

Rafael de Melo Silva Santos

Estimação do Estado de Carga de Baterias de Lítio-íon em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman

Brasil

22 de outubro de 2019

Rafael de Melo Silva Santos

Estimação do Estado de Carga de Baterias de Lítio-íon em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.

Universidade Federal da Paraíba – UFPB

Centro de Energias Alternativas e Renováveis – CEAR

Programa de Pós-Graduação em Engenharia Elétrica – PPGEE

Orientador: Dr. Euler Cássio Tavares de Macêdo

Coorientador: Dr. Juan Moises Mauricio Villanueva

Brasil

22 de outubro de 2019

Catálogo na publicação
Seção de Catalogação e Classificação

S237e Santos, Rafael de Melo Silva.

Estimação do Estado de Carga de Baterias de Lítio-íon em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman / Rafael de Melo Silva Santos. - João Pessoa, 2019.
98 f. : il.

Orientação: Euler Cássio Tavares de Macêdo, Juan Moises Mauricio Villanueva.
Dissertação (Mestrado) - UFPB/CEAR.

1. Bateria de Lítio, Processamento digital de sinais.
I. Macêdo, Euler Cássio Tavares de. II. Villanueva, Juan Moises Mauricio. III. Título.

UFPB/BC

Rafael de Melo Silva Santos


Estimação do Estado de Carga de Baterias de Lítio-íon, em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman

Dissertação de mestrado apresentado ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica.


Trabalho aprovado, Brasil, 30 de agosto de 2019 :




Dr. Euler Cássio Tavares de Macêdo
Orientador



Dr. Juan Moises Mauricio Villanueva
Coorientador



Dr. Valner João Brusamarello
Externo à Universidade



Dr. Lucas Vinicius Hartmann
Externo ao Programa

Brasil
30 de agosto de 2019

*Dedico este trabalho, ao meu filho Miguel, e a minha esposa Karol,
força motriz da minha constante ambição pelo conhecimento
e guia dos meus objetivos.*

Agradecimentos

Agradeço, primeiramente, a Deus, por ter me proporcionado tamanha força e fé para finalizar mais uma etapa em minha vida.

A minha amada esposa e filho, Ana Karoliny e Miguel, por terem me apoiado e me incentivado durante essa difícil etapa e nunca terem me deixado desistir.

Aos meus pais, Tião e Sandra, por ter me moldado o homem que sou, e por terem construído uma base sólida em meu caráter.

A minha irmã, Gabriella, e minha sobrinha, Ana Cecília, por terem tornado minha vida mais doce e leve em momentos turbulentos.

Por Claviano e Cleverson, mais que amigos, verdadeiros irmãos, por serem peças fundamentais na minha formação como pessoa.

Ao meu orientador, Prof. Dr. Euler Macêdo, pela contribuição técnica ao trabalho, e pela paciência durante todo o período de orientação.

Por fim, gostaria de agradecer a todos os meu amigos, Caio, Eduardo, José Igor, Isabelle e Rajiv por sempre me darem o suporte necessário durante o período em que estive longe da minha família.

*“Quando as raízes são profundas
não se deve temer o vento.”
Provérbio africano*

Resumo

Um dos desafios da humanidade no século XXI é reverter a degradação ambiental em andamento, sem deter o desenvolvimento humano. A isso se chamou, muito apropriadamente, de desenvolvimento sustentável. Para a obtenção do desenvolvimento sustentável, a inovação tecnológica tanto na geração quanto no uso eficiente de energia é imprescindível. O desenvolvimento de veículos elétricos é peça chave para esse desenvolvimento sustentável, e consequentemente o emprego de baterias, haja vista que são os elementos responsáveis por armazenar energia elétrica em forma de energia eletroquímica. Estimar o estado de carga de baterias é fundamental para se ter o conhecimento preciso da capacidade de fornecimento que a bateria possui no momento, além de possibilitar, por exemplo, a implementação de técnicas de gerenciamento do uso da energia e sistemas de proteção eficientes. Para isso foi implementada uma metodologia que permite a estimação de carga de baterias para diferentes condições de temperatura utilizando métodos matemáticos como o filtros de Kalman, em especial o filtro de Kalman estendido, a qual permite avaliar o comportamento do Estado de Carga para três valores de temperatura diferentes, 10 °C, 25 °C e 40 °C. Além disso, um método para identificação e determinação do modelo de circuito equivalente de uma bateria é proposto. A partir da metodologia desenvolvida, alguns resultados foram obtidos com a utilização de uma bateria Lítio (LiFePO₄) de 20 Ah de capacidade e tensão nominal de 3,3 V. A partir do método proposto para identificação do modelo de circuito equivalente adequado da bateria e da estimação dos parâmetros deste modelo, foi possível determinar um modelo com ramos RC, para a bateria de Lítio e assim, estimar os parâmetros deste modelo. Em seguida, o estado de carga de baterias para as temperaturas de 10 °C, 25 °C e 40 °C foi determinado. A partir de resultados numéricos, o Filtro de Kalman estendido implementado durante a pesquisa mostrou convergência na previsão do SoC, no qual o erro de covariância permaneceu entre 3 % e 6 %, mostrando assim a convergência do método proposto. Já o filtro de Kalman tradicional chegou a atingir um resíduo máximo de 83 %.

Palavras-chave: Bateria de Lítio, Processamento digital de sinais; Filtros de Kalman; Modelagem de baterias; Sistema de Gerenciamento de Baterias; Estimação de SoC de baterias.

Abstract

One of the challenges of humanity in the twenty-first century is to reverse environmental degradation in progress, without halting human development. This has been called, very appropriately, sustainable development. To achieve sustainable development, technological innovation in both the generation and efficient use of energy is imperative. The development of electric vehicles is a key part of this sustainable development, and consequently the use of batteries, given that they are the elements responsible for storing electrical energy in electrochemical form. Estimating the State of Charge (SoC) is fundamental for the dissemination of this type of transportation, among other current applications. In this context, a methodology was developed that allows the estimation of charge of batteries for different temperature conditions using Kalman filters, especially the extended Kalman filter, which allows to evaluate the behavior of SoC for a range of 10°C, 25°C and 40°C. In addition, a method for identifying the equivalent circuit model of a battery is proposed. Based on the methodology developed, some preliminary results were obtained with the use of a Stationary Lithium-ion (LiFePO₄) battery of 20 Ah capacity and nominal voltage of 3.3 V. From the proposed method to identify the appropriate equivalent circuit model of the battery and the parameters of this model, it was possible to determine a model with three RC branches for the Lithium-ion battery and to estimate the parameters of this model. Then the state of charge for temperatures of 10°C, 25°C and 40°C were determined. From numerical results, the extended Kalman Filter used in the research showed convergence in the prediction of the SoC, in which the covariance error is between 3 % and 6 %, showing the the proposed method convergence. Otherwise, the Kalman filter reached a maximum residual of 83 %.

Keywords: Lithium-ion Battery, Digital signal processing; Kalman filters; Battery modeling; BMS; Battery SoC estimation.

Lista de ilustrações

Figura 1 – Fenômeno de dupla camada: formação de camada de cargas positivas. .	23
Figura 2 – Fenômeno de dupla camada: formação de camada móvel de cargas negativas e positivas.	23
Figura 3 – Modelo de circuito equivalente com três ramos RC.	30
Figura 4 – Modelo Circuito Equivalente de uma Bateria Ideal.	37
Figura 5 – Modelo de Circuito Equivalente de uma Bateria com Resistência Interna. .	38
Figura 6 – Modelo Geral de Circuito Equivalente de uma Bateria.	38
Figura 7 – Modelo de circuito equivalente com um ramo RC.	39
Figura 8 – Modelo de circuito equivalente com dois ramos RC.	41
Figura 9 – Modelo de circuito equivalente com três ramos RC.	42
Figura 10 – Bateria de Chumbo Ácido 100Ah 2,2V.	44
Figura 11 – Bateria de Lítio 20Ah 3,3V.	45
Figura 12 – Sistema utilizado para realização dos procedimentos experimentais. . .	46
Figura 13 – Equipamento de aquisição de dados (<i>Datalogger</i>) utilizado nos ensaios. .	46
Figura 14 – Fonte de alimentação Kepco.	47
Figura 15 – Bateria de Lítio imersa no Banho térmico.	49
Figura 16 – Metodologia para realização dos testes em baterias.	50
Figura 17 – Disposição das etapas de modelagem da bateria.	52
Figura 18 – Ensaio de descarga pulsada.	53
Figura 19 – Processo de identificação dos pulso de corrente.	54
Figura 20 – Processo de identificação dos pulsos de corrente.	55
Figura 21 – Etapas para determinação do número de ramos RC em um modelo de circuito equivalente de uma bateria.	57
Figura 22 – Etapas para estimação dos parâmetros em um modelo de circuito equivalente de uma bateria.	58
Figura 23 – Modelo da bateria para simulação no Simulink.	67
Figura 24 – Modelo da bateria para simulação no Simulink.	67
Figura 25 – Resultados de simulação para descarga pulsada.	68
Figura 26 – Resultados experimentais para descarga pulsada.	68
Figura 27 – Identificação dos Pulsos para o Ensaio de 10° C - Simulação.	69
Figura 28 – Identificação dos Pulsos para o Ensaio de 10° C - Experimental.	69
Figura 29 – Modelo com 1 ramo RC para bateria de Chumbo-Ácido.	70
Figura 30 – Modelo com 2 ramos RC para bateria de Chumbo-Ácido.	70
Figura 31 – Resistências estimadas para a bateria de Chumbo-Ácido.	71
Figura 32 – Constantes de tempo estimadas para a bateria de Chumbo-Ácido. . . .	71

Figura 33 – Determinação do Número de Ramos RC que o Circuito Equivalente irá possuir - Simulação.	72
Figura 34 – Determinação do Número de Ramos RC que o Circuito Equivalente irá possuir - Experimental.	73
Figura 35 – Otimização da Curva de Descarga Gerada para os Dados de Simulação.	74
Figura 36 – Otimização da Curva de Descarga Gerada para os Dados Experimentais.	74
Figura 37 – Parâmetros Estimados Antes da Otimização - 10°C.	75
Figura 38 – Parâmetros Estimados Depois da Otimização - 10°C.	75
Figura 39 – Parâmetros Estimados Depois da Otimização - 25°C - Simulação.	76
Figura 40 – Parâmetros Estimados Depois da Otimização - 40°C - Simulação.	76
Figura 41 – Parâmetros Estimados Depois da Otimização - 10°C - Experimental.	77
Figura 42 – Parâmetros Estimados Depois da Otimização - 25°C - Experimental.	77
Figura 43 – Parâmetros Estimados Depois da Otimização - 40°C - Experimental.	78
Figura 44 – Modelo de Simulação OCV x SoC para 10 °C, 25 °C e 40 °C.	79
Figura 45 – Curvas da relação entre OCV e SoC para diversas temperaturas fornecidas pelo manual do fabricante. [Adaptada de (A123 Systems, 2014)]	80
Figura 46 – Modelo Experimental OCV x SoC para 10 °C, 25 °C e 40 °C.	81
Figura 47 – Estimação do SoC para bateria de Chumbo-Ácido.	83
Figura 48 – Gráfico das resistências do modelo de simulação.	84
Figura 49 – Gráfico das constantes de tempo do modelo de simulação.	86
Figura 50 – Gráfico das capacitâncias do modelo de simulação.	86
Figura 51 – Gráfico do SoC em função do tempo para temperatura de 10°C e modelo com parâmetros de simulação.	88
Figura 52 – Gráfico do SoC em função do tempo para temperatura de 25°C e modelo com parâmetros de simulação.	89
Figura 53 – Gráfico do SoC em função do tempo para temperatura de 40°C e modelo com parâmetros de simulação.	89
Figura 54 – Gráfico das resistências do modelo experimental.	90
Figura 55 – Gráfico das capacitâncias do modelo experimental.	91
Figura 56 – Gráfico das constantes de tempo do modelo experimental.	91
Figura 57 – Gráfico do SoC em função do tempo para temperatura de 10°C e modelo com parâmetros do modelo real.	92
Figura 58 – Gráfico do SoC em função do tempo para temperatura de 25°C e modelo com parâmetros do modelo real.	92
Figura 59 – Gráfico do SoC em função do tempo para temperatura de 40°C e modelo com parâmetros do modelo real.	93

Lista de tabelas

Tabela 1	–	Diferentes métodos para estimação do SoC	26
Tabela 2	–	Matriz de Decisão Pugh	34
Tabela 3	–	Especificações da bateria de íons de lítio.	45
Tabela 4	–	Modelos OCV-SoC.	59
Tabela 5	–	Dados para Ajuste de Curvas das Resistências	85
Tabela 6	–	Dados para Ajuste de Curvas das Capacitâncias	87

Lista de abreviaturas e siglas

ANATEL	Agência Nacional de Telecomunicações
BMS	<i>Battery Management System</i>
BoL	<i>Beginning of Life</i>
DoD	<i>Depth of Discharge</i>
EKF	<i>Extended Kalman Filter</i>
EoL	<i>End of Life</i>
GHKF	<i>Gauss-Hermite Kalman Filter</i>
INMETRO	Instituto Nacional de Metrologia, Normalização e Qualidade Industrial
IEC	<i>International Electrotechnical Commission</i>
KF	<i>Kalman Filter</i>
Li-ion	<i>Lithium Ion</i>
LiFePO ₄	<i>Lithium Iron Phosphate</i>
MCEB	Modelo de Circuito Equivalente da Bateria
OCV	<i>Open Circuit Voltage</i>
SoC	<i>State-of-Charge</i>
SoH	<i>State of Health</i>
UKF	<i>Unscented Kalman Filter</i>
XEV	<i>Hybrid Electric Vehicle, Extended Range Electric Vehicle</i>

Sumário

1	Introdução	14
1.1	Motivação	17
1.2	Escopo e Objetivos	17
1.3	Organização do Texto	18
2	Revisão Bibliográfica	19
2.1	Terminologias e Definições Relacionadas a Baterias	19
2.2	Fenômenos Internos à Bateria	22
2.2.1	Dinâmica dos Fenômenos	22
2.2.2	Efeitos de Transporte de Massa	22
2.2.3	Fenômeno de Dupla Camada	23
2.3	Métodos para Estimação do SoC	24
2.3.1	Método para Estimação de SoC Baseado em Integral da Corrente	27
2.3.2	Método para Estimação de SoC Baseado em Filtros de Kalman	28
2.3.3	Método para Estimação de SoC baseado em Filtros de Kalman Estendido	29
2.3.4	Matriz de Decisão Pugh para Escolha do Método de Estimação a ser Utilizado	33
2.4	Modelagem de Baterias	36
2.4.1	Introdução	36
2.4.2	Modelo RC de 1ª Ordem	39
2.4.3	Modelo RC de 2ª Ordem	40
2.4.4	Modelo RC de 3ª Ordem	42
3	Materiais e Métodos	44
3.1	Materiais	44
3.1.1	Baterias Utilizadas nos Experimentos	44
3.1.2	Sistema de Aquisição de Dados (Datalogger)	46
3.1.3	Fonte de Alimentação	47
3.1.4	Interface	47
3.1.5	Banho Térmico	48
3.2	Métodos	49
3.2.1	Determinação do Modelo de Circuito Equivalente e Estimação dos Parâmetros	51
3.2.2	Implementação do Modelo de Observação da Bateria OCV-SoC	58
3.2.3	Implementação do Método de Integral da Corrente	60
3.2.4	Implementação do Filtro de Kalman (KF)	60
3.2.5	Implementação do Filtro de Kalman Estendido (EKF)	61

4	Resultados	66
4.1	Determinação do Modelo de Circuito Equivalente e Estimação dos Parâmetros	66
4.1.1	Ensaio de Descarga Pulsada para Bateria de Chumbo-Ácido	66
4.1.2	Ensaio de Descarga Pulsada para Bateria de LiFePO ₄ - Modelo Simulado e Experimental	67
4.1.3	Identificação dos Pulsos de Descarga e Repouso Bateria de LiFePO ₄	68
4.1.4	Identificação do Número de Ramos RC para Bateria de Chumbo-Ácido	69
4.1.5	Estimação dos Parâmetros do Modelo para Bateria de Chumbo-Ácido	70
4.1.6	Identificação do Número de Ramos RC para Bateria de LiFePO ₄ - Modelo Simulado e Experimental	71
4.1.7	Otimização dos Parâmetros Estimados para Bateria de LiFePO ₄ - Modelo Simulado e Experimental	73
4.1.7.1	Modelo Simulado	74
4.1.7.2	Modelo Experimental	76
4.2	Determinação do Modelo de Observação OCV-SoC	78
4.2.1	Modelo Simulado	78
4.2.2	Modelo Experimental	80
4.3	Estimação do SoC e Comparação entre os Métodos	82
4.3.1	Resultados Obtidos para a Bateria de Chumbo-Ácido	82
4.3.2	Resultados Obtidos para a Bateria de LiFePO ₄	83
4.3.2.1	Referência Utilizada para Comparação	83
4.3.2.2	Parâmetros para o Modelo de Simulação	83
4.3.2.3	Estimação do SoC para o Modelo de Simulação	88
4.3.2.4	Parâmetros para o Modelo Experimental	89
4.3.2.5	Estimação do SoC para o Modelo Experimental	91
5	Considerações Finais	94
	Referências	95

1 Introdução

A bateria é um elemento que armazena energia elétrica na forma eletroquímica. Uma bateria não produz energia, somente armazena (Bastos, 2013). Além disso, uma bateria pode ser composta por duas ou mais células, e cada célula é composta por um terminal positivo (cátodo) e um terminal negativo (ânodo). O processo químico de troca de elétrons é conhecido como oxirredução.

A bateria é o sistema de armazenamento de energia elétrica mais conhecido e usado em vários dispositivos elétricos e eletrônicos (Rachid, 2014). É um sistema que emprega reações químicas internas para carregá-la ou descarregá-la. Várias tecnologias de baterias estão comercialmente disponíveis, mas as mais adotadas são: lítio-íon, chumbo-ácido e NiMH (*Nickel-Metal Hydride Battery*). As tecnologias têm características diferentes quanto à capacidade, tolerância à descarga profunda e perfil de carga necessário (Shafiei, 2016).

As condições críticas que podem causar problemas em uma bateria são a sobre descarga e a sobrecarga. A sobre descarga acontece quando a energia armazenada é excessivamente retirada da bateria, a tensão decresce para um nível muito baixo, e a bateria pode não mais ser carregada para a sua capacidade original, degradando a bateria e reduzindo sua vida útil (A. Purwadi, 2014).

As condições de sobrecarga são mais perigosas do que excesso de descarga, como uma energia excessiva é injetada na bateria, gás hidrogênio é produzido por eletrólise, o que pode levar a combustão, e em casos extremos, até explosões. A fim de proteger e prolongar a vida útil da bateria, níveis adequados de Estado de Carga (do inglês, *State of Charge - SoC*) não devem ser excedidos. Portanto, um sistema de gerenciamento de bateria (do inglês, *Battery Managment System - BMS*) é necessário (Rachid, 2014).

O BMS é o sistema responsável por evitar a sobrecarga e a sobre descarga de baterias, além de permitir uma recarga otimizada, fazendo com que cada célula que compõem a bateria possua sempre o mesmo valor, ou seja, o balanceamento das células. Para realizar esse tipo de avaliação, é necessário realizar a medição de grandezas diretas, tais como, tensão, corrente e temperatura das células, e realizar a estimação de grandezas indiretas, tais como, Estado de Carga, Estado de Saúde (do inglês, *State of Health - SoH*), e o Estado de Vida (*State of Life - SOL*) (Daowd, 2014). Dentre as três grandezas indiretas, a principal é o SoC, pois o mesmo também permite determinar o SoH (Rachid, 2014).

Estudos dos autores (A. Purwadi, 2014) e (Xing, 2014) demonstram que as baterias possuem uma variabilidade dinâmica, ou seja, seu comportamento depende de algumas variáveis externas, como condições ambientais. Devido à alta dependência a estes fatores ambientais, o SoC dificilmente pode ser estimado com alta precisão. Portanto, é de grande

importância analisar o comportamento dinâmico das baterias e estabelecer um modelo adequado da bateria.

Considerando a não-linearidade do modelo de bateria, na premissa de fácil implementação de hardware, os seguintes fatores devem ser considerados:

- O modelo deve refletir tanto quanto possível a tensão da bateria, a corrente e outras informações de estado;
- No ambiente estático e dinâmico de carga e descarga, o modelo da bateria deve refletir o SoC com precisão;
- O modelo da bateria deve ser simples, claro e fácil de ser processado no microprocessador escolhido para embarcar o software de um BMS, mantendo a exatidão de estimação dentro de parâmetros aceitáveis para o projeto.

Para obter o modelo adequado da bateria existem diversos métodos abordados na bibliografia, como os métodos descritos em (Birkel, 2013) que utiliza, (Dhruv Kapoor, 2014), (Aurilio, 2015), (L. C. Stevanatto, 2014), (Jackey, 2013). (Birkel, 2013) propõe um método para identificação dinâmica de modelos e estimação de parâmetros de células LiFePO₄ com base em medições de pulso de corrente e espectroscopia de impedância eletroquímica.

(Dhruv Kapoor, 2014) propõe um modelo com dois ramos compostos por elementos Resistivos e Capacitivos, e realiza a estimação dos parâmetros a partir do método de mínimos quadrados não-lineares. A técnica proposta por (Aurilio, 2015) é baseada em um algoritmo de estimativa que funciona no domínio da frequência. Em (L. C. Stevanatto, 2014), o método é dedicado a medidas de impedância sobre a faixa de frequência correspondente ao modelo Randles (L. C. Stevanatto, 2014) de primeira ordem.

No caso específico deste trabalho, o método proposto para identificação do modelo de circuito equivalente da bateria e estimação dos parâmetros deste modelo se baseia em (Jackey, 2013). De acordo com (Jackey, 2013), o modelo aproximado de uma bateria possui uma resistência interna e infinitos ramos RC em série que descrevem o comportamento dinâmico da bateria. Sendo assim, para determinar o número de ramos RC adequado para a bateria que se deseja trabalhar e estimar os parâmetros deste modelo, deve-se realizar testes de descarga-reposo ou de carga-reposo.

Em se tratando de estimação do estado de carga de uma bateria (SoC), existem diversos métodos que tentam estimar esta grandeza a partir de medições de tensão, corrente, temperatura, impedância, entre outras. Um dos métodos mais conhecidos e de simples implementação é o integral da corrente (*Coulomb Counting*), que utiliza a corrente consumida, ou fornecida, pela bateria, e, em seguida, realiza o somatório da corrente em função do tempo para determinar a capacidade atual da bateria.

Outro método bastante conhecido é o tensão de circuito aberto (OCV), este é geralmente encontrado em associação a outro método, tendo em vista que seu uso exige que a bateria esteja por um longo período em repouso para que o valor da capacidade seja coletado mais precisamente, dificultando seu uso para aplicações em tempo real. O método de Redes Neurais Artificiais (RNA) pode ser utilizando sem associação a outro métodos e aplicado a sistemas em tempo real, mas exigem uma grande quantidade de dados para treinar a rede em diversas condições de funcionamento, além de possuir uma maior complexidade de implementação que os métodos anteriores.

Com o modelo equivalente da bateria e os parâmetros estimados, pode-se implementar o método do Filtro de Kalman para estimar o SoC, seja ele o método tradicional ou estendido, para em seguida realizar a comparação e escolha do método matemático criado por Rudolf Kalman. Seu propósito é utilizar medições de grandezas realizadas ao longo do tempo (contaminadas com ruído e outras incertezas) e gerar resultados que tendam a se aproximar dos valores reais das grandezas que não podem ser medidas de forma direta. O Filtro de Kalman apresenta diversas aplicações e é uma parte essencial do desenvolvimento de tecnologias espaciais e militares.

O Filtro de Kalman pode ser escrito como uma única equação. Porém ele é comumente descrito em duas fases distintas: Previsão e Atualização. A fase de previsão usa a estimativa do estado no passo anterior para obter uma estimativa do estado no tempo atual. Esta previsão é chamada de estimativa *a priori*, pois não inclui a informação vinda da observação do estado atual. Na fase de atualização, a previsão *a priori* é combinada com a observação atual para refinar a estimativa do estado. A estimativa refinada é chamada de estimativa *a posteriori*.

Existem diversos tipos de Filtros de Kalman, o filtro de Kalman clássico que é utilizado em aplicações que envolvem sistema lineares. Para aplicações envolvendo sistemas não-lineares pode-se citar o filtro de Kalman estendido (EKF, do inglês *Extended Kalman Filter*), o filtro de Kalman que utiliza a transformada Unscented (UKF, do inglês *Unscented Kalman Filter*), o filtro de Kalman que utiliza a transformação de Gauss-Hermite (GHKF, do inglês *Gauss-Hermite Kalman Filter*).

Para a estimação do SoC de baterias é ideal que se utilize métodos aplicáveis à sistemas não lineares, tendo em vista que a bateria se comporta como um sistema não linear. Este comportamento não linear é claramente verificado no modelo de observação, ou função de observação, da bateria que é geralmente construído com base na relação quantitativa entre a tensão de circuito aberto da bateria (OCV, do inglês, *Open Circuit Voltage*) e o estado de carga da bateria (SoC). Outra evidência de que a bateria é um sistema não-linear é a forte influência que fatores externos exercem em parâmetros da bateria como a tensão e o SoC.

Sabendo que o SoC deve ser estimado com o menor erro possível, principalmente para

aplicações veiculares, pois isto garante a determinação correta do percurso total que o veículo elétrico é capaz de percorrer, além de permitir que o sistema de proteção atue de forma eficiente contra sobrecargas e sobre descargas, entre outras aplicações veiculares que exigem a estimação do SoC. Logo, este trabalho tem como motivação a modelagem da bateria e a implementação de um método para estimação do SoC com exatidão e que seja passível de implementação em um sistema embarcado para aplicações práticas, em especial, o desenvolvimento de sistemas de gerenciamento de baterias (BMS) que normalmente são importados e possuem alto valor agregado.

É importante também destacar que no início da pesquisa, uma bateria de chumbo-ácido foi utilizada para que a metodologia pudesse ser validada, e, em seguida, utilizada em uma bateria de LiFePO_4 . Com a bateria de chumbo, foi possível realizar os devidos ensaios para que o modelo elétrico equivalente e os seus respectivos parâmetros fossem determinados. As especificações desta bateria podem ser encontradas na seção 3 e alguns dos resultados obtidos até a qualificação analisados na seção 4.

1.1 Motivação

A motivação para esta pesquisa é impulsionada pela necessidade mundial em reduzir emissões e usar fontes de energia renováveis e sustentáveis. Além disso, a ânsia por contribuir com a pesquisa nacional no âmbito da eletrificação, bem como o desenvolvimento de tecnologia para veículos elétricos e híbridos, como, por exemplo, o sistema de gerenciamento de baterias (*BMS, Battery Management System*).

Nos veículos convencionais, a gasolina que permanece no tanque pode ser prontamente medida usando um sensor de nível de fluido. No entanto, nos veículos elétricos, não é fácil medir a quantidade de energia útil remanescente nas baterias, ou seja, o SoC. Isto é especificamente o caso quando a bateria está sujeita a transientes rápidos em termos de carga e descarga devido ao ciclo de condução. Como o SoC não pode ser medido, é necessário um modelo matemático preciso juntamente com uma técnica de estimativa robusta para realizar tal estimação (Bhatt, 2011).

1.2 Escopo e Objetivos

Neste trabalho pretende-se apresentar uma metodologia para modelagem de baterias de íons de LiFePO_4 e estimação do estado de carga (SoC, do inglês, *State of Charge*) para diferentes condições de temperatura utilizando Filtros de Kalman. Também será mencionado o uso de uma bateria de chumbo-ácido durante o início da pesquisa, tendo em vista a indisponibilidade da bateria de LiFePO_4 no momento citado. o uso da bateria de chumbo teve como objetivo o desenvolvimento da metodologia a ser utilizada posteriormente

na modelagem e estimação dos parâmetros da bateria de LiFePO_4 , e consequentemente, estimação do SoC. Os objetivos específicos deste trabalho podem ser elencados da seguinte forma:

- Determinar um modelo de circuito elétrico equivalente da bateria que forneça comportamento similar ao sistema real a partir de dados de medições;
- Estimar o SoC da bateria de íons de Lítio em diferentes condições de temperatura e a partir de diferentes tipos de métodos baseados em Filtro de Kalman;
- Avaliação dos métodos e escolha do que apresentar o melhor desempenho.

1.3 Organização do Texto

Este trabalho de dissertação é dividido em 5 capítulos, conforme sequência apresentada a seguir:

No Capítulo 1, a introdução sobre o tema, a motivação da dissertação e os objetivos são discutidos;

No Capítulo 2 é apresentada de forma resumida a fundamentação teórica necessária para o entendimento deste trabalho. Dentre os assuntos abordados, serão apresentados os conceitos sobre os métodos para estimação do estado de carga de baterias, além de uma abordagem mais aprofundada sobre os Filtros de Kalman. Ainda neste capítulo, um método para determinação do circuito elétrico equivalente e estimação dos parâmetros da bateria é proposto. Por fim, a implementação do Filtro de Kalman estendido é abordada;

O Capítulo 3 aborda os materiais utilizados para montagem da plataforma de teste, e são descritos os procedimentos para realização dos ensaios experimentais;

Já o Capítulo 4, são apresentados os principais resultados e análises realizadas na pesquisa;

Por fim, no Capítulo 5 reúnem-se as considerações finais deste trabalho, além da proposta das atividades de continuidade.

2 Revisão Bibliográfica

Para facilitar a compreensão dos conceitos relacionados ao estado de carga da bateria e dos métodos utilizados para estimá-lo, são apresentados neste capítulo os conceitos fundamentais e os procedimentos comumente empregados para a estimação do SoC.

2.1 Terminologias e Definições Relacionadas a Baterias

As terminologias relacionadas a bateria usadas para descrever os parâmetros, características e propriedades de uma bateria são as seguintes.

- Célula

A Célula é um dispositivo eletroquímico único que converte energia química em energia elétrica ([Globe, 2018](#)).

- Bateria

Uma bateria é um dispositivo eletroquímico, formado de diversas células, que transforma energia química em energia elétrica e vice-versa. Uma bateria armazena energia elétrica para o uso quando necessário. O processo de transformação é reversível, se a bateria pode ser carregada e descarregada por várias centenas de vezes ([Bosch, 2007](#)). Caso a bateria não possa ser carregada e descarregada várias vezes, esse processo é irreversível.

- Tensão de Célula (V_t)

A tensão da célula é o potencial padrão da célula que pode ser determinado pelo tipo de materiais ativos contidos na célula. Pode ser calculado a partir de dados de energia livre ou obtidos experimentalmente. ([Linden and Reddy, 2002](#)).

- Tensão Nominal

A tensão medida entre os terminais da bateria quando uma carga é aplicada. No caso das baterias de íons de lítio (para nosso caso LiFePO_4), a tensão (teórica) nominal de uma única célula é 3,3 volts ([A123 Systems, 2014](#)).

- Tensão de Circuito Aberto (OCV)

A tensão de circuito aberto (ou tensão fora de carga, tensão sem carga) é a tensão nos terminais da bateria sem carga. A OCV muda após o término dos processos de carga ou descarga devido à polarização e efeitos de difusão. Após um determinado tempo, quando a OCV atinge um valor estável, pode-se medir a chamada tensão

de circuito aberto de estado estável (Bosch, 2007), que por consequência pode nos fornecer o SoC.

- Capacidade Disponível

A capacidade é a quantidade de energia que pode ser armazenada. É normalmente expressa em ampère-hora cujo símbolo é Ah. Essa medida é obtida pela multiplicação da corrente em ampères pelo tempo em horas de descarga até uma tensão mínima a depender da composição da bateria. Porém, a capacidade não é um parâmetro fixo (Bosch, 2007). Ela depende dos seguintes fatores, entre outros:

- Nível da corrente de descarga;
- Densidade e temperatura do eletrólito;
- Processo de descarga em função do tempo (a capacidade é maior quando é feita uma pausa durante a descarga do que quando o processo de descarga estiver contínuo);
- Tempo de uso da bateria (devido à perda do material ativo das placas, a capacidade Ah diminui quando a bateria se aproxima do fim de sua vida útil);
- Se a bateria for movimentada durante o uso, ou se ela permanecer estacionária (quando ocorre a estratificação do eletrólito). A corrente de descarga desempenha um papel especialmente importante;
- Quanto maior a corrente de descarga, menor a capacidade disponível.

- Capacidade Nominal

A capacidade nominal é o total de ampères-horas que podem ser retiradas de uma bateria quando a mesma está sendo totalmente descarregada do estado de carga igual a 100% até sua tensão de corte nominal mínima em uma determinada corrente de descarga. A capacidade é calculada multiplicando a corrente de descarga (em ampères) pelo tempo de descarga (em horas) (Team, 2008).

- Autodescarga

Todas as baterias com ácido se auto descarregam, estejam elas usadas ou armazenadas. Mesmo que nenhum consumidor esteja ligado à bateria, as reações químicas continuam a ocorrer, como em um circuito elétrico interno fechado (Bosch, 2007). A auto descarga é causada por impurezas. A taxa de auto descarga depende principalmente de fatores como a temperatura, idade da bateria e umidade.

- Estado de Carga (SoC)

O estado de carga da bateria indica o percentual de energia acumulada (carga) que a bateria possui. O SoC pode ser medido a partir da gravidade específica do eletrólito,

ou pode ser estimado através de diversos métodos, como OCV, Filtros de Kalman, Integral da corrente, entre outros (Bosch, 2007).

- Estado de Vida (SoH)

O estado de vida (*State of Health* - SoH) indica uma condição na vida útil da bateria entre o início da vida (*Beginning of Life* - BoL) e fim da vida (*End of Life* - EoL) em porcentagem. O BoL de uma bateria é definido como o momento em que a vida útil da bateria começa. A EoL de uma bateria é atingida quando a bateria não pode fornecer energia de acordo com seus requisitos mínimos predefinidos (Farag, 2013).

- Profundidade de Descarga (DoD)

A Profundidade de Descarga (*Depth of Discharge* - DoD) é o método alternativo para indicar o SoC. O DOD é a porcentagem da capacidade da bateria que foi já descarregada. Em outras palavras, $DOD (\%) = 100 - SoC (\%)$ (Farag, 2013).

- Tensão de interrupção ou desligamento (*Cut-off Voltage*)

Corresponde a tensão mínima permitida de fornecer na qual a bateria pode ser considerada como totalmente descarregada (Farag, 2013).

- Taxa de Carga (C-Rate)

A taxa de carga da bateria, ou *C-Rate*, descreve a taxa na qual a bateria é carregada ou descarregada em relação à sua capacidade máxima. Uma taxa de 1C significa que a corrente de descarga aplicada descarregará uma bateria, totalmente carregada, em 1 hora. Para uma bateria com capacidade de 20 ampères-horas, isso equivale a uma corrente de descarga de 20 A. Uma taxa de 5C para esta bateria seria $20 \times 5 = 100$ A, e uma taxa $C / 2$ seria $20/2 = 10$ A (Farag, 2013).

- Ciclo de Vida

Este é o número de ciclos de carga/descarga que podem ser realizados antes que a bateria atinja o fim de vida (EoL) (Farag, 2013).

- Lookup Table (LUT)

Uma LUT é uma matriz que é aplicada em um conjunto de valores para transformá-los. Essa matriz pode ser um conjunto de fórmulas ou um conjunto de números predeterminados (Wolfcrow, 2013). Ou seja, é uma tabela de equivalência usada para interpolação de valores a partir de tabelas de coordenadas ou pontos conhecidos.

Em se tratando desta pesquisa, a LUT é usada para determinar o OCV a partir do SoC e a Temperatura, além de também determinar os valores dos parâmetros do modelo da bateria a partir do SoC e da temperatura.

2.2 Fenômenos Internos à Bateria

Esta seção é dedicada a introduzir um conjunto de fenômenos químicos relacionados as baterias que serão úteis no entendimento do modelo de circuito equivalente. A primeira parte é relacionada a parâmetros internos e externos que podem influenciar na dinâmica da bateria, e a segunda parte foca em descrever os diferentes fenômenos.

2.2.1 Dinâmica dos Fenômenos

Existem vários parâmetros internos e externos que podem influenciar a dinâmica da bateria no decorrer do tempo. Dentre os parâmetros internos podemos citar: estado de carga, estado de saúde, estado de funcionamento, resistência (CC e CA), parâmetros de projeto da bateria. Já em relação aos parâmetros externos, temos: Temperatura, Corrente CC e perfil de utilização a curto e longo termo ([Magalhães, 2012](#)).

2.2.2 Efeitos de Transporte de Massa

Dentro das baterias, o transporte de íons é feito por difusão e por migração. A difusão é causada pelo gradiente na concentração, enquanto a migração é causada pelas forças do campo elétrico. Ambas as forças podem ter direções diferentes. A migração é frequentemente prejudicada por moléculas imersas no solvente que cobrem o íon. Na maioria dos casos, a difusão é amplamente responsável pelo transporte de massa ([Magalhães, 2012](#)). A difusão pode ser encontrada em diferentes locais dentro da célula de bateria:

- No eletrólito livre ou no separador: como os íons são produzidos em um eletrodo e são consumidos no outro eletrodo, os íons têm que se mover entre os eletrodos;
- Dentro do eletrodo poroso como a reação eletroquímica pode ocorrer em qualquer lugar (parte interna ou externa do eletrodo poroso) na superfície da massa ativa: como a difusão dentro do eletrodo poroso é limitada pela geometria, ele desempenha um papel importante na dinâmica comportamento das baterias;
- Os produtos da reação podem se mover dentro da massa ativa até sua localização final por difusão;
- No caso de baterias de íons de lítio, existe um filme, a interface eletrolítica sólida (SEI), na superfície do ânodo. A difusão de íons de lítio através da SEI tem uma influência significativa sobre o comportamento elétrico das baterias de íons de lítio. Para células envelhecidas, em particular, o SEI é alterado, resultando em uma característica dinâmica alterada.

2.2.3 Fenômeno de Dupla Camada

Quando um eletrodo está imerso no eletrólito, ele é coberto por uma camada de cargas positivas, que por sua vez, atrai cargas negativas. Estas cargas negativas formam uma segunda camada móvel que é segura pela atração eletrostática. As duas camadas são denominadas de dupla camada elétrica e assumem o comportamento de um capacitor eletrolítico (Magalhães, 2012). Na Figura 1 correspondente a representação gráfica do efeito de dupla camada em um eletrodo.

O comportamento de um capacitor é visível ao se analisar a Figura 2, na qual a camada fixa absorvida pelo eletrodo e a camada móvel difusa representam por exemplo, as placas de alumínio de um capacitor eletrolítico. Este fenômeno é evidenciado por um circuito equivalente constituído por ramos RC em série (Magalhães, 2012). A queda de tensão provocada pela transferência de carga é modelada pela resistência e o fenômeno de dupla camada pelo elemento capacitor.




Figura 1 – Fenômeno de dupla camada: formação de camada de cargas positivas.




Figura 2 – Fenômeno de dupla camada: formação de camada móvel de cargas negativas e positivas.

2.3 Métodos para Estimação do SoC

O SoC de uma bateria é definido como a capacidade restante da bateria em comparação com a capacidade nominal da bateria (Pattipati, 2011). Diferentemente de veículos movidos a motores a combustão interna, nos quais a quantidade de combustível pode ser medida por um sensor, o SoC de uma bateria não pode ser medido diretamente. Por isso, necessita de uma técnica para realizar tal estimação.

Uma boa estimação do SoC possibilita diversas vantagens para a bateria, como por exemplo, o aumento da vida útil, melhor desempenho e alerta de falhas do conjunto de baterias. A capacidade residual da bateria pode ser determinada a partir da medição da densidade dos seus componentes químicos, no entanto, isto não é uma solução prática. Muitos métodos têm sido propostos baseados na medição da tensão e da corrente da bateria, mas muitos destes métodos não consideram o efeito da temperatura na determinação do SoC (Ayman, 2007).

Tensão, corrente e temperatura são dados da bateria que podem ser diretamente medidos utilizando algum instrumento de medição. Sendo assim, o SoC, que é uma grandeza estimada, ou seja, medida indiretamente, faz uso de medições diretas para sua estimativa, e deve ser estimado com relativa exatidão, especialmente para aplicações em veículos elétricos, nas quais o SoC é utilizado para contabilizar a autonomia restante que o veículo ainda pode percorrer. Existem diversos métodos para estimação do SoC, mas a maioria destes métodos ou possui resíduo de estimação relativamente alto (Acima de 10% para sistemas não lineares como a bateria), ou é muito complexo para implementação, particularmente em sistemas embarcados.

Alguns dos métodos de estimação de SoC descritos na bibliografia são apresentados na Tabela 1 (Ayman, 2007).

Esta tabela elenca diversos métodos utilizados para realizar a estimativa do estado de carga de uma bateria, cada um com sua particularidade no campo de aplicação. Considerando-se o objetivo desta pesquisa, é possível ver que o teste de descarga pode ser descartado para esse tipo de aplicação, pois só é utilizado para determinar a capacidade no início da vida. O método de integral da corrente pode ser utilizado para todos os tipos de baterias pois só se baseia no acúmulo da corrente, mas possui algumas limitações quando aplicado a sistemas que necessitam da estimação do SoC de forma contínua, como a sensibilidade à parâmetros externos e a necessidade de regulares recalibrações.

O método de tensão de circuito aberto necessita de grandes períodos de descanso da bateria, impossibilitando seu uso em sistemas em tempo real. Já o método de espectroscopia de impedância é bastante sensível a temperatura, o que impossibilita o uso em ambientes em que a temperatura não pode ser precisamente controlada. O método de medição da resistência interna é comumente utilizado para estimação SoH. Já os métodos de redes

neurais artificiais e lógica fuzzy podem ser utilizados comumente em sistemas em tempo real por serem métodos que consideram características do comportamento dinâmica da bateria, mas para que o RNA possa ter uma boa estimativa, a rede exige uma grande quantidade de ensaios de treinamento, ficando muito dependente de ensaios experimentais e de um sistema de medição preciso. Já a lógica fuzzy depende da geração de regras bem definidas para se ter uma boa exatidão.

A aplicação de técnicas para estimação de estados e parâmetros, bem como Filtros de Kalman e observadores de estado, são algumas das estratégias mais comuns para estimação do SoC (Chang, 2013). O Filtro de Kalman é uma das estratégias mais adotadas para estimação de estados e parâmetros desde que o sistema seja linear e tendo distribuição normal com média zero. Se o sistema é não-linear ou possui distribuição não normal, o Filtro de Kalman pode sofrer com problemas de convergência. Para este tipo de sistema não-linear existem outras derivações do Filtro de Kalman que podem proporcionar uma boa estimação, tais como o Filtro de Kalman Estendido (EKF - *Extended Kalman Filter*), ou o UKF (*Unscented Kalman Filter*, sem tradução para o português).

Neste trabalho foram utilizados o Filtro de Kalman tradicional, o Filtro de Kalman Estendido (EKF) e o Coulomb Counting para estimação do SoC e comparação entre os métodos. O método de Coulomb Counting baseia-se na medição da corrente da bateria e sua integração em relação ao tempo para obtenção da capacidade da bateria. A seguir apresenta-se algumas características dos métodos utilizados neste trabalho.

Tabela 1 – Diferentes métodos para estimação do SoC

Método	Área de aplicação	Vantagens	Desvantagens
Teste de descarga	Usada para determinação da capacidade no início da vida	Fácil e precisa; Independente do SoH.	Offline, modifica o estado da bateria, perda de energia.
Integral da corrente (Coulomb Counting)	Todos os tipos de baterias, diversas aplicações	Preciso se um número suficiente de recalibrações forem feitas e com boas medições de corrente.	Sensível a reações parasitas, necessita de pontos de recalibração regulares.
OCV (Open Circuit Voltage)	Chumbo,Lítio, Zn/Br	Online, barato, previsão do OCV.	Necessita de longos períodos de descanso. (Corrente = 0)
EMF	Chumbo, Lítio	Online, barato, previsão do EMF.	Necessita de longos períodos de descanso. (Corrente = 0)
Modelo Linear	Chumbo, aplicações fotovoltaicas	Online, fácil.	Necessita de dados de referência para ajustar os dados.
Espectroscopia de impedância	Todos os sistemas	Proporciona informações sobre o SoH e qualidade de energia.	Sensível a temperatura, custo elevado.
Resistência interna	Chumbo, Ni/Cd	Proporciona informações sobre o SoH, possibilidade de medições online.	Preciso, mas apenas para curto períodos de tempo.
Redes neurais artificiais	Todos os sistemas de baterias	Online	Precisa de dados de uma bateria similar para treinamento da rede.
Lógica fuzzy	Todos os sistemas de baterias	Online	Custo computacional elevado em aplicações no mundo real.
Filtros de Kalman	Todos os sistemas de baterias, Sistemas fotovoltaicos, aplicações dinâmicas.	Online, dinâmico	Dificuldade em implementar o algoritmo que considere todas as características do sistema real.

2.3.1 Método para Estimação de SoC Baseado em Integral da Corrente

O método de estimação do SoC baseado em integral da corrente, ou como é mais conhecido, *Coulomb Counting*, é o método mais comum e direto para estimar o SoC da bateria. Muitos sistemas de gerenciamento de baterias calculam o SoC com este método básico baseado na integral da corrente ou suas variações (tao et al., 2006), (Pei F, 2006), (Kong Soon Ng, 2009). Nestas abordagens, a saída e a entrada atuais da bateria são calculadas periodicamente, e o SoC da bateria é estimado subtraindo ou adicionando a carga líquida cumulativa.

Seja C_N a capacidade nominal de uma bateria, SoC_{t_0} seja o SoC no tempo inicial t_0 , η seja a eficiência de Coulomb, $I(t)$ a corrente que é positiva na descarga e negativa na carga, com a corrente medida, o SoC obtido com o método integral da corrente pode ser representado por,

$$SoC(t) = SoC(t_0) - \frac{1}{C_N} \int_{t_0}^t \eta I(t) dt \quad (2.1)$$

Normalmente, o SoC inicial, SoC_{t_0} , pode ser estimado pela abordagem baseada em tensão de circuito aberto ou pela abordagem baseada no filtro de Kalman estendido (Li Zhao and Chen, 2016). A capacidade nominal, C_N , pode ser obtida no fabricante da bateria ou ser medida em laboratório. A eficiência de Coulomb, η , é a relação entre a carga total extraída da bateria e a carga total colocada na bateria durante um ciclo completo. De fato, o valor de η continua mudando em todo o processo de descarga ou carregamento, a depender do valor da corrente e temperatura nas quais a bateria está submetida. Substituir o valor real de η por um valor médio ou estimado não é uma forma viável para estimar o SoC. A corrente de carga ou descarga, a temperatura, o SoC, o estado de saúde (SoH), as características da própria bateria e muitos outros fatores impõem suas influências na eficiência do processo de *Coulomb Counting* (Li Zhao and Chen, 2016). De fato, SoH é uma métrica que indica a condição da bateria relacionada a uma bateria nova.

Seja I_d a corrente de descarga, I_c a corrente de carga, t_d o tempo de descarga e t_c o tempo de carga, a eficiência de Coulomb da bateria testada, η , pode ser representada por,

$$\eta = \frac{\int_0^{t_d} I_d dt}{\int_0^{t_c} I_c dt} \quad (2.2)$$

Para efeito de simplicidade de cálculo, geralmente, o valor assumido para a eficiência de Coulomb é igual a 1 (um) para descarga e 0,998 para carga.

2.3.2 Método para Estimação de SoC Baseado em Filtros de Kalman

O Filtro de Kalman clássico foi introduzido por Rudolph E. Kalman ([Jouni Hartikainen, 2011](#)) em 1960. O propósito do Filtro de Kalman em tempo discreto é prover uma solução recursiva de ciclo fechado para estimação de sistemas dinâmicos lineares de tempo discreto que podem ser descritos por equações da forma ([Jouni Hartikainen, 2011](#)):

$$\mathbf{x}_k = \mathbf{A}_{k-1} \times \mathbf{x}_{k-1} + \mathbf{B}_{k-1} \times \mathbf{u}_k + \mathbf{q}_{k-1}; \quad (2.3)$$

$$\mathbf{y}_k = \mathbf{C}_k \times \mathbf{x}_k + \mathbf{D}_k \times \mathbf{u}_k + \mathbf{r}_k; \quad (2.4)$$

sendo,

- $\mathbf{x}_k$ é a matriz de estados do sistema no instante de tempo k ;
- $\mathbf{y}_k$ é a saída do sistema no instante de tempo k ;
- $\mathbf{q}_{k-1}$ é o ruído do processo no instante de tempo $k-1$;
- $\mathbf{r}_k$ é o ruído da medição no instante de tempo k ;
- $\mathbf{A}_{k-1}$ é a matriz de transição do modelo dinâmico;
- $\mathbf{B}_{k-1}$ é a matriz de entradas;
- $\mathbf{C}_k$ é a matriz ou função do modelo de medição. Que neste caso é representada como uma função que relaciona o SoC com as tensões nos ramos que representam a dinâmica do sistema;
- $\mathbf{D}_k$ é a matriz de alimentação.

O Filtro de Kalman possui dois passos: o de previsão, no qual o próximo estado do sistema é previsto a partir de medições anteriores, e o de atualização, no qual o estado atual do sistema é estimado a partir de medições em cada espaço de tempo. As equações que traduzem os passos estão descritas a seguir, onde os indexadores $(-)$ e $(+)$ representam o sinal a priori e a posteriori, respectivamente:

- Previsão
 - Propagação do estado estimado

$$\mathbf{x}_{k+1}^- = \mathbf{A}_k \times \mathbf{x}_k^+ + \mathbf{B}_k \times \mathbf{I}_t(\mathbf{k}) \quad (2.5)$$

- Propagação do erro de covariância

$$\mathbf{P}_{k+1}^- = \mathbf{A}_k \times \mathbf{P}_k^+ \times \mathbf{A}_k^T + \mathbf{Q}_k \quad (2.6)$$

- Correção

- Cálculo do ganho de Kalman

$$\mathbf{K}_k = \mathbf{P}_{k+1}^- \times \mathbf{C}_k^T \times [\mathbf{C}_k \times \mathbf{P}_{k+1}^- \times \mathbf{C}_k^T + \mathbf{R}_k]^{-1} \quad (2.7)$$

- Atualização do erro de covariância

$$\mathbf{P}_{k+1}^+ = \mathbf{P}_{k+1}^- - \mathbf{K}_k \times \mathbf{C}_k \times \mathbf{P}_{k+1}^- \quad (2.8)$$

- Atualização do estado estimado

$$\mathbf{x}_{k+1}^+ = \mathbf{x}_{k+1}^- + \mathbf{K}_k \times [\mathbf{V}(k) - \mathbf{U}_t(k)] \quad (2.9)$$

2.3.3 Método para Estimação de SoC baseado em Filtros de Kalman Estendido

Em comparação com os outros métodos, este método é aplicável a todos os tipos de bateria, especialmente para a estimativa do SoC de baterias de carros híbridos as quais possuem requisitos de corrente muito severos, com muitos picos de corrente positiva e negativa, simbolizando a carga e descarga brusca das baterias.

A ideia básica da teoria do Filtro de Kalman é tornar a variância mínima em termos da estimativa ótima do estado do sistema de energia (Urbain, 2007). A bateria é considerada como um sistema de energia e o SoC como um estado interno do sistema para a aplicação da estimativa. Em geral, a forma matemática da equação do estado do modelo da bateria pode ser representada como:

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{w}_k \quad (2.10)$$

$$\mathbf{y}_k = \mathbf{g}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k, \quad (2.11)$$

Sendo $\mathbf{x}_k$ o vetor do estado do sistema no índice de tempo discreto k , o vetor $\mathbf{u}_k$ é a entrada do sistema medido no tempo k e $\mathbf{w}_k$ é o ruído do processo não medido que afeta o estado do sistema. A saída do sistema é $\mathbf{y}_k$, e $\mathbf{v}_k$ é o ruído de medição.

O Filtro de Kalman é amplamente utilizado em problemas de estimativa indireta de variáveis a partir de medições de variáveis diretas, e é um estimador ótimo para modelos lineares (Kavash, 2015). No entanto, o modelo de uma bateria é não linear,

pois o comportamento do sistema depende de variáveis externas, como a temperatura e degradação da bateria. Além disso, os elementos do modelo da bateria são dependentes do estado de carga da bateria e sua curva ao longo do tempo possui característica não linear. A curva que relaciona a tensão de circuito aberto e o SoC evidencia o comportamento não linear da bateria pois não obedece aos critérios de aditividade e homogeneidade para a linearidade. Analisando o modelo da Figura 3, tem-se a Equação 2.12 que representa o modelo de medição:




Figura 3 – Modelo de circuito equivalente com três ramos RC.

$$U_t = OCV(\text{SoC}, T, t) - R_0(\text{SoC}, T, t) * I(t) - U_1(\text{SoC}, T, t) - U_2(\text{SoC}, T, t) - U_3(\text{SoC}, T, t) + w \quad (2.12)$$

Sendo, U_1 , U_2 e U_3 as tensões nos ramos R_1C_1 , R_2C_2 e R_3C_3 , respectivamente, w é o ruído branco do processo. As correntes em cada ramo RC podem ser definidas de acordo com as Equações 2.13, 2.14 e 2.15, considerando que a corrente $I(t)$ que passa por R_0 , se divide entre o resistor R_1 e pelo capacitor C_1 . O mesmo vale para os ramos 2 e 3. Ou seja,

$$I(t) = C_1(\text{SoC}, T, t) * \frac{\partial U_1}{\partial t} + \frac{U_1}{R_1(\text{SoC}, T, t)} \quad (2.13)$$

$$I(t) = C_2(\text{SoC}, T, t) * \frac{\partial U_2}{\partial t} + \frac{U_2}{R_2(\text{SoC}, T, t)} \quad (2.14)$$

$$I(t) = C_3(\text{SoC}, T, t) * \frac{\partial U_3}{\partial t} + \frac{U_3}{R_3(\text{SoC}, T, t)} \quad (2.15)$$

Que resultam nas equações 2.16, 2.17 e 2.18.

$$\frac{\partial U_1}{\partial t} = -\frac{1}{R_1(\text{SoC}, T, t) * C_1(\text{SoC}, T, t)} U_1 + \frac{1}{C_1(\text{SoC}, T, t)} I(t) \quad (2.16)$$

$$\frac{\partial U_2}{\partial t} = -\frac{1}{R_2(\text{SoC}, T, t) * C_2(\text{SoC}, T, t)} U_2 + \frac{1}{C_2(\text{SoC}, T, t)} I(t) \quad (2.17)$$

$$\frac{\partial U_3}{\partial t} = -\frac{1}{R_3(\text{SoC}, T, t) * C_3(\text{SoC}, T, t)} U_3 + \frac{1}{C_3(\text{SoC}, T, t)} I(t) \quad (2.18)$$

Definindo as constantes de tempo como $\tau_1 = R_1 * C_1$, $\tau_2 = R_2 * C_2$ e $\tau_3 = R_3 * C_3$, e sabendo que a resposta ao degrau de um circuito RC pode ser definida como:

$$U_t = (U_0 - U_s) * e^{\frac{-t}{\tau}} + U_s, \quad (2.19)$$

sendo U_0 a tensão inicial sobre o capacitor e U_s a tensão final. Logo tem-se as três tensões a seguir descritas:

$$U_1 = U_1(0) * e^{\frac{-t}{\tau_1}} + I * R_1(1 - e^{\frac{-t}{\tau_1}}) \quad (2.20)$$

$$U_2 = U_2(0) * e^{\frac{-t}{\tau_2}} + I * R_2(1 - e^{\frac{-t}{\tau_2}}) \quad (2.21)$$

$$U_3 = U_3(0) * e^{\frac{-t}{\tau_3}} + I * R_3(1 - e^{\frac{-t}{\tau_3}}) \quad (2.22)$$

Já o modelo do processo é baseado na equação do método de integral da corrente, como mostrado na Equação 2.23. Onde o valor de η foi fixado em 0,998, e a simplificação da integral foi realizada a partir de áreas retangulares. Após ser discretizada é representada pela equação 2.24.

$$\text{SoC} = \text{SoC}_0 + \frac{\eta}{C_n} \times \int_0^t I_{\text{bat}}(t) dt \quad (2.23)$$

$$\text{SoC}_k = \text{SoC}_{k-1} + \frac{\eta i_k \delta t}{C_n} + w_k \quad (2.24)$$

A relação entre OCV e SoC pode ser determinada a partir de dados experimentais de carga e descarga da bateria, onde a curva obtida pode ser ajustada em alguma equação que represente o comportamento dos dados. Sendo assim, a não linearidade do sistema está presente em cada parâmetro que rege o comportamento dinâmico da bateria.

De modo geral, o termo “não-linear” refere-se a todas as estruturas que não apresentam um único sentido, com múltiplos caminhos e destinos, desencadeando em múltiplos cenários finais. Assim, um sistema dinâmico não-linear evolui no tempo com um comportamento desequilibrado e aperiódico, sendo o seu estado futuro extremamente dependente de seu estado atual, e pode ser alterado radicalmente a partir de pequenas mudanças no presente.

No caso da bateria, o estado atual do SoC pode mudar com a temperatura ou com a tensão de circuito aberto (OCV), por exemplo.

Assim, para poder aplicar o Filtro de Kalman, ele deve ser linearizado em torno de um ponto de operação (Kavash, 2015). O método de filtragem de Kalman não pode ser usado diretamente quando a equação do estado do sistema não é linear, pois a discretização da equação do sistema é necessária. Esse tipo de discretização da equação não-linear para o Filtro de Kalman é chamado de Filtro de Kalman Estendido (EKF) (Xing, 2014).

A desvantagem do EKF é que, para uma estimativa ótima, é necessário um modelo aproximado do real e o conhecimento sobre as propriedades estatísticas dos ruídos. Na verdade, as duas condições acima mencionadas não podem ser facilmente alcançadas no ambiente em tempo real quando por exemplo, um veículo estiver trafegando, porque é difícil determinar o modelo da bateria por meio de um conjunto de parâmetros fixos devido à forte característica da propriedade de variância no tempo da bateria e da condição de condução do veículo que afetam as características dos ruídos de medição, e a dependência destas variáveis é difícil de obter antecipadamente para realizar a estimação (Chakrasali, 2015).

Em cada passo do tempo, $f(x_k, u_k)$ e $g(x_k, u_k)$ são linearizados por uma expansão em Série de Taylor de primeira ordem (Cheng, 2014). O modelo pode ser reescrito como:

$$x_{k+1} = A_k \times x_k + B_k \times u_k + w_k; \quad (2.25)$$

$$y_{k+1} = C_k \times x_k + D_k \times u_k + v_k; \quad (2.26)$$

sendo,

$$A_k = \frac{\partial[f(x_k, u_k)]}{\partial[x_k]}; \quad (2.27)$$

$$B_k = \frac{\partial[f(x_k, u_k)]}{\partial[u_k]}; \quad (2.28)$$

$$C_k = \frac{\partial[g(x_k, u_k)]}{\partial[x_k]}; \quad (2.29)$$

$$D_k = \frac{\partial[g(x_k, u_k)]}{\partial[u_k]}; \quad (2.30)$$

Para continuar a implementação do EKF, é necessário realizar a modelagem do circuito equivalente da bateria para que o modelo seja o mais próximo possível do sistema real e com a menor complexidade. Depois de escolher o modelo de bateria, as variáveis de espaço de estado podem ser definidas para serem usadas no algoritmo EKF.

2.3.4 Matriz de Decisão Pugh para Escolha do Método de Estimação a ser Utilizado

A representação na Tabela 2 faz uso da matriz Pugh para tomada de decisão em relação ao uso do método de estimação de SoC a ser utilizado nesta pesquisa. Esta metodologia foi desenvolvida por Stuart Pugh ([Wikipedia, 2018](#)), e é utilizada para realizar a decisão entre uma lista de alternativas. O método mais importante, ou mais utilizado, é fixado como referência e todas as outras alternativas são avaliadas com relação a essa base, levando em consideração uma série de critérios pré-selecionados.

Esta representação é frequentemente utilizada quando apenas uma alternativa pode ser selecionada. O método de integral da corrente foi escolhido como base de comparação para o restante dos métodos, pois está presente em grande parte das aplicações envolvendo a estimação de SoC por ser um método que fornece uma resposta precisa em relação ao esforço computacional exigido e por ser amplamente utilizado no cenário automotivo atual em aplicações como o IBS (*Intelligent Battery Sensor*), no qual este dispositivo faz uso da corrente para estimar o SoC da bateria.

Sendo assim, após a definição do método de referência, é possível elencar todos os critérios de avaliação dos métodos em questão para determinar o que possui o melhor custo-benefício de implementação/estimação. Também foram utilizados pesos para definir a prioridade entre os critérios, onde critérios como precisão, aplicação em sistemas não lineares e sensibilidade à parâmetros externos foram destacados como mais importantes na definição do método a ser utilizado.

Para realizar esta avaliação foi usada a seguinte escala de 5 pontos:

- +2: Muito melhor que;
- +1: Melhor que;
- 0: Igual a;
- -1: Pior que;
- -2: Muito pior que.

Por exemplo, analisando-se a linha do critério "Complexidade de Implementação", definir o valor +1 para o método de tensão de circuito aberto significa dizer que na escala de 5 pontos, o método avaliado é melhor que o método de referência pois possui menor complexidade de implementação. Já o método de filtro de Kalman recebeu -1 por possuir complexidade de implementação maior que o método de referência, mas não tanto quanto os métodos de filtro de Kalman estendido e Redes Neurais Artificiais, que neste modelo de avaliação foram considerados os mais complexos, em termos de implementação.

Tabela 2 – Matriz de Decisão Pugh

Métodos Critérios	Integral da Corrente (Coulomb Counting)	Pesos	Tensão de Circuito Aberto (OCV)	KF	EKF	RNA
Complexidade de Implementação	R	1	+1	-1	-2	-2
Custo Computacional	E F	1	+1	-1	-2	-1
Precisão (Tempo Real)	E R	2	-2	+1	+2	+2
Aplicação em sistemas não lineares	Ê N C	4	0	0	+2	+1
Uso em BMS	I	1	-2	0	-1	-1
Sensibilidade à parâmetros externos	A	2	-1	+1	+2	+1
Total			-6	+2	+13	+8

Fonte: (Wikipedia, 2018)

O primeiro critério a ser avaliado foi a complexidade de implementação. O método de estimação do SoC a partir da tensão de circuito aberto da bateria (OCV) é melhor que o método de referência pois baseia sua estimação em tabelas que relacionam tensão, SoC, e em alguns casos, temperatura. Outro fator importante de se ressaltar é que este método também necessita de recalibração da tabela de dados periodicamente, tendo em vista a degradação da vida útil da bateria. Já os filtros de Kalman tradicional e estendido apresentam piores resultados quando comparado com o método de referência pois fazem uso de cálculo recursivo utilizando espaço de estados para estimação do SoC, aplicado a sistemas não-lineares e variantes no tempo, além de precisar de um modelo bem definido do sistema ao qual seria aplicado. O algoritmo de redes neurais artificiais é muito pior que o método de referência pois necessita de uma grande quantidade de dados para o treinamento da rede e para que a estimação seja a mais precisa possível.

Em se tratando do custo computacional para implementação em um sistema embarcado, o método de OCV é melhor que o método de referência pois não faz uso de cálculos matemáticos complexos, precisa apenas de valores constantes em uma tabela. Já os filtros de Kalman demandam maior recurso computacional de um sistema embarcado, tendo em vista que este tipo de algoritmo é composto por filtros de mínimos quadrados recursivos que usam como referência do processo, um modelo de medições e uma série de medidas ruidosas. O método de redes neurais também requer um alto recurso computacional se comparado com o método de integral da corrente, mas em comparação com os filtros de

Kalman, este método possui esforço computacional reduzido, haja vista que este algoritmo considera o sistema como uma caixa preta e não leva em consideração o comportamento dinâmico do mesmo. Esta última característica pode ser tratada como boa, olhando pelo lado do esforço computacional, mas como não desejável se comparado em termos de sensibilidade à parâmetros externos.

Em relação ao critério de precisão, os métodos de filtro de Kalman estendido e o de redes neurais artificiais são muito melhores que o método de referência, pois levam em consideração outros parâmetros além da corrente de carga ou descarga da bateria, o que garante uma estimação mais precisa e fiel ao sistema real. Já o filtro de Kalman tradicional fornece uma resposta melhor que o método de referência, pois assim como o filtro de Kalman estendido, considera um conjunto de variáveis externas ao sistema para agregar na estimação. Mas o que faz o Filtro de Kalman tradicional ter resultado um pouco inferior quando comparado com os dois melhores é a incapacidade de fornecer uma resposta convergente se o modelo do sistema for altamente não linear, tendo em vista que este método não faz uso de nenhum método de linearização de sistemas. O método de OCV foi considerado muito pior porque não pode ser utilizado em aplicações em tempo real, tendo em conta que neste método a bateria precisa de longos períodos de repouso para determinação da tensão correta para correlacionar com o SoC.

Considerado o critério mais importante desta análise, a aplicação em sistemas não lineares, esta é muito importante, uma vez que a bateria é um sistema não linear e variante no tempo, no qual seus parâmetros variam de acordo com diversas variáveis externas, como por exemplo, temperatura, corrente de carga e descarga, ciclagem da bateria, envelhecimento da bateria. Neste quesito, o filtro de Kalman estendido é considerado o melhor, em razão de considerar o modelo do sistema o mais próximo possível do real, embora isto acarrete em um aumento da complexidade, e por consequência, do esforço computacional. O restante dos métodos considera o sistema como uma caixa preta, não se importando com a dinâmica e possíveis reações que possam vir a ocorrer internamente.

O uso em BMS é um tópico importante, considerando que o algoritmo de estimação seria desenvolvido para que no futuro fosse embarcado em um microcontrolador e integrado ao BMS. Apesar de algoritmos como o filtro de Kalman estendido e o de redes neurais artificiais serem mais eficientes na estimação do SoC, se levarmos em consideração o erro médio e o tempo de resposta do algoritmo, o método de referência continua sendo bastante utilizado na maioria das aplicações, visto que este método pode ser melhorado introduzindo algum outro método que corrija as lacunas de ineficiência. Um exemplo disso é o método de estimação da capacidade de uma bateria utilizado pela *Tesla Inc.* (Tesla, 2009), que faz uso do método de integral da corrente associado ao método de tensão de circuito aberto. O filtro de Kalman tradicional também pode ser utilizado em um BMS, mas com a mesma limitação do método de referência. Por último, o método de OCV é o único que não é

aplicável para BMS, se utilizado sem nenhuma adaptação, uma vez que sua resposta é bastante lenta.

Por fim, a sensibilidade à parâmetros externos é outro importante critério na avaliação do método de estimação a ser utilizado neste trabalho. Este critério relaciona a capacidade que o método tem em estimar o valor do SoC considerando fatores externos que tem a capacidade de alterar a dinâmica interna da bateria, como por exemplo, a temperatura. Para este critério, o filtro de Kalman estendido é o melhor dentre os métodos avaliados, tendo em vista que este método faz uso de um modelo bem definido do sistema em questão, levando em consideração a maioria dos comportamentos internos afetados por parâmetros externos.

Sendo assim, após toda esta análise feita com o auxílio da matriz de Pugh, pode-se concluir que o método de estimação mais indicado para os fins desejados desta pesquisa é o Filtro de Kalman Estendido.

2.4 Modelagem de Baterias

Nesta seção, os modelos de baterias de íons de lítio baseados na abordagem de Modelos de Circuito Equivalente são apresentados. É realizada uma introdução e uma breve descrição das vantagens e desvantagens desta abordagem de modelagem são fornecidas. Em seguida, é realizada a descrição da evolução das técnicas de modelagem de baterias e a implementação de três modelos diferentes com complexidade variadas.

2.4.1 Introdução

A bateria é um dos elementos mais desafiadores em um veículo elétrico, se não o mais desafiador, pois é dela que advém as maiores limitações, tanto técnicas, quanto econômicas. Logo, para reduzir estas limitações, uma das metodologias fundamentais é desenvolver um modelo, que integrado ao BMS, ajude a prever com rigor qual será o desempenho das baterias sobre diferentes dinâmicas de carga, condições ambientais e condições inerentes a própria bateria. O principal objetivo da modelagem é desenvolver uma representação matemática capaz de simular um comportamento do sistema. Nas baterias de íons de lítio, estão envolvidos muitos fenômenos complexos, tais como: o transporte de massa, as migrações de íons, as reações de redox (isto é, as transformações dos compostos químicos quando reagem com os eletrodos) e as reações secundárias (Magalhães, 2012).

Sendo assim, vários tipos de modelos têm surgido ao longo do tempo (Dr. Thanh-Son Dao, 2015) que podem ser classificados em puramente matemáticos, eletroquímicos, elétricos, híbridos, entre outros.

Os modelos de bateria são importantes por vários motivos. Primeiro, para prever o

desempenho em um sistema real por meio de simulações. Em segundo lugar, para otimizar a estrutura física em um banco de bateria e maximizar seu desempenho. E, em terceiro lugar, projetar controles de gerenciamento de bateria, no qual a bateria faz parte de um sistema complexo. Os modelos podem ser geralmente classificados como ideal, comportamental, eletroquímico e circuito elétrico equivalente ([Dr. Thanh-Son Dao, 2015](#)). Neste trabalho, o modelo de circuito equivalente da bateria tem o propósito de fornecer a estimativa do SoC a ser aplicado em um sistema de gerenciamento de baterias (BMS).

Como o próprio nome sugere, modelos ideais representam as baterias como uma fonte de tensão ideal de potência ilimitada. Sendo assim, estes modelos só são utilizados quando a bateria não é o elemento de interesse no sistema ([Farag, 2013](#)).

O modelo comportamental e de caixa preta simulam o comportamento da tensão no terminal das baterias sem a necessidade de especificação do comportamento físico ou eletroquímico. Esses modelos consistem em funções fenomenológicas que requerem dados experimentais para serem usados. Alternativamente, redes neurais, funções empíricas ou tabelas de consulta podem ser usadas. A Lei de Peukert é um dos primeiros exemplos mais conhecidos de um modelo comportamental para baterias, onde uma função empírica é usada para descrever a dependência da capacidade restante da bateria de acordo com a taxa de descarga ([Farag, 2013](#)).

Em seguida, tem-se os modelos eletroquímicos que buscam ilustrar o comportamento da bateria a partir de equações matemáticas, mais precisamente utilizando Equações Diferenciais Parciais (EDP). Em geral, essas EDPs são derivadas com base na lei de difusão de Fick para a concentração de material ativo, na lei de Ohm para distribuições de potencial elétrico e nas equações de Nernst e Butler-Volmer ([Dr. Thanh-Son Dao, 2015](#)). Modelos eletroquímicos representam explicitamente os processos químicos que ocorrem na bateria. Esses tipos de modelos descrevem a física da bateria em grandes detalhes, tornando-os os mais precisos de todos os modelos de bateria.




Figura 4 – Modelo Circuito Equivalente de uma Bateria Ideal.

Considerando que a modelagem será realizada a partir de um modelo de circuito elétrico equivalente, é necessário entender a evolução deste modelo, desde ideal até o

modelo elétrico mais complexo. Modelos ideais são utilizados apenas quando o modelo da bateria não possui relevância para o algoritmo de estimação. O modelo ideal está representado na Figura 4.




Figura 5 – Modelo de Circuito Equivalente de uma Bateria com Resistência Interna.

Conforme a modelagem da bateria ganha importância no trabalho, vê-se a necessidade em incrementar a complexidade da mesma visando uma representação cada vez mais fiel do equipamento. Com isso, o modelo evolui de ideal para um modelo que representa as perdas internas por efeito Joule, ou seja, a representação recebe uma resistência interna conforme ilustrado na Figura 5. Tendo em vista que para este trabalho a modelagem da bateria é elemento crucial, é preciso incrementar em complexidade o modelo para que a representação seja fiel o bastante para garantir que o SoC será estimado de forma eficiente.




Figura 6 – Modelo Geral de Circuito Equivalente de uma Bateria.

De fato, o modelo aproximado de cada bateria é composto de infinitos ramos RC em série devido às complexas características de polarização, conforme apresentado na Figura 6. Claramente, quanto maior a ordem, mais complexo e maiores os requisitos para implementação do modelo (Jackey, 2013). Existem muitos métodos para identificar os

parâmetros do modelo da bateria, (L. C. Stevanatto, 2014), (Birkel, 2013), (Aurilio, 2015), (Dhruv Kapoor, 2014), mas o método proposto neste trabalho é baseado em (Jackey, 2013).

Neste modelo, OCV é a tensão de circuito aberto, U_t é a tensão do terminal da bateria, I é a corrente de saída, R_0 é a resistência ôhmica dos conectores, eletrodos e eletrólito, e os ramos RC paralelos conectados em série R_1, C_1 a R_n, C_n são responsáveis pela dinâmica transitória, na qual a constante de tempo tende a ser maior de acordo com o crescimento do índice n . Os elementos resistivos e as constantes de tempo neste circuito são dependentes do SoC, temperatura, tensão e corrente, conforme apresentado em 2.19.

$$R_x = f(\text{SoC}, \text{temperatura}, V, I) \quad (2.31)$$

As células da bateria apresentam desafios de modelagem que tornam complexa a estimativa de parâmetros. Alguns desses desafios são a resposta dinâmica complexa, a histerese de tensão significativa e a relação OCV-SoC quase plana, entre 10% e 90% do SoC (A123 Systems, 2014). Na Seção 3.2.1 a seguir, apresenta-se passo-a-passo, o procedimento para determinar o número de ramos RC em um modelo de circuito equivalente de uma bateria.

2.4.2 Modelo RC de 1ª Ordem

O modelo de circuito equivalente de primeira ordem é o modelo mais simples dentre aqueles que consideram ramos RCs como parte do comportamento das baterias, como mostrado na Figura 7 (Farag, 2013). O modelo é constituído de 3 partes: a tensão de circuito aberto (OCV), a resistência interna e o ramo constituído de uma resistência e um capacitor usado para modelar a dinâmica da bateria.




Figura 7 – Modelo de circuito equivalente com um ramo RC.

Este modelo é capaz de capturar a dinâmica da bateria e pode ser facilmente implementado em aplicações em tempo real. Este modelo pode ser representado de acordo com 2.32 e 2.33.

$$\begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} \end{bmatrix} * \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \end{bmatrix} + \begin{bmatrix} \frac{-\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \end{bmatrix} i(k); \quad (2.32)$$

$$y(k) = U_t(k) = \text{OCV}(\text{SoC}) - U_1(k) - R_0 \times i(k); \quad (2.33)$$

Onde,

- SoC é o estado de carga da bateria;
- OCV é a tensão de circuito aberto;
- C é a capacidade nominal da bateria;
- R_0 é a resistência ôhmica da bateria;
- $R_1 C_1$ se refere a dinâmica de polarização;
- U_1 é um estado que representa a tensão no capacitor C_1 ;
- SoC(k) e U_1 são os estados do sistema;
- $y(k)$ é a saída do sistema, a qual corresponde a tensão no terminal com a bateria conectada a uma carga;
- $i(k)$ é a corrente de entrada;
- $\eta_i = \frac{1}{3600 \times C_i}$, sendo i um índice para representar a variação da capacidade em relação ao tempo;
- Δt é o período de amostragem.

2.4.3 Modelo RC de 2ª Ordem

O modelo de segunda ordem é ilustrado na Figura 8. O modelo é capaz de representar adequadamente o comportamento das constantes de tempo rápida (ramo $R_1 C_1$) e lenta (ramo $R_2 C_2$) para recuperação de tensão da bateria (Farag, 2013).




Figura 8 – Modelo de circuito equivalente com dois ramos RC.

Este modelo é capaz de capturar a dinâmica da bateria e pode ser facilmente implementado. Este modelo pode ser representado da seguinte forma:

$$\begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \\ U_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_2 C_2} \end{bmatrix} * \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \\ U_2(k) \end{bmatrix} + \begin{bmatrix} \frac{-\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \end{bmatrix} i(k); \quad (2.34)$$

$$y(k) = U_t(k) = \text{OCV}(\text{SoC}) - U_1(k) - U_2(k) - R_0 \times i(k); \quad (2.35)$$

Onde,

- SoC é o estado de carga da bateria;
- OCV é a tensão de circuito aberto;
- C é a capacidade nominal da bateria;
- R_0 é a resistência ôhmica da bateria;
- $R_1 C_1$ é referente a constante de tempo rápida de polarização e de dupla camada;
- $R_2 C_2$ é referente a constante de tempo lenta;
- U_1 e U_2 são estados que representam as tensões em volta dos capacitores C_1 e C_2 ;
- $\text{SoC}(k)$, U_1 e U_2 são os estados do sistema;
- $y(k)$ é a saída do sistema, a qual corresponde a tensão no terminal com a bateria conectada a uma carga;

- $i(k)$ é a corrente de entrada;
- $\eta_i = \frac{1}{3600 \times C_i}$, sendo i um índice para representar a variação da capacidade em relação ao tempo;
- Δt é o período de amostragem.

2.4.4 Modelo RC de 3ª Ordem

No modelo de terceira ordem ilustrado na Figura 9, o primeiro ramo representa o comportamento da constante de tempo rápida e os dois ramos restantes representam o comportamento das constantes de tempo lentas. Embora seja um modelo que fornece uma representação mais exata que os anteriores, o custo computacional é relativamente maior devido ao aumento na ordem do sistema, ou seja, inclusão de mais um estado (U_3) (Farag, 2013).




Figura 9 – Modelo de circuito equivalente com três ramos RC.

$$\begin{bmatrix} \text{SoC}(k+1) \\ U_1(k+1) \\ U_2(k+1) \\ U_3(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 - \frac{\Delta t}{R_1 C_1} & 0 & 0 \\ 0 & 0 & 1 - \frac{\Delta t}{R_2 C_2} & 0 \\ 0 & 0 & 0 & 1 - \frac{\Delta t}{R_3 C_3} \end{bmatrix} \begin{bmatrix} \text{SoC}(k) \\ U_1(k) \\ U_2(k) \\ U_3(k) \end{bmatrix} + \begin{bmatrix} \frac{-\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \\ \frac{\Delta t}{C_3} \end{bmatrix} i(k); \quad (2.36)$$

$$y(k) = U_t(k) = \text{OCV}(\text{SoC}) - U_1(k) - U_2(k) - U_3(k) - R_0 \times i(k); \quad (2.37)$$

Onde,

- SoC é o estado de carga da bateria;
- OCV é a tensão de circuito aberto;
- C é a capacidade nominal da bateria;
- R_0 é a resistência ôhmica da bateria;
- R_1C_1 é referente a constante de tempo rápida de polarização e de dupla camada;
- R_2C_2 é referente a constante de tempo lenta;
- R_3C_3 é referente a constante de tempo mais lenta que o ramo anterior;
- U_1 , U_2 e U_3 são estados que representam as tensões em volta dos capacitores C_1 , C_2 e C_3 ;
- $SoC(k)$, U_1 , U_2 e U_3 são os estados do sistema;
- $y(k)$ é a saída do sistema, a qual corresponde a tensão no terminal com a bateria conectada a uma carga;
- $i(k)$ é a corrente de entrada;
- $\eta_i = \frac{1}{3600 \times C_i}$, sendo i um índice para representar a variação da capacidade em relação ao tempo;
- Δt é o período de amostragem.

3 Materiais e Métodos

Neste capítulo serão apresentados os materiais utilizados para realização dos ensaios de carga e descarga para identificação do modelo da bateria e estimação do estado de carga. Além disso, são apresentados os métodos utilizados para realização dos ensaios de acordo com normas nacionais e internacionais.

3.1 Materiais

3.1.1 Baterias Utilizadas nos Experimentos

No início desta pesquisa, para validar os materiais e métodos para modelagem da bateria e, em seguida, estimar o SoC, utilizou-se uma bateria de chumbo ácido com 100Ah de capacidade e 2,2V de tensão nominal, Figura 10. Essa bateria foi tida como elemento principal da pesquisa até a qualificação. A partir da qualificação, os esforços se voltaram para a bateria de Lítio descrita a seguir.



Figura 10 – Bateria de Chumbo Ácido 100Ah 2,2V.

Foi utilizada uma bateria de Lítio Ferro Fosfato (LiFePO_4) de 20Ah ([A123 Systems, 2014](#)) geralmente utilizada em aplicações automotivas, na qual as especificações podem ser verificadas na Tabela 3. A bateria utilizada é representada por meio da Figura 11.

Tabela 3 – Especificações da bateria de íons de lítio.

		Condições de Operação
Capacidade Nominal	20 Ah	-
Capacidade Mínima	19,5 Ah	25°C, 6A de descarga, 3,6V a 2,0V no BoL
Tensão Nominal	3,3V	@ 50% SoC
Faixa de Tensão	2V a 3,6V	Completamente descarregada a completamente carregada
Tensão máxima	4,0V	Acima disso causa dano
Tensão Máxima de Carga	3,6V	-
Tensão de Fim de Descarga	2,0V	-
Corrente de Carga Padrão	20A	Até 3,6V
Corrente Máxima de Carga	100A	Até 3,6V e Temp <= +85°C
Peso	495g	+/- 10g
Temperatura de Operação	-30 °C a +60 °C	Ambiente em volta da célula

Fonte: ([A123 Systems, 2014](#))



Figura 11 – Bateria de Lítio 20Ah 3,3V.

Na Figura 12 apresenta-se a plataforma de testes utilizada para realizar os ensaios de carga e descarga nas baterias.




Figura 12 – Sistema utilizado para realização dos procedimentos experimentais.

Sendo assim, considerando que a plataforma de testes é composta por quatro submódulos, que são: a interface de controle e monitoramento dos testes, o sistema de aquisição dos dados (*Datalogger*), a fonte de alimentação responsável por injetar e drenar energia da bateria e o banho térmico que é responsável por manter a temperatura ambiente da bateria controlada.

3.1.2 Sistema de Aquisição de Dados (*Datalogger*)

Consiste em um sistema que tem a função de monitorar e registrar as grandezas analógicas ao longo do tempo, com uma elevada exatidão. Para a realização da medição dos parâmetros referentes à bateria, tais como: temperatura na superfície e tensão em circuito aberto, foi utilizado um *datalogger* fabricado pela empresa *Keysight Technologies* ([Technologies, 2019](#)), que é ilustrado na Figura 13.



Figura 13 – Equipamento de aquisição de dados (*Datalogger*) utilizado nos ensaios.

Com o auxílio do manual de dados técnicos deste equipamento disponibilizado pelo fabricante é possível apresentar as seguintes especificações.

- Especificações:
 - 3 slots com 20 canais cada (60 canais);
 - Tipos de sinais diferentes: 11;
 - Comandos de controle: SCPI;
 - Comunicações Entrada e Saída: USB, LAN, RS-232;
 - Resolução:
 - * Tensão: 6 1/2 dígitos = 22 bits;
 - * Temperatura: 0,1°C;
 - Precisão:
 - * Tensão: 0,0035+0,0005 (%de leitura + %da faixa);
 - * Temperatura do termopar tipo K: 1,0°C;

3.1.3 Fonte de Alimentação

É um equipamento eletrônico que tem como função fornecer energia elétrica a uma determinada carga. A fonte utilizada foi a BOP 1 KW, da fabricante Kepco Inc., conforme ilustrado na Figura 14. A fonte possui limites de corrente entre -10,0 A a +10,0 A e tensão de -100 V a +100 V, podendo ser configurada para funcionar tanto no modo de corrente constante quanto de tensão constante.



Figura 14 – Fonte de alimentação Kepco.

Esse equipamento possibilita uma comunicação via porta serial com um computador que realiza o controle da operação da fonte enviando comandos SCPI (*Standard Commands for Programmable Instruments*), no momento em que é requerida uma nova operação.

3.1.4 Interface

O computador, nesse processo, tem a função de controlar o processo de ensaio dos experimentos na bateria, tal como, realizar a apresentação dos dados dos parâmetros ao

usuário, servindo assim, de um sistema de monitoramento. A interface de computador foi desenvolvida em cooperação entre alunos do mestrado e da graduação (participantes do Formula SAE elétrico) usando a linguagem de programação C# (C Sharp).

Os dados coletados pelo Datalogger, por meio da comunicação padrão Ethernet, são apresentados pela interface ao usuário. Ao início do programa, os dados referentes aos parâmetros medidos são salvos em arquivos no formato de texto, possibilitando a organização dos arquivos com o nome do experimento e o dia, tal como o fácil tratamento dos dados usando outros softwares, como por exemplo, o Matlab.

Por sua vez, o controle da fonte de alimentação foi realizado a partir do software *putty*, que permite a comunicação serial entre o computador e a fonte.

3.1.5 Banho Térmico

Para realizar o ensaio com diferentes valores de temperatura do meio ao qual a célula de bateria está inserida, foi necessário utilizar um equipamento da empresa Polyscience, que permite resfriar ou aquecer o líquido refrigerante que envolve a célula de bateria.

Esse sistema de variação térmica é composto por um tanque preenchido por um líquido composto por 40% de etilenoglicol, usado como aditivo de radiador, e 60% de água destilada, necessários para evitar perdas maiores de líquido quando aquecido. O equipamento possibilita alterar a temperatura do líquido a uma faixa de $-20\text{ }^{\circ}\text{C}$ a $120\text{ }^{\circ}\text{C}$ e ainda realizar a circulação interna do líquido.

A inserção de um objeto no tanque faz com que o sistema atue como um banho térmico. Devido as dimensões das baterias utilizadas nesse trabalho foi elaborado um tanque para inserção da bateria e controle da temperatura. Apresenta-se na Figura 15 o sistema com a célula de bateria em seu interior.



Figura 15 – Bateria de Lítio imersa no Banho térmico.

A prática de imersão de baterias em banho térmico é comumente utilizada entre as maiores fabricantes de acumuladores de energia, sendo realizada a análise da influência da temperatura na capacidade nominal da bateria. Esse teste, que é referenciado pela norma N°601/2012 da ANATEL, tem como propósito a elaboração dos relatórios técnicos para submissão da aprovação da bateria nos órgãos regulatórios ao qual elas serão empregadas, tal como ANATEL (Agência Nacional de Telecomunicações), ANEEL (Agência Nacional de Energia Elétrica) e outras agências, e pelo Regulamento Técnico Metrológico e de Avaliação da Conformidade - RTAC 0001652, do INMETRO, de 2011.

3.2 Métodos

Toda a metodologia utilizada para desenvolver a pesquisa está representada na Figura 16. A etapa de ensaios de carga e descarga consistiu na aquisição de dados de descarga pulsada, para modelagem elétrica da bateria, e carga, para caracterização da função de observação OCVxSoC. Vale destacar que os ensaios realizados valem tanto para a bateria de LiFePO₄, quanto para a de Chumbo-Ácido, modificando apenas valores de corrente e tempo.

Para realização destes procedimentos, a bateria deve ser imersa em um tanque com uma mistura entre água destilada e solução arrefecedora para uso em radiadores de motores automotivos. A fonte de corrente e o datalogger devem ser conectados aos polos

da bateria, e todo o ajuste de valores de corrente e tempo devem ser realizados utilizando a interface desenvolvida.




Figura 16 – Metodologia para realização dos testes em baterias.

Os ensaios de descarga pulsada para as temperaturas de 10°C, 25°C e 40°C para bateria de LiFePO4, e 10°C, 40°C e 70°C para chumbo-ácido. Foram realizados como se segue:

- Ensaio de Descarga-Repouso (EXPERIMENTO 1):
 - Ajustar a temperatura do banho térmico para o valor desejado e depois manter a bateria em repouso sob a temperatura desejada por 2h antes de iniciar o procedimento de carga.
 - A bateria deve ser carregada a uma corrente de 1C, levando em consideração o máximo que a fonte fornece, até a tensão máxima limite da célula (3,6V para LiFePO4, 2,2V para Chumbo-ácido). Por exemplo, para uma bateria com capacidade de 20AH, a corrente utilizada seria 10A. Em seguida, deve-se fixar a tensão da fonte em 3,6V para LiFePO4, 2,2V para Chumbo-ácido, e esperar a corrente ficar abaixo de $= 0,1A$.
 - A bateria deve ser descarregada a uma corrente constante de 10 A durante 12 minutos para a bateria de LiFePO4 e 1 hora para chumbo-ácido, isto é, descarregando em 10% da capacidade nominal, e depois a bateria deve ser submetida

a uma corrente de 0 A durante 2 h (Ambas as baterias), caracterizando a região de repouso, para alcançar o equilíbrio térmico e eletroquímico. Teoricamente, quando a bateria estiver totalmente descarregada, a tensão deve estar em volta de 2,0V para LiFePO₄, e 1,75V para chumbo-ácido.

- Passo (b) deve ser repetido 10 vezes para que a bateria seja teoricamente 100% descarregada e para que o experimento possua 10 pulsos de descarga-repouso. Teoricamente, quando a bateria estiver totalmente descarregada, a tensão deve estar em volta de 2,0V para LiFePO₄, e 1,75V para chumbo-ácido.
 - Passos de (a) a (c) devem ser realizados para temperaturas de 10°C, 25°C e 40°C para LiFePO₄, e 10°C, 40°C e 70°C para chumbo-ácido.
- Ensaio de Carga-Descarga (EXPERIMENTO 2):
 - A bateria deve ser carregada usando a corrente máxima que a fonte pode fornecer (10 A) até a tensão máxima limite da célula (3,6V para LiFePO₄, 2,2V para Chumbo-ácido). Uma vez que a corrente foi reduzida a 0,1 A a bateria estará completamente carregada. Em seguida, a bateria é descarregada com uma corrente constante de 10 A até a sua tensão de corte de descarga (2,0V para LiFePO₄, e 1,75V para chumbo-ácido)
 - Passo (a) deve ser realizado para temperaturas de 0°C, 25°C e 40°C para LiFePO₄, e 10°C, 40°C e 70°C para chumbo-ácido.

Após a aquisição dos dados do experimento 1 (Descarga pulsada), a etapa de modelagem elétrica da bateria e identificação dos parâmetros pôde ser desenvolvida como mostrado na seção 3.2.1. Em seguida, após a determinação do modelo elétrico equivalente com um número N de ramos RCs e da look up table com os valores de cada parâmetro para cada valor de temperatura, o modelo de espaço de estados pode ser determinado a partir das equação matemáticas e equações do teorema de Thévenin.

Na etapa seguinte, com os dados adquiridos a partir do experimento 2 (Carga - Descarga), a função de observação para cada temperatura pode ser determinada através de ajuste de curvas. Por fim, os métodos de KF e EKF podem ser implementados no Matlab e em seguida comparados para que o método com menor resíduo de estimação seja determinado.

3.2.1 Determinação do Modelo de Circuito Equivalente e Estimação dos Parâmetros

Utilizando algumas ferramentas da Mathworks®, técnicas de estimação e dados medidos com a bateria de LiFePO₄, foi possível identificar os parâmetros do circuito equivalente

da bateria para cada valor de SoC e para diferentes valores de temperatura. O circuito equivalente da bateria consiste em um circuito RC com um elemento representando a tensão de circuito aberto (OCV), uma resistência série representando a resistência interna, e de 1 a N pares RC representando comportamentos como o transporte de massa, polarização e dupla camada, etc.

Para determinar o número recomendado de ramos RC, fornecer estimativas iniciais para os parâmetros do circuito, e estimar os parâmetros para ajustar o modelo aos dados experimentais, foram utilizadas técnicas de otimização numérica com o emprego de funções do MATLAB e modelos do SIMULINK que podem ser encontrados na versão R2018a. O fluxo das etapas do pré-processamento dos dados até a estimação dos parâmetros está organizado de acordo com a Figura 17.




Figura 17 – Disposição das etapas de modelagem da bateria.

O procedimento de modelagem da bateria adotado pode ser dividido nos seguintes passos (Mathworks, 2019):

1. Carregamento e pré-processamento dos dados;
2. Determinação do número de pares RC;
3. Estimação dos parâmetros;
4. Definição dos valores para cada parâmetro e construção da *look-up table* (Tabela contendo os valores dos parâmetros em função do SoC).

Tratando-se do carregamento e pré-processamento dos dados, existem alguns requisitos de formato e precisão a se seguir. Primeiro, o experimento precisa conter dados relativos a corrente, tensão e temperatura, além de serem coletados sob temperatura constante. Segundo, a taxa de amostragem utilizada foi de 1 Hz (Mathworks, 2019). O tempo de relaxamento após cada pulso de corrente deve ser suficiente para garantir que a bateria se aproxime de um valor de tensão estável.

Após carregar os dados de tensão, corrente, tempo de medição e temperatura, o algoritmo divide os dados em objetos da classe bateria (Battery.Pulse, desenvolvida pela equipe da Mathworks) (Mathworks, 2019). Esta classe possui diversos atributos, como tensão, corrente, temperatura, tempo, parâmetros do modelo, etc. Além de vários métodos

para determinar o número de ramos RC do modelo, parâmetros iniciais (chute inicial para determinar os parâmetros), método para otimização da estimativa dos parâmetros, etc.

Em seguida, os dados são representados graficamente como mostrado na Figura 18, e o processo de identificação dos pulsos é iniciado. A identificação dos pulsos é um passo importante para a determinação dos parâmetros do modelo, tendo em vista que este processo identifica a porção da curva referente a variação instantânea da tensão, que diz respeito a resistência interna da bateria, e a porção referente as constantes de tempo do modelo.

A identificação dos pulsos é feita a partir do par de pontos que circundam a carga e o par de pontos que circundam o processo de relaxação. Desta forma, o algoritmo desenvolvido possui uma função que identifica quando a bateria está em carga ou relaxação de acordo com o valor da corrente. Ou seja, primeiro o valor inicial da corrente é definido de acordo com os dados experimentais para identificar se houve o início do processo de relaxação ou de carga, e em seguida, quando há uma variação positiva para a corrente assume-se que esta saiu do processo de relaxação para carga e o valor inicial e final da variação são destacados na Figura. O mesmo acontece para o caso de haver uma variação negativa que indica uma passagem de carga para relaxação. Os valores representando a relaxação estão em verde e os representando a carga estão em vermelho na Figura 19.




Figura 18 – Ensaio de descarga pulsada.




Figura 19 – Processo de identificação dos pulso de corrente.

Sabe-se que o modelo de circuito equivalente da bateria possui infinitos pares RC, mas que existe uma limitação relativa ao esforço computacional para determinar o valor dos parâmetros e estimar o SoC da bateria conforme o número de pares RC aumentam. Desta forma, para estimar o número de pares RC que forneçam uma resposta satisfatória o algoritmo faz uso de uma equação que representa o comportamento das constantes de tempo relativas ao número de pares RC. Esta equação é similar a Eq. 2.19, e também utiliza a caixa de ferramentas do Matlab conhecida como “*Curve fitting toolbox*”. O ajuste de curva começa com apenas um par RC, que é relativo a uma constante de tempo, e vai até 5 pares RC (5 constantes de tempo) para que a comparação entre as curvas seja realizada, e por conseguinte, a escolha do número adequado de pares RC.

A comparação entre os pulsos é realizada no passo 2 do algoritmo e representada conforme ilustrado na Figura 20, na qual os dados são ajustados para cada número de ramos RC, conforme dito anteriormente, e o erro residual representado graficamente para servir como critério de escolha do número de ramos RC adequado para o modelo. Cada pulso gerado é comparado com os pulsos de descarga pulsada experimentais fornecidos no início do algoritmo.




Figura 20 – Processo de identificação dos pulsos de corrente.

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

Em seguida, uma estimação inicial da constante de tempo de cada ramo RC é realizada utilizando o método de ajuste de curvas fornecida pelo Matlab para cada pulso de relaxação em cada SoC. Este método utiliza interpolação polinomial para ajustar os dados a uma curva pré determinada baseada no método de mínimos quadrados não lineares, aliado ao algoritmo "*Trust-Region-Reflective*" (Recomendado por (MathWorks, 2019) como método padrão) para otimização da solução. Este algoritmo funciona da seguinte forma, supondo-se que esteja-se em um ponto $\mathbf{x}$ no espaço $\mathbf{n}$ e se deseje melhorar, ou seja, passar para um ponto com um valor de função menor. A ideia básica é aproximar f com uma função mais simples $\mathbf{q}$, que reflete razoavelmente o comportamento da função $\mathbf{f}$ em uma região $\mathbf{N}$ em torno do ponto $\mathbf{x}$. Uma etapa é minimizar o erro de aproximação do ponto $\mathbf{x}$ com a função $\mathbf{f}$ (MathWorks, 2019).

Desta forma, é usada uma equação formada por exponenciais e que representam o comportamento das constantes de tempo levando em consideração o número de ramos RC. Após a obtenção da constante de tempo para cada ramo RC e para cada valor de SoC, os dados são representados graficamente juntamente com a sequência de pulsos dos dados simulados. Estes dados simulados são referentes as estimações iniciais de E_m , R_0 e das constantes de tempo.

Ainda no passo 3 do algoritmo, usando uma aproximação para sistemas lineares, os parâmetros são identificados e valores iniciais são definidos pulso-a-pulso. Então, possuindo-se estes valores iniciais e a sequência de pulsos simulada, pode-se realizar o passo de otimização das estimativas utilizando o *Simulink Design Optimization* (SDO). O SDO fornece funções, ferramentas interativas e blocos para analisar e ajustar os parâmetros do modelo. É possível determinar a sensibilidade do modelo, preparar o modelo para testar dados e ajustá-lo para atender aos requisitos. Usando técnicas como simulação de Monte Carlo e Design de experimentos, é possível explorar o sistema como um todo e calcular a influência de parâmetros no comportamento do modelo. O SDO ajuda a aumentar a precisão do modelo. É possível pré-processar os dados de teste, estimar automaticamente os parâmetros do modelo e validar os resultados da estimativa.

Quando a corrente é ajustada em 0 A, a resposta do sistema é ditada pela resistência R_0 e pelos ramos RC do circuito equivalente. O primeiro determina a resposta instantânea do sistema, podendo considerar que a constante de tempo é nula. Os ramos RC ditam a resposta dinâmica da bateria, na qual a resposta do sistema é do tipo exponencial, e esse comportamento é caracterizado por constantes de tempo τ (tau). Para um modelo aproximado quanto maior o número de ramos RC, mais fiel este modelo será. É importante destacar que a cada adição de um ramo RC ao modelo de circuito equivalente da bateria, uma constante de tempo mais lenta é adicionada a resposta do sistema.

O segundo passo é estimar os parâmetros do modelo ajustando os dados das curvas de relaxamento à uma equação pré-definida. Esse é um passo importante para o sucesso da estimação. Os fluxogramas apresentados nas Figuras 21 e 22 representam graficamente os passos adotados.




Figura 21 – Etapas para determinação do número de ramos RC em um modelo de circuito equivalente de uma bateria.




Figura 22 – Etapas para estimação dos parâmetros em um modelo de circuito equivalente de uma bateria.

3.2.2 Implementação do Modelo de Observação da Bateria OCV-SoC

A função de observação que representa a relação entre a tensão de circuito aberto da bateria (OCV) e o SoC tem grande importância na determinação da estimação do SoC a partir do algoritmo proposto. Esta função é diferente para cada tipo de bateria e geralmente é não-linear. Em métodos como os Filtros de Kalman, esta relação é essencial para a determinação precisa do valor a ser estimado. A função OCV-SoC é implementada normalmente em sistemas de gerenciamento de baterias a partir de uma tabela de equivalência (*look-up table*) ou como uma expressão analítica.

O monitoramento de baterias de íons de lítio é uma das tarefas mais importantes em um BMS, consistindo da estimação do SoC. De fato, o SoC serve como um indicador da autonomia disponível de um veículo elétrico e de sua eficiência. Atualmente pode-se encontrar na bibliografia diversos trabalhos relacionados a métodos de estimação de estado de carga (SoC) de baterias. As aproximações baseadas em modelo precisam de um OCV com baixa incerteza, em que a relação OCV-SoC seja o mais próximo da curva experimental (tao et al., 2006). A modelagem do OCV pode ser numérica, como uma *look-up table*, ou analítica, como uma expressão matemática. No entanto, a última tem mais vantagens incluindo eficiência computacional, desde que nenhuma interpolação é necessária, como regressão linear ou algoritmos de spline (Cunha, 2000).

A melhoria dos modelos de OCV pode contribuir significativamente para aumentar a precisão da estimativa do SoC (A. Szumanowski, 2008). A relação entre OCV e SoC é um dos principais precursores da não linearidade do modelo e impacta diretamente na estimação do SoC, principalmente quando o método utilizado envolve filtros de Kalman. A modelagem do OCV é imperativa, uma vez que é o principal componente do modelo da bateria, e faz parte do complexo comportamento físico durante os processos químicos envolvendo os íons de lítio (tao et al., 2006). O OCV de uma célula de bateria é a diferença de potencial entre os eletrodos positivo e negativo quando nenhuma carga é aplicada e a bateria está em equilíbrio.

Vários modelos de OCV foram propostos na literatura (Farag, 2013), (tao et al., 2006), (Kong Soon Ng, 2009), (Jouni Hartikainen, 2011), (Baccouche, 2015), (Plett, 2004). Alguns desses modelos são muito simples e não levam em conta a não-linearidade, como a aproximação linear. Mesmo que sejam modelos de fácil implementação, a não consideração da não linearidade pode afetar de maneira negativa a precisão da estimação do SoC. Alguns modelos revisados na literatura, que incluem modelos polinomiais, logarítmicos, exponenciais e combinados, serão comparados neste trabalho, e será avaliado a relação precisão-complexidade de implementação antes de realizar a escolha do modelo que integrará o algoritmo de estimação do SoC. Alguns dos modelos encontrados na literatura e suas respectivas referências estão dispostos na tabela 4.

Tabela 4 – Modelos OCV-SoC.

	Modelos Propostos	REF.
Pol. 1ª Ord.	$p_1 * x + p_0$	(Baccouche, 2015)
Pol. 7ª Ord.	$p_7 * x^7 + p_6 * x^6 + p_5 * x^5 \dots + p_1 * x + p_0$	(A. Szumanowski, 2008)
Exponencial	$p_0 * \exp(p_1 * x) + p_2 * \exp(p_3 * x)$	(Yasser Diab, 2017)
Logarítmico	$p_0 + \frac{p_1}{x+0.01} + p_2 * x - p_3 * \log(x + 0.01) - p_4 * \log(1.01 - x)$	(Plett, 2004)

Alguns desses modelos são complexos, o que os torna difíceis de implementar em aplicações em tempo real. Modelos polinomiais estão entre os modelos mais usados, onde a ordem

pode chegar a nove (Yasser Diab, 2017). Quanto maior a ordem do polinômio, mais preciso é o modelo, porém os requisitos computacionais também aumentam e consequentemente a resposta do sistema fica mais lenta. Alguns outros modelos são propostos com base na combinação de funções exponenciais e logarítmicas, dentre eles, (Farag, 2013), (tao et al., 2006), (Kong Soon Ng, 2009). De fato, o modelo de Weng apresentado em (Plett, 2004) é comprovadamente mais preciso do que modelos polinomiais e rastreia o aspecto dinâmico da bateria, mas apresenta um grande número de parâmetros. É claro que essa comprovação serve para o modelagem feita a partir de medições obtidas por (Plett, 2004), e não se aplica indubitavelmente ao nosso modelo.

3.2.3 Implementação do Método de Integral da Corrente

A integral da corrente é o método mais comum de estimativa de SoC para aplicações de consumo de energia de baterias. O princípio simples usado na contagem de Coulombs é que o número de elétrons transferidos para carregar a bateria é igual ao número de elétrons transferidos para descarregar a bateria (tao et al., 2006). Portanto, o número máximo de elétrons que são transferíveis em torno da carga é igual à capacidade nominal em Ampères-segundos.

$$\text{SoC} = \text{SoC}_0 + \frac{\eta}{C_n} \times \int_0^t I_{\text{bat}}(t) dt \quad (3.1)$$

Sendo SoC_0 o valor inicial do SoC, η o coeficiente de eficiência de Coulomb que assume o valor de 1 para descarga e 0,992 para carga.

Este método pode ser implementado facilmente em um sistema embarcado utilizado a equação 2.26 discretizada.

$$\text{SoC}_k = \text{SoC}_{k-1} + \frac{\eta i_k \delta t}{C_n} + w_k \quad (3.2)$$

3.2.4 Implementação do Filtro de Kalman (KF)

O Filtro de Kalman clássico foi introduzido pela primeira vez por Rudolph E. Kalman. A finalidade do filtro de Kalman em tempo discreto é fornecer a solução recursiva de forma fechada para a estimação de sistemas dinâmicos lineares em tempo discreto, que podem ser descritos por equações da forma (Jouni Hartikainen, 2011):

$$x_{k+1} = A_k \times x_k + w_k \quad (3.3)$$

$$y_{k+1} = C_k \times x_k + v_k \quad (3.4)$$

O filtro de Kalman tem duas etapas: a etapa de previsão, na qual o próximo estado do sistema é previsto, dadas as medições anteriores, e a etapa de atualização, na qual o estado atual do sistema é estimado, dada a medição nesse intervalo de tempo. Essas duas etapas são traduzidas da seguinte maneira:

- Previsão KF

- Propagação do estado estimado:

$$\mathbf{x}_{k+1}^- = \mathbf{A}_k \mathbf{x}_k^+ + \mathbf{B}_k \mathbf{I}_t(k) \quad (3.5)$$

- Propagação do erro de covariância:

$$\mathbf{P}_{k+1}^- = \mathbf{A}_k \mathbf{P}_k^+ \mathbf{A}_k^T + \mathbf{Q}_k \quad (3.6)$$

- Correção KF

- Cálculo do ganho de Kalman:

$$\mathbf{K}_k = \mathbf{P}_{k+1}^- \mathbf{C}_k^T [\mathbf{C}_k \mathbf{P}_{k+1}^- \mathbf{C}_k^T + \mathbf{R}_k]^{-1} \quad (3.7)$$

- Atualização do erro de covariância:

$$\mathbf{P}_{k+1}^+ = \mathbf{P}_{k+1}^- - \mathbf{K}_k \mathbf{C}_k \mathbf{P}_{k+1}^- \quad (3.8)$$

- Atualização do estado estimado:

$$\mathbf{x}_{k+1}^+ = \mathbf{x}_{k+1}^- + \mathbf{K}_k [\mathbf{V}(k) - \mathbf{U}_t(k)] \quad (3.9)$$

Em se tratando de sistemas não lineares, como uma bateria, o filtro de Kalman tradicional é deficiente, pois não faz uso de nenhuma técnica de linearização para estimar os estados do sistema e acaba por não convergir conforme o número de iterações cresce. Desta forma, o filtro de Kalman estendido é uma boa alternativa considerando-se que este utiliza séries de Taylor em associação ao Jacobiano para linearizar o sistema em função de um ponto de operação. Neste caso, o ponto de operação seria o SoC, a temperatura e a corrente, e a cada iteração do filtro, teríamos um novo ponto de operação.

3.2.5 Implementação do Filtro de Kalman Estendido (EKF)

O primeiro passo para implementar o EKF é definir o sistema em espaço de estados. Mas para isso é preciso definir as equações do sistema que fornecerão as variáveis de estado.

A primeira variável de estado, e com certeza a de maior importância, é o SoC, que pode ser obtido a partir do método de contagem de Coulombs pela integração da corrente medida.

$$\text{SoC} = \text{SoC}_0 + \zeta \times \int_0^t i(t) dt; \quad (3.10)$$

sendo $\zeta = \frac{1}{3600 \times C}$, SoC_0 é o SoC inicial, e C a capacidade da bateria em Ah.

A Equação 3.10 não pode ser diretamente usada para calcular o SoC da bateria por dois motivos. Primeiro este método é diretamente ligado a medição da corrente, que pode conter erros de medição e ruído excessivo. Sendo assim, os erros e o ruído se acumulariam no cálculo do SoC afetando a exatidão da medição. Segundo, o SoC inicial da bateria pode não ser conhecido.

A partir do modelo de circuito equivalente na Figura 9, e sabendo que a soma das tensões em uma malha é igual a zero e que a corrente que passa pelo ramo RC_1 é igual a corrente que passa pelos ramos RC_2 e RC_3 , então as seguintes equações podem ser obtidas:

$$y(k) = U_t(t) = \text{OCV}(\text{SoC}) - U_1(t) - U_2(t) - U_3(t) - R_0 \times i(k) \quad (3.11)$$

$$i = \frac{v_1}{R_1} + C_1 \frac{d}{dt} v_1 = \frac{v_2}{R_2} + C_2 \frac{d}{dt} v_2 = \frac{v_3}{R_3} + C_3 \frac{d}{dt} v_3 \quad (3.12)$$

sendo U_t a tensão no terminal da bateria; i a corrente da bateria; R_0, R_1, R_2, C_1, C_2 e R_3, C_3 , os parâmetros da bateria que refletem o comportamento dinâmico da bateria e sua capacidade.

A partir das Equações 3.10, 3.11 e 3.12, tem-se as Equações Diferenciais 3.13, 3.14, 3.15 e 3.16, as quais originam os estados do sistema.

$$\frac{d}{dt} \text{SoC} = 0 + \frac{\eta}{C_n} i(t); \quad (3.13)$$

$$\frac{d}{dt} v_1 = -\frac{v_1}{R_1 \times C_1} + \frac{i}{C_1}; \quad (3.14)$$

$$\frac{d}{dt} v_2 = -\frac{v_2}{R_2 \times C_2} + \frac{i}{C_2}; \quad (3.15)$$

$$\frac{d}{dt} v_3 = -\frac{v_3}{R_3 \times C_3} + \frac{i}{C_3}; \quad (3.16)$$

E de acordo com a equação da resposta ao degrau de um circuito RC obtida em 2.19, outra forma de representar tais equações seria conforme definido em 2.20, 2.21 e 2.22.

Logo, a equação de espaço de estado pode ser expressa como:

$$\begin{bmatrix} \dot{\text{SoC}} \\ \dot{u}_1 \\ \dot{u}_2 \\ \dot{u}_3 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & -\frac{\Delta t}{R_1 C_1} & 0 & 0 \\ 0 & 0 & -\frac{\Delta t}{R_2 C_2} & 0 \\ 0 & 0 & 0 & -\frac{\Delta t}{R_3 C_3} \end{bmatrix} * \begin{bmatrix} \text{SoC}(t) \\ u_1(t) \\ u_2(t) \\ u_3(t) \end{bmatrix} + \begin{bmatrix} \frac{\eta_i \Delta t}{C} \\ \frac{\Delta t}{C_1} \\ \frac{\Delta t}{C_2} \\ \frac{\Delta t}{C_3} \end{bmatrix} I(t); \quad (3.17)$$

sendo os estados do sistema $\dot{\mathbf{x}} = \begin{pmatrix} \text{SoC} & u_1 & u_2 & u_3 \end{pmatrix}^t$.

Reescrevendo o espaço de estados com base na equação da resposta ao degrau e discretizando o espaço de estados obtido na Equação 3.17, tem-se o seguinte sistema em espaço de estados discreto (Cheng, 2014).

$$\begin{bmatrix} \text{SoC}(k+1) \\ u_1(k+1) \\ u_2(k+1) \\ u_3(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \exp(-T_s/\tau_1) & 0 & 0 \\ 0 & 0 & \exp(-T_s/\tau_2) & 0 \\ 0 & 0 & 0 & \exp(-T_s/\tau_3) \end{bmatrix} * \begin{bmatrix} \text{SoC}(k) \\ u_1(k) \\ u_2(k) \\ u_3(k) \end{bmatrix} + \begin{bmatrix} \frac{\eta T_s}{C_n} \\ R_1(1 - \exp(-T_s/\tau_1)) \\ R_2(1 - \exp(-T_s/\tau_2)) \\ R_3(1 - \exp(-T_s/\tau_3)) \end{bmatrix} I(k) + W_k \quad (3.18)$$

$$y_k(k) = u_t = u_{oc}(\text{SoC}(k)) - u_3(k) - u_2(k) - u_1(k) - R_0 \times I(k) + V_k, \quad (3.19)$$

Como o EKF é uma versão não-linear do filtro de Kalman clássico que lineariza o sistema em torno do valor médio de cada estado, então a não-linearidade do sistema é aproximada pela versão linearizada do modelo original em volta do último estado estimado. Assim, para um espaço de estados não-linear, tem-se:

$$\mathbf{x}(k+1) = f(\mathbf{x}(k), \mathbf{u}(t)) + \mathbf{w}(k) \quad (3.20)$$

$$\mathbf{y}(k) = \mathbf{h}(\mathbf{x}(k)) + \mathbf{v}(k) \quad (3.21)$$

Dessa maneira, as matrizes A_k , B_k , C_k e D_k podem ser determinadas a partir da linearização do sistema apresentado a seguir, mas lembrando que os parâmetros do modelo

são dependentes do SoC, temperatura, corrente e tempo.

$$A_k = \frac{\delta f}{\delta x} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \exp(-T_s/\tau_1) & 0 & 0 \\ 0 & 0 & \exp(-T_s/\tau_2) & 0 \\ 0 & 0 & 0 & \exp(-T_s/\tau_3) \end{bmatrix} \quad (3.22)$$

$$B_k = \frac{\delta f}{\delta u} = \begin{bmatrix} \frac{\eta T_s}{C_n} \\ R_1(1 - \exp(-T_s/\tau_1)) \\ R_2(1 - \exp(-T_s/\tau_2)) \\ R_3(1 - \exp(-T_s/\tau_3)) \end{bmatrix} \quad (3.23)$$

$$C_k = \frac{\delta h}{\delta x} = \begin{bmatrix} \frac{\delta U_{oc}}{\delta SoC}|_{SoC=SoC_{-1}} & -1 & -1 & -1 \end{bmatrix} \quad (3.24)$$

$$D_k = \frac{\delta h}{\delta u} = [-R_0(k)] \quad (3.25)$$

Na sequência, se faz necessário realizar a definição dos valores iniciais dos estados e a matriz de covariância inicial, por exemplo, no caso deste trabalho foram utilizadas as matrizes a seguir:

$$X_0 = \begin{bmatrix} SoC(0) \\ U_1(0) \\ U_2(0) \\ U_3(0) \end{bmatrix} \quad (3.26)$$

$$P_0 = \begin{bmatrix} \sigma_{SoC}^2 & 0 & 0 & 0 \\ 0 & \sigma_{U_1}^2 & 0 & 0 \\ 0 & 0 & \sigma_{U_2}^2 & 0 \\ 0 & 0 & 0 & \sigma_{U_3}^2 \end{bmatrix} \quad (3.27)$$

Por fim, o último passo consiste na definição dos parâmetros $R_0, R_1, R_2, R_3, \tau_1, \tau_2$ e τ_3 que podem ser obtidos como visto na seção 3.2.1. Também é necessário determinar uma tabela de parâmetros em relação ao SoC e a temperatura (*Lookup table*) e definir a equação que relaciona a tensão em circuito aberto (OCV) e o SoC. Para determinar todas essas equações, são necessários testes de carga-reposou ou descarga-reposou.

O EKF é um algoritmo recursivo, no qual os estados são estimados para cada amostra de tempo, e a implementação é dividida em duas grandes etapas, Previsão e Correção, e cada uma destas é subdividida em mais algumas etapas. Os sobrescritos (-) e (+) indicam a estimativa anterior e posterior, respectivamente. Similarmente ao Filtro de Kalman, essas etapas estão representadas a seguir (Cheng, 2014).

- Previsão EKF

- Propagação do estado estimado:

$$\mathbf{x}_{k+1}^- = \mathbf{A}_k \mathbf{x}_k^+ + \mathbf{B}_k \mathbf{I}_t(k) \quad (3.28)$$

- Propagação do erro de covariância:

$$\mathbf{P}_{k+1}^- = \mathbf{A}_k \mathbf{P}_k^+ \mathbf{A}_k^T + \mathbf{Q}_k \quad (3.29)$$

- Correção EKF

- Cálculo do ganho de Kalman:

$$\mathbf{K}_k = \mathbf{P}_{k+1}^- \mathbf{C}_k^T [\mathbf{C}_k \mathbf{P}_{k+1}^- \mathbf{C}_k^T + \mathbf{R}_k]^{-1} \quad (3.30)$$

- Atualização do erro de covariância:

$$\mathbf{P}_{k+1}^+ = \mathbf{P}_{k+1}^- - \mathbf{K}_k \mathbf{C}_k \mathbf{P}_{k+1}^- \quad (3.31)$$

- Atualização do estado estimado:

$$\mathbf{x}_{k+1}^+ = \mathbf{x}_{k+1}^- + \mathbf{K}_k [\mathbf{V}(k) - \mathbf{U}_t(k)] \quad (3.32)$$

Sendo $\mathbf{V}(k)$ a tensão medida e $\mathbf{U}_t(k)$ a tensão estimada. $\mathbf{R}$ é a matriz de covariância do ruído de medição e $\mathbf{Q}$ é a matriz de covariância do ruído do processo.

Resumindo, o EKF/KF possui basicamente os passos a seguir:

1. Determinação do modelo de circuito elétrico equivalente;
2. Estimação dos parâmetros em relação ao SoC;
3. Determinação da função de observação $\text{OCV} \times \text{SoC}$;
4. Determinação dos modelos do processo e da medição;
5. Determinar a variância do processo e a variância de medição;
6. Implementação das equações do EKF/KF discutidas anteriormente nesta seção.

4 Resultados

Neste capítulo são apresentados os resultados obtidos com a implementação da metodologia proposta. Todos os ensaios para modelagem e estimação do estado de carga foram realizados tendo como sistema principal uma bateria de Lítio (LiFePO_4) apresentada na Seção 3.1.1, mas também uma bateria de Chumbo-Ácido que foi utilizada para validar a metodologia e métodos para estimação de parâmetros e SoC. Dentre os principais resultados obtidos pode-se citar o procedimento para determinação de um modelo de circuito elétrico equivalente da bateria que fornece uma resposta similar a do sistema real, além da estimação de seus parâmetros. Na sequência são apresentados os resultados obtidos empregando o método de estimação de SoC baseado em Filtro de Kalman Estendido que apresentou resultados superiores em comparação com o filtro de Kalman tradicional e o método de integral da corrente.

4.1 Determinação do Modelo de Circuito Equivalente e Estimação dos Parâmetros

Seguindo as etapas descritas na Seção 3.2.1, foi possível obter os resultados referentes a estimação dos parâmetros da bateria, os quais são apresentados a seguir. O objetivo principal da estimação dos parâmetros é definir um modelo da bateria preciso para estimar o SoC por meio do Filtro de Kalman.

4.1.1 Ensaio de Descarga Pulsada para Bateria de Chumbo-Ácido

Para a bateria de Chumbo-Ácido, os resultados referentes ao ensaio de descarga pulsada estão representados em 23.




Figura 23 – Modelo da bateria para simulação no Simulink.

4.1.2 Ensaio de Descarga Pulsada para Bateria de LiFePO4 - Modelo Simulado e Experimental

A seguir serão apresentados os resultados de simulação e experimentais obtidos para a modelagem e estimação dos parâmetros da bateria de LiFePO4.

O modelo de Simulink utilizado para representar eletricamente a bateria e para gerar o ensaio de descarga pulsada pode ser observado na Figura 24. O resultado referente a este ensaio está representado na Figura 25.




Figura 24 – Modelo da bateria para simulação no Simulink.




Figura 25 – Resultados de simulação para descarga pulsada.

Já a Figura 26, representa o ensaio de descarga pulsada utilizando a bancada de testes apresentada na seção 3.1.




Figura 26 – Resultados experimentais para descarga pulsada.

4.1.3 Identificação dos Pulsos de Descarga e Repouso Bateria de LiFePO4

Tendo os dados de simulação e experimental é possível iniciar o processo de identificação dos pulsos para determinação do número de ramos RC do circuito equivalente, e em seguida, estimar os parâmetros do modelo. Temos na Figura 27 a identificação dos pulsos para o ensaio de descarga pulsada a temperatura de 10° C. E na Figura 28 representa-se a identificação dos pulsos para os dados experimentais. Os pulsos são identificados de maneira simples, apenas considerando o sinal de corrente. Ou seja, quando o valor da

corrente ultrapassa 0,1A é considerado que houve um pulso de descarga. Isto pode ser feito utilizando o método "*createPulses()*" da classe "*Battery.PulseSequence*".




Figura 27 – Identificação dos Pulsos para o Ensaio de 10° C - Simulação.




Figura 28 – Identificação dos Pulsos para o Ensaio de 10° C - Experimental.

4.1.4 Identificação do Número de Ramos RC para Bateria de Chumbo-Ácido

Durante a fase de validação da metodologia, tendo como elemento principal a bateria de chumbo-ácido, o resultado obtido, até a qualificação deste trabalho, para o número de ramos RC pode ser constatado nas Figuras 29 e 30, onde a primeira representa a

aproximação para um modelo com 1 ramo RC, e a segunda a aproximação para 2 ramos RC. Desta forma, o modelo com 2 ramos RC foi escolhido.




Figura 29 – Modelo com 1 ramo RC para bateria de Chumbo-Ácido.




Figura 30 – Modelo com 2 ramos RC para bateria de Chumbo-Ácido.

4.1.5 Estimação dos Parâmetros do Modelo para Bateria de Chumbo-Ácido

A determinação dos parâmetros para a bateria de Chumbo seguiu a mesma metodologia encontrada em (Jackey, 2013), e que foi utilizada para desenvolver a classe "Battery.Pulse" utilizada para estimar os parâmetros da bateria de LiFePO_4 . Os resultados da estimação dos parâmetros podem ser analisados nas Figuras 31 e 32.




Figura 31 – Resistências estimadas para a bateria de Chumbo-Ácido.




Figura 32 – Constantes de tempo estimadas para a bateria de Chumbo-Ácido.

4.1.6 Identificação do Número de Ramos RC para Bateria de LiFePO4 - Modelo Simulado e Experimental

Para a bateria de LiFePO4, analisando as Figuras 33 (Simulação) e 34 (Experimental), e visando a determinação de um modelo que possua o menor erro residual, pode-se concluir

que o circuito equivalente com 3 ramos RCs permite representar mais fielmente o modelo simulado, tanto para os dados simulados quanto para os dados reais.

Na Figura 33 é possível notar que conforme o numero de ramos RC aumenta, a aproximação para os primeiros 60 segundos, que representa a dinâmica mais rápida do sistema, possui um resíduo de aproximação maior. Este comportamento pode ser atribuído ao longo período de repouso, que pode ser constatado no gráfico localizado no canto superior esquerdo. Desta forma, a medida que o número de ramos RC é incrementado, a dinâmica mais lenta do sistema vai ficando cada vez mais significativa, fazendo assim, com que a análise nos 60 primeiros segundos possua um resíduo maior.

Já para a Figura 34, quanto maior o número de ramos RCs, melhor a aproximação. A afirmação feita anteriormente para o sistema de simulação não é verídica para este caso, tendo em vista que a porção que representa a dinâmica mais lenta do sistema não possui tamanha importância a ponto da dinâmica mais rápida não influenciar de maneira significativa na aproximação. Isto ocorre, pois em se tratando de uma bateria real, o tempo para que a tensão estabilize é bem maior que em um sistema simulado.




Figura 33 – Determinação do Número de Ramos RC que o Circuito Equivalente irá possuir - Simulação.




Figura 34 – Determinação do Número de Ramos RC que o Circuito Equivalente irá possuir - Experimental.

4.1.7 Otimização dos Parâmetros Estimados para Bateria de LiFePO4 - Modelo Simulado e Experimental

A determinação dos parâmetros foi feita para cada curva de repouso e foi possível obter dez valores para cada parâmetro, tendo em vista que cada curva de repouso representa o comportamento dinâmico dos elementos do sistema. O algoritmo implementado realiza um ajuste de curvas dos dados fornecidos (Curva de descarga pulsada), e na sequência realiza uma primeira estimativa dos parâmetros. Então, usando o *Simulink Design Optimization* - SDO, os parâmetros estimados inicialmente podem ser otimizados tendo como base o método dos mínimos quadrados não lineares e o modelo de circuito equivalente com 3 ramos RCs. Ou seja, o método dos mínimos quadrados implica em minimizar os quadrados dos resíduos e procura encontrar o melhor ajuste para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre o valor estimado e os dados observados (tais diferenças são chamadas resíduos).

As Figuras 35 e 36 permitem representar o processo de otimização das curvas de descarga geradas pelo algoritmo descrito em 3.2.1 utilizado para estimar os parâmetros para que estas sejam o mais próximo possível dos dados simulados ou reais. É possível verificar que houve uma redução considerável do erro médio entre os dados de entrada do método de estimação e a curva gerada internamente ao método, sendo 6,88 mV para os dados de simulação, e 12,17 mV para os dados reais. Isto pode ser constatado analisando a diferença entre a curva em amarelo, que representa a estimação inicial antes da otimização utilizando o SDO, e a curva em vermelho, que representa a otimização da estimação inicial

utilizando o SDO.




Figura 35 – Otimização da Curva de Descarga Gerada para os Dados de Simulação.




Figura 36 – Otimização da Curva de Descarga Gerada para os Dados Experimentais.

4.1.7.1 Modelo Simulado

Finalmente, os parâmetros estimados considerando os dados obtidos através do modelo simulado para temperatura de 10°C antes da otimização e depois da otimização estão representados nas Figuras 37 e 38, respectivamente.




Figura 37 – Parâmetros Estimados Antes da Otimização - 10°C.




Figura 38 – Parâmetros Estimados Depois da Otimização - 10°C.

Seguindo as mesmas etapas realizadas para as temperaturas de 25°C e 40°C, obtêm-se os parâmetros representados pelas Figuras 39 e 40, respectivamente.




Figura 39 – Parâmetros Estimados Depois da Otimização - 25°C - Simulação.




Figura 40 – Parâmetros Estimados Depois da Otimização - 40°C - Simulação.

Para utilização no método de estimação do SoC, os valores estimados para cada parâmetro em cada temperatura serão armazenados em *Look up Tables*, nas quais os valores intermediários, que não existem nos dados estimados, serão calculados por meio de interpolação polinômial.

4.1.7.2 Modelo Experimental

Os resultados obtidos para os dados experimentais podem ser constatados abaixo.




Figura 41 – Parâmetros Estimados Depois da Otimização - 10°C - Experimental.

Seguindo as mesmas etapas realizadas anteriormente para as temperaturas de 25°C e 40°C, teremos os parâmetros representados pelas Figuras 39 e 40, respectivamente.




Figura 42 – Parâmetros Estimados Depois da Otimização - 25°C - Experimental.




Figura 43 – Parâmetros Estimados Depois da Otimização - 40°C - Experimental.

Da mesma forma que para os parâmetros estimados para os dados de simulação, os parâmetros para os dados reais também serão utilizados como *Look up Tables*.

4.2 Determinação do Modelo de Observação OCV-SoC

De acordo com a seção 3.2.2, após realizar o ajuste de curvas tendo com base as quatro equações propostas, a que proporcionou o menor erro foi a equação polinomial de 7º grau. Esta comparação foi feita utilizando a função de "*Curve Fitting*" do Matlab, em que cada equação é inserida no campo "*Custom Equation*" desta funcionalidade e o ajuste dos dados eram analisados para identificar a equação com menor resíduo. A seguir serão apresentados os resultados de simulação e experimental para determinação do modelo de observação, sendo $x = \text{SoC}$.

4.2.1 Modelo Simulado

A Figura 44 representa as curvas de tensão de circuito aberto em relação ao estado de carga para o modelo de simulação nos valores de temperatura de 10°C, 25°C e 40°C. Foi constatado que as curvas não possuem distinção com relação a mudança de temperatura do ambiente devido ao modelo de térmico da bateria utilizado no Simulink não ser representativo.




Figura 44 – Modelo de Simulação OCV x SoC para 10 °C, 25 °C e 40 °C.

- Equação para temperatura de 10 °C (Simulação):

$$OCV(x) = p7 * x^7 + p6 * x^6 + p5 * x^5 + p4 * x^4 + p3 * x^3 + p2 * x^2 + p1 * x + p0 \quad (4.1)$$

Com $p7 = 164.7$, $p6 = -615.6$, $p5 = 936.8$, $p4 = -747.4$, $p3 = 335.2$, $p2 = -84.25$, $p1 = 11.19$, $p0 = 2.745$.

- Equação para temperatura de 25 °C (Simulação):

$$OCV(x) = p7 * x^7 + p6 * x^6 + p5 * x^5 + p4 * x^4 + p3 * x^3 + p2 * x^2 + p1 * x + p0 \quad (4.2)$$

Com $p7 = 163.7$, $p6 = -611.6$, $p5 = 930.4$, $p4 = -742.3$, $p3 = 333.3$, $p2 = -83.93$, $p1 = 11.19$, $p0 = 2.743$.

- Equação para temperatura de 40 °C (Simulação):

$$OCV(x) = p7 * x^7 + p6 * x^6 + p5 * x^5 + p4 * x^4 + p3 * x^3 + p2 * x^2 + p1 * x + p0 \quad (4.3)$$

Com $p7 = 170.7$, $p6 = -636$, $p5 = 930.4$, $p4 = -765.2$, $p3 = 341.4$, $p2 = -85.32$, $p1 = 11.27$, $p0 = 2.743$.

4.2.2 Modelo Experimental

Em relação aos ensaios experimentais, os dados relativos a OCV x SoC podem ser visualizados nas Figuras 26 e ?? ou seja, para cada valor de SoC (10%, 20% ...) um valor de tensão foi coletado da curva de repouso do ensaio de descarga pulsada. Depois de ter um valor de tensão para cada valor de SoC, ajustou-se uma função aos dados obtidos. Comparando as curvas obtidas a partir de ensaios experimentais com os as curvas de OCV x SoC, da Figura 45, fornecidas pelo manual do fabricante para cada temperatura, pode-se perceber que o comportamento é similar. Conforme a temperatura aumenta, o valor de tensão para representar um mesmo valor de SoC também aumenta.




Figura 45 – Curvas da relação entre OCV e SoC para diversas temperaturas fornecidas pelo manual do fabricante. [Adaptada de (A123 Systems, 2014)]

Para a representação das curvas ilustradas na Figura 46 foi escolhida uma função polinomial de 7º grau, tendo em vista que no ajuste de curvas, foi a que obteve o menor erro de aproximação.

Verificou-se que OCV e SoC têm correlações positivas não lineares. Quando o SoC está acima de 80%, o OCV da bateria de LiFePO diminui rapidamente com a descarga da bateria. E em seguida entra em um período estável. Quando o SoC varia de 80% a 20%, a OCV diminuiu lentamente com a bateria sendo descarregada. Quando o SoC está abaixo de 20%, a reação eletroquímica no interior da bateria é intensa e o OCV da bateria cai rapidamente durante o período de descarga.




Figura 46 – Modelo Experimental OCV x SoC para 10 °C, 25 °C e 40 °C.

- Equação para temperatura de 10 °C (Experimental):

$$OCV(x) = p7 * x^7 + p6 * x^6 + p5 * x^5 + p4 * x^4 + p3 * x^3 + p2 * x^2 + p1 * x + p0 \quad (4.4)$$

Com $p7 = 340$, $p6 = -1274$, $p5 = 1939$, $p4 = -1536$, $p3 = 674.6$, $p2 = -84.25$, $p1 = 11.19$, $p0 = 2.238$.

- Equação para temperatura de 25 °C (Experimental):

$$OCV(x) = p7 * x^7 + p6 * x^6 + p5 * x^5 + p4 * x^4 + p3 * x^3 + p2 * x^2 + p1 * x + p0 \quad (4.5)$$

Com $p7 = 332.9$, $p6 = -1246$, $p5 = 1893$, $p4 = -1498$, $p3 = 657.7$, $p2 = -157.8$, $p1 = 19.06$, $p0 = 2.342$.

- Equação para temperatura de 40 °C (Experimental):

$$OCV(x) = p7 * x^7 + p6 * x^6 + p5 * x^5 + p4 * x^4 + p3 * x^3 + p2 * x^2 + p1 * x + p0 \quad (4.6)$$

Com $p7 = 323.9$, $p6 = -1219$, $p5 = 1863$, $p4 = -1482$, $p3 = 654.4$, $p2 = -157.7$, $p1 = 19.09$, $p0 = 2.422$.

4.3 Estimação do SoC e Comparação entre os Métodos

Uma etapa importante tanto para implementação do KF, quanto para o EKF, consiste em determinar propriamente as variâncias do processo e da medição. À título de definição do valor inicial da variância do processo foi considerado que os estados do sistema não possuem correlação cruzada. Então, o valor assumido para $\mathbf{Q}$ foi de 10^{-6} . Em resumo, a variância nos diz o quão distante estão os dados estimados da média, ou seja, a variabilidade dos dados.

Para a precisão da medição da tensão foram considerados os dados de especificação do datalogger fabricado pela empresa *Keysight Technologies*, que é de $0,0035 \pm 0,0005$ (%de leitura + %da faixa). Sendo assim, a variância da medição para a tensão nominal (3,3V) é igual a soma das variâncias para a leitura e para a faixa (Wahlstrom, 2010).

$$\sigma_{\text{medicao}}^2 = \sigma_{\text{leitura}}^2 + \sigma_{\text{faixa}}^2 = (3,3 * 35 * 10^{-4})^2 + (3,3 * 5 * 10^{-4})^2 = 1,7 * 10^{-4} \quad (4.7)$$

A seleção das matrizes de covariância $\mathbf{Q}$, $\mathbf{R}$ e $\mathbf{P}_0$ pode ter um efeito significativo no desempenho da estimativa de um filtro de Kalman. A seleção de $\mathbf{P}_0$ é acoplada ao estado inicial e afeta a convergência inicial do filtro. Em muitas situações, o efeito de $\mathbf{P}_0$ não é significativo e, na verdade, é muitas vezes arbitrariamente inicializado para uma matriz de identidade, por questões de simplicidade.

Os efeitos de $\mathbf{Q}$ e $\mathbf{R}$ são muito mais significativos e afetam o desempenho geral do filtro. Uma maneira básica de pensar em $\mathbf{Q}$ e $\mathbf{R}$ é que eles são fatores de ponderação entre as equações de previsão (estado) e as equações de medição (saída). Essa relação é mostrada dentro da equação de ganho de Kalman.

Considerar um $\mathbf{Q}$ maior equivale a considerar incerteza maior nas equações de estado, o que equivale a confiar menos no resultado dessas equações, o que efetivamente significa que o filtro deve se corrigir mais com a atualização da medição. Da mesma forma, considerar um $\mathbf{R}$ maior equivale a considerar uma incerteza maior na medição, o que equivale a confiar menos na medida, o que efetivamente significa que o filtro deve corrigir menos com a atualização da medição.

Por fim, o último passo está fundamentado na implementação do filtro de Kalman propriamente dito, utilizando as equações para predição e atualização da estimação dos estados. Abaixo temos os resultados para estimação do SoC para cada valor de temperatura proposto.

4.3.1 Resultados Obtidos para a Bateria de Chumbo-Ácido

A estimação do SoC utilizando EKF para a bateria de Chumbo é representada na Figura 47. Esta curva representa a carga da bateria por um pouco mais de uma hora, a

corrente de 10A e a temperatura controlada de 25 °C. A utilização do EKF tendo como sistema principal a bateria de chumbo possibilitou o aperfeiçoamento do método para utilização tendo como sistema a bateria de LiFePO₄.




Figura 47 – Estimação do SoC para bateria de Chumbo-Ácido.

4.3.2 Resultados Obtidos para a Bateria de LiFePO₄

4.3.2.1 Referência Utilizada para Comparação

O método de referência utilizado como base de comparação para o EKF e KF é o *Coulomb Counting*, por ser um dos métodos mais utilizados em equipamentos para estimação do SoC. Vale salientar que este método possui incertezas de estimação que não foram mensuradas, e que, portanto, o resíduo de estimação do EKF e KF é meramente teórico, e poderia ser menor, ou até mesmo maior, se comparado com um equipamento de estimação calibrado e regulamentado. Outro motivo para uso de tal método como referência, foi a ausência de um equipamento de estimação do SoC com baixa incerteza.

4.3.2.2 Parâmetros para o Modelo de Simulação

Começando com o modelo de simulação, onde os parâmetros foram obtidos como explicado anteriormente, para que o método de estimação possa calcular os parâmetros do modelo em valores intermediários do SoC, por exemplo, 0,15, é necessário que o ajuste dos dados seja realizado. Para realizar a estimativa para os dados de simulação, os dados dos parâmetros foram ajustados para uma equação polinomial que pode variar o grau entre 5 e 7 de acordo com cada parâmetro.

As Figuras 48, 50 e 49 representam os parâmetros para as 3 temperaturas propostas e para um modelo parametrizado a partir de dados de simulação. Após cada Figura, temos as equações equivalentes dos parâmetros representados.

As resistências internas para cada valor de temperatura têm uma correlação negativa não linear com SoC. Com a descarga da bateria, a concentração de íons carregados na bateria diminui e a resistência ôhmica interna aumenta. A resistência ôhmica aumenta acentuadamente quando a bateria é descarregada a uma profundidade de SoC inferior a 20%.

Para as resistências dos ramos RCs, é possível observar que possuem uma correlação negativa não linear com o SoC, e que as resistências 1 e 2 são mais sensíveis a temperatura e ao valor do SoC que a resistência 3. Até 50% do SoC, a sensibilidade a temperatura é bastante relevante para as resistências 1 e 2, mas para resistência 3, até 30%. Após estes valores, apenas o SoC importa significativamente.




Figura 48 – Gráfico das resistências do modelo de simulação.

A tabela 5 possui o valor de todas as constantes para a equação polinômial de 7º grau que representa o comportamento de cada uma das resistências para os três valores de temperaturas estudados.

Considerando uma equação polinomial de n graus, temos:

$$p_n * x^n + p_{n-1} * x^{n-1} + \dots p_2 * x^2 + p_1 * x + p_0 \quad (4.8)$$

Tabela 5 – Dados para Ajuste de Curvas das Resistências

	p_8	p_7	p_6	p_5	p_4	p_3	p_2	p_1	p_0
R_0 (10°C)	0	0	-7.332e-05	0.0004385	-0.0004086	-0.0006148	0.0006975	-5.771e-05	0.001813
R_0 (25°C)	0	0	-3.15e-05	0.0004785	-0.0006424	-0.0006991	0.001002	-8.129e-05	0.001774
R_0 (40°C)	0	0.0004162	-0.0009876	-0.0002172	0.00198	-0.001285	-0.0004086	0.0004184	0.001883
R_1 (10°C)	0	0	-0.0006357	0.001186	0.001062	-0.002785	0.00136	-0.0003907	0.0009099
R_1 (25°C)	0	0	0	0.0001955	-0.0003827	-0.0002123	0.001025	-0.0009926	0.001105
R_1 (40°C)	-0.0008717	0.001624	0.002155	-0.005031	-8.854e-05	0.003668	-0.0006384	-0.001421	0.001322
R_2 (10°C)	0	0	-0.0001278	0.0002005	0.0002597	-0.0005093	0.0001547	-1.662e-05	0.0002396
R_2 (25°C)	0	0	-0.000809	0.001054	0.001864	-0.002231	-0.0002827	0.0003108	0.0002314
R_2 (40°C)	0	-0.0001062	5.123e-05	0.0003643	-6.815e-05	-0.0003978	0.0001083	-2.414e-05	0.0002677
R_3 (10°C)	0	-0.0007259	0.001137	0.00147	-0.00214	-0.0007051	0.000937	2.819e-05	8.379e-05
R_3 (25°C)	0	-0.001101	0.001585	0.002508	-0.00311	-0.001481	0.00147	0.0001288	6.773e-05
R_3 (40°C)	0	0	0	0.0001198	0.003194	-0.008433	0.00772	-0.002928	0.000486

Já em relação as capacitâncias, elas tem uma correlação com o SoC inversamente proporcional a relação das resistências com o SoC, tendo em vista que conforme a bateria é carregada, as capacitâncias formadas internamente, também crescem em energia. Por outro lado, as contantes de tempo tendem a estabilizar em um valor após 10% de SoC, diminuindo a sensibilidade a alterações no SoC ou na temperatura.




Figura 49 – Gráfico das constantes de tempo do modelo de simulação.




Figura 50 – Gráfico das capacitâncias do modelo de simulação.

Considerando uma equação polinomial de n graus, temos:

$$p_n * x^n + p_{n-1} * x^{n-1} + ... p_2 * x^2 + p_1 * x + p_0 \tag{4.9}$$

Tabela 6 – Dados para Ajuste de Curvas das Capacitâncias

	p ₇	p ₆	p ₅	p ₄	p ₃	p ₂	p ₁	p ₀
C ₁ (10°C)	0	1431	-243.3	-5160	-1638	3549	7413	8259
C ₁ (25°C)	819.2	731.9	-3397	-2826	1241	2165	6536	8372
C ₁ (40°C)	-2196	2733	8053	-9207	-9495	7595	8437	7456
C ₂ (10°C)	0	6190	2417	-4712	8463	-1.998e+04	4.169e+04	8.022e+04
C ₂ (25°C)	-1.273e+05	1.67e+05	3.724e+05	-4.2e+05	-2.617e+05	2.552e+05	3.724e+04	7.019e+04
C ₂ (40°C)	2.117e+04	4577	-7.951e+04	-1.879e+04	8.02e+04	9014	9491	7.391e+04
C ₃ (10°C)	0	-7.916e+04	1.632e+05	6.284e+04	-2.412e+05	-8.482e+04	5.359e+04	1.02e+06
C ₃ (25°C)	0	-2.391e+05	1.759e+05	5.943e+05	-1.391e+05	-4.32e+05	-1.023e+05	9.891e+05
C ₃ (40°C)	-4.965e+05	3.994e+05	1.686e+06	-1.097e+06	-1.273e+06	4.922e+05	2.07e+05	9.232e+05

4.3.2.3 Estimação do SoC para o Modelo de Simulação

É importante destacar que o algoritmo faz uso da linearização por séries de Taylor em cada ponto, e para isso, necessita do jacobiano da função de observação OCV(SoC). Sendo assim, este é um passo que não deve ser esquecido, tendo em vista que isso que diferencia o EKF do KF. Outro ponto bastante importante é saturar o valor dos parâmetros calculados em 0, para que não se tenha problemas de convergência.

Por fim, as equações do filtro de Kalman e do filtro de Kalman estendido podem ser aplicadas e o SoC pode ser estimado. As Figuras 51, 52 e 53 representam os resultados da estimação para o modelo de simulação. É possível verificar que o EKF é extremamente eficiente comparado com o KF, pois o erro máximo obtido para as temperaturas de 10°C, 25°C e 40°C é de **4,41%**, **4,16%** e **6,66%**, respectivamente. Já para o KF o erro máximo obtido para as temperaturas de 10°C, 25°C e 40°C é de **83,55%**, **21,54%** e **54,78%**, confirmando a tese de que o EKF possui uma estimativa mais exata se comparado com o KF. Pode-se observar também que para a temperatura de 25°C, a estimação do SoC, tanto para o KF quanto para o EKF, obteve um resíduo de estimação menor por estar em torno da temperatura de operação nominal da bateria.




Figura 51 – Gráfico do SoC em função do tempo para temperatura de 10°C e modelo com parâmetros de simulação.




Figura 52 – Gráfico do SoC em função do tempo para temperatura de 25°C e modelo com parâmetros de simulação.




Figura 53 – Gráfico do SoC em função do tempo para temperatura de 40°C e modelo com parâmetros de simulação.

4.3.2.4 Parâmetros para o Modelo Experimental

Para realizar a modelagem do sistema real, foi realizado um ensaio para cada temperatura proposta neste trabalho. O ensaio era composto por uma descarga a 10A durante 6 minutos, e um repouso a 0A durante 2 horas.

As Figuras 54, 55 e 56 representam os parâmetros para as 3 temperaturas propostas e para um modelo parametrizado a partir de dados experimentais. Após cada Figura, temos as equações equivalentes dos parâmetros representados.

Com relação à estimação para os experimentos utilizando uma bateria física, pode-se observar que o comportamento das resistências internas para cada valor de temperatura têm uma correlação negativa não linear com SoC, assim como o resultado obtido para as

estimativas utilizando a bateria modelada. A resistência interna da bateria continua sendo sensível a variações da temperatura e do SoC.

Já para as resistências dos ramos RCs, é possível observar a mesma correlação negativa não linear com o SoC que o resultado obtido para a bateria modelada, mas neste caso, esta correlação vai até o valor de 90% do SoC. As resistências 1 e 2 mostram uma sensibilidade a temperatura e ao SoC bem mais relevante que o resultado obtido para o modelo simulado, sendo importante observar que ambas as resistências 1 e 2 possuem um comportamento crescente para o SoC maior que 90%. Já a resistência 3 demonstrou uma correlação negativa com o SoC e uma baixa sensibilidade com relação a temperatura.




Figura 54 – Gráfico das resistências do modelo experimental.

Em relação as capacitância, pode-se observar que conforme a bateria é carregada, os valores das capacitâncias também acumulam energia, com exceção da capacitância do ramo 2, que apresentou um comportamento não esperado. Apesar deste comportamento, todas as capacitâncias demonstraram sensibilidade tanto ao SoC, quanto a temperatura.

Por fim, as constantes de tempo do modelo de circuito elétrico equivalente apresentaram um resultado esperado, mostrando que a cada vez que um ramo RC é incluído, a constante de tempo desse é maior do que a do anterior, ou seja, a constante de tempo 3 é maior que a constante de tempo 2, que por sua vez é maior que a constante de tempo 1. E todas elas mostraram ter sensibilidade em relação ao SoC e a temperatura, com exceção da constante de tempo 3, que após 20%, não foi mais influenciada pela temperatura.




Figura 55 – Gráfico das capacitâncias do modelo experimental.




Figura 56 – Gráfico das constantes de tempo do modelo experimental.

4.3.2.5 Estimação do SoC para o Modelo Experimental

Os resultados obtidos para a estimação do SoC utilizando o KF e EKF estão representados nas Figuras 57, 58 e 59 representam os resultados da estimação para o modelo de simulação. É possível verificar que o EKF é extremamente eficiente comparado com o KF, pois o erro máximo obtido para as temperaturas de 10°C, 25°C e 40°C é de **3,42%**, **3,19%** e **3,36%**, respectivamente. Já para o KF o erro máximo obtido para as temperaturas de

10°C, 25°C e 40°C é de **33,23%**, **84,82%** e **22,98%**. Para este caso, apenas o EKF obteve um resultado similar ao resultado obtido para o modelo simulado, onde o menor resíduo de estimação foi obtido para a temperatura de 25 °C.




Figura 57 – Gráfico do SoC em função do tempo para temperatura de 10°C e modelo com parâmetros do modelo real.




Figura 58 – Gráfico do SoC em função do tempo para temperatura de 25°C e modelo com parâmetros do modelo real.




Figura 59 – Gráfico do SoC em função do tempo para temperatura de 40°C e modelo com parâmetros do modelo real.

5 Considerações Finais

Neste trabalho foram apresentados os procedimentos realizados de forma preliminar no desenvolvimento de um sistema para estimação do estado de carga de baterias, além do desenvolvimento de um procedimento para modelagem de baterias. A metodologia proposta foi dividida em três atividades principais, nas quais consistem na realização de ensaios de carga e descarga com o objetivo de obter dados para a modelagem e estimação da carga da bateria; determinar o modelo adequado para a bateria e estimar seus parâmetros além de implementar o Filtro de Kalman para a estimação do estado de carga da bateria.

Foi proposta a estimativa do SoC de uma bateria de Lítio baseada em EKF (Filtro de Kalman Estendido). A estimativa do SoC apresentou resultados satisfatórios para os experimentos realizados, os quais permitiram a estimativa recursiva de resistências e o modelo de circuito equivalente da bateria sob análise que contribuiu para a validação dos resultados. O modelo da bateria é peça fundamental para estimação precisa do SoC.

A partir de resultados numéricos, o EKF apresentou convergência na previsão do comportamento dinâmico do sistema conforme apresentado nas Figuras 51, 52, 53, 57, 58 e 59, na qual o erro de covariância convergiu para um valor entre 3% e 6%, mostrando assim a convergência do método. Já o filtro de Kalman tradicional se mostrou impróprio para a estimação do SoC para modelos altamente não lineares como o modelo de uma bateria. Outro ponto importante de se destacar é a escolha das covariâncias do processo (Q) e da medição (R), que neste caso serviram como pesos para determinar que porção do filtro seria mais utilizada. No nosso caso, confiamos cerca de 100 vezes ($Q = 10^{-6}$ e $R = 1,7 * 10^{-4}$) mais na modelagem do sistema e na previsão do valor do SoC a partir do modelo e seus estados, que na correção utilizando as medições. Esta implementação do EKF para estimar o SoC é um dos passos-chave para alcançar o desenvolvimento de um sistema de gerenciamento de baterias aplicado a veículos elétricos a ser desenvolvido em trabalhos futuros.

Referências

- A. Purwadi, A. R. (2014). State of charge estimation method for lithium battery using combination of coulomb counting and adaptive system with considering the effect of temperature. *IEEE International Conf. on Power Engineering and Renewable Energy*. Citado na página 14.
- A. Szumanowski, Y. C. (2008). A unified open circuit voltage model of lithium ion batteries for state of charge estimation and state-of health monitoring. *IEEE Trans. Veh. Technol.* 57. Citado na página 59.
- A123 Systems, L. (2014). *Battery Pack Design, Validation, and Assembly Guide using A123 Systems AMP20m1HD-A Nanophosphate Cells*. Citado 6 vezes nas páginas 9, 19, 39, 44, 45 e 80.
- Aurilio, G. e. a. (2015). A battery equivalent-circuit model and an advanced technique for parameter estimation. *2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC) Proceedings*. Citado 2 vezes nas páginas 15 e 39.
- Ayman, S. E. (2007). Battery management systems for electric vehicle. *International Conference on Communication, Computer and Power (ICCCP07)*., page 6. Citado na página 24.
- Baccouche, I.; Mlayah, A. (2015). Implementation of a coulomb counting algorithm for soc estimation of li ion battery for multimedia applications. *2015 IEEE 12th International Multi Conference on Systems, Signals Devices (SSD15), Sakiet Ezzit Sfax, Tunisia*. Citado na página 59.
- Bastos, R. F. (2013). Sistema de gerenciamento para carga e descarga de baterias (chumbo-Ácido) e para busca do ponto de máxima potência gerada em painéis fotovoltaicos empregados em sistemas de geração distribuída. *Universidade de São Paulo*, page 115. Citado na página 14.
- Bhatt, N. (2011). Model-based estimation of state of charge of lithium cells. *Master Thesis*. Citado na página 17.
- Birkel, C. (2013). Model identification and parameter estimation for lifepo4 batteries. *IET Hybrid and Electric Vehicles Conference (HEVC)*. Citado 2 vezes nas páginas 15 e 39.
- Bosch, R. (2007). Manual de baterias bosch. *Manual BOSCH*. <http://https://www.bosch.com/>. Citado 3 vezes nas páginas 19, 20 e 21.

- Chakrasali, S. V. P. A. S. (2015). Comparative study on soc estimation techniques for optimal battery sizing for hybrid vehicles. *International Journal on Recent and Innovation Trends in Computing and Communication*, 3:1957–1963. Citado na página 32.
- Chang, W.-Y. (2013). The state of charge estimating methods for battery: A review. *Hindawi Publishing Corporation*. Citado na página 25.
- Cheng, Z. e. a. (2014). Estimation of state of charge for lithium-ion battery based on finite difference extended kalman filter. *Journal of Applied Mathematics*. Citado 3 vezes nas páginas 32, 63 e 64.
- Cunha, M. C. C. (2000). *Métodos Numéricos*. edição revisada e ampliada. ed. Campinas, SP, 2 edition. Citado na página 59.
- Daowd, M. e. a. (2014). Battery management system-balancing modularization based on a single switched capacitor and bi-directional dc/dc converter with the auxiliary battery. *Energies* 2014, 7:2897–2937. Citado na página 14.
- Dhruv Kapoor, P. S. A. K. (2014). Estimation of parameters for battery storage models. *2014 IEEE Conference on Energy Conversion (CENCON)*. Citado 2 vezes nas páginas 15 e 39.
- Dr. Thanh-Son Dao, D. C. S. (2015). Developing mathematical models of batteries in modelica for energy storage applications. *11th International Modelica Conference*. Citado 2 vezes nas páginas 36 e 37.
- Farag, M. S. M. (2013). Lithium-ion batteries: Modelling and state of charge estimation. *Master Thesis*. Citado 7 vezes nas páginas 21, 37, 39, 40, 42, 59 e 60.
- Globe, C. (2018). Difference between cell and battery. Último acesso em 16 Julho 2019. Citado na página 19.
- Jackey, R. e. a. (2013). Battery model parameter estimation using a layered technique: An example using a lithium iron phosphate cell. *SAE International Conference*. Citado 4 vezes nas páginas 15, 38, 39 e 70.
- Jouni Hartikainen, A. S. (2011). Optimal filtering with kalman filters and smoothers a manual for the matlab toolbox ekf/ukf. *Department of Biomedical Engineering and Computational Science, Aalto University School of Science. Espoo, Finland*, page 131. Citado 3 vezes nas páginas 28, 59 e 60.
- Kavash, A. (2015). Estimation soc for li-ion batteries in evs using ekf. *International Journal of Sciences: Basic and Applied Research*, 22(1):225–234. Citado 2 vezes nas páginas 29 e 32.

- Kong Soon Ng, C. S. M. e. a. (2009). Enhanced coulomb counting method for estimating state of charge and state of health of lithium-ion batteries. *Applied Energy*. Citado 3 vezes nas páginas 27, 59 e 60.
- L. C. Stevanatto, V. J. Brusamarello, S. T. (2014). Parameter identification and analysis of uncertainties in measurements of leadacid batteries. *IEEE Transactions on Instrumentation and Measurement*, 63(4). Citado 2 vezes nas páginas 15 e 39.
- Li Zhao, M. L. and Chen, Y. (2016). Least-squares based coulomb counting method and its application for state-of-charge (soc) estimation in electric vehicles. *INTERNATIONAL JOURNAL OF ENERGY RESEARCH*. Citado na página 27.
- Linden, D. and Reddy, T. B. (2002). *Handbook of Batteries*. ISBN 0-07-135978-8. McGraw-Hill, 3 edition. Citado na página 19.
- Magalhães, D. F. P. (2012). Projeto de um sistema de gestão de baterias (bms) aplicadas na alimentação de veículos elétricos (evs). *Master Thesis*. Citado 3 vezes nas páginas 22, 23 e 36.
- MathWorks (2019). Choosing the algorithm. Último acesso em 05 de Agosto 2019. Citado na página 55.
- Mathworks (2019). Generate parameter data for equivalent circuit battery block. Último acesso em 16 de Julho 2019. Citado na página 52.
- MathWorks (2019). Least-squares (model fitting) algorithms. Último acesso em 05 de Agosto 2019. Citado na página 55.
- Pattipati, C. S. (2011). System identification and estimation framework for pivotal automotive battery management system characteristics. *IEEE Trans. Syst. Man Cybern. Part C Appl. Rev.*, 41(6):869–884. Citado na página 24.
- Pei F, Zhao K, L. Y. (2006). Battery variable current– discharge resistance characteristics and state-ofcharge estimation of electric vehicle. *Proc IEEE World Congress Intell Control Automat*. Citado na página 27.
- Plett, G. L. (2004). Extended kalman filtering for battery management systems of lipb based hev battery packs part 2. modeling and identification. *Journal of Power Sources* 134. Citado 2 vezes nas páginas 59 e 60.
- Rachid, R. Y. A. A. (2014). Embedded state of charge and state of health estimator based on kalman filter for electric scooter battery management system. *IEEE Fourth International Conference on Consumer Electronic, Berlin*, pages 440–444. Citado na página 14.

- Shafiei, N. e. a. (2016). Burst mode elimination in high-power llc resonant battery charger for electric vehicles. *IEEE Trans. on Power Electronics*, 31(2). Citado na página 14.
- tao et al., L. C. (2006). Improved ah counting method for state of charge estimation of electric vehicle batteries. *Journal of Tsinghua University*. Citado 3 vezes nas páginas 27, 59 e 60.
- Team, M. E. V. (2008). A guide to understanding battery specifications. Último acesso em 16 September 2018. Citado na página 20.
- Technologies, K. (2019). *34970A Unidade de aquisição, comutação e registro de dados*. Citado na página 46.
- Tesla (2009). Battery capacity estimating method and apparatus. Último acesso em 16 Julho 2019. Citado na página 35.
- Urbain, M. e. a. (2007). State estimation of a lithium-ion battery through kalman filter. *IEEE Power Electronics Specialists Conference*. Citado na página 29.
- Wahlstrom, M. (2010). Design of a battery state estimator using a dual extended kalman filter. *Master Thesis*. Citado na página 82.
- Wikipedia (2018). Decision-matrix method. Último acesso em 16 Julho 2019. Citado 2 vezes nas páginas 33 e 34.
- Wolfcrow (2013). What is a lut (look-up table)? Último acesso em 18 de Julho 2019. Citado na página 21.
- Xing, Y. e. a. (2014). State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures. *Applied Energy*, 113:106–115. Citado 2 vezes nas páginas 14 e 32.
- Yasser Diab, e. a. (2017). Estimating lithium-ion battery state of charge and parameters using a continuous-discrete extended kalman filter. *Energies 2017*. Citado 2 vezes nas páginas 59 e 60.