

Alcançando a Superioridade Operacional com Baterias Inteligentes: Eficiência e Segurança dos VANTs Militares

Eli Ana Costa Camargo, Tobias Morato Portilho, Andrés Mauricio Oviedo Pinzón, Roberto d'Amore, Marcus Henrique Victor Junior, Lester de Abreu Faria.
Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

Resumo – Veículos Aéreos Não-Tripulados (VANTs) militares se mostram altamente dependentes da autonomia de suas baterias para o perfeito cumprimento da missão. Uma vez que tais vetores devem ser cada vez mais autônomos e “auto-suficientes”, a estimação da quantidade de energia existente na bateria deve ser indicada de forma precisa, maximizando o tempo de voo e realizando operações estratégicas com eficiência e segurança aprimoradas. Desta forma, o presente trabalho visa a desenvolver uma metodologia para a estimação do Estado de Carga (SOC) de baterias de lítio comumente utilizadas em VANTs militares. Para tanto, inicialmente foi realizada a modelagem da bateria, por meio de um circuito equivalente de primeira ordem, bem como estimado o SOC com um algoritmo proprietário baseado em Filtro de Kalman. Ainda, para fins de validação, um teste de pulsos híbridos foi utilizado para caracterizar o modelo e testar o algoritmo, atingindo erros menores que 1%.

Palavras-Chave – Veículos Aéreos Não-Tripulados Militares, Baterias, Estado de Carga (SOC).

I. INTRODUÇÃO

A tecnologia de Veículos Aéreos Não-Tripulados (VANTs) militares vem sendo desenvolvida ao longo de todo o século XX, porém seu uso em grande escala para operações reais de guerra só ocorreu a partir do ano 2000 [1]. Segundo o Glossário das Forças Armadas (2015), o termo VANT é definido como “Veículo aéreo, sem operador a bordo, com asas fixas ou rotativas, que dispõe de propulsão própria, podendo ser pilotado remotamente ou dotado de um sistema autônomo de navegação. É empregado em ações de ataque ou reconhecimento, sendo recuperável ou não” [2]. Neste sentido, entende-se que as baterias de VANTs devam ser capazes de suprir a necessidade energética durante toda a operação [3], por mais limitofe que ela seja, bem como não devem ter muito peso. Baterias de íons de Lítio são comumente utilizadas nesse tipo de veículo, principalmente as de Polímero de Lítio (LiPo).

O estado de carga (do inglês, *State of Charge - SOC*) é uma grandeza não mensurável que serve como um indicador da quantidade de energia restante na bateria, devendo ser estimado e sendo uma das principais funções do sistema de gerenciamento de baterias (do inglês, *Battery Management System - BMS*).

Tal conceito reflete diretamente no bom desempenho do VANT, bem como na vida útil da bateria a longo prazo. Estimar o SOC de forma simples e garantindo uma precisão relevante é um dos grandes desafios enfrentados por vários setores para o uso eficiente de baterias [4], [5].

A literatura propõe diversas formas para se estimar o SOC, as quais podem ser classificadas em três grupos: i. métodos convencionais; ii. métodos baseados em modelos; e iii. métodos baseados em dados. Os métodos convencionais geralmente são de fácil implementação, porém são baseados em medição direta, o que os torna dependentes da qualidade dos instrumentos utilizados para realizar as medições. Os mais populares neste grupo são o método “por tensão de circuito aberto (OCV)” e o método “de contagem de coulomb (CC)”. Os métodos “baseados em modelos”, como o próprio nome sugere, utilizam modelos para descrever o comportamento dinâmico eletroquímico da bateria e, dessa forma, gerar estimativas precisas. Os Filtros de Kalman (FK) são exemplos de métodos baseados em modelos que são amplamente utilizados para a estimação do SOC. Diferente dos métodos baseados em modelos, os métodos “baseados em dados” não precisam de muitas informações a respeito da dinâmica eletroquímica da bateria. Nestes métodos uma grande quantidade de dados é utilizada para treino do algoritmo, possibilitando realizar a estimação do SOC. De forma geral, métodos baseados em dados são robustos para sistemas não-lineares, sendo relativamente simples, mas necessitam de muito recurso computacional para operarem. As redes neurais artificiais são um exemplo desse tipo de método [6], [7].

Assim sendo, dada a relevância do tema para as Aplicações Operacionais em Áreas de Defesa, o presente trabalho tem por finalidade desenvolver um algoritmo que estime o SOC de baterias comumente utilizadas em VANTs militares, de forma que a mesma metodologia possa vir a ser utilizada para diferentes químicas de baterias de íons de lítio. Para tanto, foi utilizado um modelo de circuito equivalente de primeira ordem para modelar a bateria e um algoritmo baseado no Filtro de Kalman Estendido (FKE) para estimar o SOC. A caracterização do modelo e o teste do algoritmo foram feitos utilizando dados de um teste de pulsos híbridos, o que contribui para a minimização dos erros da estimação e para os resultados alcançados.

II. MÉTODOS DE ESTIMAÇÃO DO SOC

A estimação do SOC é realizada com base em informações medidas da bateria, tais como corrente, tensão e temperatura, estas alimentando então um algoritmo responsável pela estimação do SOC. Alguns dos métodos mais conhecidos para tal estimação são descritos na presente seção, sendo

apresentados na Tabela I um resumo das vantagens e desvantagens dos principais existentes.

A. Tensão de circuito aberto (OCV)

A OCV tem uma relação direta com o SOC, porém devendo ser amostrado somente quando a bateria estiver internamente equilibrada. Tal situação só ocorre após um longo período em circuito aberto da bateria, sendo este conhecido como repouso ou relaxamento [6]. Uma maneira de identificar a função não-linear que descreve a relação OCV-SOC é por meio de um teste de pulsos híbridos, também conhecido por *Hybrid Pulse Power Characterization* (HPPC). Durante tais testes a bateria é descarregada aos poucos, por meio de pulsos de corrente. Cada pulso descarrega a bateria até um valor específico de SOC, possuindo o teste um longo período de relaxamento entre os pulsos, e permitindo identificar a OCV e relacioná-la com o SOC. Ramachandran (2020), utilizou o teste HPPC junto a um FKE (Filtro de Kalman Estendido) para estimar o SOC de uma bateria modelada por um circuito equivalente de primeira ordem [8]. A metodologia aplicada gerou uma estimativa de estado de carga (SOC) com erro médio de 10%. Em [4], é aplicada uma metodologia similar, na qual se encontrou a relação OCV-SOC por meio de um ajuste de curva, obtendo um polinômio de 7ª ordem. Uma desvantagem do método OCV é o de ele ser feito de maneira *offline*, uma vez que necessita de dados experimentais que são obtidos por meio de testes em ambiente controlado [9].

B. Contagem de coulomb (CC)

Neste método a estimação do SOC é feita por meio da integração da corrente ao longo do tempo. O método tem como vantagem a de poder ser realizado *online*, bem como ser de simples implementação. Porém, este método é baseado em medições, de forma que os erros de medição do sensor de corrente acabam se acumulando (erros acumulativos), afetando a estimação. Uma outra desvantagem do método é que o valor do SOC inicial não é tão simples de ser amostrado em um veículo elétrico [6]. Em [10], foi desenvolvida uma adaptação do método CC que permite calcular o SOC inicial baseando-se no modelo de operação da bateria (carregando, descarregando ou circuito aberto). Assim, o problema de encontrar o SOC inicial pôde ser resolvido, reduzindo o erro de estimação de 8.93% (sem utilizar o método) para 2.43% (utilizando o método desenvolvido), conforme demonstrado em [10].

C. Filtro de Kalman (FK)

O procedimento para aplicação do método baseado em FK na estimação do SOC pode ser resumido pela Fig. 1. O FK utiliza um modelo que representa o comportamento da bateria, bem como os dados medidos, para estimar estados no “momento atual”, baseado na estimação feita no momento anterior. Por fim, os valores estimados e medidos são comparados para que a estimação possa ser corrigida baseada no ganho de Kalman [6].

O FK garante boa precisão apenas para sistemas lineares. Para aplicar o método FK a sistemas não-lineares é necessário utilizar variações do FK, como por exemplo o FKE. Florin (2017), utilizou um modelo de circuito equivalente de segunda

ordem e a aplicação de um algoritmo baseado em FKE para a estimação do SOC de uma bateria de lítio-ferro-fosfato (LiFePO4). O método proposto atingiu uma boa precisão na estimação, com erro máximo de aproximadamente 2% [11].




Figura 1– Diagrama de Blocos do processo de aplicação do método baseado em Filtro de Kalman [6]

D. Redes neurais artificiais

As redes neurais artificiais são algoritmos que utilizam uma grande quantidade de dados de carga e descarga da bateria para “aprender” as características dinâmicas da mesma. Além disso, o processo de “treinamento” também é utilizado para corrigir erros. Porém, muitos fatores podem influenciar na precisão da estimação por redes neurais artificiais, fazendo com que esse método não se mostre como uma boa opção para a aplicação prática [12].

TABELA I. COMPARAÇÃO ENTRE OS MÉTODOS DE ESTIMAÇÃO DO SOC

Classificação	Método	Vantagens e desvantagens
Convencional	OCV	Fácil de implementar. Porém, offline, requer longo período para relaxamento da célula.
	CC	Fácil de implementar, online, não requer muito recurso computacional. Porém, sensível ao estado inicial, depende da precisão do sensor.
Baseado em modelos	FK	Online, estimativa em tempo real, tem bom desempenho em sistemas lineares. Porém, não tem bom desempenho em sistemas não-lineares.
	FKE	Online, estimativa em tempo real, não é sensível ao estado inicial, tem bom desempenho em sistemas não-lineares. Porém, erros na linearização prejudicam a estimação.
Baseado em dados	Redes Neurais	Não depende do modelo da bateria. Porém, depende fortemente das amostras de treino.

III. METODOLOGIA

O estimador de SOC desenvolvido neste trabalho é baseado em um algoritmo de FKE, considerando um MCE de ordem n , com parâmetros identificados por meio de dados de um teste HPPC. Nessa seção serão apresentados os detalhes da metodologia utilizada.

A. Modelagem da bateria

A modelagem da bateria foi feita baseando-se no MCE de ordem n ilustrado na Fig. 2, na qual cada elemento é relacionado a uma característica comportamental da bateria. A tensão V_{OC} representa a tensão de circuito aberto que varia com relação ao SOC, sendo V_1 e V_n as tensões dos ramos RC, V_{term} e I_{term} , respectivamente, como tensão e corrente medidas nos terminais da bateria, R_0 sendo a resistência em série que representa a resposta instantânea de tensão durante a

polarização e R_n, C_n compondo os ramos RC que representam as tensões de difusão durante a polarização [13].




Figura 2 – Modelagem de bateria por circuito equivalente de ordem n

Considerando o modelo da Fig. 2 como um sistema que tem a corrente I_{term} como entrada e V_{term} como saída, pode-se utilizar as Leis de Kirchoff para equacionar o modelo, conforme (1) e (2).

$$\begin{cases} \dot{SOC}(t) = -\frac{\eta \cdot I_{term}}{Q_n} \\ \dot{V}_n(t) = -\frac{V_n}{R_n \cdot C_n} + \frac{I_{term}}{C_n} \end{cases} \quad (1)$$

$$V_T = V_{OC}(SOC) - I_{term} \cdot R_0 - V_n \quad (2)$$

Resolvendo \dot{V}_n por meio da solução geral de equações diferenciais, temos:

$$V_n(t) = V_n(0)e^{-\frac{\Delta t}{\tau}} + I_{term} \cdot R_n \left(1 - e^{-\frac{\Delta t}{\tau}}\right) \quad (3)$$

onde, $V_n(0)$ é a tensão inicial do ramo RC, Δt é o tempo de amostragem e τ é a constante de tempo, dada por $R_n \cdot C_n$. Considerando $[k + 1]$ o tempo atual e $[k]$ o tempo anterior, os equacionamentos podem ser discretizados:

$$\begin{cases} SOC[k + 1] = SOC[k] - \frac{\eta I_{term}[k]}{Q_n} \\ \dot{V}_n[k + 1] = V_n[k]e^{-\frac{\Delta t}{\tau}} + I_{term}[k]R_n \left(1 - e^{-\frac{\Delta t}{\tau}}\right) \end{cases} \quad (4)$$

$$\begin{aligned} V_T[k + 1] = \\ V_{OC}(SOC[k + 1]) - I_{term}[k + 1]R_0 - V_n[k + 1] \end{aligned} \quad (5)$$

Dessa forma, o modelo pode ser representado na forma de espaço de estados:

$$x[k + 1] = Ax[k] + Bu[k] \quad (6)$$

$$y[k + 1] = Cx[k + 1] + Du[k + 1] + O[k + 1] \quad (7)$$

Onde,

$$A = \begin{bmatrix} e^{-\frac{T_a}{R_n C_n}} & 0 \\ 0 & 1 \end{bmatrix}; B = \begin{bmatrix} R_n \left(1 - e^{-\frac{T_a}{R_n C_n}}\right) \\ -\frac{\eta T_a}{C_n} \end{bmatrix}; \quad (8)$$

$$C = [-1 \ 0]; D = [-R_0]; O = [V_{OC}(SOC[k + 1])] \quad (9)$$

B. Identificando relação OCV-SOC e parâmetros do modelo

Uma das formas mais comuns para identificação de parâmetros de modelos de circuito equivalente de ordem n é por meio de ensaio com aplicação de pulsos de descarga na bateria. Para este trabalho foram utilizados os dados do teste HPPC de [15], sendo o perfil característico do teste mostrado na Fig. 3. O teste foi aplicado a uma célula NMC INR21700-

M50T, com um período de relaxamento de 1 hora, com pulsos de descarga de 1C e micropulsos de 0.5C, sendo o micropulso de descarga aplicado por 30 segundos e o micropulsos de carga por 10 segundos.

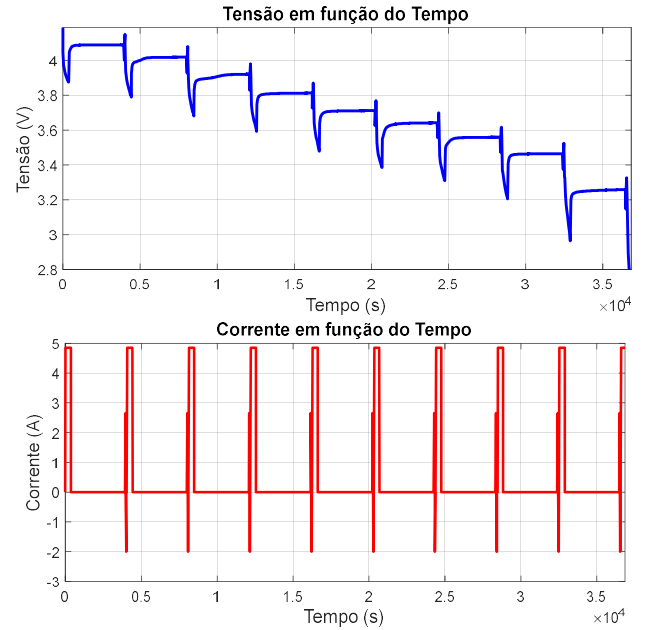


Figura 3 – Tensão e corrente do teste de pulsos

Analisando um único pulso isolado, podemos identificar pontos de interesse (Fig. 4) que auxiliarão a identificar os parâmetros do modelo. Considerando (2), percebe-se que nos pontos P1 e P5 não há corrente e não há influência dos capacitores, sendo, portanto, possível identificar valores de OCV.

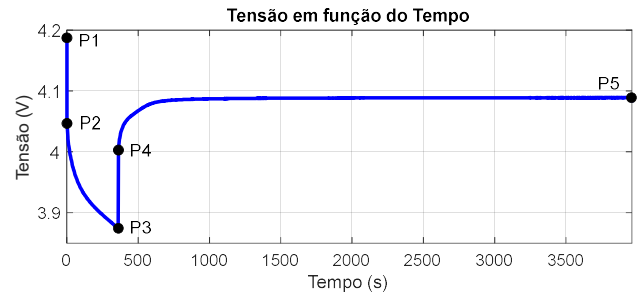


Figura 4 – Identificando ponto de interesse de um pulso

Obtendo os valores de OCV de cada pulso e tendo os respectivos valores de SOC, é possível identificar a relação entre a OCV e o SOC por meio de interpolação ou por ajuste de curva.

Para identificar o valor da resistência em série, os pontos P1-P2 e P3-P4 devem ser analisados. Durante esses períodos ainda não há influência dos capacitores e ocorrem mudanças instantâneas da tensão, devido à aplicação/retirada do pulso de descarga. Sendo assim, considerando (2), podem-se identificar os valores de R_0 da seguinte forma:

$$R_0 = -\frac{V_T - V_{OC}(SOC)}{I_{term}} \quad (10)$$

Para identificar os parâmetros RC do modelo, foi utilizado um método de ajuste de curva exponencial, por meio do *Curve Fitter* do Matlab. O ajuste utilizado foi baseado em (11), o qual tem o mesmo formato da equação da tensão dos ramos RC (4) durante o período de relaxamento da célula. Dessa forma, $V_n = a$, $x = \Delta t$ e $\tau = \frac{1}{b}$, é possível encontrar os valores RC por meio dos coeficientes obtidos com o ajuste de curva. De forma similar, também usando o *Curve Fitter* do Matlab, foi possível encontrar um polinômio de 4º que caracteriza a relação entre a OCV e o SOC.

$$f(x) = a * \exp(b * x) \quad (11)$$

C. Algoritmo baseado no filtro de Kalman estendido

Devido à não-linearidade do sistema, o FKE foi utilizado como base para o algoritmo de estimação. Um sistema não-linear pode ser representado por uma equação de estados (12) e uma equação de observação (13):

$$x[k+1] = f(x[k], u[k]) + w[k] \quad (12)$$

$$y[k+1] = g(x[k+1], u[k+1]) + v[k+1] \quad (13)$$

Por utilizar equações não-lineares, o algoritmo do FKE precisa linearizar as equações a cada iteração por meio de derivadas parciais, também chamadas de jacobianos, conforme apresentado em (14).

$$\begin{aligned} \hat{A} &= \frac{\partial f(\hat{x}^+, u, w)}{\partial \hat{x}^+}; & \hat{B} &= \frac{\partial f(\hat{x}, u, v)}{\partial w_k}; \\ \hat{C} &= \frac{\partial h(\hat{x}^-, u, w)}{\partial \hat{x}^-}; & \hat{D} &= \frac{\partial g(\hat{x}, u, v)}{\partial v_k} \end{aligned} \quad (14)$$

O processo de implementação do FKE inicia com a definição de valores iniciais (no momento $k = 0$) para o estado $x[0]$ e para as covariâncias do erro de estado $P[0]$, do ruído de processo Q_w e do ruído de medição R_v , onde o valor de R_v é encontrado de acordo com o erro ao quadrado do equipamento usado para o teste da célula de bateria [14]. Após a inicialização, é realizada a estimação do estado \hat{x} e da covariância do erro de estado \hat{P} , ambas no momento $k + 1$, baseando-se nos valores obtidos no momento k .

$$\hat{x}^-[k+1] = A[k] \hat{x}[k] + B[k] u[k] \quad (15)$$

$$\hat{P}^-[k+1] = \hat{A}[k-1] \hat{P}[k] \hat{A}^T[k-1] + Q_w \quad (16)$$

A saída estimada, também chamada de matriz de observação, é apresentada por:

$$\hat{y}[k+1] = C[k+1] \hat{x}[k+1] + D[k+1] u[k+1] \quad (17)$$

A correção das estimativas é feita baseada no ganho de Kalman L . Com o tempo o valor de L diminui, indicando que as estimativas se tornam mais precisas.

$$L[k+1] = \frac{\hat{P}^-[k+1] \hat{C}^T[k+1]}{\hat{C}[k+1] \hat{P}^-[k+1] \hat{C}^T[k+1] + R_v} \quad (18)$$

$$\hat{x}^+[k+1] = \hat{x}^-[k+1] + L[k+1] (y[k+1] - \hat{y}[k+1]) \quad (19)$$

$$\hat{P}^+[k+1] = (I - L[k+1] C[k+1]) \hat{P}^-[k+1] \quad (20)$$

Os equacionamentos de cada etapa do FKE são apresentados de forma resumida na Tabela II.

TABELA II. RESUMO DOS EQUACIONAMENTOS DO FKE

Etapas	Equações
Equação de estados:	$x[k+1] = f(x[k], u[k]) + w[k]$
Equação de saída:	$y[k+1] = g(x[k+1], u[k+1]) + v[k+1]$
Inicialização	
Estados iniciais:	$x[0]$
Covariância de erro dos estados iniciais:	$P[0]$
(1) Predição	
Predição de estados:	$\hat{x}^-[k+1] = \hat{A}[k] \hat{x}[k] + \hat{B}[k] u[k]$
Predição de covariância de erro dos estados:	$\hat{P}^-[k+1] = \hat{A}[k-1] \hat{P}[k] \hat{A}^T[k-1] + Q_w$
Predição da saída:	$\hat{y}[k+1] = \hat{C}[k+1] \hat{x}[k+1] + \hat{D}[k+1] u[k+1]$
(2) Correção	
Cálculo do ganho de Kalman:	$L[k+1] = \frac{\hat{P}^-[k+1] \hat{C}^T[k+1]}{\hat{C}[k+1] \hat{P}^-[k+1] \hat{C}^T[k+1] + R_v}$
Diferença entre saída medida e estimada:	$Erro = y[k+1] - \hat{y}[k+1]$
Correção dos estados:	$\hat{x}^+[k+1] = \hat{x}^-[k+1] + L[k+1] Erro$
Correção da covariância de erro dos estados:	$\hat{P}^+[k+1] = (I - L[k+1] C[k+1]) \hat{P}^-[k+1]$
Repetir etapa (1) e (2) uma vez a cada iteração	

IV. RESULTADOS E DISCUSSÕES

Como resultado da identificação dos parâmetros do modelo, obteve-se o gráfico da Fig. 5 que apresenta os valores de OCV e de R_0 em função do SOC, assim como o gráfico da Fig. 6, nos quais (a)-(b) apresentam as variações dos parâmetros RC do modelo de primeira e de segunda ordem em função do SOC.

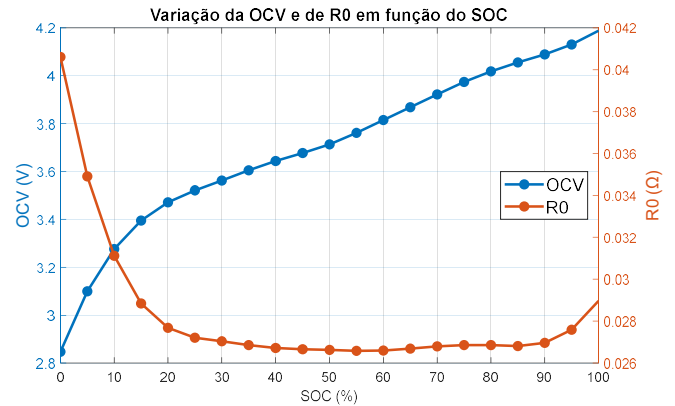


Figura 5 – Variação de OCV e R_0 em função do SOC

Apesar das variações observadas, a fim de facilitar a implementação do algoritmo, foram utilizados valores constantes para R_0 , R_1 , C_1 , conforme Tabela III.

TABELA III. VALORES CONSTANTES PARA OS PARÂMETROS

R_0	R_1	C_1
0.0266 Ω	0.0142 Ω	10081 F

Foram comparados os modelos de primeira e segunda ordem, a fim de verificar se o modelo de primeira ordem seria suficiente para o trabalho, proporcionando uma precisão adequada, enquanto simplificaria o equacionamento, diminuiria o esforço computacional e aumentaria a velocidade dos cálculos. Para isso, os valores de tensão obtidos com ambos os modelos foram comparados com o valor de tensão do teste de pulsos. Nota-se (ver Fig. 7) que os modelos tiveram

comportamento similar, bem próximos do valor real. Portanto, devido à similaridade dos modelos, e para facilitar a implementação, foi utilizado o modelo de primeira ordem.

A literatura mostra que o método CC é confiável quando o valor de SOC inicial é conhecido e, desta forma, tal abordagem foi adotada na verificação do desempenho da estimação realizada por FKE (ver Fig. 8).

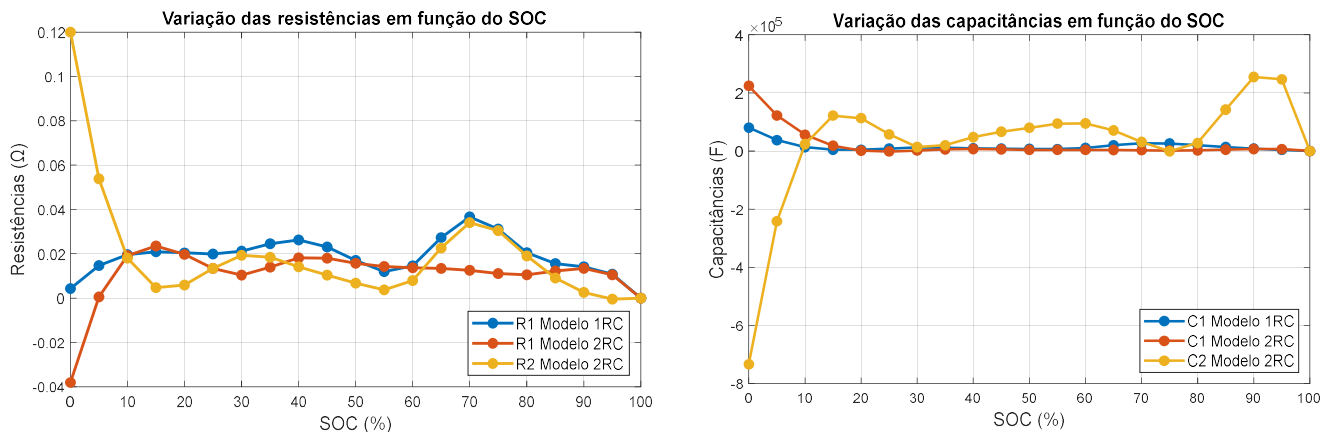


Figura 6 – Variação das resistências R1 e R2 (à esquerda) e variação das capacitâncias C1 e C2 (à direita) dos modelos de primeira e segunda ordem em função do SOC.

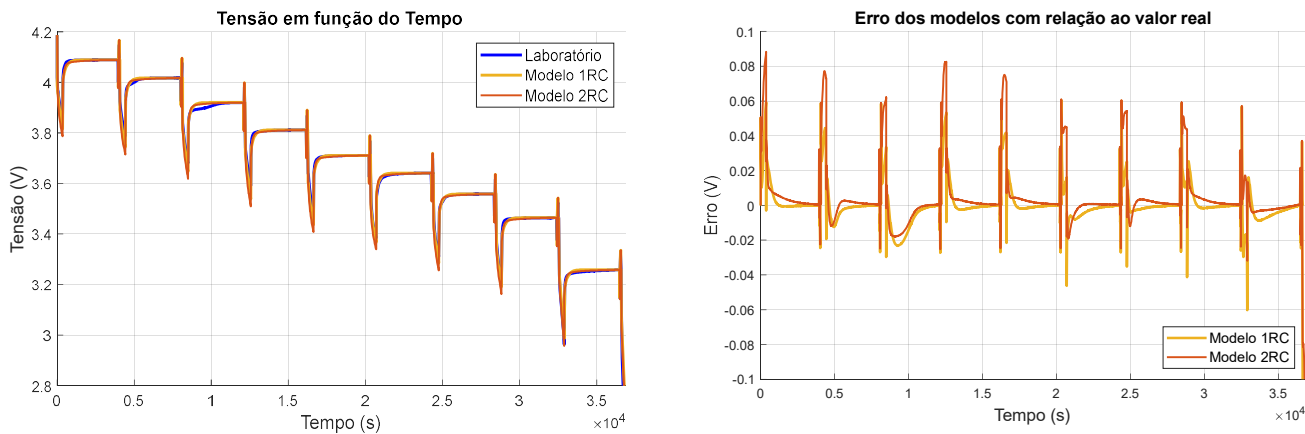


Figura 7 – Comparação entre modelos de primeira e segunda ordem (à esquerda) e erro com relação ao valor real (à direita).

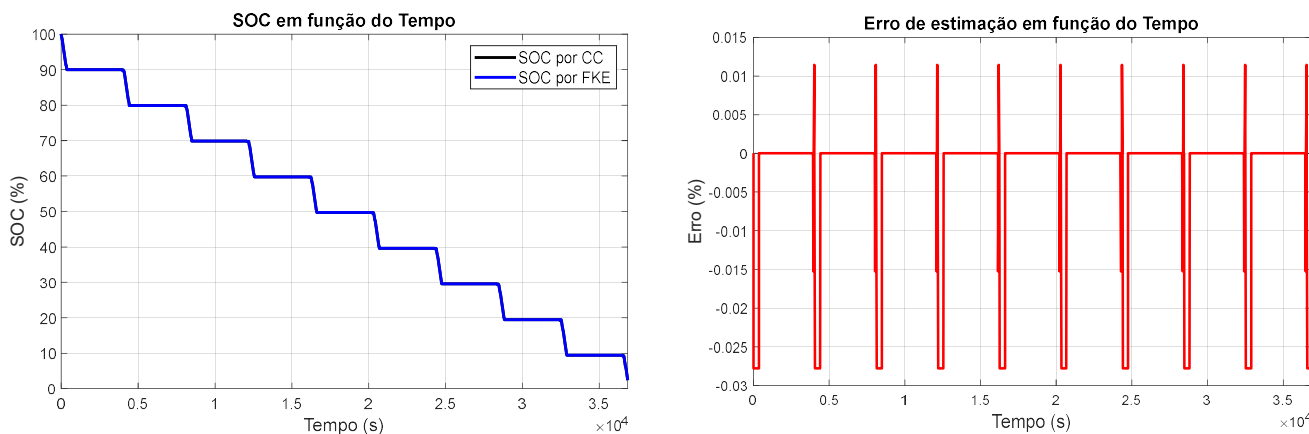


Figura 8 – Comparação da estimação do SOC por método CC e FKE (à esquerda) e erro da estimação do SOC por FKE com relação ao método CC (à direita).

Nota-se que se obteve uma boa estimação para o SOC, com erros menores que 1%, enquanto em referências encontradas na literatura, os erros se mostravam recorrentemente maiores. Vale ressaltar que os dados utilizados neste trabalho são de um teste realizado em ambiente controlado, com poucos erros de

medição e ruídos, o que também contribui para obtenção de erros menores.

V. CONCLUSÕES

Os resultados apresentados no decorrer do presente trabalho, frutos do desenvolvimento e implementação de um

algoritmo de SOC proprietário, representa um avanço significativo nas aplicações operacionais em Defesa Nacional quando o objetivo é a aplicação em Veículos Aéreos Não-Tripulados (VANTs) militares. O desenvolvimento bem-sucedido de um estimador de estado de carga de baterias, combinado com a caracterização precisa do modelo de primeira ordem e a validação do algoritmo, demonstrou resultados bastante relevantes, com erros de estimação inferiores a 1%, muito menores do que os atualmente encontrados na literatura.

Tal abordagem e solução se mostra como crucial para a implementação de um sistema eficiente de gerenciamento de baterias, oferecendo uma solução confiável para maximizar o tempo de voo dos VANTs e evitar quedas inesperadas, otimizando a operacionalidade dos vetores aéreos e tornando-os cada vez mais autônomos e “inteligentes”. Ao estender a metodologia para diferentes químicas de baterias de íons de lítio, comumente utilizadas em VANTs militares, essa abordagem se torna altamente versátil e aplicável em uma variedade de contextos operacionais.

Com base em tais resultados promissores, é possível vislumbrar um futuro no qual os VANTs militares se tornem ainda mais eficientes, autônomos e seguros, aumentando assim a capacidade de nossas Forças Armadas de executar missões críticas com excelência. Assim, a presente pesquisa mostra potencial para revolucionar as operações de Defesa Nacional, oferecendo um avanço significativo para a eficiência e eficácia das missões com VANTs.

REFERÊNCIAS

- [1] H. F. Peres, “Desenvolvimento de veículos aéreos não tripulados no Brasil: interesses nacionais, desafios internacionais”, *Conjunt. Austral*, vol. 6, n° 31, p. 29–41, 2015.
- [2] Ministério da Defesa, “Glossário das Forças Armadas”, n° 5, p. 278, 2015.
- [3] R. G. Rigo, “Desenvolvimento de sistema de monitoramento do estado de carga de baterias para uso em drones”, Universidade de Caxias do Sul, Bento Gonçalves, 2022.
- [4] Q. Zhu, N. Xiong, M.-L. Yang, R.-S. Huang, e G.-D. Hu, “State of Charge Estimation for Lithium-Ion Battery Based on Nonlinear Observer: An H_∞ Method”, *Energies*, vol. 10, n° 5, p. 679, maio 2017, doi: 10.3390/en10050679.
- [5] L. Zhi, Z. Peng, W. Zhifu, S. Qiang, e R. Yinan, “State of Charge Estimation for Li-ion Battery Based on Extended Kalman Filter”, *Energy Procedia*, vol. 105, p. 3515–3520, maio 2017, doi: 10.1016/j.egypro.2017.03.806.
- [6] B. Yang *et al.*, “Classification, summarization and perspectives on state-of-charge estimation of lithium-ion batteries used in electric vehicles: A critical comprehensive survey”, *J. Energy Storage*, vol. 39, p. 102572, jul. 2021, doi: 10.1016/j.est.2021.102572.
- [7] Z. Wang, G. Feng, D. Zhen, F. Gu, e A. Ball, “A review on online state of charge and state of health estimation for lithium-ion batteries in electric vehicles”, *Energy Rep.*, vol. 7, p. 5141–5161, nov. 2021, doi: 10.1016/j.egy.2021.08.113.
- [8] R. Ramachandran, D. Ganeshaperumal, e B. Subathra, “Parameter Estimation of Battery Pack in EV using Extended Kalman Filters”, em *2019 IEEE International Conference on Clean Energy and Energy Efficient Electronics Circuit for Sustainable Development (INCCES)*, Krishnankoil, India: IEEE, dez. 2019, p. 1–5. doi: 10.1109/INCCES47820.2019.9167740.
- [9] Y. Wang, Y. Cheng, Y. Xiong, e Q. Yan, “Estimation of battery open-circuit voltage and state of charge based on dynamic matrix control - extended Kalman filter algorithm”, *J. Energy Storage*, vol. 52, p. 104860, ago. 2022, doi: 10.1016/j.est.2022.104860.
- [10] K. S. Ng, C.-S. Moo, Y.-P. Chen, e Y.-C. Hsieh, “Enhanced coulomb counting method for estimating state-of-charge and state-of-health of lithium-ion batteries”, *Appl. Energy*, vol. 86, n° 9, p. 1506–1511, set. 2009, doi: 10.1016/j.apenergy.2008.11.021.
- [11] F. Ciordea, C. Rusu, M. Nemes, e C. Gatea, “Extended Kalman Filter for state-of-charge estimation in electric vehicles battery packs”, em *2017 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM) & 2017 Intl Aegean Conference on Electrical Machines and Power Electronics (ACEMP)*, Brasov, Romania: IEEE, maio 2017, p. 611–616. doi: 10.1109/OPTIM.2017.7975036.
- [12] N. Li *et al.*, “Review of lithium-ion battery state of charge estimation”, *Glob. Energy Interconnect.*, vol. 4, n° 6, p. 619–630, dez. 2021, doi: 10.1016/j.gloei.2022.01.003.
- [13] G. L. Plett, *Battery management systems: battery modeling. Volume 1*. Boston : London: Artech House, 2015.
- [14] R. de M. S. Santos, “Estimação do Estado de Carga de Baterias de Lítio-ion em Diferentes Condições de Temperaturas Utilizando Filtros de Kalman”, Universidade Federal da Paraíba - UFPB, Paraíba, 2019.
- [15] G. Pozzato, A. Allam, e S. Onori, “Lithium-ion battery aging dataset based on electric vehicle real-driving profiles”. 2022. doi: <https://doi.org/10.1016/j.dib.2022.107995>.