

# ALGORITMO PARA ESTIMATIVA DO TEMPO DE DESCARGA DE BATERIAS DE CHUMBO-ÁCIDO APLICADO A FONTES ININTERRUPTAS DE ENERGIA

Pedro Cerutti Bolsi<sup>1,2</sup>, Edemar de Oliveira Prado<sup>1,2</sup>, Romario de Jesus Nazaré<sup>2</sup>, Antonio Cezar de Castro Lima<sup>2</sup>, Hamiltom Confortin Sartori<sup>1</sup>, José Renes Pinheiro<sup>1,2</sup>

<sup>1</sup>Universidade Federal de Santa Maria (UFSM), Santa Maria – RS, Brasil

<sup>2</sup>Universidade Federal da Bahia (UFBA), Salvador – BA, Brasil

e-mail: pcbolsi@gmail.com, edemar.prado@ufba.br, romario.jesus@ufba.br, acdcl@ufba.br, hamiltomsar@gmail.com, jrenes@gepoc.ufsm.br

**Resumo** – Este trabalho apresenta um algoritmo para estimativa do tempo de descarga de baterias de chumbo ácido reguladas por válvula aplicados a fontes ininterruptas de energia. É empregado um modelo de circuito simples combinado ao aprendizado da característica de descarga (tensão e corrente) medida na bateria. O funcionamento do algoritmo é baseado na predição da tensão nos terminais da bateria através de regressões de curva sucessivas, realizadas por um algoritmo levenberg-marquardt. Em função da estratégia usada de ajustes contínuos da predição em tempo real, o algoritmo possui alta adaptabilidade, sendo resistente à variações de temperatura e ondulações na corrente de descarga. Os resultados experimentais demonstram a acurácia obtida com o algoritmo.

**Palavras-chave** – Algoritmo, Baterias De Chumbo-Ácido, Fonte Ininterrupta de Energia, Predição do Tempo de Descarga.

## ALGORITHM FOR ESTIMATION OF DISCHARGE TIME OF LEAD-ACID BATTERIES APPLIED TO UNINTERRUPTIBLE POWER SUPPLIES

**Abstract** – This work presents an algorithm for estimating the discharge time of valve regulated lead acid batteries applied to uninterruptible power sources. A simple circuit model combined with the learning of the discharge characteristic (voltage and current) measured in the battery is used. The operation of the algorithm is based on the prediction of the voltage at the battery terminals through successive curve regressions, performed by a levenberg-marquardt algorithm. Due to the used strategy of continuous adjustments of the real-time prediction, the algorithm has high adaptability, being resistant to temperature variations and ripples in the discharge current. Experimental results demonstrate the accuracy achieved by the algorithm.

**Keywords** – Algorithm, Discharge Time Prediction, Lead-Acid Battery, Uninterruptible Power Supply.

Manuscript received 07/29/2022; first revision 11/15/2022 and accepted for publication 12/06/2022, by recommendation of Editor Telles Brunelli Lazzarin. <http://dx.doi.org/10.18618/REP.2022.4.0034>.

## I. INTRODUÇÃO

As baterias desempenham um papel significativo na sociedade moderna, sendo usadas em equipamentos domésticos, automóveis convencionais e elétricos, sistemas de telecomunicação, armazenamento em fontes renováveis e cargas críticas em geral [1]–[4]. Baterias de chumbo-ácido, apesar da baixa densidade de energia, são robustas, de baixo custo, e com menor impacto ambiental que outros tipos de bateria [5]–[8].

A principal desvantagem relacionada ao uso de baterias de chumbo-ácido é a sua degradação (envelhecimento), que ocorre em função da frequência dos ciclos, da profundidade das descargas, da tensão de carga, da temperatura ambiente, e também pela simples passagem do tempo [8]–[11]. Desta maneira, a estimativa da autonomia, estado de carga (*state of charge*, SOC) e estado de saúde (*state of health*, SOH) são importantes para se antever a problemas causados pela falha das baterias. Os principais métodos de estimativa de tensão e estado de carga de baterias podem ser divididos em quatro grandes grupos [12]–[14]: (1) Baseado em tabelas de referência (*look-up table*); (2) Integração ampere-hora; (3) Baseado em modelo equivalente; (4) Estimativa por dados históricos (*data-driven*). Estes métodos serão resumidos a seguir, contrapondo-os aos desafios que apresentam.

### A. Método Baseado em Tabelas de Referência (Look-Up Table)

Estes métodos buscam mapear o SOC e SOH a partir de características estáticas medidas na bateria. Alguns valores de referência podem ser dados pelos fabricantes, enquanto outros exigem o levantamento experimental, o que demanda tempo, e necessita de arranjo de configurações de bancada. As principais aplicações deste método são a relação entre a tensão de circuito aberto (*open circuit voltage*, OCV) e SOC, e a relação entre a resistência (ou impedância) e SOC e SOH [5], [15]–[17].

A tensão de circuito aberto é a tensão existente entre os polos de uma bateria em circuito aberto após um período de repouso. As recomendações normativas para medição da OCV determinam um período de repouso entre 4 h e 24 h [18]. No entanto, em [17] mostra-se que a diferença de tensão após 30 minutos e após 240 minutos de repouso é sempre menor que 10 mV. A relação entre a OCV e o SOC pode ser expressa por uma função de primeiro grau obtida nos manuais técnicos dos fabricantes.

Em métodos que empregam modelos de resistência/

impedância, a principal dificuldade reside no conhecimento dos valores da mesma para diferentes SOC e SOH, já que não são normalmente fornecidos pelos fabricantes. Portanto, o uso de um modelo de referência de impedância implica na necessidade de extensivos ensaios nas baterias. Isto se dá pois, na prática, a impedância da bateria varia de forma não linear em função do SOC e do SOH [15], [16], [19]–[23], e este, por sua vez, também depende de fatores de difícil previsão, como os modos de carga/descarga, frequência dos ciclos, tensões utilizadas para flutuação e corte, profundidade das descargas, e temperatura [9]–[11]. Em suma, um modelo de impedância exige um grande volume de dados, obtidos pela caracterização exaustiva da bateria em função de diversos fatores, que se combinam não linearmente.

### B. Método da Integração Ampere-Hora

O método de medição direta da corrente é utilizado na obtenção da capacidade (C) da bateria em Ah, sendo principalmente empregado em conjunto com outros métodos. A partir da medição da corrente de descarga ( $i_d$ ), o SOC é calculado como [18]:

$$SOC(t) = \frac{C_0 - \int_0^t i_d(t) dt}{C_0} = 1 - DOD(t) \quad (1)$$

em que  $t$  é a duração da descarga, e  $C_0$  de capacidade no instante zero. Caso a bateria estiver completamente carregada,  $C_0$  corresponderá a quantos ampere-hora podem ser armazenados na bateria em seu estado presente; não necessariamente igual ao valor da capacidade nominal ( $C_{ref}$ ). O valor de SOC varia de 1 (bateria completamente carregada) a 0 (bateria completamente descarregada). A profundidade de descarga (*depth of discharge*, DOD) é a grandeza recíproca ao SOC, conforme (1). Existem dois principais desafios associados ao uso da integração ampere-hora na obtenção do SOC.

1) *Sensibilidade ao erro*: devido ao uso de uma integração, esta estratégia torna-se sensível à exatidão da medição de corrente. Por consequência, este método não é indicado, por si só, para o monitoramento constante do SOC da bateria, pois poderão haver deslocamentos e divergência em longo prazo do estado real da bateria. Para contornar isso, são utilizados métodos numéricos para eliminação do erro [24], principalmente filtros Kalman e suas variações, como o *Extended Kalman Filter* e o *Unscented Kalman Filter* [25]–[27].

2) *Ajuste pela temperatura*: a capacidade da bateria depende da temperatura. Assim sendo, o uso da integração ampere-hora deve estar associado a medição da temperatura. A variação da capacidade em função da temperatura pode ser aproximada pela expressão [9], [10]:

$$C(T) = C(25^\circ C)(1 + 0,01(T - 25)). \quad (2)$$

### C. Métodos Baseados em Modelos Equivalentes

Os métodos baseados em modelos são empregados para a predição da tensão nos terminais e SOC da bateria. Estes métodos podem ser resumidos em três modelos [12], sendo

cada um expresso por uma ou mais equações de estados.

Os modelos eletroquímicos [28]–[31], cuja exatidão tende a ser alta, descrevem microscopicamente o estado químico interno da bateria. Possuem alta complexidade, sendo os parâmetros exigidos pelo modelo de difícil determinação, mesmo nas formas mais simplificadas.

Os modelos de impedância eletroquímica [32]–[34] empregam circuitos elétricos, cujos componentes são obtidos através da realização da espectroscopia da impedância eletroquímica da bateria, um procedimento que aplica pequenos sinais, altamente sensível a ruídos na medição.

Os modelos de circuito equivalente [16], [26], [35]–[43] buscam caracterizar o comportamento da tensão dos terminais da bateria através de um circuito elétrico, com resistores, capacitores, diodos e fontes de tensão. Juntamente aos modelos de circuito, são utilizadas *look-up tables* e a medição direta (integração ampere-hora). No entanto, os parâmetros de resistência e capacitância devem ser ajustáveis, pois variam com o envelhecimento da bateria.

### D. Método de Estimativa por Dados Históricos (Data-Driven)

A estimativa por dados históricos busca modelar a bateria através do aprendizado de seu comportamento ao longo do tempo. Assim, este método contorna as complexidades dos métodos baseados em modelos eletroquímicos, de circuito ou impedância eletroquímica. A característica mais desejável deste método é a de não exigir necessariamente um modelo acurado da planta, podendo tratar a bateria até mesmo como uma caixa preta. Através de ferramentas de modelagem estatística não linear, buscam-se padrões no comportamento da bateria. As possibilidades são o uso de controladores fuzzy, redes neurais, máquinas de vetores suporte, ou uma combinação destes [44]–[49]. Por usar modelos não lineares, as principais desvantagens deste método são a forte dependência dos parâmetros iniciais, o que pode resultar em dificuldade de convergência, e a necessidade de um grande volume de dados.

### E. Contribuição

Considerando os desafios relacionados aos métodos de modelagem de baterias, este trabalho apresenta o desenvolvimento de um algoritmo para predição da tensão nos terminais e tempo de descarga (autonomia), com características dos quatro métodos de modelagem de baterias apresentados. É proposto um modelo de circuito simples (Método C), que será ajustado com base em dados históricos de operação da bateria (Método D), incorporando a medição de corrente para obtenção de SOC e DOD (Método B), e que utiliza a relação entre SOC e OCV (Método A).

O funcionamento do algoritmo é baseado em um modelo de circuito simples, e na realização do aprendizado da característica de descarga (tensão e corrente) da bateria. A predição da tensão nos terminais da bateria é realizada através de regressões de curva sucessivas em tempo real, feitas por um algoritmo de otimização levenberg-marquardt (LMA) [50]. Como resultado, o algoritmo desenvolvido possui alta adaptabilidade. Estes ajustes são feitos em intervalos de tempo de até 32 segundos, de forma que os cálculos necessários para a predição da autonomia não exigem alta capacidade de processamento.

O algoritmo é aplicado a baterias de chumbo-ácido reguladas por válvula (*valve regulated lead-acid*, VRLA) em fontes ininterruptas de energia (*uninterruptible power supplies*, UPS). Neste contexto, assume-se que não há uma grande quantidade de dados históricos de operação das baterias que possibilite o emprego de alguma técnica *data-driven*, como por exemplo o treinamento de uma rede neuronal. Assume-se a possibilidade de aprendizado de apenas um pequeno volume de dados obtidos nas próprias descargas da bateria.

O desenvolvimento do manuscrito é dividido em três seções principais. Na seção II são apresentadas a topologia da UPS, as características de descarga das baterias VRLA, e os desafios associados à predição de autonomia. Na seção III o funcionamento do algoritmo proposto é descrito e demonstrado experimentalmente, usando uma UPS comercial de 1kW. Na seção IV são feitas as considerações finais.

## II. APLICAÇÃO, CARACTERÍSTICAS DAS BATERIAS VRLA E DESAFIOS ASSOCIADOS

O circuito da UPS comercial de 1 kW utilizada como aplicação é apresentado na Figura 1. Quando a rede está dentro dos limites de tensão, o conversor *full-bridge* opera como retificador tipo *boost*, e realiza a carga das baterias. Quando há um afundamento, sobretensão ou falta na rede, as baterias fornecem energia ao conversor, cuja tensão de saída é elevada à tensão da rede pelo transformador [51]. Um par de baterias Unipower UP 1270 de 12 V / 7 Ah [52] em série realiza a alimentação do circuito durante a operação sem rede. É possível a inclusão de baterias externas, cuja conexão paralela aumenta a capacidade (Ah) e autonomia do sistema.

A taxa de amostragem das grandezas utilizadas no desenvolvimento e teste do algoritmo (temperaturas, tensões e correntes médias e eficazes) é de 1 Hz, sendo medidas e registradas por um analisador de potência Yokogawa WT1803E. As temperaturas foram medidas em um datalogger Keysight DAQ970A com termopares tipo K, de acurácia de  $\pm 2\%$ . Em todos os testes, a temperatura das baterias foi




Fig. 1. Circuito da UPS de 1 kW.

mantida em  $26 \pm 2$  °C, estando fora do gabinete da UPS.

Os resultados apresentados com esta configuração de UPS possuem uma corrente de descarga com uma ondulação significativa em 120 Hz, conforme a Figura 2. Isso difere das descargas indicadas nos catálogos dos fabricantes, que são para corrente constante [9]–[11]. Assim sendo, as informações de descarga fornecidas em catálogo não podem ser usadas.






Fig. 2. Forma de onda de corrente instantânea na bateria da UPS, com uma carga de 600 W na saída da UPS.

### A. Relação entre SOC/DOD e a Tensão dos Terminais

Para visualização da variação de SOC ao longo de um ciclo de descarga, a Figura 3.a apresenta este valor para diferentes potências de saída. Nestes ciclos, a descarga da bateria é interrompida no instante em que a tensão de corte é atingida, de acordo com a sua potência, conforme ilustra a Figura 3.b. Descargas até tensões inferiores à tensão de corte degradam a bateria [10],[11]. Com baixas correntes (potências), a descarga da bateria é mais lenta, permitindo um aproveitamento maior



(a)



(b)

Fig. 3. Variação medida em um ciclo de descarga com cargas de diferentes potências na saída da UPS. (a) SOC. (b) Tensão média nos terminais.

dos materiais ativos na bateria. Desta forma, a bateria se descarrega mais profundamente nas potências mais baixas (Figura 3.a) antes de atingir a tensão de corte (Figura 3.b). Inversamente, para correntes altas, menos energia é fornecida antes da tensão de corte ser atingida.

A análise da relação entre SOC e o tempo decorrido até atingir a tensão de corte, permite inferir que não há uma relação direta simples entre SOC e autonomia; o que torna complexa a predição da mesma a partir da quantidade de corrente retirada da bateria (em Ah) ao longo da descarga. Assim sendo, para a predição da autonomia, evidencia-se a necessidade do desenvolvimento de um modelo para a predição da tensão nos terminais da bateria.

### B. Influência da Temperatura

Temperaturas mais altas aumentam a capacidade de fornecimento de corrente da bateria, assim como temperaturas mais baixas a diminui (2). Por conseguinte, o comportamento de descarga será afetado. A Figura 4 ilustra diferença da tensão e duração da descarga de uma bateria em diferentes temperaturas, com a potência de 300 W na saída da UPS.

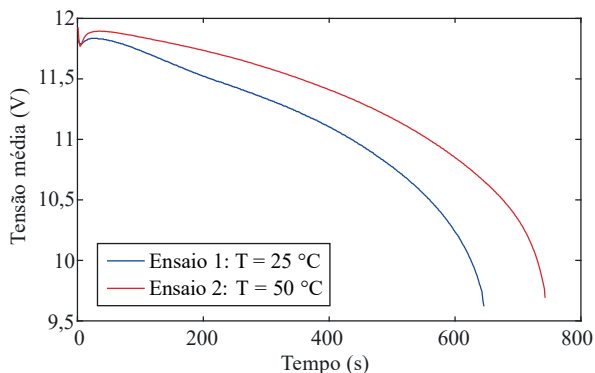


Fig. 4. Tensão de uma bateria durante a descarga, com potência de 300 W na saída da UPS, com temperatura ambiente de 25 °C e 50 °C.

## III. PROPOSTA DE ALGORITMO PARA PREDIÇÃO DE AUTONOMIA

Nesta seção é apresentada uma descrição do algoritmo desenvolvido para a predição da autonomia, incluindo seu conceito de funcionamento, os resultados obtidos e detalhes de sua aplicação.

### A. Modelo de Circuito Empregado

A Figura 5 apresenta o modelo de circuito empregado. A fonte de tensão, dada pelo valor de OCV, é determinada pela relação com o SOC (3). Os valores que compõe (3) são obtidos fornecidos pelo fabricante [9]:

$$OCV(t) = 1,23 \cdot SOC(t) + 11,77 \quad (3)$$

em que o SOC é obtido pela integração ampere-hora (1), utilizando o valor médio de  $i_d$  ( $I_d$ ). Portanto, o valor de OCV é variante no tempo. A resistência interna da bateria ( $R_{int}$ ) também é variante no tempo, sendo determinada utilizando o circuito, com base no valor médio de tensão medido nos




Fig. 5. Modelo de circuito empregado.




Fig. 6. Obtenção gráfica de  $R_{int}$ , através da equação (4), com diferentes potências na saída da UPS.

terminais da bateria ( $V_{ter}$ ),

$$R_{int}(t) = \frac{OCV(t) - V_{ter}(t)}{I_d(t)} \quad (4)$$

Utilizando este circuito, com base em  $V_{ter}$  e OCV, o comportamento de  $R_{int}$  será conforme ilustra a Figura 6. Para emprego nas predições do algoritmo, o comportamento de  $R_{int}$  é estabelecido em função da variação de DOD, conforme a Figura 7, podendo, assim, ser descrito pela expressão:

$$R_{int}(t) = x_1 + x_2 \cdot DOD(t) + x_3 e^{x_4 \cdot (DOD(t))} \quad (5)$$

em que os coeficientes  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$  são obtidos por regressão das curvas medidas. O modelo de resistência interna da bateria, neste caso, não possui necessariamente um significado físico, sendo apenas modelada para representar o comportamento da tensão nos terminais da bateria.

Opta-se por um modelo de circuito, ao invés da regressão direta da curva de tensão nos terminais, por ser, numericamente, de mais fácil convergência. Pela mesma razão, o comportamento da  $R_{int}$ , previsto por uma expressão não linear, é referenciada ao DOD.

### B. Modo de Predição de $V_{ter}$

Para utilizar o circuito na predição da tensão dos terminais, os valores futuros de SOC e DOD são estimados. Para isso, projeta-se um vetor  $i_d$  de valores futuros de corrente na bateria, assumindo-se que a corrente medida na última amostra se




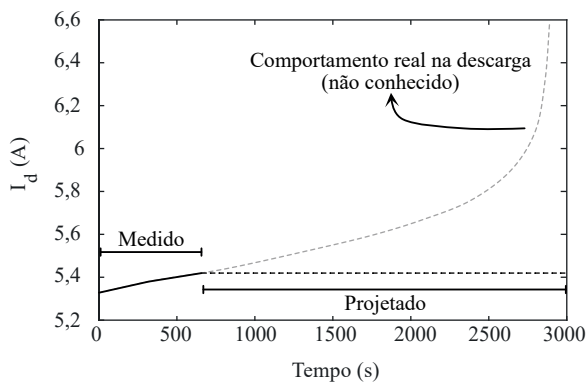


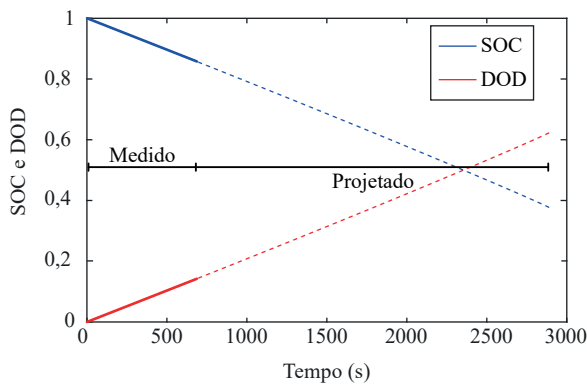
Fig. 7. Relação de DOD com a  $R_{int}$  com diferentes potências na UPS.

manterá constante, conforme exemplificado na Figura 8.a. Com a projeção de corrente, é realizada a integração no tempo, para obtenção do SOC e DOD (1) futuros (Figura 8.b). O SOC futuro é empregado na projeção da OCV (3), e o DOD aplicado na expressão da  $R_{int}$  (5). Com estes,  $V_{ter}$  é estimado:

$$V_{ter}(t) = OCV(t) - R_{int}(t) \cdot I_d(t). \quad (6)$$



(a)



(b)

Fig. 8. Exemplo de projeções (no tempo futuro) de grandezas, assumindo que a corrente medida na última amostra se manterá constante. (a) Projeção de  $I_d$ . (b) Projeção de SOC e DOD.

Por fim, a estimativa de autonomia é realizada pela identificação do instante em que  $V_{ter}(t)$  atingirá a tensão de corte (9,6 V): verificam-se quantos segundos faltam para esse instante, conforme exemplo da Figura 9.

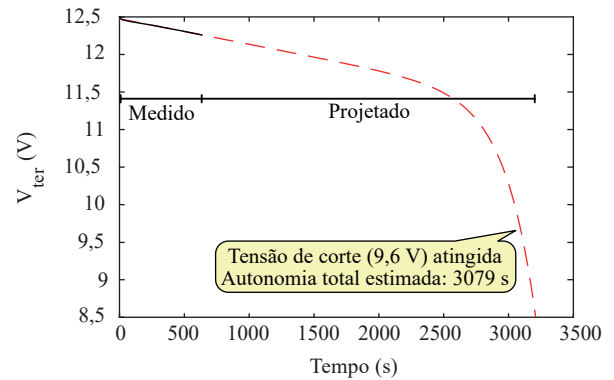


Fig. 9. Projeção da tensão a partir do modelo de circuito, com uma carga de 100 W na saída da UPS, identificando o instante em que se estima que a tensão de corte será atingida.

### C. Obtenção e Uso dos Coeficientes de Regressão de Curva

Por tratar-se de um problema de regressão não-linear, o valor inicial dos coeficientes é fundamental para a convergência do algoritmo, quando este for empregado em intervalos regulares para previsão da autonomia. O valor inicial dos coeficientes  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$  é obtido a partir da regressão de curva de  $R_{int}$  medido, conforme o exemplo da Figura 10, devendo ser feito em uma descarga completa (até atingir a tensão de corte). Esta pode ser chamada de “descarga de aprendizado”, sendo fundamental para o funcionamento ideal do algoritmo proposto. Para realização da regressão da curva, é utilizado um algoritmo LMA.

Uma vez que o comportamento de  $R_{int} \times DOD$  é diferente para cada potência (Figura 7), os valores iniciais dos coeficientes de regressão de curva são escolhidos com base na faixa de potência na saída da UPS. Para delimitar cada faixa, utiliza-se a corrente eficaz ( $I_{rms}$ ) na saída da UPS como referência, pois o valor desta é constante ao longo do tempo, enquanto a corrente média da bateria varia com a queda da tensão nos terminais (Figura 11).

Na Tabela I estão exemplificados valores de  $I_{rms}$  usados para delimitação das faixas de potência conectada à bateria, associando-as aos intervalos entre previsões, e aos valores

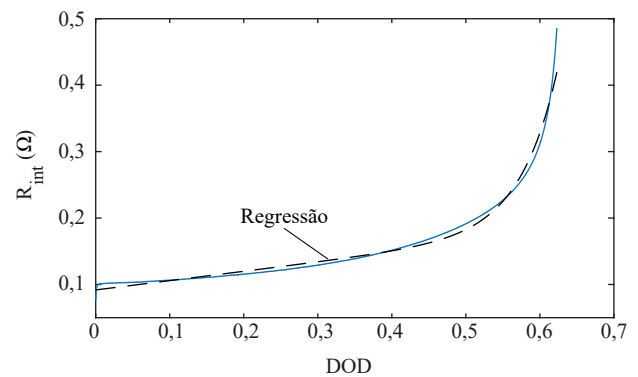


Fig. 10. Curva de  $R_{int}$  medida, e sua regressão por LMA, para uma potência de 100 W na saída da UPS.

**TABELA I**  
**Tabela de Referência para as Faixas de Potência Atribuídas**

Faixa	$I_{rms}$ na saída (A)	Potência na saída (W)	Intervalo entre previsões (s)	Valor partida coef.			
				$x_1$	$x_2$	$x_3$	$x_4$
1	$I \leq 1,3$	100	32	91,8e-3	140,1e-3	1e-6	19,88
2	$1,3 < I \leq 2,2$	200	22	60,4e-3	109,4e-3	20,6e-6	16,87
3	$2,2 < I \leq 3,0$	300	13	63,3e-3	57,2e-3	100,6e-6	15
4	$3,0 < I \leq 3,9$	400	7	44,9e-3	93,8e-3	115e-6	15
5	$3,9 < I \leq 4,7$	500	5	50,6e-3	58,7e-3	166,7e-6	15
6	$4,7 < I \leq 5,6$	600	5	45,5e-3	59,2e-3	418,4e-6	15
7	$5,6 < I \leq 6,5$	700	5	39,8e-3	83,1e-3	520,2e-6	15
8	$6,5 < I \leq 7,3$	800	3	25,94e-3	10,07	-	-
9	$7,3 < I \leq 8,2$	900	3	33e-3	9,76	-	-
10	$8,2 < I$	1000	2	68,25e-3	9,26	-	-




Fig. 11. Corrente eficaz na saída comparada a corrente média na bateria, com uma carga de 100 W na saída da UPS.

de partida para os coeficientes de (5), obtidos nas descargas medidas da bateria em análise. A partir da faixa 8, em função das altas correntes drenadas da bateria, o comportamento da tensão nos terminais aproxima-se de uma reta, sendo vantajoso adaptar o modelo de (5) para uma função afim, com apenas  $x_1$  e  $x_2$ , conforme mostrado na Figura 12. A função dos intervalos entre as previsões está descrita na seção III-D. Caso necessário ou desejável, mais faixas podem ser atribuídas, e diferentes intervalos podem ser adotados; a duração destes é proporcional ao tempo típico de uma descarga na faixa de potência associada.




Fig. 12. Tensão nos terminais para as faixas de potência 8 a 10.

Destaca-se que ao ser modificada a característica de descarga da bateria, seja por mudança do fabricante, modelo, ou estado de saúde da bateria, a única mudança necessária ao

algoritmo proposto são os valores de partida dos coeficientes. Observa-se também que o funcionamento normal do algoritmo prevê que os valores de partida dos coeficientes sejam modificados a cada “descarga de aprendizado”.

#### D. Funcionamento do Algoritmo

A partir dos valores iniciais, a previsão de autonomia ao longo de uma descarga é feita sucessivamente, em intervalos regulares. Com base na medição de  $R_{int}$  a cada intervalo, os coeficientes são ajustados para corrigir a previsão de autonomia. A Figura 13 ilustra uma das regressões de curva sucessivas, para a carga de 300 W na saída. O valor da previsão anterior de  $R_{int}$  é comparado ao valor medido no último intervalo entre as previsões, e é utilizado para realizar a nova previsão de  $R_{int}$ , através do algoritmo LMA.

A fim de evitar que a convergência do algoritmo LMA obtenha um mínimo que descaracterize a curva de descarga, conforme exemplificado na Figura 14.a, é atribuído um limite de variação para os coeficientes de regressão de curva. Esta limitação é necessária para que a previsão do LMA reproduza uma estimativa adequada do comportamento de  $R_{int}$ , conforme a Figura 14.b. Os limites foram obtidos empiricamente para a convergência do algoritmo de otimização LMA em todas as potências analisadas, sendo 15% ( $x_1$ ), 50% ( $x_2$ ), 7% ( $x_3$ ) e 2% ( $x_4$ ).

Para exemplificar a evolução das previsões do algoritmo, a Figura 15.a apresenta todas as curvas de  $R_{int}$  estimadas ao longo de uma descarga com potência de 300 W na

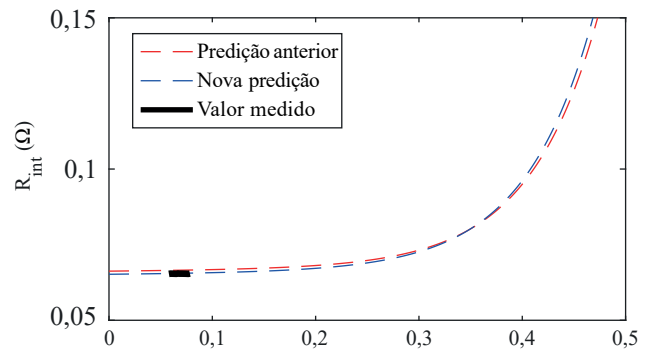


Fig. 13. Correção de previsão através do LMA, com base no valor medido no último intervalo entre as previsões.

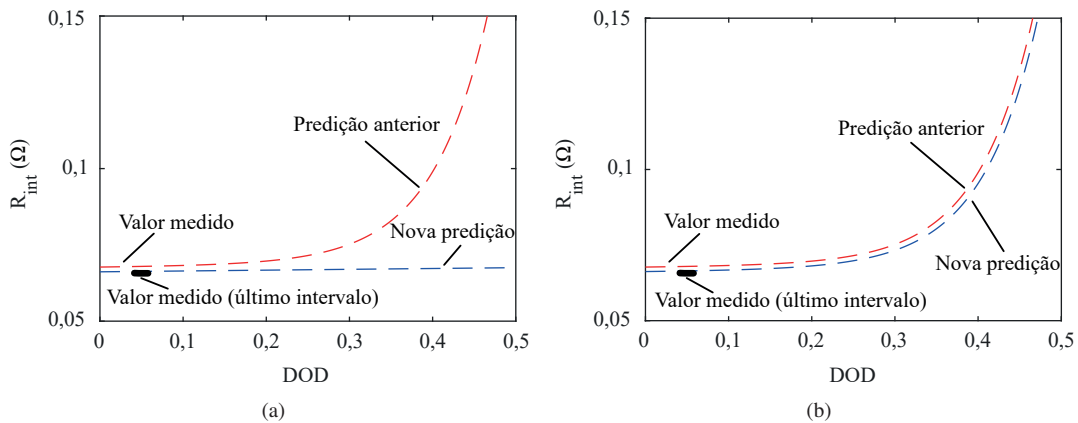


Fig. 14. Ajuste da predição da  $R_{int}$  com uma carga de 300 W na saída da UPS. (a) Predição sem limitar a variação dos coeficientes. (b) Predição com limitação da variação dos coeficientes.

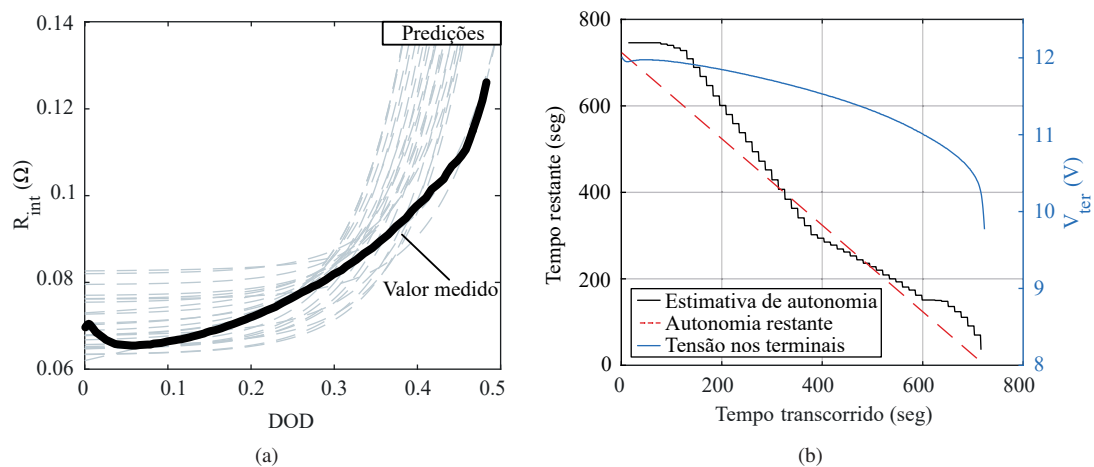


Fig. 15. Progressão das predições do algoritmo com uma carga de 300 W na saída da UPS. (a) Predição da  $R_{int}$ . (b) Predição da autonomia comparada à duração do ensaio, e tensão nos terminais..

saída da UPS. A Figura 15.b apresenta a evolução da predição da autonomia com base nas estimativas de  $R_{int}$  da Figura 15.a. Utilizada como referência, a linha vermelha tracejada representa a autonomia restante do ensaio (medido em laboratório), e está traçada juntamente com a estimativa de autonomia (linha preta contínua), na Figura 15.b. Logo, quanto mais próximas estiverem as linhas preta e vermelha no início, meio, e fim da descarga, mais exatas foram as predições de autonomia. A linha contínua azul apresenta o comportamento da tensão ao longo da descarga. Após o fim das descargas, os valores iniciais de  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$  para a faixa de potência são re-aprendidos fazendo a regressão na curva de  $R_{int}$  completa.

Em função da correção contínua da predição de autonomia, obtém-se as seguintes vantagens:

- O erro introduzido pela suposição que a corrente medida na bateria se manterá constante (Figura 8) é compensado;
- O erro introduzido pela desconsideração da ondulação de corrente e tensão nos terminais da bateria (utiliza-se o valor médio) é compensado;
- Dispensa-se uma acurácia elevada na medição da corrente. Este é o primeiro desafio associado ao uso do método da integração ampere-hora;
- O uso de (2) para compensação da capacidade em função

da temperatura é dispensado, conforme demonstrado na seção III-E. Este é o segundo desafio associado ao uso do método da integração ampere-hora.

As Figuras 16, 17, 18, e 19 apresentam os resultados da predição de autonomia para as potências na saída da UPS de 100 W, 200 W, 400 W e 700 W, respectivamente.




Fig. 16. Predições do algoritmo com uma carga de 100 W na UPS.

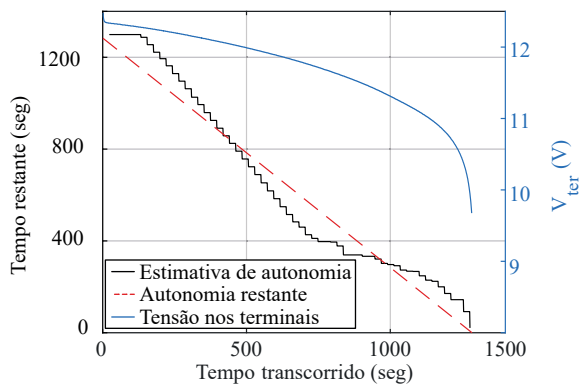


Fig. 17. Predições do algoritmo com uma carga de 200 W na UPS.




Fig. 18. Predições do algoritmo com uma carga de 400 W na UPS.




Fig. 19. Predições do algoritmo com uma carga de 700 W na UPS.

### E. Operação do Algoritmo com Baterias em Alta Temperatura

Na ocasião de elevação da temperatura durante a descarga, as correções sucessivas do algoritmo são suficientes para corrigir a predição de autonomia, já que a temperatura tende a aumentar lentamente conforme a Figura 20.

A fim de testar a adaptação do algoritmo para uma variação alta e inesperada de temperatura já na partida, as baterias foram aquecidas por uma fonte externa de calor, de 25 °C a 50 °C. Neste cenário, realizou-se uma descarga em 300 W, cujas tensões estão apresentadas na Figura 4, e os resultados de autonomia estão apresentados nas Figura 21.a (25 °C) e Figura 21.b (50 °C).

Para predição da autonomia, foram utilizados os valores partida de  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$  obtidos para temperatura de 25 °C. Este resultado é apresentado para demonstrar que o algoritmo pôde ajustar-se ao novo cenário, mesmo com os coeficientes de partida diferentes do ideal. Deve ser mencionado que,




Fig. 20. Variação de temperatura ao longo dos ensaios realizados.

normalmente, a temperatura em que os coeficientes de partida são obtidos corresponderá às condições normais de operação de bateria: em torno do regime permanente de temperatura. Logo, a diferença de 25 °C entre os ensaios trata-se de uma diferença grande, e normalmente inesperada.

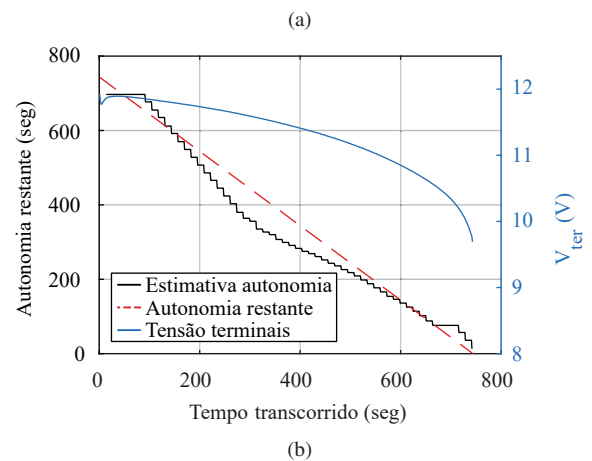
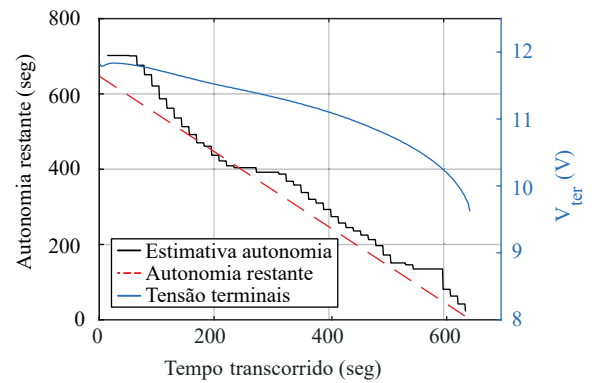


Fig. 21. Comparação da predição de autonomia para uma descarga com 300 W na saída, utilizando os mesmos coeficientes iniciais. (a) Ensaio em temperatura ambiente (em torno de 25 °C). (b) Ensaio com alta temperatura (em torno de 50 °C).

### F. Operação do Algoritmo com Diferentes Fabricantes

Existem diferenças entre as descargas baterias de diferentes fabricantes, por apresentarem significativas variações em seus parâmetros. Na Figura 22 estão apresentadas curvas de descarga de baterias com capacidade similar e SOH  $\approx$  100%, de três fabricantes diferentes: CSB GP 1272 (12 V / 7,2 Ah) [53], Moura 12MVA-7 [10] (12 V / 7 Ah) e Unipower UP 1270 (12 V / 7 Ah) [52].






Fig. 22. Curva de descarga para baterias de diferentes fabricantes descarregadas com uma potência de 200 W na saída da UPS.

Embora as curvas de descarga sejam diferentes, devido à versatilidade inerente ao algoritmo, esta diferença pode ser desconsiderada. As Figuras 23 e 24 comparam o uso dos valores de partida de  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$  obtidos para um fabricante, aplicados em baterias de outro fabricante, para uma descarga de 300 W. No exemplo da Figura 23, são utilizados os coeficientes obtidos com baterias CSB para predição da autonomia em baterias Moura (Figura 23.a) e Unipower (Figura 23.b). Na Figura 24 são utilizados os coeficientes obtidos com baterias Moura para predição em baterias CSB (Figura 24.a) e Unipower (Figura 24.b).

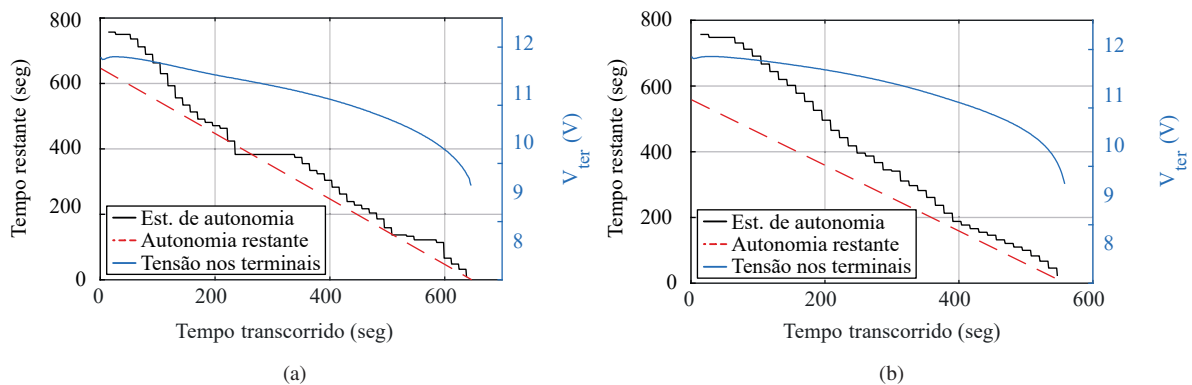


Fig. 23. Predição de autonomia com coeficientes de partida obtidos nas baterias do fabricante CSB, aplicados a baterias outros fabricantes. (a) Moura 12MVA-7. (b) Unipower UP 1270.

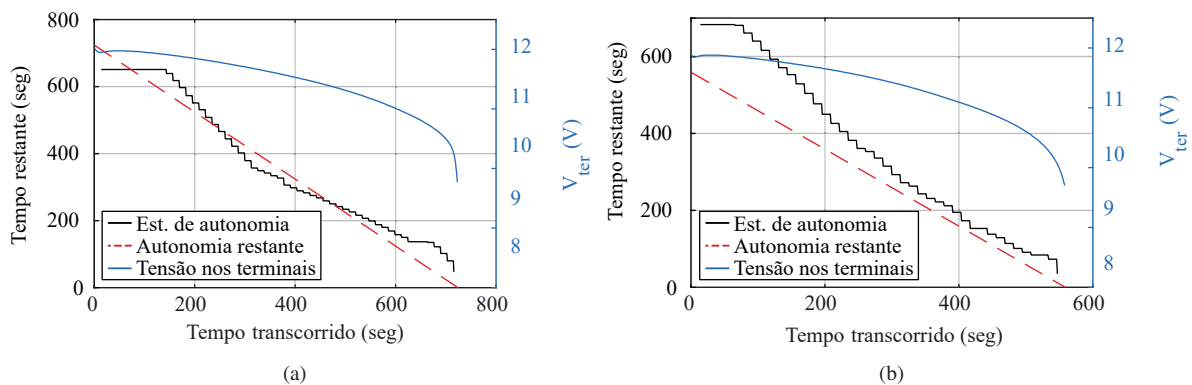


Fig. 24. Predição de autonomia com coeficientes de partida obtidos nas baterias do fabricante Moura, aplicados a baterias outros fabricantes. (a) CSB GP 1272. (b) Unipower UP 1270.

#### IV. PASSO-A-PASSO DE EXECUÇÃO DO ALGORITMO

A fim de sintetizar os passos de operação do algoritmo de predição de autonomia descritos nas seções anteriores, um fluxograma geral está apresentado na Figura 25. Os passos identificados pelos blocos do fluxograma são:

1. Identificação dos coeficientes: com base na faixa de potência detectada na saída, os coeficientes iniciais de  $x_1$ ,  $x_2$ ,  $x_3$ , e  $x_4$  (valores de partida) são adotados. Os valores de partida são ajustados/aprendidos à medida que o tempo passa e ocorrem novas descargas na bateria. Detalhado na seção III-C.
2. Estimativa da  $R_{int}$ : a projeção de OCV e DOD futuros na bateria são utilizados em conjunto com a expressão da  $R_{int}$  no modelo de circuito, para estimativa de  $V_{ter}$ . A projeção de  $V_{ter}$  é usada na determinação da autonomia. Detalhado nas seções III-A e III-B.
3. Comparação valor estimado  $\times$  medido: o valor projetado de  $R_{int}$  é comparado ao valor medido, sendo este obtido a partir da tensão medida nos terminais, aplicado ao modelo de circuito, utilizando a OCV e DOD projetados. Caso haja a necessidade de ajuste, os coeficientes são corrigidos por regressão não-linear de menores quadrados, utilizando o algoritmo LMA. Detalhado na seção III-D.
4. Atualização dos valores de partida de  $x_1$ ,  $x_2$ ,  $x_3$ , e  $x_4$ : após o fim da descarga, se esta cumprir as condições descritas

na seção III-C, os valores de partida de  $x_1$ ,  $x_2$ ,  $x_3$ , e  $x_4$  são atualizados.

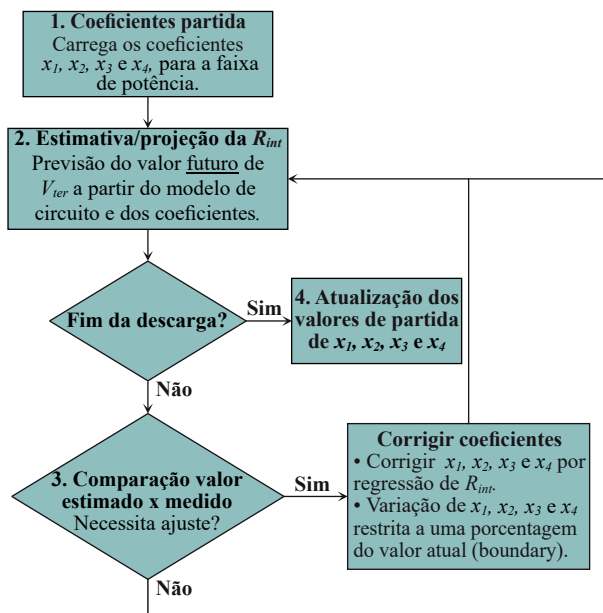


Fig. 25. Fluxograma geral do algoritmo desenvolvido para predição de autonomia.

## V. CONSIDERAÇÕES FINAIS

Neste trabalho foi proposto um algoritmo para a estimativa do tempo de descarga de baterias VRLA aplicadas a UPSs. Para predição do valor futuro da tensão nos terminais, utilizou-se um modelo de circuito equivalente. Este emprega uma resistência interna e a tensão de circuito aberto. Para predição da primeira, utilizou-se um modelo não-linear obtido por regressões de curva de um algoritmo LMA, ajustando-o com base em dados medidos durante as descargas da bateria. Para a tensão de circuito aberto, foi empregada a relação da mesma com o estado de carga, que por sua vez depende da corrente drenada das baterias.

A principal característica do algoritmo proposto é a realização das predições de autonomia de forma sucessiva em intervalos de tempo regulares. Utilizando essa estratégia, as predições são corrigidas sucessivamente para maior acurácia, mesmo com as aproximações feitas no modelo, como a desconsideração da relação da temperatura à capacidade (SOC) e a assunção de corrente de baterias constante a cada intervalo entre as predições.

Como resultado, obteve-se um método de predição do tempo de descarga de baterias que é compatível com formas de onda de descarga com alta ondulação. Apresentou-se a descrição do modo de funcionamento do algoritmo proposto, e demonstrou-se a sua acurácia para diferentes potências (Figuras 15 e 16 a 19), em caso de variações de temperatura (Figura 21) e para diferentes fabricantes de bateria VRLA (Figuras 23 e 24).

## AGRADECIMENTOS

O presente trabalho foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível

Superior – Brasil (CAPES/PROEX) – Código de financiamento 001.

## REFERÊNCIAS

- [1] F. T. Carneiro, I. Barbi, “Análise, projeto e implementação de um conversor com transferência de energia sem fio para carregadores de baterias de veículos elétricos”, *Revista Eletrônica de Potência-SOBRAEP*, vol. 26, pp. 260–267, Set. 2021.
- [2] H. Jank, W. A. Venturini, G. G. Koch, M. L. Martins, F. E. Bisogno, V. F. Montagner, H. Pinheiro, “Controle baseado em um LQR com estabilidade robusta a incerteza paramétrica aplicado a um carregador de baterias”, *Revista Eletrônica de Potência-SOBRAEP*, vol. 22, pp. 408–417, out. 2017.
- [3] I. R. Machado, D. Oliveira, L. Barreto, S. Souza, M. Young, *et al.*, “Sistema Eólico de Pequeno Porte para Carregamento de Baterias”, *Revista Eletrônica de Potência-SOBRAEP*, vol. 12, no. 2, pp. 97–104, Jul. 2007.
- [4] I. F. Lopes, R. L. Valle, P. G. Barbosa, L. d. M. Honório, N. A. Cruz, A. C. Matos, “Projeto e otimização da compensação de um transformador de núcleo separado usado para recarregar as baterias de um veículo subaquático autônomo”, *Eletrônica de Potência*, vol. 19, no. 1, pp. 97–109, Dez. 2013.
- [5] S. Jiang, Z. Song, “A review on the state of health estimation methods of lead-acid batteries”, *Journal of Power Sources*, vol. 517, p. 230710, Jan. 2022.
- [6] E. Karden, “Development trends for future automobiles and their demand on the battery”, in *Lead-Acid Batteries for Future Automobiles*, pp. 3–25, Elsevier, Dez. 2017.
- [7] A. D. Ballantyne, J. P. Hallett, D. J. Riley, N. Shah, D. J. Payne, “Lead acid battery recycling for the twenty-first century”, *Royal Society open science*, vol. 5, no. 5, p. 171368, Mai. 2018.
- [8] D. Linden, T. B. Reddy, *Handbook of batteries*, vol. 3, McGraw-Hill, Ago. 2003.
- [9] Unicoba, *Manual técnico bateria estacionária*, Unicoba Indústria de componentes eletrônicos e informática Ltda, 2021.
- [10] Moura, *Manual de Instalação e Operação Baterias Estacionárias VRLA*, Acumuladores Moura SA, 2021.
- [11] Panasonic, *VRLA Handbook*, Panasonic Industrial Europe GmbH, 2021.
- [12] R. Xiong, J. Cao, Q. Yu, H. He, F. Sun, “Critical review on the battery state of charge estimation methods for electric vehicles”, *Ieee Access*, vol. 6, pp. 1832–1843, Dez. 2017.
- [13] Y. Wang, J. Tian, Z. Sun, L. Wang, R. Xu, M. Li, Z. Chen, “A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems”, *Renewable and Sustainable Energy Reviews*, vol. 131, p. 110015, Out. 2020.
- [14] M. U. Cuma, T. Koroglu, “A comprehensive review on estimation strategies used in hybrid and battery electric vehicles”, *Renewable and Sustainable Energy Reviews*, vol. 42, pp. 517–531, Fev. 2015.

- [15] M. Coleman, W. G. Hurley, C. K. Lee, "An improved battery characterization method using a two-pulse load test", *IEEE Transactions on energy conversion*, vol. 23, no. 2, pp. 708–713, Jun. 2008.
- [16] M. Einhorn, F. V. Conte, C. Kral, J. Fleig, "Comparison, selection, and parameterization of electrical battery models for automotive applications", *IEEE Transactions on Power Electronics*, vol. 28, no. 3, pp. 1429–1437, Mar. 2013.
- [17] A. Mariani, T. Stockley, K. Thanapalan, J. Williams, P. Stevenson, "Simple and effective OCV prediction mechanism for VRLA battery systems", in *Proceedings of the 3rd International Conference on Mechanical Engineering and Mechatronics*, pp. 1–10, Ago. 2014.
- [18] NBR16659, "NBR16659 - Baterias chumbo-ácido de pequeno porte do tipo reguladas por válvula - Requisitos gerais, características funcionais e métodos de ensaio", *IEC TS 61000-3-4:1998*, vol. 2, pp. 1–18, Abr. 2020.
- [19] P. d. R. CARDOSO, *Estudo de Correlação de Parâmetros Elétricos Terminais com Características de desempenho em baterias*, Tese de Doutorado, Dissertação (Mestrado)–Universidade Estadual de Campinas, Ago. 2005.
- [20] G. Instruments, "Basics of electrochemical impedance spectroscopy", *G Instruments, Complex impedance in Corrosion*, pp. 1–30, Dez. 2007.
- [21] A. Tenno, R. Tenno, T. Suntuo, "Battery impedance and its relationship to battery characteristics", in *24th Annual International Telecommunications Energy Conference*, pp. 176–183, IEEE, Dez.2002.
- [22] M. Kiel, O. Bohlen, D. Sauer, "Harmonic analysis for identification of nonlinearities in impedance spectroscopy", *Electrochimica Acta*, vol. 53, no. 25, pp. 7367–7374, Out. 2008.
- [23] T. Takasaki, K. Takano, M. Ichimura, "Deterioration measuring method of VRLA battery used in UPS systems", in *Proceedings of Intelec'96-International Telecommunications Energy Conference*, pp. 799–804, IEEE, Out. 1996.
- [24] M. Danko, J. Adamec, M. Taraba, P. Drgona, "Overview of batteries State of Charge estimation methods", *Transportation Research Procedia*, vol. 40, pp. 186–192, Dez. 2019.
- [25] B. S. Bhangu, P. Bentley, D. A. Stone, C. M. Bingham, "Nonlinear observers for predicting state-of-charge and state-of-health of lead-acid batteries for hybrid-electric vehicles", *IEEE transactions on vehicular technology*, vol. 54, no. 3, pp. 783–794, Mai. 2005.
- [26] W. He, N. Williard, C. Chen, M. Pecht, "State of charge estimation for electric vehicle batteries using unscented kalman filtering", *Microelectronics Reliability*, vol. 53, no. 6, pp. 840–847, Jun. 2013.
- [27] E. A. Wan, R. Van Der Merwe, "The unscented Kalman filter for nonlinear estimation", in *Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium (Cat. No. 00EX373)*, pp. 153–158, Ieee, Out. 2000.
- [28] A. P. Schmidt, M. Bitzer, Á. W. Imre, L. Guzzella, "Experiment-driven electrochemical modeling and systematic parameterization for a lithium-ion battery cell", *Journal of Power Sources*, vol. 195, no. 15, pp. 5071–5080, Ago. 2010.
- [29] S. K. Rahimian, S. Rayman, R. E. White, "State of charge and loss of active material estimation of a lithium ion cell under low earth orbit condition using Kalman filtering approaches", *Journal of the Electrochemical Society*, vol. 159, no. 6, p. A860, Abr. 2012.
- [30] M. Doyle, T. F. Fuller, J. Newman, "Modeling of galvanostatic charge and discharge of the lithium/polymer/insertion cell", *Journal of the Electrochemical society*, vol. 140, no. 6, p. 1526, Dez. 1993.
- [31] M. Doyle, J. Newman, A. S. Gozdz, C. N. Schmutz, J.-M. Tarascon, "Comparison of modeling predictions with experimental data from plastic lithium ion cells", *Journal of the Electrochemical Society*, vol. 143, no. 6, p. 1890, Dez. 1996.
- [32] J. Xu, C. C. Mi, B. Cao, J. Cao, "A new method to estimate the state of charge of lithium-ion batteries based on the battery impedance model", *Journal of power sources*, vol. 233, pp. 277–284, Jul. 2013.
- [33] J. Kowal, D. Hente, D. U. Sauer, "Model parameterization of nonlinear devices using impedance spectroscopy", *IEEE Transactions on Instrumentation and Measurement*, vol. 58, no. 7, pp. 2343–2350, Fev. 2009.
- [34] W. Waag, S. Käbitz, D. U. Sauer, "Experimental investigation of the lithium-ion battery impedance characteristic at various conditions and aging states and its influence on the application", *Applied energy*, vol. 102, pp. 885–897, Fev. 2013.
- [35] M. Ceraolo, "New dynamical models of lead-acid batteries", *IEEE transactions on Power Systems*, vol. 15, no. 4, pp. 1184–1190, Nov. 2000.
- [36] C. Burgos, D. Sáez, M. E. Orchard, R. Cárdenas, "Fuzzy modelling for the state-of-charge estimation of lead-acid batteries", *Journal of Power Sources*, vol. 274, pp. 355–366, Jan. 2015.
- [37] I. A. Azzollini, V. Di Felice, F. Fraboni, L. Cavallucci, M. Breschi, A. Dalla Rosa, G. Zini, "Lead-acid battery modeling over full state of charge and discharge range", *IEEE Transactions on Power Systems*, vol. 33, no. 6, pp. 6422–6429, Jun. 2018.
- [38] F. Sun, R. Xiong, H. He, "A systematic state-of-charge estimation framework for multi-cell battery pack in electric vehicles using bias correction technique", *Applied Energy*, vol. 162, pp. 1399–1409, Jan. 2016.
- [39] R. Xiong, F.-C. Sun, H.-W. He, "Data-driven state-of-charge estimator for electric vehicles battery using robust extended Kalman filter", *International Journal of Automotive Technology*, vol. 15, no. 1, pp. 89–96, Fev. 2014.
- [40] S. Sepasi, R. Ghorbani, B. Y. Liaw, "Improved extended Kalman filter for state of charge estimation of battery pack", *Journal of Power Sources*, vol. 255, pp. 368–376, Jun. 2014.

- [41] S. Wang, M. Verbrugge, J. S. Wang, P. Liu, “Multi-parameter battery state estimator based on the adaptive and direct solution of the governing differential equations”, *Journal of Power Sources*, vol. 196, no. 20, pp. 8735–8741, Out. 2011.
- [42] H. He, X. Zhang, R. Xiong, Y. Xu, H. Guo, “Online model-based estimation of state-of-charge and open-circuit voltage of lithium-ion batteries in electric vehicles”, *Energy*, vol. 39, no. 1, pp. 310–318, Mar. 2012.
- [43] R. Xiong, H. He, F. Sun, K. Zhao, “Evaluation on state of charge estimation of batteries with adaptive extended Kalman filter by experiment approach”, *IEEE Transactions on Vehicular Technology*, vol. 62, no. 1, pp. 108–117, Out. 2012.
- [44] M. Charkhgard, M. Farrokhi, “State-of-charge estimation for lithium-ion batteries using neural networks and EKF”, *IEEE transactions on industrial electronics*, vol. 57, no. 12, pp. 4178–4187, Fev. 2010.
- [45] A. J. Salkind, C. Fennie, P. Singh, T. Atwater, D. E. Reisner, “Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology”, *Journal of Power sources*, vol. 80, no. 1-2, pp. 293–300, Jul. 1999.
- [46] P. Singh, R. Vinjamuri, X. Wang, D. Reisner, “Design and implementation of a fuzzy logic-based state-of-charge meter for Li-ion batteries used in portable defibrillators”, *Journal of power sources*, vol. 162, no. 2, pp. 829–836, Nov. 2006.
- [47] Y. Shen, “Adaptive online state-of-charge determination based on neuro-controller and neural network”, *Energy Conversion and Management*, vol. 51, no. 5, pp. 1093–1098, Mai. 2010.
- [48] T. Hansen, C.-J. Wang, “Support vector based battery state of charge estimator”, *Journal of Power Sources*, vol. 141, no. 2, pp. 351–358, Mar. 2005.
- [49] H. Cao, J. Yu, L. Kang, H. Yang, X. Ai, “Modeling and prediction for discharge lifetime of battery systems using hybrid evolutionary algorithms”, *Computers & chemistry*, vol. 25, no. 3, pp. 251–259, Mai. 2001.
- [50] K. Levenberg, “A method for the solution of certain non-linear problems in least squares”, *Quarterly of applied mathematics*, vol. 2, no. 2, pp. 164–168, Jul. 1944.
- [51] E. O. Prado, P. C. Bolsi, H. C. Sartori, J. R. Pinheiro, “Comparative Analysis of Modulation Techniques on the Losses and Thermal Limits of Uninterruptible Power Supply Systems”, *Micromachines*, vol. 13, no. 10, p. 1708, Out. 2022.
- [52] Unicoba, *Unipower UP 1270*, Unicoba Indústria de componentes eletrônicos e informática Ltda, 2021.
- [53] CSB, *GP Series 1272*, CSB Energy Technology Company Ltd., 2021.

#### DADOS BIOGRÁFICOS

**Pedro Cerutti Bolsi**, natural de Frederico Westphalen (RS), possui graduação (2018) e mestrado (2020) em Engenharia Elétrica. Atualmente, é aluno de doutorado em Engenharia

Elétrica pela Universidade Federal de Santa Maria (UFSM) e pela Universidade Federal da Bahia (UFBA). Possui experiência em eletrônica de potência, atuando principalmente nas áreas de projeto físico e otimização de dispositivos magnéticos, modelagem de perdas no cobre e núcleo, tempo de vida de capacitores, projeto de filtros e modelagem de baterias.

**Edemar de Oliveira Prado**, natural de Frederico Westphalen (RS), possui graduação em Engenharia Elétrica (2018) e mestrado (2020). Atualmente, é aluno de doutorado em Engenharia Elétrica pela Universidade Federal de Santa Maria (UFSM) e pela Universidade Federal da Bahia (UFBA). Possui experiência na área de eletrônica de potência, atuando principalmente na área de otimização de transistores aplicados a conversores estáticos, sistemas de transferência de calor e análise física de semicondutores.

**Romário de Jesus Nazaré** é graduado em Engenharia de Controle e Automação de Processos pela Universidade Federal da Bahia – UFBA (2019). Atualmente é mestrando em Engenharia Elétrica, pelo Programa de Pós Graduação em Engenharia Elétrica da Universidade Federal da Bahia – PPGEE – UFBA, desenvolvendo pesquisas com foco em eletrônica de potência no Laboratório de Eficiência Energética da UFBA – LABEFEA. Possui conhecimentos nas áreas de eletrônica de potência, sistemas embarcados e teoria de controle.

**Antonio Cezar de Castro Lima** é graduado em Engenharia Elétrica pela Universidade Federal da Bahia (1988), mestre em Engenharia Elétrica pela Universidade Estadual de Campinas (1990) e doutor em Engenharia Eletrônica pela University of Kent at Canterbury (1994). Em 2002, Prof. Antonio Cezar concluiu suas atividades de pós-doutorado na McMaster University, onde desenvolveu pesquisas na área de Comunicação Sem-Fio. Atualmente ele é Professor Titular da Universidade Federal da Bahia.

**Hamilton Confortin Sartori**, natural de Marau (RS), possui graduação em Engenharia Elétrica (2007) na Universidade Federal de Santa Maria, mestrado (2009), doutorado (2013) e pós-doutorado (2016) em Engenharia Elétrica. Atualmente é professor Adjunto de Departamento de Processamento de Energia Elétrica da Universidade Federal de Santa Maria. Possui experiência na área de eletrônica de potência, atuando principalmente nas áreas de projetos otimizados de conversores estáticos, conversores de alto ganho, projetos de componentes magnéticos, semicondutores de potência, sensoramento e compatibilidade eletromagnética (EMI).

**José Renes Pinheiro**, recebeu o grau de Eng Eletricista pela UFSM, e os graus de Mestre e Doutor em Engenharia Elétrica pela UFSC, em 1981, 1984, e 1994, respectivamente. É Prof. Titular (Voluntário) do DPEE da UFSM, onde atua desde 1985. Desde 2018, também atua como Prof. Titular Visitante no PPGEE da UFBA. Em 1987, foi um dos fundadores e líder do Grupo de Eletrônica de Potência e Controle (GEPOC). Entre 2006 e 2015 foi coord. do PPGEE da UFSM. Entre 2001 e 2002, realizou pós-doutorado no Center for Power Electronics Systems (CPES), Virginia Tech, EUA.