

Avaliação da Precisão e Confiabilidade da Medição do Estado de Carga (SoC) em Sistemas BESS

Paulo César Ajeje¹, Frederico Silva Moreira¹

¹Universidade Federal de Mato Grosso do Sul, Campo Grande, MS, Brasil
(paulo.ajeje@ufms.br)

Resumo: Este estudo analisa métodos de estimativa do Estado de Carga (SoC) em sistemas de armazenamento de energia por baterias (BESS), avaliando contagem de Coulomb, OCV, EKF e técnicas de aprendizado de máquina. Considera fatores como temperatura, Estado de Saúde da bateria (SoH) e ruídos. Destaca o papel do Sistema de Gerenciamento de Baterias (BMS) na aplicação desses métodos e conclui que abordagens híbridas aumentam a confiabilidade e precisão

Palavras-chaves: BESS; Estado de Carga (SoC); Estado de Saúde (SoH); sistemas de medição; BMS

INTRODUÇÃO

Os sistemas BESS desempenham papel fundamental na integração de fontes renováveis e na estabilidade de sistemas elétricos modernos. Nesse contexto, o Estado de Carga (SoC) é uma variável crítica, pois representa a energia disponível na bateria em um dado instante (DUNN *et al.*, 2011).

Entretanto, o SoC não pode ser medido diretamente, sendo estimado a partir de grandezas elétricas como corrente e tensão, o que introduz incertezas e dependência de modelos matemáticos. Conforme descrito por Liu *et al.* (2026), o SoC varia entre 0% e 100% e sua estimativa adequada é essencial para evitar falhas operacionais.

Este artigo tem como objetivo analisar a precisão e confiabilidade dos métodos de medição do SoC, considerando fatores operacionais, instrumentação e tratamento de dados.

MATERIAL E MÉTODOS

Este estudo possui caráter teórico-analítico, com abordagem qualitativa e comparativa, baseado na revisão da literatura científica sobre métodos de estimativa do Estado de Carga (SoC) em sistemas BESS. Foram analisados quatro métodos principais: contagem de Coulomb, tensão de circuito aberto (OCV), filtro de Kalman estendido (EKF) e técnicas de aprendizado de máquina, selecionados por sua relevância e utilização prática em sistemas de gerenciamento de baterias (BMS).

A comparação entre os métodos foi realizada a partir de critérios como acurácia, sensibilidade às condições iniciais, robustez a ruídos, influência da temperatura e dependência do Estado de Saúde (SoH). Também

foram considerados aspectos de complexidade computacional e viabilidade de implementação em tempo real.

Adicionalmente, foram avaliados fatores operacionais que impactam a precisão das estimativas, bem como estratégias de mitigação descritas na literatura, incluindo calibração e abordagens híbridas. A partir dessa análise, foram identificadas as principais vantagens e limitações de cada método, com foco na aplicação em Sistema de Gerenciamento de Baterias (BMS) mais confiáveis.

RESULTADOS

Fundamentação teórica

O Estado de Carga (SoC) constitui um dos principais parâmetros para a avaliação do desempenho de baterias em sistemas de armazenamento de energia, sendo definido como a razão entre a carga disponível e a capacidade nominal da bateria, expressa em termos percentuais. Essa relação fornece uma medida direta do nível de energia armazenada, porém está sujeita a variações decorrentes das condições operacionais e do envelhecimento do sistema. O Estado de Carga é definido pela Equação 1:

$$SoC = \frac{Q_{disponível}}{Q_{nominal}} \times 100\% \quad (1)$$

Onde:

$Q_{disponível}$: carga atual armazenada na bateria.

$Q_{nominal}$: capacidade nominal total da bateria.

Nesse contexto, a degradação da bateria é representada pelo Estado de Saúde (SoH), que influencia diretamente a capacidade efetiva disponível, reduzindo-a ao longo do tempo (Hu *et al.*, 2026).

Assim, a capacidade real da bateria pode ser expressa como função do *SoH*, evidenciando que a não consideração desse parâmetro pode introduzir erros significativos na estimativa do *SoC*, especialmente em aplicações de longo prazo.

A degradação da bateria é representada pelo Estado de Saúde (*SoH*), que influencia diretamente a capacidade, dada pela Equação 2 (Hu *et al.*, 2026).

$$Q_{efetivo} = SoH \times Q_{nominal} \quad (2)$$

Onde:

$Q_{efetivo}$: capacidade atual da bateria.

SoH: estado de saúde da bateria em %.

A compreensão das dinâmicas de integração entre sistemas de armazenamento e fontes renováveis exige o domínio de uma terminologia técnica específica, que abrange desde parâmetros eletroquímicos até algoritmos de inteligência de dados.

A Tabela 1 consolida as principais abreviações e acrônimos utilizados nesta pesquisa, estabelecendo uma base conceitual que integra indicadores de performance, como o *SoH* (*State of Health*) e o *LCOS* (*Levelized Cost of Storage*), às novas fronteiras da *XAI* (*Explainable Artificial Intelligence*). Essa padronização é fundamental para a estabilidade operacional das futuras *Smart Grids*, onde a capacidade de adaptação ao envelhecimento e à variabilidade de tipos de baterias será o pilar da sustentabilidade energética e da viabilidade econômica do sistema.

Tabela 1. Siglas e terminologias técnicas aplicadas a BESS e sistemas de energia.

Abreviação	Significado (Português)	Full Form (English)
BESS	Sistema de Armazenamento de Energia por Baterias	Battery Energy Storage System
EMS	Sistema de Gestão de Energia	Energy Management System
BMS	Sistema de Gestão de Baterias	Battery Management System
VRE	Energias Renováveis Variáveis	Variable Renewable Energy
SoC	Estado de Carga	State of Charge
SoH	Estado de Saúde (Degradação)	State of Health
LCOS	Custo Nivelado de Armazenamento	Levelized Cost of Storage
PCS	Sistema de Conversão de Potência	Power Conversion System
XAI	Inteligência Artificial Explicável	Explainable Artificial Intelligence
RUL	Vida Útil Remanescente	Remaining Useful Life
DER	Recursos Energéticos Distribuídos	Distributed Energy Resources

PV	Fotovoltaica	Photovoltaic
SHAP	Explicações Aditivas de Shapley	SHapley Additive exPlanations
ML	Aprendizado de Máquina	Machine Learning
DL	Aprendizado Profundo	Deep Learning

Fonte: Elaborada pelo autor (2026).

A estimativa do Estado de Carga (*SoC*) é um problema não trivial, uma vez que essa grandeza não pode ser medida diretamente, sendo inferida a partir de variáveis elétricas e modelos matemáticos. Os métodos existentes podem ser classificados em quatro categorias principais: métodos diretos, que focam na simplicidade operacional como a contagem de Coulomb e o método OCV; baseados em modelos, que utilizam representações de circuitos equivalentes associadas a filtros de Kalman; baseados em dados, que empregam o aprendizado de máquina e redes neurais para mapear não linearidades; e híbridos, que representam o estado da arte ao buscarem a sinergia entre o determinismo dos modelos físicos e a adaptabilidade da inteligência artificial.

A. Contagem de Coulomb

O método da contagem de Coulomb é amplamente utilizado devido à sua simplicidade e viabilidade em tempo real. Ele consiste na integração da corrente elétrica ao longo do tempo para determinar a variação da carga armazenada na bateria (Liu *et al.*, 2026).

Matematicamente, pode ser expresso pela Equação 3.

$$SoC(t) = SoC(t_0) - \frac{1}{C_n} \int_{t_0}^t \eta \cdot I(\tau) dt \quad (3)$$

Onde:

$SoC(t)$: Estado de carga no tempo t ;

$SoC(t_0)$: Estado de carga inicial;

C_n : Capacidade nominal da bateria (Ah);

$I(\tau)$: Corrente instantânea da bateria, sendo $I>0$ para bateria descarregando e $I<0$ para bateria carregando.

η : Eficiência coulômbica de carga/descarga.

Vantagens

- ✓ Implementação simples;
- ✓ Baixo custo computacional;
- ✓ Aplicável em tempo real.

Limitações

- ✓ Acúmulo de erro ao longo do tempo (*drift*);
- ✓ Sensibilidade a erros de medição da corrente;
- ✓ Dependência de uma condição inicial precisa.

Análise crítica

- ✓ Mesmo pequenas imprecisões na medição da corrente ou na estimativa inicial do *SoC* podem resultar em desvios significativos após longos períodos de operação, tornando necessário o uso de técnicas de correção periódica (Liu *et al.*, 2026).

B. Tensão em Circuito Aberto (OCV)

O método OCV baseia-se na relação entre a tensão da bateria em circuito aberto (Figura 1) e o *SoC*, obtida experimentalmente por curvas características (Fan *et al.*, 2025).




Figura 1. Modelo de Circuito Aberto (Thevenin simplificado).

Vantagens

- ✓ Alta precisão em condições estáticas;
- ✓ Não depende de integração acumulativa.

Limitações

- ✓ Requer longos períodos de repouso para estabilização;
- ✓ Influência significativa da temperatura;
- ✓ Relação não linear e dependente da química da bateria.

Análise crítica

- ✓ Embora preciso em laboratório, o método OCV é pouco aplicável em sistemas BESS operando continuamente, sendo mais adequado como referência para calibração de outros métodos.

De acordo com Baccouche *et al.* (2018), para melhores resultados, a maioria dos sistemas modernos combina os dois métodos: usa o *OCV* para recalibrar a Contagem de Coulomb quando o sistema está em repouso.

C. Filtros de Kalman Estendido

A linearização de sistemas não lineares, realizada via expansão de Taylor de primeira ordem, é amplamente empregada em algoritmos como o Filtro de Kalman Estendido (*Extended Kalman Filter – EKF*). Embora essa técnica seja válida apenas localmente e sujeita à degradação de desempenho em sistemas fortemente

não lineares, o EKF é extensamente aplicado em baterias de íons de lítio para estimar estados internos a partir de medições ruidosas. Esse processo ocorre por meio de um ciclo recursivo de predição e correção, baseado na comparação entre a tensão medida e a estimada pelo modelo, calculadas pelas Equações 4 e 5 (Plett, 2004).

O modelo discreto geral pode ser expresso por:

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k, \mathbf{u}_k) + \omega_k \quad (4)$$

$$\mathbf{y}_k = h(\mathbf{x}_k) + \mathbf{v}_k \quad (5)$$

Onde:

$\mathbf{x}_k$: Estado de carga no instante k .

$\mathbf{u}_k$: Entrada (medição de corrente).

$\mathbf{y}_k$: Saída (medição de tensão).

ω_k : Ruído de processo (incertezas do modelo).

$\mathbf{v}_k$: Ruído de medição.

Vantagens

- ✓ Alta precisão em condições dinâmicas;
- ✓ Robustez a ruídos;
- ✓ Correção automática de erros;
- ✓ Considera as variáveis de temperatura e de envelhecimento (*SoH*).

Limitações

- ✓ Dependência de modelagem precisa;
- ✓ Ajuste complexo de parâmetros;
- ✓ Maior custo computacional.

Análise crítica

- ✓ Os métodos baseados em modelos, como o EKF, oferecem alta precisão e robustez a ruídos, porém dependem fortemente da modelagem e calibração, podendo apresentar degradação de desempenho diante de não linearidades e variações operacionais (Yang *et al.*, 2026).

Uma variação mais avançada, que lida melhor com comportamentos altamente não lineares e pode oferecer maior precisão que o *EKF* em certas condições, é o Filtro de Kalman *Unscented* (*UKF*).

D. Baseados em Aprendizado de Máquina

Com o avanço da inteligência artificial, técnicas baseadas em dados vêm sendo amplamente exploradas para estimativa do *SoC* e *SoH*, tais como: redes neurais artificiais (*Artificial Neural Networks – ANN*), redes recorrentes (*Long Short-Term Memory – LSTM*), máquinas de vetores de suporte (*Support Vector Machines – SVM*), redes convolucionais temporais (*Temporal Convolutional Network – TCN*) e dados históricos (Wang *et al.*, 2025; Liu *et al.*, 2026).



Vantagens

- ✓ Capacidade de modelar não linearidades complexas;
- ✓ Não requer modelagem física detalhada;
- ✓ Alta precisão em sistemas complexos.

Limitações

- ✓ Necessidade de grandes volumes de dados;
- ✓ Dependência de treinamento prévio;
- ✓ Baixa explicabilidade física.

Análise crítica

- ✓ Esses métodos são promissores, especialmente em sistemas com grande variabilidade operacional, porém sua aplicação prática ainda enfrenta desafios relacionados à generalização e robustez.

As técnicas de Aprendizado de Máquina aplicadas a BESS apresentam diferentes níveis de complexidade e aplicabilidade, conforme detalhado na Tabela 2. Essa evolução abrange desde as modelagens clássicas de Plett (2004) até arquiteturas temporais modernas, como LSTM e TCN (Yang *et al.*, 2020; Chemali *et al.*, 2018), que permitem lidar com a dinâmica complexa dos sistemas de armazenamento.

Tabela 2. Comparativo de Técnicas de Aprendizado de Máquina para BESS.

Técnica	Aplicação Principal no BESS	Complexidade
ANN	Mapeamento OCV-SoC e estimativa de parâmetros (R e C)	Baixa
SVM	Estimativa de Saúde (SoH) e predição de vida útil (RUL)	Média
LSTM	Estimativa de SoC em perfis de carga altamente dinâmicos	Alta
TCN	Gestão de energia (EMS) em séries temporais longas	Alta

E. Métodos Híbridos

Os métodos híbridos configuram o estado da arte na estimação de SoC ao promoverem a sinergia entre modelos físicos e da inteligência computacional. Esta abordagem busca fundir técnicas distintas para obter vantagens complementares e mitigar deficiências intrínsecas, como o acúmulo de erros (*drift*) de métodos integrativos ou a necessidade de repouso absoluto exigida pelo método OCV. Exemplos dessa categoria incluem a integração da contagem de Coulomb com o método OCV para recalibrações periódicas em repouso, a fusão de Filtros de Kalman Estendidos (EKF) com algoritmos de *Machine Learning* (como Redes Neurais, TCN ou LSTM) e o emprego de

modelos físicos de circuitos equivalentes associados a correções adaptativas.

Essas arquiteturas garantem uma maior precisão global e a redução sistemática de incertezas, apresentando desempenho superior sob as condições dinâmicas e ruidosas da operação real. Conforme destacado pela literatura recente, a tendência atual para sistemas BESS converge para o uso dessas soluções híbridas integradas diretamente ao BMS, o que permite uma gestão de dados robusta e estimativas mais confiáveis, fundamentais para a segurança operacional e para a viabilidade econômica do armazenamento (Hu *et al.*, 2026; Liu *et al.*, 2026).

Exemplos

- ✓ *Coulomb Counting* + OCV;
- ✓ Kalman + *Machine Learning*;
- ✓ Modelos físicos + correção adaptativa.

Vantagens

- ✓ Maior precisão global;
- ✓ Redução de erros acumulados;
- ✓ Melhor desempenho em condições reais.

Análise crítica

- ✓ A tendência atual em sistemas BESS é o uso de métodos híbridos integrados ao BMS, permitindo estimativas mais robustas e confiáveis (Hu *et al.*, 2026; Liu *et al.*, 2026).

Observa-se que o método de contagem de Coulomb, apesar de sua simplicidade e viabilidade para implementação contínua, apresenta precisão apenas moderada devido ao acúmulo progressivo de erros (Liu *et al.*, 2026).

Em contrapartida, o método baseado na tensão em circuito aberto (OCV) oferece elevada precisão, porém sua aplicação é limitada por exigir condições de repouso da bateria, inviabilizando seu uso em operação dinâmica (Fan *et al.*, 2025).

Já os métodos baseados em filtros de Kalman destacam-se por combinar alta precisão com capacidade de operação em tempo real, embora dependam fortemente da qualidade do modelo matemático adotado, o que implica maior complexidade de implementação (Yang *et al.*, 2026; Plett, 2004).

Por fim, as abordagens baseadas em aprendizado de máquina apresentam o maior nível de precisão entre os métodos analisados, sendo capazes de capturar comportamentos altamente não lineares; entretanto, essa vantagem vem acompanhada de elevada complexidade computacional e da necessidade de grandes volumes de dados para treinamento.



Dessa forma, a escolha do método mais adequado deve considerar o equilíbrio entre desempenho, custo computacional e requisitos operacionais do sistema BESS (Hu *et al.*, 2026; Liu *et al.*, 2026).

A seguir, a Tabela 3 apresenta uma análise comparativa dos principais métodos de estimação do Estado de Carga (*SoC*), evidenciando os compromissos inerentes entre precisão, complexidade computacional e aplicabilidade em tempo real.

Tabela 3. Comparativo Métodos de Estimação do *SoC*.

Tipo	Métodos	Vantagens	Pontos Fracos	Principal Uso
Diretos	Contagem de Coulomb, OCV	Precisão média, simples e baixo custo computacional	Acúmulo de erro e sensibilidade do método	Sistemas simples e embarcados
Baseados em Modelos	Filtro de Kalman, EKF, UKF	Alta precisão, operação em tempo real	Complexo e depende de modelo preciso	BESS industrial /veículos elétricos
Baseados em IA	Redes Neurais, SVM	Alta precisão, boa adaptação e capta não linearidades	Requer muitos dados e difícil de entender	Sistema com grande base de dados
Híbridos	Kalman + IA, Modelos flexíveis	Precisão Elevada, melhor desempenho global	Complexo e maior custo	Usos críticos e sistema confiável

A precisão da estimativa do Estado de Carga (*SoC*) é fortemente influenciada por diversos fatores operacionais, instrumentais e intrínsecos à própria bateria, conforme sintetizado na Tabela 4.

Tabela 4. Fatores de Precisão da Estimativa do *SoC*.

Fator	Impacto Técnico	Efeito	Estratégia de Mitigação
Temperatura	Variação da resistência interna	Desvio na estimativa	Compensação térmica
Taxa de carga (C-rate)	Efeitos dinâmicos na tensão	Erros de modelagem	Modelos adaptativos
Estado de Saúde (<i>SoH</i>)	Redução da capacidade	Erro sistemático	Recalibração periódica
Ruído de medição	Interferência nos sinais	Perda de precisão	Filtragem digital
<i>SoC</i> inicial incorreto	Base de cálculo inadequada	Propagação de erro	Procedimentos de calibração

Observa-se que a temperatura exerce impacto direto sobre a resistência interna da bateria, provocando desvios na estimativa caso não haja compensação térmica adequada (Yang *et al.*, 2026). De forma semelhante, a taxa de carga ou descarga (*C-rate*) introduz efeitos dinâmicos na tensão terminal, o que pode comprometer a acurácia de modelos simplificados, exigindo a adoção de modelos adaptativos (Fan *et al.*, 2025).

O envelhecimento da bateria, representado pelo Estado de Saúde (*SoH*), reduz progressivamente a capacidade disponível, gerando erros sistemáticos quando não realizadas recalibrações periódicas via ciclos de capacidade, método OCV (em repouso) como referência ou algoritmos adaptativos no BMS que ajustam o *SoC* ao envelhecimento (Hu *et al.*, 2026).

Além disso, o ruído de medição, decorrente de interferências eletromagnéticas e limitações dos sensores, afeta a qualidade dos sinais adquiridos, sendo necessária a aplicação de técnicas de filtragem digital (Liu *et al.*, 2026).

Por fim, a definição incorreta do *SoC* inicial constitui uma fonte crítica de erro, especialmente em métodos integrativos, pois leva à propagação acumulativa de desvios ao longo do tempo, o que reforça a importância de procedimentos rigorosos de calibração (Liu *et al.*, 2026).

A análise integrada dos métodos de estimação do Estado de Carga (*SoC*) evidencia que não existe uma abordagem universalmente superior, mas sim soluções com diferentes compromissos entre precisão, robustez e viabilidade de implementação.

De maneira geral, os métodos diretos, como a contagem de Coulomb e a medição por tensão (OCV), destacam-se pela simplicidade e baixo custo computacional, sendo amplamente utilizados em aplicações práticas; entretanto, apresentam limitações importantes, como o acúmulo de erros ao longo do tempo e a dependência de condições específicas de operação, o que compromete sua confiabilidade em cenários dinâmicos.

Por outro lado, os métodos baseados em modelos, como os filtros de Kalman e suas variantes, oferecem elevada precisão e capacidade de operação em tempo real, ao incorporar modelos matemáticos que representam o comportamento eletroquímico da bateria; contudo, sua eficácia está diretamente condicionada à qualidade da modelagem e à correta identificação de parâmetros, implicando maior complexidade técnica e computacional.

No contexto mais recente, os métodos baseados em inteligência artificial emergem como alternativas altamente adaptativas, capazes de capturar relações não lineares complexas e de se ajustar a diferentes condições operacionais; apesar disso, sua aplicação

prática depende fortemente da disponibilidade de grandes volumes de dados representativos e de processos de treinamento robustos, além de apresentar desafios relacionados à alta complexidade.

Diante dessas limitações individuais, os métodos híbridos têm se destacado como a solução mais promissora, ao combinar diferentes técnicas, integrando modelos físicos com algoritmos de aprendizado de máquina, a fim de explorar as vantagens de cada abordagem e mitigar suas deficiências.

Assim, tais métodos tendem a oferecer o melhor desempenho global, especialmente em aplicações críticas de sistemas BESS, onde a precisão e a confiabilidade da estimativa do *SoC* são fundamentais para a segurança e a eficiência operacional.

DISCUSSÃO

A análise dos métodos de estimação do Estado de Carga (*SoC*) em sistemas BESS evidencia que o principal desafio não reside apenas na escolha do algoritmo, mas na capacidade de lidar com as múltiplas fontes de incerteza que afetam a medição ao longo do tempo.

Conforme discutido nas Tabelas 1, 2, 3 e 4, fatores como temperatura, envelhecimento da bateria (*SoH*), condições dinâmicas de operação e qualidade da instrumentação influenciam diretamente o desempenho dos métodos, podendo degradar significativamente sua precisão quando não devidamente tratados.

Nesse contexto, observa-se que abordagens simplificadas, embora atrativas do ponto de vista computacional, tendem a apresentar limitações importantes em aplicações reais, especialmente em sistemas sujeitos a variações operacionais intensas, como microrredes e sistemas de armazenamento conectados à rede.

Adicionalmente, a literatura demonstra que a propagação de erros é um problema crítico, sobretudo em métodos integrativos como a contagem de Coulomb, nos quais pequenas imprecisões iniciais podem resultar em desvios significativos ao longo do tempo (Liu *et al.*, 2026).

Por outro lado, métodos mais sofisticados, como os baseados em filtros de Kalman, oferecem mecanismos de correção contínua por meio da fusão de dados e modelagem probabilística, porém exigem elevado grau de calibração e conhecimento prévio do sistema (Yang *et al.*, 2026).

Nesse sentido, a confiabilidade da estimativa do *SoC* está intrinsecamente relacionada à qualidade dos modelos e dos parâmetros utilizados, o que representa uma limitação prática em cenários onde há variabilidade entre células, degradação não uniforme ou ausência de dados precisos.

Outro ponto relevante refere-se ao avanço das técnicas baseadas em inteligência artificial, que têm demonstrado elevado potencial para superar limitações dos métodos tradicionais, especialmente na modelagem de comportamentos não lineares e na adaptação a diferentes condições operacionais.

No entanto, tais métodos ainda enfrentam desafios importantes, como a necessidade de grandes volumes de dados para treinamento, a dependência de infraestrutura computacional e a baixa explicabilidade dos modelos, o que pode dificultar sua aceitação em aplicações críticas do ponto de vista de segurança (Hu *et al.*, 2026).

Diante desse panorama, a tendência atual converge para o uso de abordagens híbridas, que combinam diferentes técnicas de estimação com o objetivo de aumentar a robustez e a confiabilidade dos resultados.

Essas abordagens permitem, por exemplo, utilizar métodos diretos para inicialização, modelos matemáticos para acompanhamento em tempo real e algoritmos de inteligência artificial para correção adaptativa de erros.

Tal integração se mostra particularmente promissora em sistemas BESS de grande porte, nos quais a precisão da estimativa do *SoC* impacta diretamente a eficiência energética, a vida útil dos ativos e a segurança operacional.

Por fim, destaca-se que a escolha do método mais adequado deve considerar não apenas critérios técnicos, mas também aspectos econômicos, computacionais e operacionais.

Em aplicações industriais, a solução ótima tende a ser aquela que equilibra precisão, robustez e viabilidade de implementação, garantindo desempenho confiável ao longo de todo o ciclo de vida do sistema.

Dessa forma, a discussão reforça a importância de uma abordagem sistêmica e integrada na medição do *SoC*, alinhada às demandas crescentes de desempenho e segurança dos sistemas BESS modernos.

Resumidamente, a análise demonstra que métodos isolados apresentam limitações significativas, como erro acumulativo, sensibilidade a ruídos e degradação sob condições dinâmicas, enquanto a combinação de diferentes técnicas aumenta a confiabilidade e a precisão das estimativas, sendo o sistema de gestão de baterias (BMS) essencial para integração funcional, processamento de dados e correção de erros.

CONCLUSÃO

A estimativa do Estado de Carga (*SoC*) em sistemas BESS configura-se como um problema multidimensional, no qual interagem fenômenos eletroquímicos, condições operacionais dinâmicas e limitações inerentes aos sistemas de medição.

Ao longo deste trabalho, evidenciou-se que a acurácia e a confiabilidade da estimativa do *SoC* não dependem exclusivamente do método empregado, mas de um conjunto integrado de fatores que incluem modelagem adequada, qualidade da instrumentação, estratégias de aquisição de dados e tratamento das incertezas associadas.

Os resultados analisados indicam que não há um método universalmente superior para todas as aplicações. Métodos diretos apresentam vantagens operacionais pela simplicidade, porém são suscetíveis a erros acumulativos; métodos baseados em modelos oferecem maior precisão, ao custo de maior complexidade e dependência de parametrização; enquanto abordagens baseadas em inteligência artificial ampliam a capacidade de adaptação a comportamentos não lineares, mas exigem grande volume de dados e apresentam desafios quanto à explicabilidade.

Nesse cenário, as abordagens híbridas destacam-se como a solução mais robusta, ao combinar diferentes técnicas de forma complementar, mitigando limitações individuais e elevando o desempenho global da estimativa.

Adicionalmente, ficou evidente que fatores como temperatura, taxa de operação, envelhecimento (*SoH*), ruídos de medição e condições iniciais exercem influência significativa sobre os resultados, podendo comprometer a confiabilidade da estimativa caso não sejam devidamente considerados. Assim, práticas como calibração periódica, compensação térmica, filtragem de sinais e atualização contínua de parâmetros são essenciais para assegurar a qualidade das medições.

Conclui-se que o avanço na estimativa do *SoC* em sistemas BESS está diretamente associado à integração entre técnicas de modelagem, processamento de sinais e inteligência computacional, aliada a uma abordagem rigorosa de instrumentação e validação experimental.

Como perspectiva futura, destaca-se o desenvolvimento de métodos mais adaptativos, explicáveis e computacionalmente eficientes, capazes de operar de forma confiável em tempo real, atendendo às crescentes demandas de segurança, eficiência e sustentabilidade dos sistemas de armazenamento de energia.

AGRADECIMENTOS

O presente estudo foi realizado com apoio da Universidade Federal de Mato Grosso do Sul – UFMS/MEC – Brasil e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (Capes) – Código de Financiamento 001.

REFERÊNCIAS

- BACCOUCHE, Ines; JEMMALI, Sabeur; MLAYAH, Asma; MANAI, Bilal. *Implementation of an improved Coulomb-counting algorithm based on a piecewise SOC-OCV relationship for SOC estimation of Li-Ion battery*. International Journal of Renewable Energy Research, v. 8, n. 1, p. 179–187, 2018.
- CHEMALI, Ephrem; KOLLMEYER, Phillip; PREINDL, Matthias; AHMED, Ryan; EMADI, Ali. *Long short-term memory networks for accurate state-of-charge estimation of Li-ion batteries*. Energy, [s. l.], v. 151, p. 553–560, 2018.
- DUNN, Bruce; KAMATH, Haresh; TARASCON, Jean-Marie. *Electrical energy storage for the grid: A battery of choices*. Science, v. 334, n. 6058, p. 928–935, 2011.
- FAN, Yunsheng; HUANG, Zhiwu; LI, Heng; KALEEN, Muaaz Bin; ZHANG, Rui; LIU, Weirong. *State of charge estimation for lithium-ion batteries with enhanced open-circuit voltage model*. Measurement, v. 251, p. 117124, 30 June, 2025.
- HU, Zhiyong; WU, Zixian; WANG, Xiaoxian; JUNCAI, Canção; LU, Siliang. *SOH estimation and prediction of lithium-ion batteries based on a physically constrained hybrid neural network*. Journal of Energy Storage, v. 151, p. 120587, 2026.
- LIU, Ling; HUANG, Zhi; SHU, Xing; SHEN, Jiangwei. *State of charge estimation for lithium-ion batteries integrating machine learning and filter methods*. Electric Power Systems Research, v. 253, p. 112577, 2026.
- PLETT, Gregory L. *Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part I. Background*. Journal of Power Sources, v. 134, n. 2, p. 252–261, August, 2004.
- WANG, Chao; WU, Chao; YI, Jingguang; SU, Xiaoli; CAO, Xiangyang; ZHANG, Kaixin. *Study in a novel lithium-ion semi-solid-state batteries: Specific equivalent circuit modeling and improved SOC estimation method*. International Journal of Electrochemical Science, v. 20, p. 101001, 2025.
- YANG, Li; ELE, Mingjian; REN, Yatao; GAO, Baohai; QI, Hong. *State of charge estimation for lithium-ion batteries via a diffusion-enhanced equivalent circuit model and an improved extended Kalman filter*. Energy, v. 345, p. 140181, 15 February, 2026.