

Gerenciamento Avançado de Baterias para VANTs militares: Estimando com Precisão SoC e SoH em Tempo Real.

Andrés Mauricio Oviedo Pinzón¹, Eli Ana Costa Camargo¹, Tobias Morato Portilho¹, Roberto d'Amore¹, Marcus Henrique Victor Junior¹ e Lester de Abreu Faria¹

¹Instituto Tecnológico de Aeronáutica (ITA), São José dos Campos/SP – Brasil

Resumo – O presente artigo propõe e valida um algoritmo de estimação conjunta para o Estado de Carga (SoC) e Estado de Saúde (SoH) a ser implementado em um sistema de gerenciamento de baterias (BMS) para veículos aéreos não tripulados (VANTs) de asa rotativa elétrico, com fins a aplicações operacionais em áreas de Defesa. Para a estimação em tempo real, uma bateria de íon de lítio foi modelada por meio de um circuito equivalente, com parâmetros estimados em tempo real com o método dos Mínimos Quadrados Recursivos e Fator de Esquecimento. Estes alimentam o estimador de estados por meio de um Filtro de Kalman Estendido, estimando o SoC e finalmente calculando SoH. A estimação em tempo real de parâmetros aprimora a precisão da estimação do SoC, demonstrando que é possível realizar tal integração e medir o SoH.

Palavras-Chave – VANTs, Estimação de Estado de Carga, Estimação de Estado de Saúde

I. INTRODUÇÃO

O termo VANT (Veículo Aéreo Não Tripulado) se refere a um tipo de drone específico que leva carga útil embarcada e que pode ser operado de forma remota ou autônoma. A principal razão do seu desenvolvimento está relacionada com a diminuição da intervenção humana direta em tarefas de risco como, por exemplo, as atividades militares e aplicações operacionais em áreas de defesa. O uso dos VANTs militares tem proporcionado mudanças organizacionais e doutrinárias na forma de fazer guerra e manter a paz, por meio do reconhecimento e inteligência, vigilância e patrulha, operações de contraterrorismo, ataques de precisão, entre outros, tudo em tempo real [1]–[3].

VANTs elétricos do tipo de asa rotativa têm ganhado popularidade pela sua simplicidade mecânica, alta manobrabilidade, pouso e decolagem vertical, capacidade de pairar no ar, menor ruído, além do seu custo razoável quando comparados às aeronaves tradicionais. Eles usam normalmente baterias de lítio como principal fonte de energia, com todas as complicações e cuidados decorrentes desse uso, os quais merecem atenção, podendo, caso mal avaliados, gerarem transtornos para os operadores, ainda mais em missões críticas.

Uma das maiores preocupações em VANTs é a duração da carga e confiabilidade da bateria, uma vez que uma medição errada dos seus estados pode levar a perdas de conectividade, atrasos no percurso e, no pior dos casos, desligamento do

VANT durante o voo, causando a queda e possível perda [4], [5].

Para monitorar constantemente a bateria e atuar em seus parâmetros, caso necessário, existe o BMS (*Battery Management System*), o qual apresenta como uma de suas funções a de fornecer estimativas do estado de carga (SoC – *State of Charge*) e o estado de saúde (SoH – *State of Health*) da bateria a partir de medições de corrente, tensão e temperatura. Tais indicadores podem ser usados para calcular outros estados úteis da bateria, tais como o fim de descarga (*EoD - End of Discharge*) e a vida útil remanescente (*RUL - Remaining Useful Time*). Como o SoH, *EoD* e *RUL* são geralmente derivados da estimação do SoC, esta estimação deve ser o mais precisa possível, sempre dependendo de dois aspectos: o modelo da bateria e o algoritmo de estimação. A literatura geralmente apresenta o modelo “por circuito equivalente” como uma boa opção para a modelagem da bateria, enquanto para o algoritmo de estimação, a literatura destaca os Filtros de Kalman como uma opção promissória [6].

Existem diversos trabalhos focando no uso dos indicadores SoC e SoH para melhorar o desempenho das VANTs, o que mostra a importância do tema, não somente acadêmica, mas ainda nas aplicações de tais conceitos. Dentre os mais relevantes nesse sentido está [7], que estima o SoC usando Filtro de partículas (algoritmo similar ao filtro de Kalman) para depois calcular o *EoD* e a sua incerteza. Já [3] e [4] fazem um estudo similar, só que focado em VANTs de asa rotativa pequenos, no qual se usa um filtro Bayesiano (que está na mesma categoria dos filtros de Kalman) para estimar o SoC a partir de um modelo por circuito equivalente simples. Este também estima os parâmetros da bateria ao longo de seu uso, e aprimora a estimação do SoC usando um laço de correção adicional no filtro bayesiano. Tal implementação de laço adicional para incluir o efeito da variação de parâmetros tem se tornado popular na estimação do SoH, onde, por exemplo [6], usa Filtro de Kalman Estendido (FKE) para estimar o SoC para VANTs, e aproveita a técnica de Mínimos Quadrados recursivos (MQR) para estimar os parâmetros do circuito equivalente da bateria e, assim, aprimorar a precisão da estimação do SoC em ambiente simulado.

O uso desta estimação conjunta de parâmetros e estados é usada não só para aplicações em VANTs, mas também para outros tipos de dispositivos de transporte elétrico, tais como veículos subaquáticos [8] e veículos puramente elétricos [9]. A literatura relacionada com a estimação conjunta é ampla, mas dentre todas as soluções apresentadas para implementação, pode ser identificada uma tendência de uso do FKE para estimação de estados em conjunto com alguma variante do método MQR.

Neste artigo se propõe e implementa a estimação conjunta do SoC e SoH, juntamente com parâmetros da bateria para um VANT de asa rotativa visando ao seu uso em aplicações

Andrés Mauricio Oviedo Pinzón, andresoviedopinzon@gmail.com; Eli Ana Costa Camargo, eli.ccamargo@yahoo.com.br; Tobias Morato Portilho, tobias_vot@hotmail.com; Roberto d'Amore, roberto.damore@gp.ita.br; Marcus Henrique Victor Junior, marcus.victor@gp.ita.br; Lester de Abreu Faria, lester@ita.br.

Este trabalho foi financiado pela Fundep, através do Projeto ROTA2030 (BMS-Auto), PROCESSO Nº: 27192.03.03/2021.01-00.

militares de vigilância e reconhecimento, as quais requerem uma estimativa precisa de tais parâmetros por ocorrer em situações críticas de alto risco e demandar maior autonomia de voo. O *SoC* será estimado usando o FKE aplicado a um modelo de bateria por circuito equivalente RC de ordem 2, na qual a atualização dos parâmetros do circuito equivalente será feita usando MQR com fator de esquecimento (MQRFE).

II. ESTIMAÇÃO CONJUNTA DOS ESTADOS DA BATERIA

A. O Algoritmo de Estimação Conjunta

O *SoH* pode ser entendido como um indicativo do nível de degradação da bateria e definido como a razão entre a capacidade de carga da bateria atual (Q_{at}) e a capacidade de carga da mesma quando nova (Q_{no}), como apresentado em (1). Com isso, pode-se estimar sua vida útil de acordo com o apresentado e proposto em [9]–[11]. Normalmente se considera que se atingiu o fim da vida útil da bateria quando a sua capacidade Q_{at} diminui até a 80% ($Q_{at} = 0,8$). Tal definição tem o problema de não dar uma indicação intuitiva do estado de saúde (por estar entre 1 e 0,8), sendo assim possível adaptar o conceito para a forma apresentada em (2), na qual o *SoH* seria 1 para uma bateria nova e 0 para uma bateria que atingiu seu fim de vida. A capacidade “atual” da bateria pode ser calculada como uma função do *SoC* e da corrente em terminais da mesma ($i_t(t)$), tal como mostrado em (3), sendo t_a e t_b os tempos de início e fim de análise respectivamente [12], [13].

$$Q_r = Q_{at}/Q_{no} \quad (1)$$

$$SoH = 5(Q_r - 0.8) \quad (2)$$

$$Q_{at} = \frac{\int_{t_a}^{t_b} i_t(t) dt}{SoC(t_b) - SoC(t_a)} \quad (3)$$

Em (3), é possível notar que a precisão da estimação do *SoH* depende principalmente da precisão da medição da corrente e da estimação do *SoC*. Quando se tem um bom modelo de bateria, estando ele bem parametrizado, os algoritmos de estimação do *SoC* terão um bom desempenho com erro de estimação pequeno; mas quando os parâmetros usados no modelo divergem dos parâmetros reais da bateria, a estimação do *SoC* perderá em precisão. Como em baterias de íon de Lítio existe o fenômeno de perda de capacidade por degradação da bateria, vai existir variação do valor de Q_{at} e dos outros parâmetros do modelo da bateria ao longo do tempo [13], [14], fazendo com que os estimadores de estado percam precisão naturalmente. Para solucionar tal problema de forma coerente e relevante para a operação, principalmente as críticas, é necessário fazer a estimação em tempo real dos parâmetros do modelo, sendo aqui onde entram as soluções de estimação conjunta de estados e estimação de parâmetros, principal contribuição do modelo gerado e proposto no presente artigo.

A Fig. 1 apresenta o esquema geral de estimação conjunta para *SoC* e *SoH* usado neste trabalho, no qual o processo inicia com a caracterização da bateria com os testes *HPPC* (*Hybrid Pulse Power Characterization*) e de capacidade [15] para obter a capacidade inicial da bateria (Q_{no}) e os parâmetros iniciais do modelo por circuito equivalente. Esse conjunto inicial de parâmetros serve como ponto de partida para a estimação

online dos mesmos, usando a técnica MQRFE, a qual estima os valores atuais dos parâmetros, permitindo fazer uma estimação de estados mais precisa ao usar o algoritmo KFE. Finalmente, com os estados estimados, se usa o *SoC* e as (1)–(3) para calcular o *SoH* e Q_{at} , valor que será realimentado para o algoritmo de estimação.

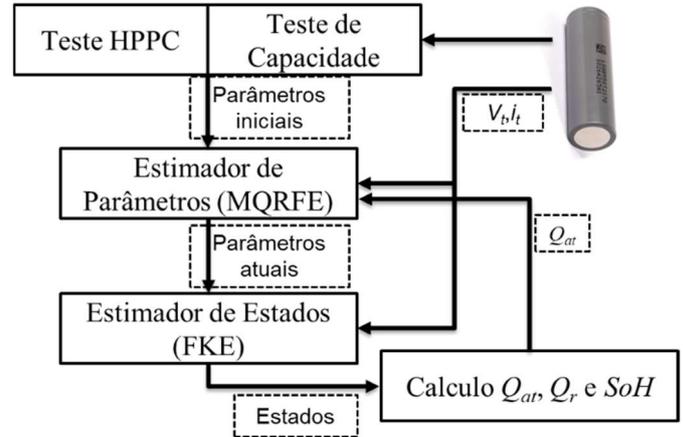


Fig. 1 Esquema geral de estimação conjunta de estados.

B. Modelagem da Bateria

Para aplicações de estimação conjunta de estados, a forma mais comum de modelar a bateria é o uso de um circuito equivalente que usa fonte de tensão, resistores e capacitores para criar um circuito equivalente que possa representar o comportamento da bateria.

Uma vez que a precisão da estimação de estados depende bastante do modelo selecionado, o modelo por circuito equivalente com dois ramos Resistor-Capacitor em série (MCE2RC) é uma opção interessante por ter um equilíbrio razoável entre complexidade matemática, custo computacional e precisão[9], [16], [17]. A Fig. 2 apresenta o MCE2RC, no qual o circuito consiste de uma fonte de tensão de circuito aberto (*OCV- Open Circuit voltage*) em série com uma resistência característica (R_0) e dois ramos RC. R_R e C_R representam a resistência e capacitância de polarização rápida na bateria, assim como R_L e C_L representam as mesmas grandezas de polarização lenta.

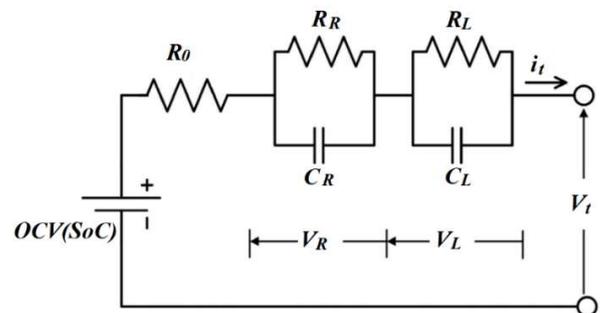


Fig. 2 Modelo por circuito equivalente com dois ramos RC.

A relação entre a tensão dos terminais da bateria (V_t) e a sua corrente (i_t) é apresentada em (4)–(7), sendo $\tau_R = R_R C_R$ a constante de tempo rápida e $\tau_L = R_L C_L$ a constante de tempo lenta. A eficiência de carga/descarga ($\eta(t)$) normalmente está

em um valor perto de 1. A relação entre SoC e a tensão de circuito aberto ($OCV(SoC(t))$) pode ser modelada como uma tabela de dados na qual o resultado ($OCV(t)$) será uma interpolação dos mesmos.

$$\dot{V}_R(t) = -V_R(t)/\tau_R + i_t(t)/C_R \quad (4)$$

$$\dot{V}_L(t) = -V_L(t)/\tau_L + i_t(t)/C_L \quad (5)$$

$$S\dot{o}C(t) = -\eta(t)i_t(t)/Q_{at} \quad (6)$$

$$V_t(t) = OCV(SoC(t)) - V_R(t) - V_L(t) - R_0 i_t(t) \quad (7)$$

É possível discretizar o modelo de forma analítica fazendo duas suposições: (i) para um passo pequeno de tempo ($T_s = t - t_0$) a tensão de circuito aberto (OCV) tem mudança desprezível e será considerada constante; (ii) da mesma forma, a entrada $i_t(t)$ será considerada constante para o T_s . Resolvendo o sistema de equações diferenciais com as suposições mencionadas, o modelo pode ser descrito por (8)-(11).

$$V_R[k+1] = e^{(-T_s/\tau_R)}V_R[k] + R_R(1 - e^{(-T_s/\tau_R)})i_t[k] \quad (8)$$

$$V_L[k+1] = e^{(-T_s/\tau_L)}V_L[k] + R_L(1 - e^{(-T_s/\tau_L)})i_t[k] \quad (9)$$

$$SoC[k+1] = SoC[k] - T_s\eta[k]i_t[k]/Q_{at} \quad (10)$$

$$V_t[k+1] = OCV(SoC[k+1]) - V_R[k+1] - V_L[k+1] - R_0 i_t[k] \quad (11)$$

C. Estimação de Parâmetros da Bateria

A aplicação do método dos mínimos quadrados recursivos exige que o sistema seja representado da forma proposta em (12) e (13), onde $y[k]$ representa a amostra de variável de saída atual, $u[k]$ a entrada atual e a_n os coeficientes relacionados com os valores de saídas anteriores. Então, para poder aplicar o algoritmo, é necessário aplicar a seguintes etapas: (i) Definição do modelo matemático, (ii) Adequação do modelo, (iii) Vetorização do modelo, (iv) aplicação das equações método por MQRFE, e (v) cálculo dos parâmetros[18], [19].

$$y[k] = -a_1 y[k-1] - a_2 y[k-2] \dots - a_n [k-n] + b_0 u[k] + b_1 u[k-1] \dots + b_m u[k-m] \quad (12)$$

$$\frac{Y(z)}{U(z)} = \frac{b_0 + b_1 z^{-1} + \dots + b_n z^{-n}}{1 + a_1 z^{-1} + \dots + a_m z^{-m}} \quad (13)$$

A etapa (i) de definição do modelo matemático já está resumida no MCE2RC e (4)-(7). Desta forma, para adequar o modelo (ii), se representam os equacionamentos na forma de função de transferência (Ver (14)), na qual, no momento de aplicar a transformada de Laplace, se assume que as condições iniciais de V_R e V_L são nulas. Também se assume que a tensão de circuito aberto $OCV(s)$ é conhecida em todo momento (estimada), e assim, a saída Y do sistema é definida. O passo seguinte é a aproximação discreta da função de transferência $Y(s)/U(s)$ (substituindo $s = (2/T_s)(1 - z^{-1})/(1 + z^{-1})$, $K_R = 2\tau_R/T_s$ e $K_L = 2\tau_L/T_s$) da forma $Y(z)/U(z)$ (ver (15)). Essa aproximação para o MCE2RC requer algumas equações de transição, como apresentado em (16)-(20).

$$\frac{Y(s)}{U(s)} = \frac{OCV(s) - V_t(s)}{i_t(s)} = R_0 + \frac{R_R}{1 + \tau_R s} + \frac{R_L}{1 + \tau_L s} \quad (14)$$

$$\frac{Y(z)}{U(z)} = \frac{b_0 + b_1 z^{-1} + b_2 z^{-2}}{1 - a_1 z^{-1} - a_2 z^{-2}} \quad (15)$$

$$den = (1 + K_R)(1 + K_L) \quad (16)$$

$$a_1 = 2 - 2(2 + K_R + K_L)/den$$

$$a_2 = -1 + 2(K_R + K_L)/den \quad (17)$$

$$b_0 = R_0 + (R_R(1 + K_L) + R_L(1 + K_R))/den \quad (18)$$

$$b_1 = 2(R_R + R_L + R_0(1 - K_R K_L))/den \quad (19)$$

$$b_2 = -R_0 a_2 + (R_R(1 - K_L) + R_L(1 - K_R))/den \quad (20)$$

A etapa de vetorização do problema (iii) consiste da definição do vetor de medidas (\mathbf{h}_k) e parâmetros ($\boldsymbol{\theta}_k$) como mostrado em (21) e (22).

$$\mathbf{h}_k = [-Y[k-1] - Y[k-2] U[k] \dots U[k-1] U[k-2]]^T \quad (21)$$

$$\boldsymbol{\theta}_k = [a_1 \ a_2 \ b_0 \ b_1 \ b_2]^T \quad (22)$$

A etapa (iv), de aplicação metodologia de estimação de parâmetros por MQRFE tem quatro passos de cálculo (Ver (23)-(26)) a cada iteração do algoritmo: (1) Avaliação do erro de estimação (e_k), (2) Cálculo do ganho (\mathbf{K}_k), (3) Atualização dos parâmetros estimados ($\hat{\boldsymbol{\theta}}_k$) e Atualização da matriz de covariâncias (\mathbf{P}_k). O método pode resultar numa solução do problema mal condicionada e instável, onde se perde a convergência, por causa da diferença entre a duas constantes de tempo que podem variar em ordem de magnitude ($\tau_L \gg \tau_R$)[17]. Para diminuir a possibilidade de um mal condicionamento e instabilidade, pode-se controlar o fator de esquecimento (λ) e modificar de forma artificial (ou reiniciar) a matriz de covariância do erro (\mathbf{P}_k)[19]. Para este trabalho, se implementa uma execução condicional do algoritmo MQRFE, no qual o algoritmo só atualizará os parâmetros caso o erro de estimação esteja fora da zona de tolerância ($|e_k| > tol$). Adicionalmente a matriz \mathbf{P}_k será reiniciada a cada 1000 atualizações de parâmetros. Finalmente (v) os parâmetros do circuito equivalente se calculam com (23)-(35).

$$e_k = Y[k] - \mathbf{h}_k^T \hat{\boldsymbol{\theta}}_{k-1} \quad (23)$$

$$\mathbf{K}_k = \mathbf{P}_{k-1} \mathbf{h}_k / (\lambda + \mathbf{h}_k^T \mathbf{P}_{k-1} \mathbf{h}_k) \quad (24)$$

$$\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_{k-1} + \mathbf{K}_k e_k \quad (25)$$

$$\mathbf{P}_k = (1/\lambda)(\mathbf{I} - \mathbf{K}_k \mathbf{h}_k^T) \mathbf{P}_{k-1} \quad (26)$$

$$d2 = 1 - \hat{a}_1 - \hat{a}_2 \quad (27)$$

$$a = (T_s^2/4)(1 + \hat{a}_1 - \hat{a}_2)/d2$$

$$b = T_s(1 + \hat{a}_2)/d2 \quad (28)$$

$$c = (\hat{b}_0 + \hat{b}_1 + \hat{b}_2)/d2 \quad (29)$$

$$d = T_s(\hat{b}_0 - \hat{b}_2)/d2 \quad (30)$$

$$\hat{R}_0 = (\hat{b}_0 - \hat{b}_1 + \hat{b}_2)/(1 + \hat{a}_1 - \hat{a}_2) \quad (31)$$

$$\hat{R}_R = (\hat{R}_0 \tau_L + c \tau_R - d)/(\tau_R - \tau_L) \quad (32)$$

$$\hat{R}_L = (-\hat{R}_0 \tau_L - c \tau_R + d)/(\tau_R - \tau_L) \quad (33)$$

$$\hat{\tau}_R = (b - \sqrt{b^2 - 4a})/2 \quad (34)$$

$$\hat{t}_L = (b + \sqrt{b^2 - 4a}) / 2 \quad (35)$$

D. Estimação de SoC e SoH usando FKE

O filtro de Kalman estendido usa dados de entrada e de saída para encontrar a estimação ótima dos valores das variáveis de estados internas do sistema em questão, usando um modelo matemático representado na forma de espaço de estados tal como apresentado em (36) e (37), onde (36) é a equação de estados enquanto (37) representa a equação de saída. Nelas, o vetor de estados no momento futuro ($\mathbf{x}[k+1]$) é calculado a partir do vetor de estados atual ($\mathbf{x}[k]$), o vetor de entrada ($\mathbf{u}[k]$) e o ruído de processo ($\mathbf{w}[k]$); de forma similar se calcula a saída ($\mathbf{y}[k]$) incluindo o efeito do erro de medição ($\mathbf{v}[k]$). $f(\mathbf{x}[k], \mathbf{u}[k])$ representa o modelo matemático escolhido para as equações de estado ((8)-(10) para o caso do MCE2RC) e $g(\mathbf{x}[k], \mathbf{u}[k])$ representa a função de saída do modelo ((11) para o caso do MCE2RC)[20]–[22].

$$\mathbf{x}[k+1] = f(\mathbf{x}[k], \mathbf{u}[k]) + \mathbf{w}[k] \quad (36)$$

$$\mathbf{y}[k] = g(\mathbf{x}[k], \mathbf{u}[k]) + \mathbf{v}[k] \quad (37)$$

No geral, é possível resumir a estimação de estados usando FKE em 3 etapas: (i) Definição, (ii) Inicialização, e (iii) iteração. A etapa de definição (i) consiste da seleção do modelo matemático e seus equacionamentos, assim como a definição dos estados a serem estimados ($\mathbf{x}[k] = [V_R[k] \ V_L[k] \ SoC[k]]^T$), a saída ($\mathbf{y}[k] = i_t[k]$) e entrada ($\mathbf{u}[k] = V_t[k]$) a serem medidas. Também se definem as funções f e g com o modelo matemático e as matrizes aproximadas dinâmicas $\hat{\mathbf{A}}[k]$ e $\hat{\mathbf{C}}[k]$ (ver (38) e (39)), onde $m_{SoC}(SoC)$ representa a pendente da reta da interpolação linear da relação OCV(SoC). Outra definição importante, é a das matrizes de variância de processo (\mathbf{Q}_w) e medição (\mathbf{Q}_v) (ver (40) e (41)), onde w_V e w_{SoC} estão relacionados à variância do erro de cálculo do modelo para os estados, seus valores normalmente são baixos (da ordem de 0,001 ou menos); já o valor de v depende da medição e está mais relacionado com a precisão dos medidores de aquisição.

$$\mathbf{x}[k+1] = f(\mathbf{x}[k], \mathbf{u}[k]) + \mathbf{w}[k] \quad (36)$$

$$\mathbf{y}[k] = g(\mathbf{x}[k], \mathbf{u}[k]) + \mathbf{v}[k] \quad (37)$$

$$\hat{\mathbf{A}}[k] = \left. \frac{\partial f(\mathbf{x}[k], \mathbf{u}[k])}{\partial \mathbf{x}[k]} \right|_{\mathbf{x}[k]=\hat{\mathbf{x}}^+[k]} \quad (38)$$

$$\hat{\mathbf{A}}[k] = \begin{bmatrix} e^{(-T_s/\tau_R)} & 0 & 0 \\ 0 & e^{(-T_s/\tau_L)} & 0 \\ 0 & 0 & 1 \end{bmatrix}_{SoC=\hat{SoC}^+[k]} \quad (38)$$

$$\hat{\mathbf{C}}[k] = \left. \frac{\partial g(\mathbf{x}[k], \mathbf{u}[k])}{\partial \mathbf{x}[k]} \right|_{\mathbf{x}[k]=\hat{\mathbf{x}}^-[k]} \quad (39)$$

$$\hat{\mathbf{C}}[k] = [-1, -1, m_{SoC}(SoC)]_{SoC=\hat{SoC}^-[k]}$$

$$\mathbf{Q}_w = \begin{bmatrix} w_V & 0 & 0 \\ 0 & w_V & 0 \\ 0 & 0 & w_{SoC} \end{bmatrix} \quad (40)$$

$$\mathbf{Q}_v = [v] \quad (41)$$

A etapa de inicialização (ii) compreende a definição do ponto inicial do algoritmo, estados iniciais ($\mathbf{x}[0] =$

$[0 \ 0 \ SoC[0]]^T$), onde o $SoC[0]$ dependera das condições do ensaio de laboratório (também poderia ser inicializado com valor nulo), e matriz de covariância inicial ($\mathbf{P}[0]$). Já na etapa de iterações (iii), é necessário atualizar as funções f e g com os parâmetros do circuito equivalente atualizados provenientes do algoritmo MQRFE. Esta etapa abrange os passos de predição e correção característicos dos algoritmos baseados em filtros de Kalman. Na predição (ver (42)-(48)) se estimam os estados em função de valores anteriores ($\hat{\mathbf{x}}^-[k]$, o sobrescrito “-“ indica que é um valor predito), se atualiza a covariância em função da condição anterior do sistema e também se calcula o valor estimado da saída ($\hat{\mathbf{y}}[k]$) em função do estado predito e a entrada atual. Posteriormente se obtém os valores corrigidos dos estados ($\hat{\mathbf{x}}^+[k]$, o sobrescrito “+“ indica que é um valor corrigido) e da matriz de covariância ($\mathbf{P}^+[k]$) em função do erro de estimação ($\mathbf{E}[k]$) e o ganho do filtro de Kalman ($\mathbf{L}[k]$).

Finalmente, após os cálculos dos estados, se usam as medições de corrente e a estimação do SoC resultante do FKE para avaliar (1)-(3) e obter a estimação do SoH .

$$\hat{\mathbf{x}}^-[k] = f(\mathbf{x}^+[k-1], \mathbf{u}[k-1]) \quad (42)$$

$$\mathbf{P}^-[k] = \hat{\mathbf{A}}[k-1] \mathbf{P}^+[k-1] \hat{\mathbf{A}}^T[k-1] + \mathbf{Q}_w \quad (43)$$

$$\hat{\mathbf{y}}[k] = g(\hat{\mathbf{x}}^-[k], \mathbf{u}[k]) \quad (44)$$

$$\mathbf{L}[k] = \frac{\mathbf{P}^-[k] \hat{\mathbf{C}}^T[k]}{\hat{\mathbf{C}}[k+1] \mathbf{P}^-[k+1] \hat{\mathbf{C}}^T[k+1] + \mathbf{Q}_v} \quad (45)$$

$$\mathbf{E}[k] = \mathbf{y}[k] - \hat{\mathbf{y}}[k] \quad (46)$$

$$\hat{\mathbf{x}}^+[k] = \hat{\mathbf{x}}^-[k] + \mathbf{L}[k] \mathbf{E}[k] \quad (47)$$

$$\mathbf{P}^+[k] = (\mathbf{I} - \mathbf{L}[k] \hat{\mathbf{C}}[k]) \mathbf{P}^-[k+1] \quad (48)$$

III. METODOLOGIA E EXPERIMENTO DE ESTIMAÇÃO CONJUNTA DOS ESTADOS DA BATERIA

Para avaliar o esquema de estimação conjunta proposto, foram usados os dados de ensaios de laboratório apresentados em [15], no qual diferentes ensaios $HPPC$ e de teste de capacidade são feitos para diferentes estágios de ciclagem de uma bateria de íon de Lítio do tipo NMC (Níquel-Manganésio-Cobalto) INR21700-M50T com capacidade e tensão nominal de 4.85Ah e 3.63V respectivamente. Neste artigo se faz uma caracterização inicial dos parâmetros do modelo da bateria a partir do ensaio $HPPC$ de quando a célula está nova e quando a célula já sofreu 341 ciclos. Posteriormente o algoritmo de estimação conjunta será aplicado nos dados do ensaio, onde o ponto de partida dos parâmetros é o resultado da parametrização inicial. Os ensaios de teste de capacidade mostram que a capacidade da bateria no ciclo 0 é de 4.8743Ah, e no ciclo 341 se reduz para 4.4636Ah.

IV. RESULTADOS E DISCUSSÃO

A. Determinação dos Parâmetros iniciais

A partir do ensaio $HPPC$ é possível caracterizar a bateria no modelo MCE2RC. O resultado do ensaio é apresentado na Fig. 3 (a), (b) e (c), do qual é possível determinar a relação $OCV-SoC$ considerando que OCV em cada pulso corresponde à tensão em terminais no ponto P5 do pulso correspondente, considerando que o SoC é conhecido no ponto P5. O SoC é calculado por integral de corrente (Contagem de Coulomb) onde se assume que a bateria está completamente carregada no

início do ensaio e a capacidade da bateria no momento do ensaio é conhecida a partir do teste de capacidade. A resistência R_0 em cada pulso de descarga pode ser calculado com (49), enquanto para os parâmetros R_R , R_L , C_R e C_L é necessário fazer ajuste de curvas ou aplicar o MQRFE.

Para dar um ponto inicial coerente para o algoritmo MQRFE se faz o ajuste de curva com ajuda da ferramenta *CurveFitting* do Matlab para o pulso apresentado na Fig. 3(c). A Fig. 3(d) apresenta os resultados da caracterização inicial da bateria, mostrando as relações $OCV-SoC$ e R_0-SoC . Os resultados para o pulso específico da Fig. 3(c), e que serão usados como ponto inicial no MQRFE são: $R_0 = 0.0266 \Omega$, $R_R = 0.0159 \Omega$, $R_L = 0.0066 \Omega$, $C_R = 4450 F$, $C_L = 127030 F$, $\tau_R = 70.7 s$, $\tau_L = 838.2 s$.

$$R_0(SoC(P1)) = -(V_{tP2} - V_{tP1})/i_{tP2} \quad (49)$$

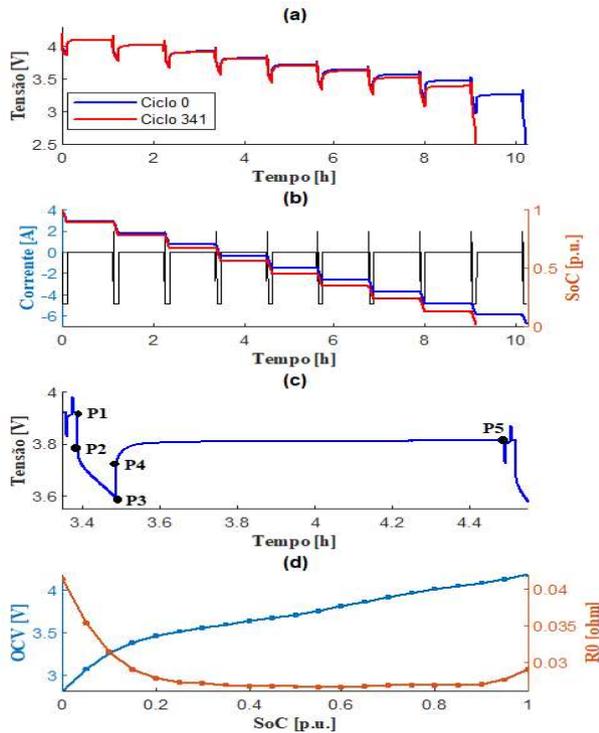


Fig. 3 Resultados de ensaio HPPC e caracterização. (a)-Tensão em terminais, (b)-Corrente de descarga e SoC , (c)-Pontos notáveis de tensão para cada pulso de descarga, (d)-Relações $OCV-SoC$ e R_0-SoC obtidas do ensaio HPPC no ciclo 0

B. Determinação de Parâmetros aplicando MQRFE

Para o primeiro ensaio, se assume que o SoC do estimador é completamente eficaz e a estimação de parâmetros será feita usando o SoC medido do ensaio de ciclo 0. A tensão $OCV(SoC[k])$ é obtida como uma interpolação linear da tabela de dados característica da Fig. 3(d). Com isso, é possível calcular a tensão de saída $(Y[k])$ aplicando (14), e definindo a entrada $(U[k])$ como a corrente de descarga da bateria $(i_t[k])$. A Fig. 4 apresenta os resultados da estimação pelo método MQRFE proposto do parâmetro R_0 , comparados com a caracterização inicial feita, na qual é possível notar que os dois métodos convergem a valores similares durante a operação da bateria.

Os valores encontrados para os outros parâmetros do MCE2RC (R_R , R_L , C_R e C_L) mostraram resultados que saiam facilmente da faixa de valores aceitáveis, mesmo quando os

valores de $\hat{\theta}_k$ são coerentes e com valores de erro de estimação da tensão e_k menores do que 1mV. Os resultados indicam que o método por MQRFE aplicado precisa de uma excitação (mudança no valor da corrente) para ter uma mudança notória na estimação dos parâmetros. Ao mesmo tempo uma mudança grande no erro de estimação pode causar a saída dos parâmetros da faixa aceitável.

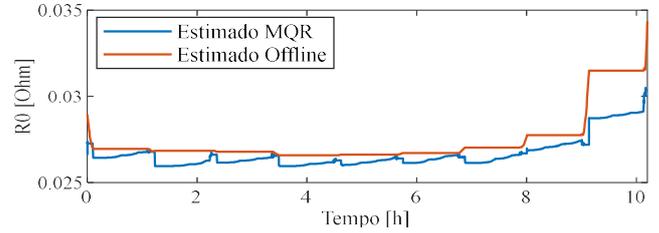


Fig. 4 Resultado de estimação de R_0 para ensaio de ciclo 0 usando MQRFE

C. Estimação de estados aplicando MQRFE+FKE

Neste segundo ensaio, se integram os dois algoritmos e se usa o mesmo ponto de partida que no ensaio anterior. Aqui, para a estimação de parâmetros, a tensão $OCV(SoC[k])$ se calcula com SoC estimado da iteração anterior fornecido pelo FKE, e a mesma interpolação linear da tabela de dados característica da Fig. 3(d). Assim, em cada iteração, se calcula a tensão de saída $(Y[k])$ aplicando (14) e a entrada $(U[k])$ continua como a corrente de descarga da bateria $(i_t[k])$.

Para esse segundo ensaio se usaram os dados do ensaio no ciclo 341, onde a Fig 5 apresenta a estimação dos valores de R_0 , que se comparados com o os valores encontrados na Fig 4, são maiores em magnitude, evidenciando o acréscimo de resistência devido ao envelhecimento da bateria, um fenômeno esperado. Posteriormente, a Fig 6 mostra os resultados da estimação do estado de carga, onde a estimação por FKE inclui atualização de R_0 em tempo real. Comparando os dados de estimação por contagem de coulomb, FKE e dados de laboratório, é notável que o método mais impreciso é o de contagem de coulomb por ser calculado com o valor inicial da capacidade da bateria ($Q_{at} = 4.8743Ah$), enquanto que a estimativa por FKE+MQRFE apresenta comportamento mais próximo do valor medido em laboratório, mesmo sem a atualização de Q_{at} .

Os resultados desse ensaio permitem estimar a capacidade atual da bateria aplicando (3), no qual se obtém Q_{at} para o ensaio, com um valor de 4.3014Ah, o qual, embora menor que a capacidade esperada para o ciclo 341 (4.4636Ah), está mais perto do que o valor inicial. Os dados estimados também permitiram calcular o SoH usando (1) e (2), obtendo um valor de 0,8869 para a capacidade relativa (Q_r) significando que o SoH seja de 0,4345 (ou 43,45%). A distância entre os valores estimados e os dados de laboratório indicam que a estimação deve ser aprimorada para ter ainda mais precisão.

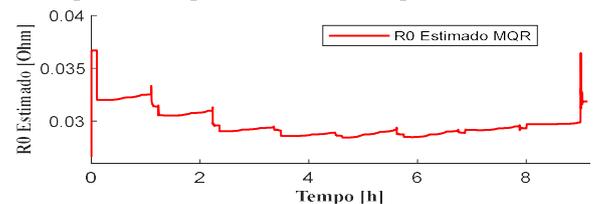


Fig. 5 Resultado de estimação de R_0 para ensaio de ciclo 341 usando MQRFE+FKE

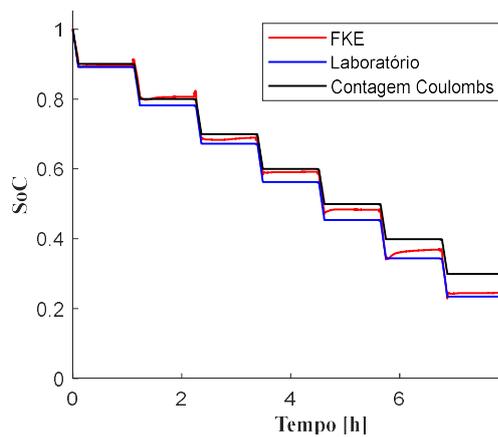


Fig. 6 Resultados da estimação do SoC para o ensaio de pulsos no ciclo 341

V. CONCLUSÕES E CONSIDERAÇÕES FINAIS

Por meio do presente estudo e dos resultados atingidos, é possível concluir que a integração conjunta de SoC e SoH por meio de estimação é passível de ser realizada por meio do algoritmo proposto usando o MQRFE para estimar parâmetros e FKE para estimar estados, no entanto precisa ser refinada com fins a manter a estabilidade e obter parâmetros dentro dos limites razoáveis.

Na abordagem implementada, a estimação de estados realimenta o SoC para as posteriores estimações de parâmetros, permitindo tal realimentação estimar o SoC com erro menor se comparado com a estimação por contagem de Coulombs mesmo no ensaio com a bateria degradada por 341 ciclos de uso. Por outro lado, a estimação do SoH apresentou erros que, embora estão perto dos valores determinados nos ensaios de laboratório, ainda precisam refinamento na estimação.

Ao usar o MCE2RC, é importante destacar que a complexidade algébrica na implementação do estimador de parâmetros e a natureza do modelo matemático podem causar mau condicionamento numérico, motivo pelo qual o presente algoritmo e abordagem se propõe a refinar cada vez mais o mesmo de forma a torná-lo robusto e aplicável mesmo sob forte condições de criticidade como as existentes em aplicações Militares. Tais razões fazem necessário que as matrizes e variáveis internas do algoritmo precisem ser modificadas ou ajustadas a fim de melhorar a resposta para tais situações.

REFERÊNCIAS

[1] P. P. José Maria e V. Ricardo, “Estudo Sobre a Indústria Brasileira e Europeia de Veículos Aéreos Não Tripulados”. Acesso em: 4 de maio de 2023. [Online]. Disponível em: https://www.gov.br/produtividade-e-comercio-exterior/pt-br/images/publicacaoa_DRONES-20161130-20012017-web.pdf

[2] L. A. Nascimento, “Good Kill:: el impacto de los drones en la doctrina militar.”, *Perspect. Rev. Cienc. Soc.*, no 7, p. 68–80, dez. 2019, doi: 10.35305/pres.v0i7.12.

[3] G. K. Sierra Páez, “TOWARDS BATTERY HEALTH MANAGEMENT FOR LITHIUM POLYMER BATTERY-POWERED SMALL-SIZE ROTARY-WING UNMANNED AERIAL

VEHICLES”, Tese de doutorado, Universidad de Chile, Santiago de Chile, 2018.

[4] G. Sierra, M. Orchard, K. Goebel, e C. Kulkarni, “Battery health management for small-size rotary-wing electric unmanned aerial vehicles: An efficient approach for constrained computing platforms”, *Reliab. Eng. Syst. Saf.*, vol. 182, p. 166–178, fev. 2019, doi: 10.1016/j.res.2018.04.030.

[5] M. M. Shibl, L. S. Ismail, e A. M. Massoud, “A machine learning-based battery management system for state-of-charge prediction and state-of-health estimation for unmanned aerial vehicles”, *J. Energy Storage*, vol. 66, p. 107380, ago. 2023, doi: 10.1016/j.est.2023.107380.

[6] S. Zhang, H. Tao, K. Bi, W. Yan, e H. Ni, “SOC Estimation of Lithium-ion Battery Based on RLS-EKF for Unmanned Aerial Vehicle”, *J. Phys. Conf. Ser.*, vol. 2216, no 1, p. 012002, mar. 2022, doi: 10.1088/1742-6596/2216/1/012002.

[7] B. Saha et al., “Battery health management system for electric UAVs”, em 2011 Aerospace Conference, Big Sky, USA: IEEE, mar. 2011, p. 1–9. doi: 10.1109/AERO.2011.5747587.

[8] P. Chen et al., “Evaluation of Various Offline and Online ECM Parameter Identification Methods of Lithium-Ion Batteries in Underwater Vehicles”, *ACS Omega*, vol. 7, no 34, p. 30504–30518, ago. 2022, doi: 10.1021/acsomega.2c03985.

[9] P. Shen, M. Ouyang, L. Lu, J. Li, e X. Feng, “The Co-estimation of State of Charge, State of Health, and State of Function for Lithium-Ion Batteries in Electric Vehicles”, *IEEE Trans. Veh. Technol.*, vol. 67, no 1, p. 92–103, jan. 2018, doi: 10.1109/TVT.2017.2751613.

[10] S. K. Pradhan e B. Chakraborty, “Battery management strategies: An essential review for battery state of health monitoring techniques”, *J. Energy Storage*, vol. 51, p. 104427, jul. 2022, doi: 10.1016/j.est.2022.104427.

[11] R. Schacht-Rodríguez, J.-C. Ponsart, C. D. García-Beltrán, e C. M. Astorga-Zaragoza, “Prognosis & Health Management for the prediction of UAV flight endurance”, *IFAC-Pap.*, vol. 51, no 24, p. 983–990, 2018, doi: 10.1016/j.ifacol.2018.09.705.

[12] L. Zheng, “Development of Lithium-Ion Battery State Estimation Techniques for Battery Management Systems”, Doctoral Thesis, University of Technology Sydney, Sydney, Australia, 2018.

[13] S. R. Hashemi, A. M. Mahajan, e S. Farhad, “Online estimation of battery model parameters and state of health in electric and hybrid aircraft application”, *Energy*, vol. 229, p. 120699, ago. 2021, doi: 10.1016/j.energy.2021.120699.

[14] M. S. Hosen, J. Jaguemont, J. Van Mierlo, e M. Bercibar, “Battery lifetime prediction and performance assessment of different modeling approaches”, *iScience*, vol. 24, no 2, p. 102060, fev. 2021, doi: 10.1016/j.isci.2021.102060.

[15] G. Pozzato, A. Allam, e S. Onori, “Lithium-ion battery aging dataset based on electric vehicle real-driving profiles”, *Data Brief*, vol. 41, p. 107995, abr. 2022, doi: 10.1016/j.dib.2022.107995.

[16] G. L. Plett, *Battery management systems: battery modeling*. Volume 1. Boston : London: Artech House, 2015.

[17] A. Mondal, A. Routray, e S. Puravankara, “Parameter identification and co-estimation of state-of-charge of Li-ion battery in real-time on Internet-of-Things platform”, *J. Energy Storage*, vol. 51, p. 104370, jul. 2022, doi: 10.1016/j.est.2022.104370.

[18] R. Isermann e M. Münchhof, *Identification of Dynamic Systems: An Introduction with Applications*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. doi: 10.1007/978-3-540-78879-9.

[19] A. A. Coelho e L. D. S. Coelho, *Identificação de Sistemas Dinâmicos Lineares*. Florianópolis: Editora da UFSC, 2004.

[20] G. L. Plett, *Battery management systems: Volume II*. em Artech House Power engineering series. Boston: Artech house, 2016.

[21] Z. Zhang, L. Jiang, L. Zhang, e C. Huang, “State-of-charge estimation of lithium-ion battery pack by using an adaptive extended Kalman filter for electric vehicles”, *J. Energy Storage*, vol. 37, p. 102457, maio 2021, doi: 10.1016/j.est.2021.102457.

[22] B. Rzepka, S. Bischof, e T. Blank, “Implementing an Extended Kalman Filter for SoC Estimation of a Li-Ion Battery with Hysteresis: A Step-by-Step Guide”, *Energies*, vol. 14, no 13, p. 3733, jun. 2021, doi: 10.3390/en14133733.