com o aumento da temperatura de ensaio.

$$MAE = \frac{1}{n} \sum_{i=1}^n |SoC_{referência} - SoC_{estimado}| \quad (79)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SoC_{referência} - SoC_{estimado})^2}{n}} \quad (80)$$

É importante destacar que os erros existentes também são provenientes da comparação entre dados simulados e dados experimentais. Os dados simulados, em certos casos, englobam parâmetros divergentes dos valores reais presentes na bateria, aumentando o erro inerente ao processo de estimação.

Tabela 5 - Comparação da precisão das estimações feitas pelos filtros sob diferentes temperaturas.

Temperatura	+10 °C		+20 °C		+30 °C	
Método	UKF	EKF	UKF	EKF	UKF	EKF
MAE (%)	2,1976	3,3252	3,6876	6,0870	2,6839	8,6692
RMSE (%)	2,5838	4,3939	4,5096	8,9450	3,4745	9,9312

## 6. Conclusões

Neste trabalho, foi construído um modelo para representar o comportamento dinâmico de um sistema de energia altamente não-linear. A partir do modelo desenvolvido, foram implementados algoritmos de filtros de Kalman usados na estimação de carga em baterias de lítio-íon. As etapas de tratamento dos dados utilizados, a determinação da complexidade do modelo elétrico, seguida pela estimação dos parâmetros dele e a implementação dos filtros foram realizados no ambiente do *Matlab/Simulink*®.

O modelo de circuito equivalente de segunda ordem proposto, associado à ferramenta de otimização disponibilizada pelo *software Matlab/Simulink*®, foi capaz de representar o comportamento da bateria de maneira satisfatória, não comprometendo o funcionamento do método de estimação usado. Os parâmetros do modelo foram obtidos em função do estado de carga e da temperatura ambiente.

O método de estimação foi implementado com base no algoritmo do filtro de Kalman *Unscented* (UKF). O UKF emprega equações recursivas na estimação de estados atuais com base nos valores obtidos no instante anterior e nos sinais de tensão e de corrente envolvidos no sistema. O SoC foi estimado satisfatoriamente pelo UKF em todos os cenários considerados neste trabalho (ensaios sob temperatura de 10 °C, 20 °C e 30 °C). Na análise de acuracidade do filtro, o UKF apresentou erro médio absoluto (MAE) de, no máximo, 3,69 % enquanto a raiz do erro quadrático médio foi de no máximo 4,51, ambos os casos para temperatura de 20 °C. Portanto, o UKF é uma excelente opção para estimação de estados em sistema altamente não-lineares.

Com este trabalho foi possível, também, identificar os impactos diretos da temperatura no desempenho da bateria. Essa influência externa sobre a composição interna do sistema afeta sua capacidade de armazenamento de energia, diminuindo-a à medida que a temperatura ambiente decai. Sendo assim, é importante considerar esses efeitos na modelagem da bateria e na aplicação de métodos de estimação de carga para obter resultados mais seguros e confiáveis.

# Referências

A123 Systems, LLC. (2014). *Battery Pack Design, Validation, and Assembly Guide using A123 Systems AMP20m1HD-A Nanophosphate® Cells*.

AUGER, F.; HILAIRET, M.; GUERRERO, J. M.; MONMASSON, E.; ORLOWSKA-KOWALSKA, T.; KATSURA, S.. Industrial Applications of the Kalman Filter: A Review. In: *IEEE Transactions on Industrial Electronics*, v. 60, n. 12, p. 5458 – 5471, 2013. ISSN 1557-9948. Disponível em: <<http://doi: 10.1109/TIE.2012.2236994>>.

BALAGOPAL, B.; CHOW, M.. The state of the art approaches to estimate the state of health (SOH) and state of function (SOF) of lithium Ion batteries. In: IEEE. *Industrial Informatics (INDIN), 2015 IEEE 13th International Conference on*. Cambridge, 2015. p. 1302 – 1307. Disponível em: <<http://doi: 10.1109/INDIN.2015.7281923>>.

BALASINGAM, B.; PATTIPATI, K.. Elements of a Robust Battery-Management System: From Fast Characterization to Universality and More. *IEEE Electrification Magazine*, v. 6, n. 3, p. 34 - 37, 2018. ISSN 2325-5889. Disponível em: <<http://doi: 10.1109/MELE.2018.2849918>>.

BOCCA, A.; MACII, A.; MACII, E.; PONCINO, M.. Composable Battery Model Templates Based on Manufacturers' Data. In *IEEE Design & Test*, vol. 35, n. 3, p. 66-72. 2018. Disponível em: <<http://doi: 10.1109/MDAT.2017.2755642>>.

BRONDANI, M. de F.. *Modelagem Matemática do Tempo de Vida de Baterias de Lítio Íon Polímero utilizando Algoritmos Genéticos*. Dissertação (Mestrado) – Universidade Regional do Noroeste do Estado do Rio Grande do Sul (Unijuí). Ijuí – RS, 2015.

CHEN, A.; SEN, P. K.. Advancement in battery technology: A state-of-the-art review. In: IEEE. *Industry Applications Society, 2016 IEEE Annual Meeting*. Portland, OR, 2016, p. 1 - 10. Disponível em: <<http://doi: 10.1109/IAS.2016.7731812>>.

CHEN, X.; XU, W.; FU, X.. An improved particle filter for target tracking withIRST system. In IEEE. *Fuzzy Systems and Knowledge Discovery, 2012 9th International Conference on*, p. 1618-1621. Sichuan, 2012. Disponível em: <<http://doi: 10.1109/FSKD.2012.6233867>>.

DA SILVA, L. M.; DA SILVA, E. J. A.; FERREIRA, L. M.; GONÇALVES, R. M.; DA SILVA, B. Q.. Estado da arte dos fundamentos e ideias da Lógica Fuzzy aplicada as Ciências e Tecnologia. *Revista Brasileira de Geomática*, v. 7, n. 3, p. 149-169. Curitiba, 2019. ISSN 2317-4285. Disponível em: <<http://doi: 10.3895/rbgeo.v7n3.9365>>.

EL DIN, M. S.; HUSSEIN A. A.; ABDEL-HAFEZ, M. F. Improved Battery SOC Estimation Accuracy Using a Modified UKF With an Adaptive Cell Model Under Real EV Operating Conditions. In IEEE. *Transportation Electrification, IEEE Transactions on*, v. 4, n. 2, p. 408-417. [S.l.], 2018. Disponível em: <<http://doi: 10.1109/TTE.2018.2802043>>.

GARCIA, R. V.; KUGA, H. K.; ZANARDI, M. C. F. P. S. Eficiência do Filtro de Kalman Unscented na estimação de atitude utilizando dados reais do satélite CBERS. In SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 16. (SBSR), 2013, Foz do Iguaçu. Anais. São José dos Campos: INPE, 2013. p. 2241-2249. DVD, Internet. ISBN 978-85-17-00066-9 (Internet), 978-85-17-00065-2 (DVD). IBI: <3ERPFQRTRW34M/3E7GLET>. Disponível em: <<http://urlib.net/rep/3ERPFQRTRW34M/3E7GLET>>.

GAZZARRI, J. Battery Modeling. MATLAB Central File Exchange. 2020. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/36019-battery-modeling>>.

GUO, H.; WANG, Z.; LI, Y.; WANG, D.; WANG, G.. State of charge and parameters estimation for Lithium-ion battery using dual adaptive unscented Kalman filter. In IEEE. *2017 29th Chinese Control And Decision Conference (CCDC)*, p. 4962-4966. Chongqing, 2017. Disponível em: <<http://doi: 10.1109/CCDC.2017.7979374>>.

HAASE, J.; ALJUHESHI, F.; NISHI, H.; PLOENNIGS, J.; TSANG, K. F.; ALJUHAISHI, N.; ALAHMAD, M.. Analysis of batteries in the built environment an overview on types and applications. In: IEEE. *Industrial Electronics Society, IECON 2017 - 43rd Annual Conference of the IEEE*. Beijing, 2017. p. 8113 - 8118. Disponível em: <<http://doi: 10.1109/IECON.2017.8217424>>.

HANNAN, M. A.; HOQUE, M. M.; HUSSAIN, A.; YUSOF, Y.; KER, P. J.. State-of-the-Art and Energy Management System of Lithium-Ion Batteries in Electric Vehicle Applications: Issues and Recommendations. *IEEE Access*, v. 6, p. 19362 - 19378, 2018. ISSN 2169-3536. Disponível em: <<https://doi: 10.1109/ACCESS.2018.2817655>>.

HE, W.; WILLIARD, N.; CHEN, C.; PECHT, M. State of charge estimation for electric vehicle batteries using unscented kalman filtering. In ELSEVIER. *Microelectronics Reliability*, v. 53, n. 6, p. 840-847. EUA, 2013. Disponível em: <<https://doi.org/10.1016/j.microrel.2012.11.010>>.

HU, X.; LI, S.; PENG, H.. A comparative study of equivalent circuit models for Li-ion batteries. *Journal of Power Sources*, v. 198, p. 359 – 367, 2012. ISSN 0378-7753. Disponível em: <<http://doi.org/10.1016/j.jpowsour.2011.10.013>>.

HUANG, C.; WANG, Z.; ZHAO, Z.; WANG, L.; LAI, C. S.; WANG, D. Robustness Evaluation of Extended and Unscented Kalman Filter for Battery State of Charge Estimation. In IEEE Access, v. 6, p. 27617-27628. [S.l.], 2018. Disponível em: <<http://doi: 10.1109/ACCESS.2018.2833858>>.

JACKEY, R.; SAGINAW, M.; SANGHVI, P.; GAZZARRI, J.; HURIA, T.; CERAOLO, M.. Battery Model Parameter Estimation Using a Layered Technique: An Example Using a Lithium Iron Phosphate Cell. *SAE World Congress*. (2013). Disponível em: <<https://www.mathworks.com/company/newsletters/articles/battery-model-parameter-estimation-using-a-layered-technique-an-example-using-a-lithium-iron-phosphate-cell.html>>

JOKIĆ, I.; ZEČEVIĆ, Ž.; KRSTAJIĆ, B.. State-of-charge estimation of lithium-ion batteries using extended Kalman filter and unscented Kalman filter. In IEEE. *Information Technology (IT), 2018 23rd International Scientific-Professional Conference on*. Zabljak, 2018. p. 1 – 4. Disponível em: <<http://doi: 10.1109/SPIT.2018.8350462>>.

JULIER, S. J.; UHLMANN, J. K. A New Extension of the Kalman Filter to Nonlinear Systems. *Proceedings of the 1997 SPIE AeroSense Symposium, SPIE*. Orlando – FL, 1997.

LIU, X. L.; CHENG, Z. M.; YI, F. Y.; QIU, T. Y.. SOC calculation method based on extended Kalman filter of power battery for electric vehicle. In: IEEE. *Intelligent Systems and Knowledge Engineering (ISKE), 2017 12th International Conference on*. Nanjing, 2017, p. 1 – 4. Disponível em: <<http://doi: 10.1109/ISKE.2017.8258840>>.

LIU, Y.. *Robust Nonlinear Control Design with Proportional-Integral-Observer Technique*. Tese (Doutorado) – University of Duisburg-Essen. Duisburg, 2011.

LIU, Y.; HE, Z.; GAO, M.; LI, Y.; LIU, G. Dual estimation of lithium-ion battery internal resistance and SOC based on the UKF. In IEEE. *Image and Signal Processing, 2012 5th*

*International Congress on*, p. 1639-1643. Chongqing, 2012. Disponível em: <<http://doi:10.1109/CISP.2012.6469649>>.

LOUKIL, J.; MASMOUDI, F.; DERBEL, N.. State of charge estimation of lead acid battery using a Kalman filter. In IEEE. *Systems, Signals & Devices (SSD), 2017 14th International Multi-Conference on*. p. 308-312. Marrakech, 2017. Disponível em: <<http://doi:10.1109/SSD.2017.8167026>>.

MATHWORKS (2020). Generate Parameter Data for Equivalent Circuit Battery Block. Último acesso em 15 de dezembro de 2020. Disponível em: <[https://www.mathworks.com/help/autoblks/ug/generate-parameter-data-for-estimations-circuit-battery-block.html?s\\_tid=srchtitle](https://www.mathworks.com/help/autoblks/ug/generate-parameter-data-for-estimations-circuit-battery-block.html?s_tid=srchtitle)>

MEDIOUNI, H.; EL HANI, S.; EL HAROURI, K.; MARTINS, J.; GONÇALVES, R. J.. Robustness Evaluation of Unscented Kalman Filter for State of Charge Estimation Based on Battery Capacity Degradation Model. In IEEE. *Industrial Electronics Society, IECON 2019 - 45th Annual Conference of the IEEE*, p. 4537-4542. Lisbon, Portugal, 2019. Disponível em: <<http://doi:10.1109/IECON.2019.8926868>>.

MISYRIS, G. S.; DOUKAS, D. I.; PAPADOPOULOS, T. A.; LABRIDIS, D. P.; AGELIDIS, V. G.. State-of-Charge Estimation for Li-Ion Batteries: A More Accurate Hybrid Approach. In IEEE. *Energy Conversion IEEE Transactions on*, v. 34, n. 1, p. 109-119, 2019. Disponível em: <<http://doi:10.1109/TEC.2018.2861994>>.

MOURA, J. J. P.. *Modelo para Estimação do Estado de Carga de Baterias de Lítio-Íon Baseado em Redes Neurais Auto Regressivas Não-Lineares Com Entradas Externas*. Dissertação (Mestrado) – Universidade Federal da Paraíba. João Pessoa, 2019.

PARTOVIBAKHSH, M.; LIU, G.. An Adaptive Unscented Kalman Filtering Approach for Online Estimation of Model Parameters and State-of-Charge of Lithium-Ion Batteries for Autonomous Mobile Robots. In IEEE *Transactions on Control Systems Technology*, v. 23, n. 1, p. 357-363, 2015. Disponível em: <<http://doi:10.1109/TCST.2014.2317781>>.

PENG, S.; CHEN, C.; SHI, H.; YAO, Z.. State of Charge Estimation of Battery Energy Storage Systems Based on Adaptive Unscented Kalman Filter With a Noise Statistics Estimator. In IEEE

Access, v. 5, p. 13202-13212. 2017. ISSN 2169-3536. Disponível em: <<http://doi:10.1109/ACCESS.2017.2725301>>.

PIAO, C.; SUN, Z.; LIANG, Z.; CHO, C.. SOC Estimation of Lead-Acid Batteries Based on UKF. In IEEE. *Electrical and Control Engineering, 2010 International Conference on*, p. 1968-1972. Wuhan, 2010. Disponível em: <<http://doi:10.1109/iCECE.2010.484>>.

PLETT, G. L.. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background. In ELSEVIER. *Journal of Power Sources*, v. 134, n. 2, p. 252 – 261, 2004. ISSN 0387-7753. Disponível em: <<https://doi.org/10.1016/j.jpowsour.2004.02.031>>.

PURWADI, A.; RIZQIAWAN, A.; KEVIN, A.; HERYANA, N.. State of Charge estimation method for lithium battery using combination of Coulomb Counting and Adaptive System with considering the effect of temperature. In: IEEE. *Power Engineering and Renewable Energy (ICPERE), 2014 The 2nd IEEE Conference on*. Bali, 2014. p. 91 – 95. Disponível em: <<http://doi:10.1109/ICPERE.2014.7067233>>.

QIN, X.; GAO, M.; HE, Z.; LIU, Y. State of Charge Estimation for Lithium-Ion Batteries Based on NARX Neural Network and UKF. In IEEE. *Industrial Informatics (INDIN), 2019 IEEE 17th International Conference on*, p. 1706-1711. Helsinki, Finland, 2019. Disponível em: <<http://doi:10.1109/INDIN41052.2019.8972319>>.

RAHIMI-EICHI, H.; Ojha, U.; BARONTI, F.; Chow, M.. Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles. In IEEE. *Industrial Electronics Magazine*, v. 7, n. 2, p. 4-16, 2013. Disponível em: <<http://doi:10.1109/MIE.2013.2250351>>.

SANTOS, R de M. S.. *Estimação do Estado de Carga de Baterias de Lítio-íon em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman*. Dissertação (Mestrado) – Universidade Federal da Paraíba (UFPB). João Pessoa – PB, 2019.

SANTOS, R de M. S.; ALVES, C. L. G. d. S.; MACEDO, E. C. T.; VILLANUEVA, J. M. M.; HARTMANN, L. V.; CATUNDA, S. Y. C.. Lead acid battery SoC estimation based on extended Kalman Filter method considering different temperature conditions. In IEEE. *2017 IEEE*

*International Instrumentation and Measurement Technology Conference (I2MTC)*, p. 1-6. Turin, 2017. Disponível em: <[doi: 10.1109/I2MTC.2017.7969966](https://doi.org/10.1109/I2MTC.2017.7969966)>.

SCARDUA, L. A.. *Sintonia-automática do filtro de Kalman Unscented*. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, 2015.

SUN, F.; HU, X.; ZOU, Y.; LI, S. Adaptive unscented Kalman filtering for state of charge estimation of a lithium-ion battery for electric vehicles. In ELSEVIER. *Energy*, v. 36, n. 5, p. 3531-3540. Beijing, 2011. Disponível em: <<https://doi.org/10.1016/j.energy.2011.03.059>>.

TIAN, Y.; XIA, B.; SUN, W.; XU, Z.; ZHENG, W. SOC estimation of LiNi<sub>1/3</sub>Co<sub>1/3</sub>Mn<sub>1/3</sub>O<sub>2</sub> battery using Unscented Kalman Filtering Method. In IEEE. *Industrial Electronics and Applications, 2014 9th IEEE Conference on*, p. 883-887. Hangzhou, 2014. Disponível em: <<http://doi: 10.1109/ICIEA.2014.6931287>>.

TOPAN, P. A.; RAMADAN, M. N.; FATHONI, G.; CAHYADI, A. I.; WAHYUNGGORO, O.. State of Charge (SOC) and State of Health (SOH) estimation on lithium polymer battery via Kalman filter. In IEEE. *2016 2nd International Conference on Science and Technology-Computer (ICST)*, p. 93-96. Yogyakarta, 2016. Disponível em: <<http://doi: 10.1109/ICSTC.2016.7877354>>.

WAN, E. A.; VAN DER MERWE, R.. The unscented Kalman filter for nonlinear estimation. In IEEE. *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No.00EX373)*, p. 153-158. Lake Louise, Alberta, Canada, 2000. Disponível em: <<http://doi: 10.1109/ASSPCC.2000.882463>>.

WU, X.; LI, X.; DU, J.. State of Charge Estimation of Lithium-Ion Batteries Over Wide Temperature Range Using Unscented Kalman Filter. In IEEE. *IEEE Access*, vol. 6, pp. 41993-42003, 2018. Disponível em: <<http://doi: 10.1109/ACCESS.2018.2860050>>.

XIAO, T.; SHI, X.; ZHOU, B.; WANG, X.. Comparative Study of EKF and UKF for SOC Estimation of Lithium-ion Batteries. In IEEE. *2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia)*, p. 1570-1575. Chengdu, China, 2019. Disponível em: <<http://doi: 10.1109/ISGT-Asia.2019.8880915>>.

XIONG, R.; CAO, J.; YU, Q.; HE, H.; SUN, F.. Critical Review on the Battery State of Charge Estimation Methods for Electric Vehicles. In *IEEE Access*, v. 6, p. 1832-1843, 2018. Disponível em: <<http://doi: 10.1109/ACCESS.2017.2780258>>.

ZHANG, F.; LIU, G.; FANG, L.. Battery state estimation using Unscented Kalman Filter. In *IEEE. Robotics and Automation, 2009 IEEE International Conference on*, p. 1863-1868. Kobe, 2009. Disponível em: <<http://doi: 10.1109/ROBOT.2009.5152745>>.

ZHANG, R.; XIA, B.; LI, B.; CAO, L.; LAI, Y.; ZHENG, W.; WANG, H.; WANG, W.. State of the Art of Lithium-Ion Battery SOC Estimation for Electrical Vehicles. In *Energies*, v. 11, article number 1820. 2018. Disponível em: <<https://doi.org/10.3390/en11071820>>.

ZHANG, X.; WU, J.; KANG, G. SOC estimation of Lithium battery by UKF algorithm based on dynamic parameter model. In *IEEE. Ubiquitous Robots and Ambient Intelligence (URAI), 2016 13th International Conference on*, p. 945-950. Xi'an, 2016. Disponível em: <<http://doi: 10.1109/URAI.2016.7734116>>.

ZHANG, Y.; ZHAO, Z.; LU, T.; YUAN, L.; XU, W.; ZHU, J.. A comparative study of Luenberger observer, sliding mode observer and extended Kalman filter for sensorless vector control of induction motor drives. In *IEEE. 2009 IEEE Energy Conversion Congress and Exposition*. p. 2466-2473. San Jose - CA, 2009. Disponível em: <<http://doi: 10.1109/ECCE.2009.5316508>>.

ZHAO, L.; XU, G.; LI, W.; TAIMOOR, Z.; SONG, Z.. LiFePO<sub>4</sub> battery pack capacity estimation for electric vehicles based on unscented Kalman filter. In *IEEE. Information and Automation (ICIA), 2013 IEEE International Conference on*, p. 301-305. Yinchuan, 2013. Disponível em: <<http://doi: 10.1109/ICInfA.2013.6720314>>.

ZINI, E. de O. C.. *Algoritmo Genético Especializado na Resolução de Problemas com Variáveis Contínuas e Altamente Restritos*. Dissertação (Mestrado) – Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2009. Disponível em: <<http://hdl.handle.net/11449/87116>>

ZUBI, G.; DUFO-LOPÉS, R.; CARVALHO, M.; PASAOGLU, G.. The lithium-ion battery: Tate of the art and future perspectives. *Renewable and Sustainable Energy Reviews*, v. 89, p. 292 - 308, 2018. ISSN 1364-0321. Disponível em: <<https://doi.org/10.1016/j.rser.2018.03.002>>.