

Estudo comparativo entre UKF e EKF na estimação de SoC em baterias de lítio-íon sob diferentes condições de temperatura

Filippe José Gadelha Tertuliano*. Rafael de Melo Silva Santos*
Euler Cássio Tavares de Macêdo*. Juan Moises Maurício Villanueva*

*Departamento de Engenharia Elétrica
Universidade Federal da Paraíba
João Pessoa-PB, Brasil

E-mails: filippe.tertuliano@cear.ufpb.br, rafael.santos@cear.ufpb.br,
euler@cear.ufpb.br, jmauricio@cear.ufpb.br

Abstract: The batteries have become a subject widely studied in different scientific areas after the increase of applications high dependent on energy systems in different sectors of society and industry. In order to guarantee the safety and efficiency of energy storage, it is necessary to monitor and control the batteries continuously with robust and accurate algorithms, based on model of the system. The State of Charge (SoC) is one of the most important parameters of the battery once it represents the remaining capacity of the battery in relation to its nominal capacity. For its estimation, the Extended Kalman Filter (EKF) method is commonly used to estimate parameters of the nonlinear dynamic system model from a complex, but effective, linearization process. However, there is the Unscented Kalman Filter (UKF) capable of estimating the model parameters using the Unscented Transform, which is easier to implement than the linearization performed by EKF. Thus, in this paper, the SoC is estimated for the lithium-ion batteries based on the EKF and the UKF algorithms looking for the best performance with the lowest complexity of implementation considering the impacts of different temperature conditions.

Resumo: As baterias se tornaram um assunto amplamente estudado em diferentes áreas científicas após o aumento de aplicações dependentes de sistemas de energia em diferentes setores da sociedade e industrial. Com o intuito de aumentar a segurança e eficiência do armazenamento de energia, é necessário monitorar e controlar as baterias continuamente com algoritmos robustos e precisos, baseados em um modelo do sistema. O Estado de Carga (*State of Charge* - SoC) é um dos mais importantes parâmetros da bateria, pois ele representa a sua capacidade disponível de fornecimento de energia em relação à sua capacidade nominal. É comum utilizar o método de Filtro de Kalman Estendido (EKF), que estima parâmetros do modelo do sistema dinâmico não-linear a partir de um processo de linearização complexo, mas eficaz. Contudo, o algoritmo de estimação do SoC baseado em Filtro de Kalman *Unscented* (UKF) é capaz de estimar os parâmetros do modelo com maior eficácia computacional com relação a sua contraparte EKF. Assim, neste artigo, é realizada a estimação do SoC de baterias de lítio-íon utilizando os algoritmos EKF e UKF para identificar qual deles apresenta melhor desempenho em comparação com a complexidade de implementação, considerando a influência da variação de temperatura sob o sistema.

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

Palavras-chaves: UKF; EKF; Estimação de SoC; Modelagem de Bateria; Bateria de Lítio-Íon.

1. INTRODUÇÃO

Com o objetivo de reduzir o impacto ambiental causado pela geração de energia, as fontes renováveis têm ganhado maior destaque no mercado tecnológico. Por apresentarem uma geração intermitente, elas precisam ser associadas a Sistemas de Armazenamento de Energia (SAE) para auxiliar a integração da eletricidade gerada à rede. O aumento de *smart grids*, também, demanda uma maior participação de SAE no mercado, visando melhorar a operação de sistemas de comunicação e computacional dessas redes, além de permitir a postergação de investimentos de repotencialização (Rahimi-Eichi et al. 2013).

O mesmo ocorre com a eletrificação dos sistemas automotivos. Os veículos elétricos estão cada vez mais presentes na sociedade com o objetivo de diminuir a dependência de combustíveis fósseis (Zubi et al. 2018). Para isso, são utilizados bancos de baterias capazes de atender às demandas de potência e de densidade energética exigidas pelo sistema de *powertrain* dos veículos.

Um dos exemplos mais comuns de SAE, na atualidade, é baseado em baterias de lítio-íon e tem sua importância de acordo com a aplicação final. Na indústria, tem ganhado destaque por apresentar melhores propriedades, como alta densidade de energia e baixo custo de manutenção,

quando comparada a outros SAE (Bereczki et al. 2019). Assim, estudos sobre esse tipo de sistema contribuem para melhorar a operação e aumentar a confiabilidade e o rendimento dos dispositivos a ele associados.

O sistema interno de uma bateria de lítio-íon, como em qualquer bateria, é composto por um cátodo (polo positivo) e um ânodo (polo negativo) envoltos pelo eletrólito (composição pela qual existe a troca de elétrons entre os polos) e afastados um do outro pelo separador para evitar um curto-circuito interno. Estes quatro elementos principais funcionam de maneira que a carga e a descarga da bateria ocorram de forma segura e eficiente (Hannah et al. 2018).

Contudo, diferentes fatores podem colocar em risco o bom funcionamento de uma bateria. Dentre eles, destacam-se a temperatura de operação, a descarga excessiva e a sobrecarga. Adicionalmente, é importante destacar que existe uma queda drástica na durabilidade da bateria quando ela é submetida a temperaturas fora dos limites estabelecidos pelo fabricante. Já em casos de descarga excessiva, ocorre degradação dos compostos químicos internos comprometendo diretamente o funcionamento da bateria e afetando, assim, sua capacidade original. O mesmo ocorre com a sobrecarga a qual provoca formação de compostos químicos perigosos não só para o seu funcionamento como também para a segurança de operação do sistema (Balagopal; Chow, 2015).

Dessa forma, o uso contínuo da bateria exige que ela seja constantemente monitorada e controlada por um usuário ou um sistema supervisor automático, também conhecido como Sistema de Gerenciamento de Baterias (do inglês, *Battery Management System – BMS*) (Purwadi et al. 2014).

O BMS atua no monitoramento do sistema para que não ocorra um descarregamento da bateria abaixo de um valor de tensão pré-determinado (*cut-off voltage*), além de evitar que o dispositivo continue recebendo carga após estar completamente carregado, ou seja, mantém a carga ou descarga dentro de uma faixa segura de operação respeitando os limites determinados pelo fabricante da bateria e assegurando uma vida útil mais longa (Chen et al. 2016).

O BMS, também, estima alguns estados de interesse para esse tipo de sistema de armazenamento. Esses estados são usados para representar a condição atual da bateria. Dentre eles, um dos mais importantes é o Estado de Carga (do inglês, *State of Charge – SoC*), que representa a capacidade atual da bateria como uma porcentagem da sua capacidade nominal. Porém, o SoC não pode ser obtido diretamente, exigindo o uso de métodos/algoritmos que viabilizem a sua estimação de maneira precisa e confiável a partir de medições diretas de tensão, corrente e temperatura. Outros estados também estimados são o Estado de Saúde (do inglês, *State of Health – SoH*) e o Estado de Função (do inglês, *State of Function – SoF*) (Jokić et al. 2018).

Existe uma série de técnicas empregadas na estimação de SoC em sistemas de energia, variando em precisão de estimação ou na complexidade de implementação (Zhang et al., 2018). O método Contagem Ampère-hora,

também conhecido por *Coulomb Counting* (CC), usa a integral da corrente de carga/descarga no cálculo da capacidade restante na bateria. É de baixa complexidade computacional. Porém, exige conhecimento do estado inicial da carga e apresenta baixa exatidão, além de depender de parâmetros sujeitos a erros de medição (Purwadi et al., 2014). Já os Filtros de Kalman (do inglês, *Kalman Filter – KF*) usam equações recursivas para estimar estados atuais com base nos estados obtidos em instantes anteriores. Eles são amplamente usados por promover a autocorreção dos erros durante operação do sistema (Plett, 2004).

O Filtro de Kalman Estendido (do inglês, *Extended Kalman Filter – EKF*) é a variação mais comum do KF usada na estimação de estados em baterias. Nele, ocorre a linearização das funções, que representam o sistema não-linear, com base em expansões de série de Taylor de primeira ordem. O Filtro de Kalman *Unscented* (do inglês, *Unscented Kalman Filter – UKF*) é outra variação ótima na estimação de estados em sistemas não-lineares, que se diferencia dos demais métodos por estimar os valores médios e covariâncias dos estados por meio de técnica menos complexa formada por um conjunto de amostras em torno de um ponto de operação geradas em um processo chamado de Transformada *Unscented* (Scardua, 2015).

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

Métodos de estimação de SoC podem ser combinados de forma a compensar as desvantagens de uns com as vantagens dos outros (ZHANG et al., 2018). Portanto, neste trabalho, tem-se como objetivo realizar a análise comparativa do desempenho dos algoritmos EKF e UKF para a estimação do SoC, visando avaliar a capacidade de estimação desses métodos sob a influência da variação da temperatura. Nesta comparação, serão utilizados dados coletados de ensaios de descarga de baterias de lítio-íon.

2. FILTROS DE KALMAN

O Filtro de Kalman engloba uma série de métodos largamente empregada na estimação de parâmetros variantes com o tempo, que não podem ser obtidos de maneira direta, em sistemas dinâmicos. Com ele, são aplicadas equações recursivas ao longo da operação do sistema para estimar estados atuais a partir de seus valores prévios e de dados de entrada e saída do sistema. Esse comportamento regressivo viabiliza uma maior tolerância a distúrbios externos por sempre autocorrigir os erros durante a execução do sistema (Plett, 2014).

2.1 Filtro de Kalman Estendido

Para a estimação de sistemas dinâmicos não-lineares, é comum utilizar o filtro de Kalman Estendido. Com ele, ocorre um processo de linearização, durante cada passo de tempo, das funções não-lineares que definem o sistema.

A linearização usa expansões em série de Taylor de primeira ordem e derivadas parciais para calcular matrizes Jacobianas, o que torna o processo de estimação complexo. Na sequência, ocorre a etapa de predição dos estados seguida pela atualização deles. Para melhor compreender o funcionamento desse filtro, considere a representação em modelo de espaço de estados formada por (1) e (2) (Plett, 2004).

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

$$y_k = g(x_k, u_k) + r_k \quad (2)$$

Equações (1) e (2) são conhecidas como equação de estado e equação de saída, respectivamente. Nelas, k representa o índice de tempo discreto; q_k e r_k representam os ruídos de processo e de medição, respectivamente; $f(x_k, u_k)$ é a função de estados não-linear ou modelo dinâmico; $g(x_k, u_k)$ é a função de medição ou modelo de medidas; x_k corresponde ao vetor transposto de estados; u_k e y_k correspondem às matrizes de entrada e de saída do sistema, respectivamente.

A implementação do EKF ocorre em quatro etapas principais apresentadas na Fig. 1.

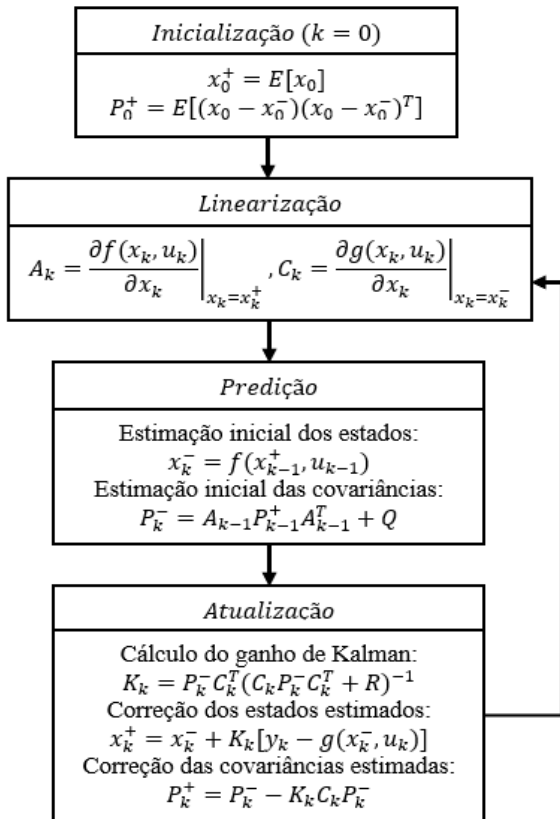


Fig. 1 Fluxograma de implementação do filtro de Kalman Estendido.

2.2 Filtro de Kalman Unscented

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

Ao invés de realizar aproximações lineares em funções não-lineares do sistema dinâmico, este método utiliza a Transformada *Unscented* (do inglês, *Unscented Transform* – UT), durante cada passo de tempo, nas funções que definem o sistema. Com ela, é possível obter um bom desempenho na estimação da média e do erro de covariância dos estados do sistema de maneira precisa e menos complexa do que o EKF (Partovibakhsh; Liu, 2015).

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

Considere, novamente, a representação em modelo de espaço de estados formada por (1) e (2). Assim como no EKF, a implementação do UKF para um sistema com L estados apresenta as etapas de predição e de atualização exibidas na Fig. 2.

Nela $(\sqrt{(L+\lambda)P_i})_i$ corresponde a i -ésima coluna da matriz $\sqrt{(L+\lambda)P_i}$ enquanto λ é um parâmetro de escalonamento obtido por (3). O parâmetro α é um parâmetro responsável por definir o espelhamento dos pontos sigma em torno do valor médio dos estados. O parâmetro κ é responsável pelo escalonamento secundário e o parâmetro β , por incorporar conhecimento prévio sobre a distribuição dos estados.

$$\lambda = \alpha^2(L + \kappa) - L \quad (3)$$

3. MODELAGEM DA BATERIA

A modelagem da bateria é realizada com o objetivo de representar, de maneira precisa e simples, uma série de limitações ligadas ao sistema de energia, como a composição eletroquímica complexa, os efeitos internos relacionados às condições de trabalho e de operação, dentre outros (HU et al., 2012).

Neste estudo, a modelagem da bateria de lítio-íon será feita com base no modelo de circuito equivalente de Thévenin. Esse subtipo do modelo elétrico é capaz de simular o comportamento da bateria a partir de elementos resistivos e capacitivos associados à tensão de circuito, como apresentado na Fig. 3 (Peng et al. 2017).

Dentre os diferentes tipos de modelo, o modelo elétrico apresenta um melhor equilíbrio entre exatidão e complexidade computacional de modo que pode ser facilmente implementado em microprocessadores sem comprometer o cálculo das estimativas (Boca et al. 2018).

Contudo, um dos grandes desafios encontrado ao utilizá-lo é a determinação dos parâmetros que o compõem.

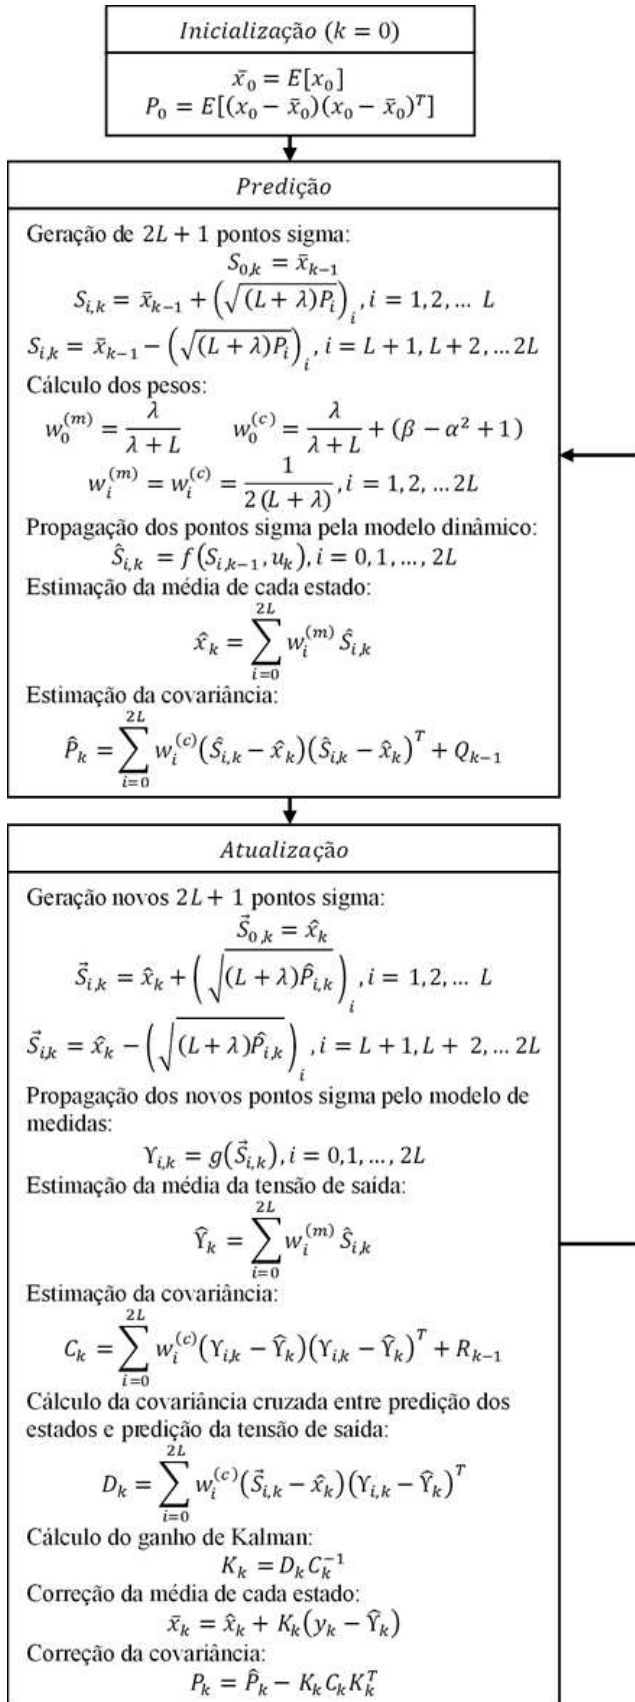


Fig. 2 Fluxograma de implementação do filtro de Kalman *Unscented*.

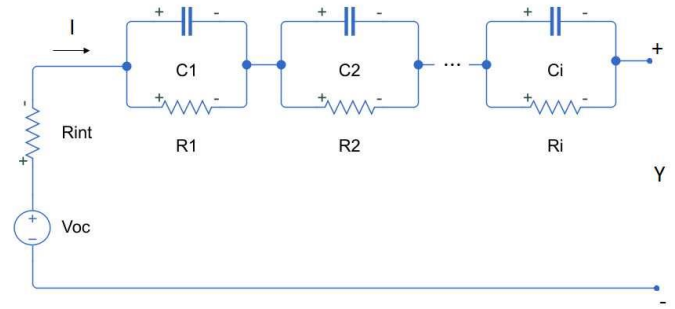


Fig. 3 Modelo genérico da bateria baseado em Circuito Equivalente.

Na Fig. 3, R_{int} é a resistência interna da bateria; R_i e C_i em paralelo representam o comportamento dinâmico da bateria; V_{oc} é a tensão de circuito aberto; Y e I são a tensão de saída e a corrente do sistema, respectivamente.

A quantidade de ramos RC irá determinar a exatidão e a complexidade do modelo. Para isso, é necessário realizar ensaios de descarga pulsada para a obtenção de tensão de saída e da corrente, resultando, consequentemente, na análise da quantidade de ramos RC (Jackey et al. 2013). Neste trabalho, os dados experimentais utilizados foram obtidos de (Bole et al. 2014).

4. ESTIMAÇÃO DO SOC BASEADA EM FILTROS DE KALMAN

Nesta seção, serão apresentados os passos adotados na modelagem e otimização da bateria de lítio-íon e na implementação do UKF e do EKF a partir das equações e parâmetros do modelo.

4.1 Modelagem da bateria de lítio-íon

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

O conjunto de dados experimentais relacionados à bateria e utilizado neste estudo foi obtido do *Prognostics Data Repository* pertencente a *National Aeronautics and Space Administration* (NASA), do trabalho feito por Bole et al. (2014).

Bole et al. (2014) realizaram uma série de ensaios de carga/descarga contínuos e aleatórios em um conjunto de baterias de lítio-íon do tipo 18650, com correntes entre -4,5 A e 4,5 A. Neste estudo, foram analisadas as baterias identificadas por RW9, RW12 e RW23 sob as temperaturas ambientes de ensaio de 30 °C, 20 °C e 40 °C, respectivamente. Dos diferentes perfis de corrente empregados pelos autores, foram coletados os dados resultantes apenas do perfil de descarga pulsada, da bateria

completamente carregada (4,2 V) até completamente descarregada (3,2 V). A corrente de descarga consiste em -1 A durante 10 minutos seguido por 20 minutos com corrente nula.

Do conjunto de resultados obtidos, foram coletados para as três baterias os sinais de tensão com 10 pulsos de descarga, que resultam em uma análise de 10 estados de carga variando de 90% até 0% com passo de 10%. Na Fig. 4, apresentam-se os sinais de tensão de saída obtidos por Bole et al. (2015) e analisados neste estudo.

Para identificar o número de ramos RC empregado no modelo do sistema, foram realizados ajustes da curva de tensão durante o período de descanso da bateria ($I=0$), de acordo com (4), a partir da variação da ordem da equação exponencial apresentada. Para os ajustes, foi utilizada a ferramenta *Curve Fitting Toolbox* inclusa no ambiente computacional *Matlab*®.

$$Y(t) = V_{oc} + V_1 \left(1 - e^{-\frac{t}{R_1 C_1}}\right) + \dots + V_i \left(1 - e^{-\frac{t}{R_i C_i}}\right) \quad (4)$$




Fig. 4 Tensões de saída em ensaios de descarga pulsada sob diferentes condições de temperatura.

Resultados próximos da curva de tensão real foram obtidos com uma equação exponencial de segunda ordem, ou seja, com 2 ramos RC. Praticamente o mesmo resultado foi obtido a partir do emprego do modelo com 3 ramos RC. Contudo, a utilização do modelo com 3 ramos RC ocasionou um maior requisito computacional e tempo de processamento. Assim, optou-se pelo modelo de circuito equivalente com 2 ramos RC apresentado na Fig. 5.

Com a ordem do modelo de circuito equivalente definida, foi utilizado, novamente, a ferramenta *Curve Fitting Toolbox* no ambiente do *Matlab*®, para ajustar todas as curvas de tensão geradas nos períodos de descanso da bateria e, conseqüentemente, realizar a extração dos parâmetros do modelo para cada Estado de Carga.

Para verificar o desempenho do modelo da bateria, foram feitas simulações no *Simulink*®, comparando os resultados obtidos com os experimentais (Gazzarri, 2020). Na simulação, foram usadas tabelas de equivalência (*look-up*

tables), carregadas com os dados obtidos na estimação, para representar cada parâmetro do modelo. Assim, os valores dos parâmetros não estimados ao longo do SoC serão obtidos por interpolação polinomial.




Fig. 5 Modelo da bateria baseado em circuito equivalente de segunda ordem.

Com o objetivo de diminuir o erro inerente ao processo de modelagem e melhorar a estimação dos parâmetros do modelo, foi empregada uma ferramenta de otimização inclusa no *Simulink*®, conhecida como *Parameter Estimation*. Com o uso dessa ferramenta, é possível o usuário identificar quais parâmetros serão otimizados a partir da inserção das curvas de referência (real) e da simulada, as quais serão aproximadas durante o processo de otimização.

Após a modelagem do sistema, com a identificação e a otimização dos seus parâmetros, foram extraídas expressões matemáticas que caracterizam o comportamento de cada parâmetro do modelo em função do SoC da bateria e da temperatura.

Com base no modelo apresentado na Fig. 5, nas leis de Kirchhoff e nas características transitórias de um circuito RC, a tensão de saída do sistema (Y) e a corrente (I) podem ser expressas de acordo com (5) e (6), respectivamente.

$$Y = V_{oc} - V_1 - V_2 - R_{int} I \quad (5)$$

$$I = \frac{V_1}{R_1} + C_1 \frac{dV_1}{dt} = \frac{V_2}{R_2} + C_2 \frac{dV_2}{dt} \quad (6)$$

Para que os métodos de estimação UKF e EKF sejam empregados, o modelo da bateria deve estar representado na forma de espaço de estados discretizado. Assim, rearranjando (5) e (6), e discretizando-as, obtém-se o modelo como apresentado em (7) e (8) (Peng et al. 2017), sendo Δt o período de amostragem; τ_1 e τ_2 correspondem às constantes de tempo de cada ramo RC; q e r correspondem aos ruídos de processo e de medição do sistema, respectivamente; R_1 , R_2 e R_{int} correspondem as resistências presentes no modelo; I é a corrente no circuito e Y , a tensão de saída do sistema; V_{oc} é a tensão de circuito aberto; V_1 e V_2 são os estados correspondentes às tensões sobre os ramos RC; C_n é a capacidade nominal da bateria e η é a constante de Coulomb. A variável *SoC* corresponde ao estado de carga da bateria, estimado de acordo com (9), expressão proveniente do método de estimação Ampère-hora (Zhang et al., 2018).

$$\begin{bmatrix} SoC(k+1) \\ V_1(k+1) \\ V_2(k+1) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \exp\left(-\frac{\Delta t}{\tau_1}\right) & 0 \\ 0 & 0 & \exp\left(-\frac{\Delta t}{\tau_2}\right) \end{bmatrix} \begin{bmatrix} SoC(k) \\ V_1(k) \\ V_2(k) \end{bmatrix} + \begin{bmatrix} \frac{\eta \Delta t}{3600 C_n} \\ R_1 [1 - \exp\left(-\frac{\Delta t}{\tau_1}\right)] \\ R_2 [1 - \exp\left(-\frac{\Delta t}{\tau_2}\right)] \end{bmatrix} I(k) + q(k) \quad (7)$$

$$Y(k) = V_{oc}(k) - V_1(k) - V_2(k) - R_{int}I(k) + r(k) \quad (8)$$

$$SoC = SoC_0 + \frac{\eta}{3600 * C_n} \int_0^t I(t) dt \quad (9)$$

4.2 Implementação dos Filtros de Kalman

Após a modelagem do sistema, foram obtidos os valores dos parâmetros para cada estado de carga da bateria e para cada temperatura de ensaio. Assim, foi possível determinar as funções que representam a relação entre SoC/temperatura a partir de cada parâmetro.

Essas funções foram, conseqüentemente, aplicadas ao UKF, implementado com base no algoritmo descrito na Fig. 2: inicialmente foi realizada a transformada *Unscented*, com a geração dos pontos sigma e a sua aplicação no modelo dinâmico do sistema; novos valores médios e de covariância dos estados foram calculados e aplicados na equação de saída do modelo, resultando, em seguida, na obtenção do ganho de Kalman e na estimação dos estados e da matriz do erro de covariância.

As funções, também, foram aplicadas ao EKF com base no algoritmo apresentado na Fig. 1: as equações que definem o sistema foram linearizadas por expansão em séries de Taylor de primeira ordem, sendo as matrizes determinantes do comportamento dinâmico da bateria obtidas a partir de derivadas parciais; em seguida, os estados e a matriz de covariância foram preditos, corrigidos pelo ganho de Kalman e, conseqüentemente, atualizados.

5. RESULTADOS E ANÁLISES

Nesta seção, serão apresentados e analisados os resultados obtidos com a implementação do UKF e do EKF na estimação do SoC sob diferentes condições de temperatura. Com isso, objetiva-se identificar qual dos métodos aplicados permitiu uma melhor estimação do SoC a partir do modelo de circuito equivalente com 2 ramos RC.

5.1 Sinais de referência

Os sinais de referência foram simulados com base nas expressões de cada parâmetro otimizado em função do

SoC e da temperatura, construídas a partir da função *fit* do *Matlab*®. A corrente de descarga foi considerada constante no valor de 2,2 A. Já os ruídos branco gaussiano aditivo de processo e de medição foram produzidos de maneira aleatória com base nos valores iniciais de $Q=10^{-5}$ e de $R=5 \times 10^{-4}$. O cálculo do SoC de referência foi feito por meio do método de *Coulomb Counting* (CC).

A adição de ruídos aleatórios aos modelos dinâmico e de medidas, em cada passo de tempo, não permite que o SoC de referência seja uma reta. Na Fig. 6, estão apresentados os sinais de tensão de saída gerados na simulação e usados como referência na estimação dos estados, para os casos de ensaio sob 20 °C, 30 °C, e 40 °C.




Fig. 6 Tensões de saída de referência para diferentes condições de temperatura.

5.2 Estudo de caso 1

Neste estudo de caso, são consideradas as expressões dos parâmetros otimizados obtidos do ensaio de descarga pulsada sob a temperatura de 20 °C. A variável SoC foi estimada pelos métodos EKF e UKF de maneira satisfatória, pois, como apresentado na Fig. 7, ambas as curvas de estimação ficaram próximas do SoC de referência.

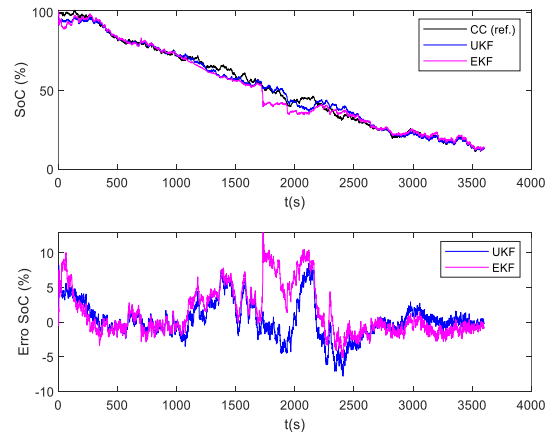


Fig. 7 Estimação de estado de carga usando filtros de Kalman sob temperatura de 20 °C.

Em torno dos 1700 segundos, é possível observar que o EKF divergiu significativamente do referencial em virtude dos ruídos de processo e de medição aleatórios naquela faixa de tempo. Em oposição, a divergência não foi observada pelo UKF que, sob os mesmos ruídos, conseguiu manter a estimação próxima do referencial, corroborando em seu melhor desempenho.

5.3 Estudo de caso 2

Neste estudo de caso, são consideradas as expressões dos parâmetros otimizados obtidos do ensaio de descarga pulsada sob a temperatura de 30 °C. Na Fig. 8, é possível observar novamente que ambas as curvas de estimação de SoC estão próximas do referencial. Contudo, nota-se que, no início da estimação, o UKF apresentou menor erro, convergindo mais rapidamente do que o EKF.




Fig. 8 Estimação de estado de carga usando filtros de Kalman sob temperatura de 30 °C.

5.4 Estudo de caso 3

Neste estudo de caso, são consideradas as expressões dos parâmetros otimizados obtidos do ensaio de descarga pulsada sob a temperatura de 40 °C. Na Fig. 9, é possível observar que ambas as estimas divergem significativamente do valor referencial no final da estimação. Isso, aliado com o observado no Caso 2, demonstra problemas de estimação nos extremos da bateria, sendo necessário obter mais dados experimentais no começo e no final dos ensaios, aumentando a resolução de estimação.

5.5 Comparação numérica

Com base nos valores de SoC estimados anteriormente, foram destacados, na Tabela 1, os valores do erro médio absoluto (do inglês, *Mean Absolute Error* – MAE) e da raiz do erro quadrático médio (do inglês, *Root-Mean Square Error* – RMSE) calculados para verificar numericamente a acuracidade desses filtros de Kalman e comprovar o melhor desempenho do UKF sobre o EKF. Com o aumento da temperatura, mais difícil foi o processo de

modelagem da bateria. Como consequência disso, é possível notar que quanto maior a temperatura, maior o erro de estimação causado. Mesmo assim, o UKF apresentou um melhor desempenho em todos os cenários analisados.




Fig. 9 Estimação de estado de carga usando filtros de Kalman sob temperatura de 40 °C.

Tabela 1. Comparação da Precisão entre UKF e EKF.

Temp. (°C)	20		30		40	
Método	UKF	EKF	UKF	EKF	UKF	EKF
MAE (%)	1.97	2.61	1.31	2.07	2.67	3.26
RMSE (%)	2.71	3.67	1.87	3.11	4.14	5.17

6. CONCLUSÕES

Neste trabalho, foi apresentado um estudo sobre a estimação do estado de carga em baterias de lítio-íon, sistema de armazenamento de energia largamente utilizado no setor industrial. Assim, foi construído um modelo para representar o comportamento dinâmico desse sistema e foram implementados algoritmos de filtros de Kalman usados na estimação de seus parâmetros no ambiente do *Matlab/Simulink*®.

O modelo de circuito equivalente de segunda ordem proposto foi capaz de representar o comportamento da bateria sem comprometer o funcionamento dos métodos de estimação usados, o UKF e o EKF, resultando em erros na estimação do SoC inferiores à 5,2%. Os parâmetros do modelo foram obtidos em função do estado de carga e da temperatura ambiente.

A partir dos resultados obtidos, é possível observar que o SoC da bateria foi estimado de forma superior pelo UKF sob todas as diferentes condições de temperatura consideradas neste trabalho, empregando, também, um algoritmo mais simples que o do EKF.

AGRADECIMENTOS

Os autores gostariam de agradecer à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pelo suporte no desenvolvimento desta pesquisa.

REFERÊNCIAS

- Balagopal, B.; Chow, M. (2015). The state of the art approaches to estimate the state of health (SOH) and state of function (SOF) of lithium Ion batteries. In: IEEE. *Industrial Informatics (INDIN), 2015 IEEE 13th International Conference on*. Cambridge, 2015. p. 1302-1307.
- Bereczki, B.; Hartmann, B.; Kertész, S. (2019). Industrial Application of Battery Energy Storage Systems: Peak shaving. In IEEE. *Energy, 2019 7th International Youth Conference on (IYCE)*. Bled, Slovenia. p. 1-5.
- Bocca, A.; Macii, A.; Macii, E.; Poncino, M. (2018). Composable Battery Model Templates Based on Manufacturers' Data. In IEEE Design & Test, vol. 35, n. 3, p. 66-72.
- Bole, B.; Kulkani, C.; Daigle, M. (2015). Randomized battery Usage Data Set, NASA Ames Prognostics Data Repository, <http://ti.arc.nasa.gov/project/prognostic-data-repository>, NASA Ames Research Center, Moffett Field, CA.
- Bole, B.; Kulkani, C.; Daigle, M. (2014). Adaptation of an Electrochemistry-based Li-Ion Battery Model to Account for Deterioration Observed Under Randomized Use. Annual Conference of the Prognostics and Health Management Society, 2014.
- Chen, A.; Sen, P. K. (2016). Advancement in battery technology: A state-of-the-art review. In: IEEE. *Industry Applications Society, 2016 IEEE Annual Meeting*. Portland, OR, 2016, p. 1-10.
- Gazzarri, J. (2020). Battery Modeling. MATLAB Central File Exchange. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/36019-battery-modeling>>.
- Hannan, M. A.; Hoque, M. M.; Hussain, A.; Yusof, Y.; Ker, P. J. (2018). State-of-the-Art and Energy Management System of Lithium-Ion Batteries in Electric Vehicle Applications: Issues and Recommendations. In IEEE Access, v. 6, p. 19362-19378. ISSN 2169-3536.
- Haase, J.; Aljuheshi, F.; Nishi, H.; Ploennigs, J.; Tsang, K. F.; Aljuhaishi, N.; Alahmad, M. (2017). Analysis of batteries in the built environment an overview on types and applications. In: IEEE. *Industrial Electronics Society, IECON 2017 - 43rd Annual Conference of the IEEE*. Beijing, 2017. p. 8113-8118.
- Hu, X.; Li, S.; Peng, H. (2012). A comparative study of equivalent circuit models for Li-ion batteries. In Elsevier. *Journal of Power Sources*, v. 198, p. 359 – 367.
- Jackey, R.; Saginaw, M.; Sanghvi, P.; Gazzarri, J.; Huria, T.; Ceraolo, M. (2013). Battery Model Parameter Estimation Using a Layered Technique: An Example Using a Lithium Iron Phosphate Cell. *SAE World Congress*.
- Jokić, I.; Zečević, Ž.; Krstajić, B. (2018). State-of-charge estimation of lithium-ion batteries using extended Kalman filter and unscented Kalman filter. In: IEEE. *Information Technology (IT), 2018 23rd International Scientific-Professional Conference on*. Zabljak, 2018. p. 1-4.
- Partovibakhsh, M.; Liu, G. (2015). An Adaptive Unscented Kalman Filtering Approach for Online Estimation of Model Parameters and State-of-Charge of Lithium-Ion Batteries for Autonomous Mobile Robots. In IEEE Transactions on Control Systems Technology, v. 23, n. 1, p. 357-363.
- Peng, S.; Chen, C.; Shi, H.; Yao, Z. (2017). State of Charge Estimation of Battery Energy Storage Systems Based on Adaptive Unscented Kalman Filter With a Noise Statistics Estimator. In IEEE Access, v. 5, p. 13202-13212. ISSN 2169-3536.
- Plett, G. L. (2004). Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 1. Background. In Elsevier. *Journal of Power Sources*, v. 134, n. 2, p. 252 – 261. ISSN 0387-7753.
- Purwadi, A.; Rizqiawan, A.; Kevin, A.; Heryana, N. (2014). State of Charge estimation method for lithium battery using combination of Coulomb Counting and Adaptive System with considering the effect of temperature. In: IEEE. *Power Engineering and Renewable Energy (ICPERE), 2014 The 2nd IEEE Conference on*. Bali, 2014. p. 91-95.
- Rahimi-Eichi, H.; Ojha, U.; Baronti, F.; Chow, M. (2013). Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles. In IEEE. *Industrial Electronics Magazine*, v. 7, n. 2, p. 4-16.
- Scardua, L. A. (2015). Sintonia-automática do filtro de Kalman Unscented. Tese (Doutorado) – Escola Politécnica da Universidade de São Paulo, 2015.
- Wu, X.; Li, X.; Du, J. (2018). State of Charge Estimation of Lithium-Ion Batteries Over Wide Temperature Range Using Unscented Kalman Filter. In IEEE. IEEE Access, vol. 6, p. 41993-42003.
- Zhang, R.; Xia, B.; Li, B.; Cao, L.; Lai, Y.; Zheng, W.; Huawen, W.; Wang, W. (2018) State of the Art of Lithium-Ion Battery SOC Estimation for Electrical Vehicles. In Energies, v. 11, article number 1820.
- Zubi, G.; Dufo-Lopés, R.; Carvalho, M.; Pasaoglu, G. (2018). The lithium-ion battery: Tate of the art and future perspectives. In Elsevier, *Renewable and Sustainable Energy Reviews*, v. 89, p. 292-308. ISSN 1364-0321.