

# Avaliação do Estado de Carga em Embarcações Elétricas na Região Amazônica: Uma Análise Comparativa

Dailneide Ribeiro<sup>1</sup>, Matheus Brito<sup>1</sup>, Iago Medeiros<sup>1</sup>, Emmanuel Loureiro<sup>1</sup>  
Denis Rosário<sup>1</sup>, Andréia Antloga<sup>2</sup>, Eduardo Cerqueira<sup>1</sup>

<sup>1</sup> Universidade Federal do Pará (UFPA), Belém – PA – Brasil

<sup>2</sup>Norte Energia S.A., Brasil

{dailneide.ribeiro,matheus.moraes.brito}@itec.ufpa.br

{iagomedeiros,emmanuel,denis,cerqueira}@ufpa.br

andreianascimento@norteenergiasa.com.br

**Abstract.** *The electrification of river transport in the Amazon region presents itself as a sustainable solution to reduce emissions and operating costs, but faces the challenge of “range anxiety” and the safety risks associated with power failure on rivers. Accurate estimation of the State of Charge (SOC) of batteries is crucial to mitigate these problems. This paper presents a comparative analysis of SOC estimation methods applied to an electric “speedboat” operating on the Xingu River, using LiFePO<sub>4</sub> batteries. Approaches based on the classic Coulomb Counting method, Artificial Intelligence algorithms (XGBoost and Random Forest), and hybrid strategies were evaluated. The results demonstrated that hybrid techniques outperform isolated methods, with emphasis on the strategy that uses XGBoost to predict and correct the error of the Coulomb Counting method.*

**Resumo.** *A eletrificação do transporte fluvial na região Amazônica apresenta-se como uma solução sustentável para reduzir emissões e custos operacionais, porém enfrenta o desafio da “ansiedade de alcance” e os riscos de segurança associados à falha energética em rios. A estimativa precisa do Estado de Carga (SOC) das baterias é crucial para mitigar esses problemas. Este trabalho apresenta uma análise comparativa de métodos de estimativa de SOC aplicados a uma embarcação elétrica do tipo “voadeira” operando no Rio Xingu, utilizando baterias LiFePO<sub>4</sub>. Foram avaliadas abordagens baseadas no método clássico de Coulomb Counting, algoritmos de Inteligência Artificial (XGBoost e Random Forest) e estratégias híbridas. Os resultados demonstraram que as técnicas híbridas superam os métodos isolados, com destaque para a estratégia que utiliza o XGBoost para prever e corrigir o erro do método de Coulomb Counting.*

## 1. Introdução

A diminuição da dependência de combustíveis fósseis é um dos pilares fundamentais do movimento global de transição energética. Além dos veículos terrestres, o desenvolvimento e a implantação de embarcações elétricas são essenciais, especialmente na região Amazônica, onde comunidades ribeirinhas utilizam diariamente o transporte fluvial para se locomover e acessar serviços essenciais, como escolas e hospitais

[Sousa and Cortes 2024]. A eletrificação desses meios de transporte possibilita a redução de custos, diminui a emissão de poluentes nos rios e promove maior sustentabilidade ambiental e desenvolvimento socioeconômico regional.

Apesar do crescimento observado nos últimos anos, a autonomia dos meios elétricos ainda é motivo de insegurança, principalmente, pela falta de informação e controle sobre o consumo energético, causando o fenômeno conhecido como “ansiedade de alcance” (do inglês, *range anxiety*), que consiste no medo de ficar sem energia antes de chegar ao destino pretendido [Oyediran et al. 2024]. Esse problema se agrava no caso de embarcações elétricas, devido aos maiores riscos de ficar à deriva em rios ou no mar. Assim, diversos métodos vêm sendo estudados para melhorar a eficiência dos sistemas de predição de informações relacionadas ao consumo energético.

Entre as abordagens mais promissoras, destacam-se os modelos de inteligência artificial (IA), que tendem a apresentar bom desempenho em cenários com condições variáveis, como é o caso da região amazônica. Esses modelos têm sido amplamente estudados e aplicados em tarefas de regressão para estimar parâmetros como o Estado de Carga (do inglês *State of Charge* - SOC) de baterias e a autonomia do sistema [Yun et al. 2025] [Zhao et al. 2020]. Problemas relacionados ao SOC são amplamente investigados em veículos elétricos terrestres, pois é fundamental que o sistema forneça estimativas confiáveis desse parâmetro crítico para os sistemas de gerenciamento de bateria (BMS). Contudo, o estudo do estado de carga em sistemas de embarcações elétricas ainda é pouco explorado, embora seja essencial para auxiliar na tomada de decisão do operador e proporcionar maior segurança na navegação [Pisani Orta et al. 2025].

Este trabalho apresenta a comparação entre modelos de IA para a predição eficiente do estado de carga de embarcações elétricas na Amazônia. A avaliação precisa do SOC contribui diretamente para o aumento da segurança operacional, proporcionando maior previsibilidade ao operador e mais confiabilidade aos passageiros. Inicialmente, foi realizado a coleta através de redes de sensores embarcados dentro do barco elétrico, pré-processamento e a análise exploratória dos dados, a fim de compreender a influência das variáveis no consumo de energia da embarcação. Em seguida, foram aplicadas diferentes abordagens para a predição do SOC, e posteriormente, conduziu-se uma análise comparativa entre as estratégias avaliadas, buscando identificar as mais eficientes. A partir da análise dos resultados, verificou-se que o modelo XGBoost apresentou desempenho superior em relação ao modelo *Random Forest*. Para este trabalho, foi considerada a coleta de dados de um barco chamado Poraquê I, que faz parte de um projeto de eficiência energética em colaboração com a Norte Energia S.A., com o objetivo de reduzir o impacto ambiental dos barcos tradicionais movidos a combustíveis fósseis na região [Norte Energia 2023].

O trabalho está organizado da seguinte forma. A Seção 2 apresenta os trabalhos da literatura sobre a estimativa do SOC. A Seção 3 descreve a metodologia utilizada, incluindo os fatores que influenciam o consumo energético de embarcações elétricas e os métodos empregados para prever o estado de carga de uma bateria. A Seção 4 apresenta a metodologia de avaliação das técnicas selecionadas, bem como os resultados obtidos. Por fim, a Seção 5 traz as considerações finais e sugestões de trabalhos futuros.

## 2. Trabalhos Relacionados

Esta seção discute os trabalhos relacionados a veículos e embarcações elétricas que abordam a estimativa do estado de carga (SOC) de baterias por meio de métodos clássicos,

IA e combinações híbridas, discutindo suas contribuições, limitações e lacunas que o presente trabalho busca preencher. [De Vera and Cruz 2022] propuseram a aplicação do Filtro de Kalman Estendido (do inglês, *Extended Kalman Filter* - EKF) para estimar a autonomia restante em um barco elétrico, modelando a autonomia em quilômetros com base no SOC estimado. O estudo foca na equação da autonomia em função do SOC e avalia apenas o desempenho do EKF no contexto marítimo, sendo uma abordagem útil para aplicações de embarcações elétricas. No entanto, o trabalho não compara com outras técnicas nem explora métodos de IA ou híbridos.

[Harinarayanan and Balamurugan 2025] realizaram uma comparação detalhada entre métodos clássicos (*Coulomb Counting* e EKF) e métodos de IA para estimar o SOC de uma célula pouch de íon-lítio sob diferentes perfis de carga. O trabalho demonstra que abordagens de IA, especialmente *Random Forest* (RF), fornecem maior precisão e robustez em cenários dinâmicos do que os métodos clássicos. No entanto, não explora técnicas híbridas que integrem estimativas baseadas em modelos físico-matemáticos como entrada para modelos de aprendizado ou para correção de erros.

[Yuan et al. 2023] investigaram a integração de filtros de Kalman com algoritmos de IA para estimar o SOC, gerando variáveis derivadas a partir das medições de tensão e corrente. Essas variáveis são usadas como entradas para diferentes modelos de IA. Este trabalho mostra que a integração de características extraídas melhora a precisão em comparação com o uso isolado das medições em cada método. No entanto, este estudo não aborda nem propõe a modelagem de erro de métodos clássicos para correção e melhoria da estimativa, como é explorado nas estratégias híbridas.

[Sulaiman and Mustaffa 2024] realizaram uma análise comparativa do desempenho do RF e da *Extreme Learning Machine* (ELM) na estimativa do estado de carga da bateria de um veículo elétrico. Os resultados demonstraram a superioridade do RF na modelagem de condições operacionais realistas. No entanto, o estudo não incluiu a avaliação de métodos matemáticos isolados nem abordou técnicas híbridas, limitando-se à comparação direta entre os modelos de IA.

Técnicas de IA também vêm sendo amplamente estudadas para a previsão do SOC, pois apresentam boa precisão em diversas aplicações. Além disso, técnicas híbridas que combinam IA com métodos de estimação matemática também foram discutidas nos trabalhos analisados. Vale destacar que a maioria dos estudos encontrados foi realizada com veículos elétricos. Trabalhos que abordam esse problema em embarcações ainda são escassos.


Embora existam estudos que utilizam tanto abordagens tradicionais quanto IA para estimar o SOC, há lacunas em análises comparativas entre métodos clássicos e híbridos que usem estimativas baseadas em modelos matemáticos como entradas de modelos de aprendizado para corrigir erros recorrentes. Desta forma, pode-se observar que existe uma lacuna para usar a estimativa de SOC obtida por *Coulomb Counting* como entrada de modelos XGBoost e RF para estimar um novo SOC, bem como usar a estimativa de SOC por *Coulomb Counting* como entrada para prever o erro entre essa estimativa e o valor de referência do SOC, usando esse erro predito para corrigir a estimativa clássica.

### **3. Estimativa do Estado de Carga em Embarcações Elétricas**

O consumo de energia em embarcações elétricas é um tema desafiador, pois além de variáveis operacionais, como velocidade, rotação do motor e corrente elétrica, é ne-

cessário considerar fatores específicos do cenário de navegação marítima.

A Figura 1 ilustra o sistema de coleta, armazenamento e transmissão de dados da embarcação elétrica utilizada neste estudo. Inicialmente, os sensores instalados na embarcação realizam a aquisição de variáveis operacionais e físicas, como tensão, corrente, temperatura e velocidade. Esses dados são transmitidos por meio do barramento CAN utilizando o protocolo CANopen, responsável pela comunicação entre os dispositivos eletrônicos embarcados. Em seguida, as mensagens são recebidas por um microcontrolador Raspberry Pi 3 equipado com módulo controlador e transceptor CAN (*Controller Area Network*), que atua como unidade central de processamento e gerenciamento dos dados coletados. Localmente, os dados são armazenados em um banco SQLite, garantindo persistência mesmo em situações de indisponibilidade de conexão com a internet. Posteriormente, o Raspberry Pi atua como MQTT Publisher, enviando as informações para um MQTT Broker, responsável pelo gerenciamento e roteamento das mensagens publicadas. O MQTT Subscriber realiza a recepção dos dados e efetua o envio para o banco de dados em nuvem, permitindo armazenamento remoto, monitoramento e acesso posterior às informações coletadas.



**Figura 1. Sistema de sensoriamento**

Neste contexto, este trabalho apresenta uma análise a respeito do estudo de carga para diminuir o problema da ansiedade de carga. Este problema é muito comum em veículos elétricos, entretanto uma análise específica para embarcações elétricas é necessária devido às características únicas deste meio. O fator mais importante nesta análise baseia-se em quão rápido acontece a deteriorização do SOC.

O SOC pode ser calculado com base na energia inicialmente armazenada e na energia consumida pelo sistema. Essa abordagem é equivalente à fórmula geral, apresentada na Equação 1, na qual  $C_{release}$  representa a capacidade restante da bateria e  $C_{nom}$  a capacidade total da bateria, ambas com unidade de medida em Ah. O valor obtido corresponde ao nível de carga expresso em porcentagem.

$$SOC(\%) = \frac{C_{release}}{C_{nom}} \cdot 100 \quad (1)$$

A análise e a estimativa precisas do estado de carga são fundamentais para compreender o comportamento do consumo energético, onde é importante identificar as variáveis relevantes para o monitoramento, a fim de auxiliar na tomada de decisão dos operadores e otimizar o consumo de energia.

O método matemático de *Coulomb Counting* foi analisado por necessitar apenas da capacidade nominal total da bateria e realizar medições periódicas da corrente.

O EKF não foi implementado por necessitar de parâmetros da bateria que não foram disponibilizados. Além disso, analisaram-se técnicas de IA, especificamente XGBoost e RF, por apresentarem desempenho superior e robustez na estimativa de estado de carga, conforme evidenciado em estudos prévios [Harinarayanan and Balamurugan 2025] [Qaisar et al. 2023].

A Equação 2 descreve o comportamento recursivo do método de *Coulomb Counting* na forma contínua, em que  $t$  representa o instante de tempo atual,  $t_0$  corresponde ao o instante de tempo anterior,  $C_{nom}$  é a capacidade nominal total da bateria, e  $i(\tau)$  representa a corrente ao longo do tempo.

$$SOC(t) = SOC(t_0) + \frac{1}{C_{nom}} \int_{t_0}^t i(\tau) d\tau \quad (2)$$

Por estimar o valor atual do SOC a partir do valor previamente calculado e empregar uma aproximação simplificada da integração da corrente, o método de *Coulomb Counting* está sujeito ao acúmulo de erros ao longo do tempo, o que pode comprometer significativamente sua precisão. Além disso, o método depende fortemente da exatidão do valor inicial do SOC, uma vez que todas as estimativas subsequentes são diretamente derivadas desse valor inicial [Movassagh et al. 2021]. O diagrama apresentado na Figura 2 sintetiza as estratégias avaliadas neste trabalho.

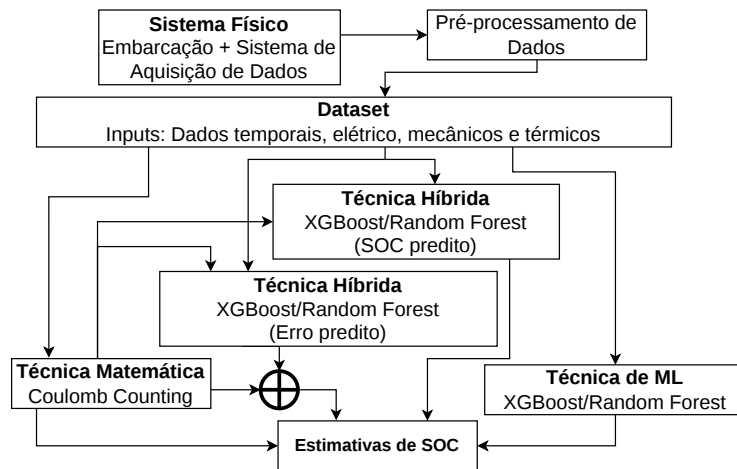


Figura 2. Visão geral das estratégias implementadas.

A análise realizada comparou o desempenho da estimação do estado de carga em diferentes estratégias, utilizando os métodos apresentados anteriormente. A primeira estratégia consiste na estimação do SOC exclusivamente por meio do método matemático de *Coulomb Counting*. A segunda estratégia estima o SOC utilizando algoritmos de aprendizado de máquina (XGBoost ou *Random Forest*), tendo como entrada apenas os dados medidos.

Além disso, foram analisadas duas abordagens híbridas, ou seja, combinam o método *Coulomb Counting* com um modelo de aprendizado de máquina. A primeira utiliza o SOC estimado pelo método CC como entrada do modelo de aprendizado de máquina, cuja saída corresponde a uma estimativa aprimorada do SOC. A segunda abordagem híbrida consiste em empregar o modelo de aprendizado de máquina para estimar

o erro de predição do SOC obtido pelo método de *Coulomb Counting*, realizando, em seguida, a correção do SOC estimado a partir do erro previsto.

A complexidade no tempo para a execução do algoritmo empregado no método CC é  $O(1)$  por etapa, devido a simples adição e subtração do SOC a cada tempo  $t$ , e  $O(n)$  para a complexidade total, levando em conta o número de aferições  $n$  [Mian Qaisar 2020]. A complexidade para o algoritmo XGBoost é definido por  $O(K \cdot d \cdot \|x\|_0 \log n)$ , o qual  $K$  é o número de árvores,  $d$  é a profundidade de cada árvore,  $\|x\|_0$  é o número de cada entrada não-faltante do dataset de treinamento e  $n$  é o número de instâncias do treinamento [Chen and Guestrin 2016]. Por fim, a complexidade computacional para o algoritmo RF é  $O(k \cdot m \cdot n \log n)$ , onde  $k$  é o número de árvores,  $m$  é o número de *features* aleatoriamente selecionadas por nó,  $n$  é o número de amostras de treinamento e  $n \log n$  é o tempo para ordenar  $n$  amostras a cada nível da árvore durante o processo de descoberta.

A complexidade dos algoritmos utilizados na análise demonstra que o algoritmo mais complexo é o XGBoost, onde possui a abordagem similar a RF, mas com mais etapas de checagem. RF possui a complexidade menor e o método de CC apresenta uma complexidade linear no tempo, sendo a menos complexa.

## 4. Avaliação

Esta seção apresenta os resultados obtidos a partir da análise das diferentes técnicas estudadas para a estimação do estado de carga da bateria de uma embarcação elétrica, com o intuito de auxiliar no entendimento do desempenho, da precisão e das limitações de cada método, bem como de sua aplicabilidade a partir da testagem em dados reais de operação.

### 4.1. Metodologia de Avaliação

O *dataset* foi coletado de uma embarcação elétrica do tipo “voadeira”, que opera no Rio Xingu, realizando a rota entre a Usina Hidrelétrica de Pimental (UHE Pimental) e o município de Altamira. A rota possui 40 km de extensão e conta com duas estações de recarga, as quais estão localizadas no local de partida (Sistema de Transposição de Embarcações - STE, em Pimental) e a outra no local de chegada (Porto dos Areeiros, em Altamira). O banco de baterias utilizado pela embarcação é composto por três células do modelo TSWB-LYP300AHA-B, do tipo  $\text{LiFePO}_4$ . Dessa forma, a capacidade nominal total é de 900 Ah, e a tensão nominal é de 3,2 V. Os dados foram coletados nos dias 9, 10 e 11 de dezembro de 2024, sendo realizada uma viagem de ida e volta em cada dia.

O *dataset* utilizado possui dados temporais, elétricos, mecânicos, térmicos e operacionais, como modo de operação da embarcação (E: Econômico; N: Normal; S: Sport), velocidade da embarcação, velocidade de rotação do motor, temperatura do motor, temperatura do controlador, tensão elétrica e corrente elétrica. Além destas coletas, o *dataset* também contempla variáveis adicionais como: intervalo de tempo, em segundos, entre a coleta anterior e o dado atual; capacidade restante da bateria, em ampère-hora; e autonomia restante da embarcação, em horas. As informações relacionadas às condições de navegação, como dados climáticos, especificações de peso e carga, diferentes trajetos e diferentes perfis de carga da bateria, não foram obtidas durante as viagens, o que caracteriza uma limitação do estudo, visto que tais fatores podem impactar no consumo energético da embarcação. Os dias analisados fazem parte do período de inverno amazônico, caracterizado por chuvas intensas e frequentes. Contudo, como as variáveis ambientais não foram monitoradas, não é possível quantificar seu impacto nos dados obtidos. Além disso, para

melhorar a capacidade de generalização do modelo, seria necessário analisar cenários com condições diferentes.

As viagens realizadas tinham como propósito validar a eficiência do sistema de telemetria da embarcação. Apesar das limitações relacionadas ao número de amostras, ao período reduzido de coleta e à utilização de apenas uma embarcação, o estudo realizado é relevante por disponibilizar um conjunto de dados reais obtidos em operação de uma embarcação elétrica na região amazônica, cenário ainda pouco discutido na literatura. Além disso, o dataset permite o pré-treinamento e a validação inicial das técnicas e modelos de aprendizado de máquina. Os modelos desenvolvidos podem posteriormente ser refinados e re-treinados com dados de diferentes embarcações, rotas, condições ambientais e perfis operacionais, contribuindo para aumentar sua capacidade de generalização em cenários reais mais diversos.

As variáveis de capacidade restante da bateria e autonomia restante da embarcação foram obtidas por meio de abordagens empíricas clássicas baseadas na Lei de Peukert para estimativa discreta da capacidade remanescente, conforme discutido em [Yazvinskaya et al. 2021]. Dessa forma, os valores de “SOC Ref” (SOC de referência) correspondem a estimativas indiretas baseadas em modelagem matemática. Embora essa abordagem seja amplamente utilizada em aplicações práticas de monitoramento energético, ela pode introduzir incertezas e vieses associados ao modelo adotado e às condições operacionais. Assim, os resultados obtidos devem ser interpretados considerando essa limitação. Ao todo, foram obtidas 2.674 amostras de dados, e o *dataset* está disponibilizado para consulta<sup>1</sup>. Os experimentos aqui expostos foram realizados em um computador equipado com processador AMD Ryzen 9 7900 (12 núcleos), 14 GB de memória RAM e GPU Radeon RX 7800 XT (16 GB).


O SOC Ref foi calculado utilizando a Equação 1, com base nos dados de capacidade restante presentes no *dataset* e na capacidade nominal. Além disso, as variáveis de tensão elétrica e corrente foram utilizadas para obter a variável de potência elétrica, em Watts, pois a inserção dessa nova variável representa a relação física entre elas. Na estimação do SOC CC, considerou-se que o SOC inicial é igual a 100%.

A Figura 3 exibe o comportamento da corrente ao longo de um período de 10 minutos para cada modo de operação da embarcação. Os modos são divididos em: E (Econômico), no qual a corrente de operação é inferior a 60 A; N (Normal), em que a corrente média é de aproximadamente 143 A; e S (Sport), no qual os valores de corrente podem ultrapassar 190 A. Essa análise confirma a influência do modo de operação no consumo energético da embarcação.

A Figura 4 apresenta a matriz de correlação entre as variáveis utilizadas na análise. Na matriz, observou-se uma correlação positiva entre o modo de operação e o estado de carga (SOC\_Ref), a qual indica que os operadores ajustam o modo de uso da embarcação de acordo com o nível de carga da bateria. Dessa forma, o modo Sport, caracterizado por maior consumo energético, tende a ser utilizado quando o SOC se encontra em níveis elevados. Adicionalmente, foi verificada uma relação diretamente proporcional entre a corrente elétrica e o SOC, a qual está associada ao comportamento da corrente em cada modo de operação, conforme discutido e ilustrado na Figura 3. Além disso, foi verificado que o SOC alto (geralmente no modo Sport) está associado a maiores velocidades,


---

<sup>1</sup>[https://drive.google.com/drive/folders/1WTBliAgrfDwRwH4g2sRQFG\\_qOXwXH78H](https://drive.google.com/drive/folders/1WTBliAgrfDwRwH4g2sRQFG_qOXwXH78H)



**Figura 3. Comportamento da corrente em cada modo de operação**

maior consumo de corrente e mais geração de calor. Velocidades e temperaturas elevadas também se relacionam a maior consumo de potência, aumentando o gasto energético e reduzindo a autonomia da embarcação.



**Figura 4. Matriz de correlação**

As estratégias foram analisadas por meio da comparação da resposta em cada dia com o valor de referência, a avaliação por meio do gráfico de resíduos e o desempenho nas métricas de erro médio absoluto (do inglês, *Mean Absolute Error* - MAE), erro médio quadrático (do inglês, *Mean Squared Error* - MSE) e raiz do erro médio quadrático (do inglês, *Root Mean Squared Error* - RMSE).

## 4.2. Resultados

As Figuras 5a, 5b e 5c exibem a comparação entre a estimativa do estado de carga pelo método de *Coulomb Counting* e o valor de referência. Observa-se que o método CC captura de forma satisfatória o comportamento do descarregamento da bateria. Contudo, a diferença entre as duas curvas é visível e aumenta significativamente ao longo do tempo, o que pode ser comprovado pela análise do gráfico de resíduos apresentado na Figura 6.

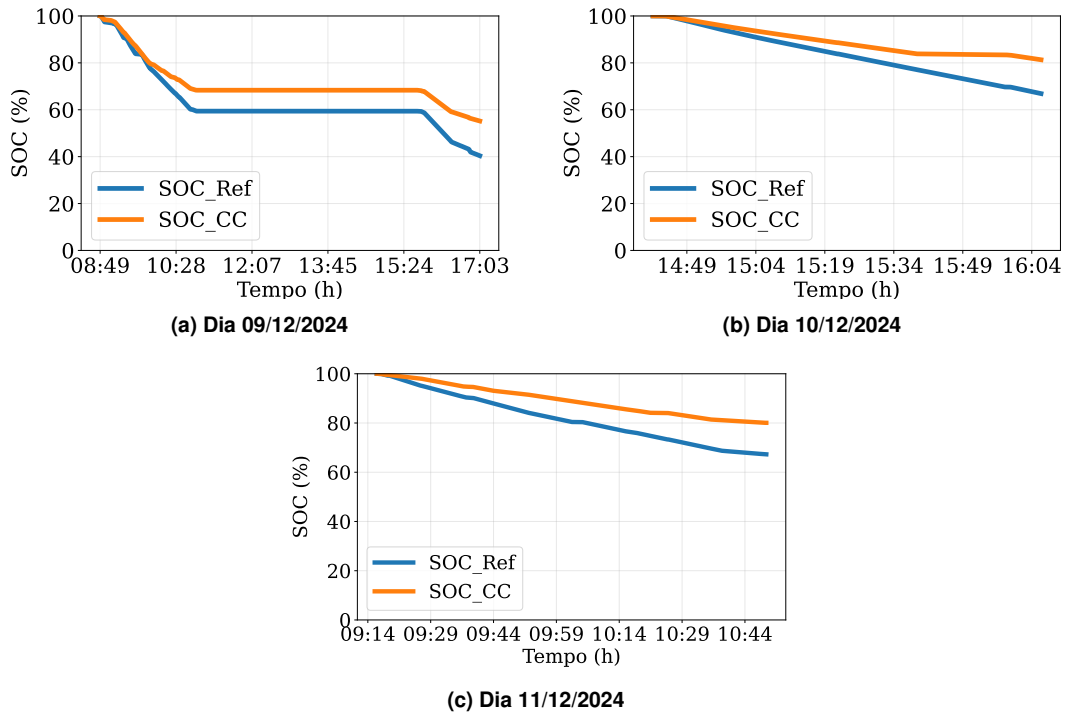


Figura 5. Comparação do SOC CC com SOC Ref




Figura 6. Resíduos - SOC por *Coulomb Counting*

A Tabela 1 mostra os resultados das métricas avaliadas para cada estratégia. Constatou-se que as quatro melhores técnicas são métodos híbridos, ou seja, utilizam a estimativa do SOC por *Coulomb Counting*. Neste trabalho, essas técnicas são referenciadas da seguinte forma:  $XG$  e  $RF$  consistem no uso do modelo para a estimativa do SOC, tendo como entrada as variáveis coletadas e SOC estimado com CC;  $XG_{correcao}$  e  $RF_{correcao}$  referem-se ao uso do modelo para a estimativa do erro entre o SOC obtido por CC e o SOC.Ref, sendo o erro predito utilizado para corrigir o valor do SOC estimado por esse método.

Tabela 1. Resultados das métricas avaliadas

Algoritmo	MAE	MSE	RMSE
Coulomb Counting (CC)	6.6036	65.0918	8.0680
XGBoost	1.0276	5.8063	2.4096
Random Forest (RF)	2.4636	19.1183	4.3724
XGBoost (CC) - Predição	0.1239	0.0403	0.2008
RF (CC) - Predição	0.6809	0.9034	0.9505
RF - Correção SOC_CC	0.4546	0.4376	0.6615
XGBoost - Correção SOC_CC	<b>0.0468</b>	<b>0.0062</b>	<b>0.0788</b>

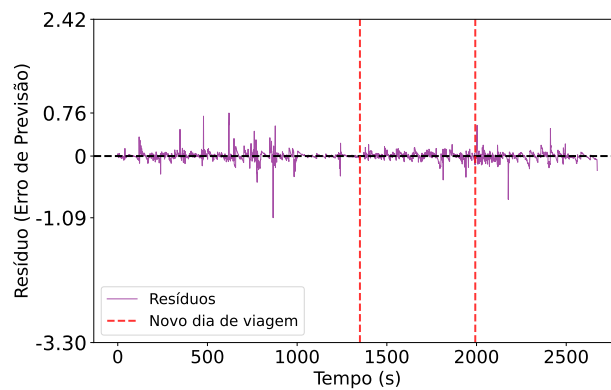


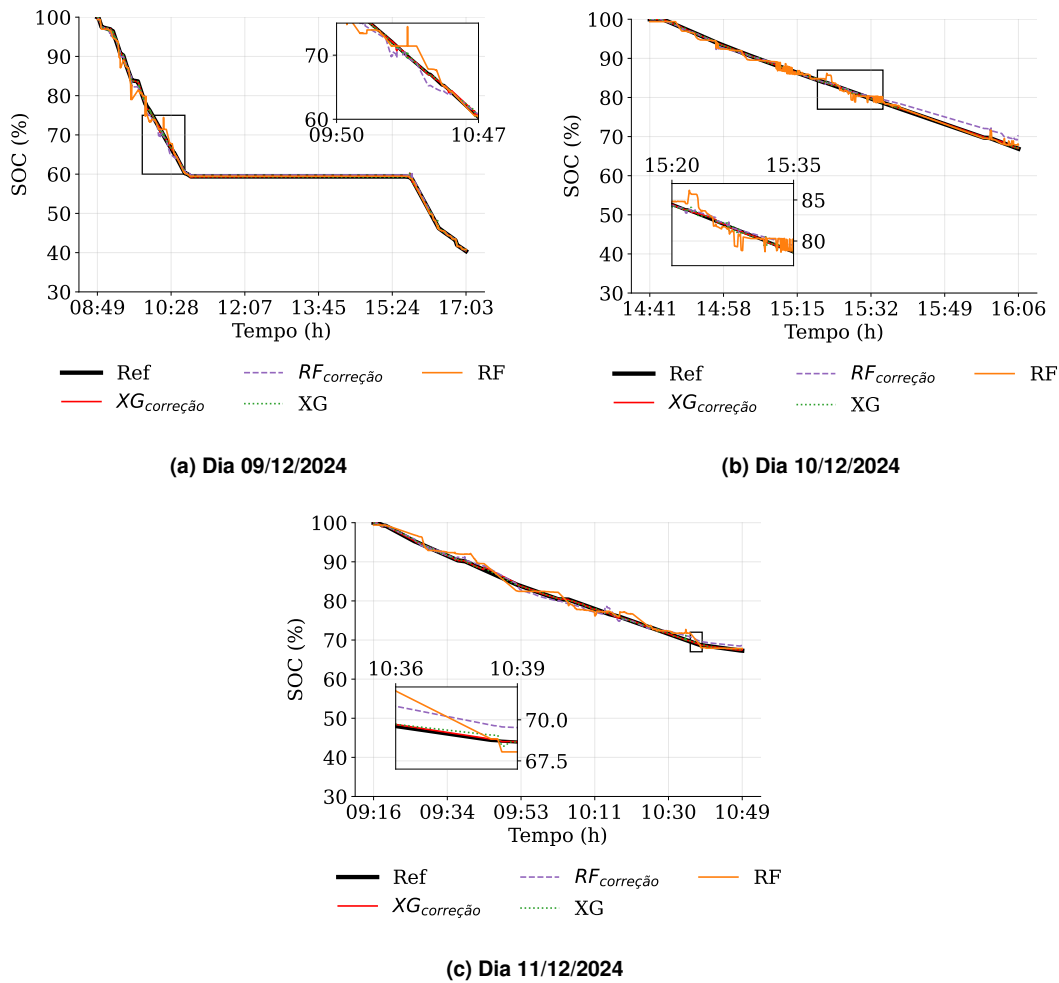
Figura 7. Resíduos XGBoost para correção (melhor caso)

Verifica-se que a estratégia  $XG_{correcao}$  apresenta o melhor desempenho em todas as métricas avaliadas e, conseqüentemente, os resíduos possuem amplitude e variação mais próximas de zero, conforme observado na Figura 7. Além disso, verifica-se que a estratégia de estimar o erro para realizar a correção do valor estimado pelo método matemático apresenta melhor desempenho em cada modelo analisado, quando comparada ao seu desempenho na estimativa direta do SOC.

Em relação ao estado da carga nos dias 9 e 10, foi observado a melhor performance do modelo  $XG_{correcao}$ , seguido do modelo  $XG$ , como mostra a Figura 8a e 8b. Na Figura 8c, verifica-se, ao longo do período de coleta do dia 11, que as estratégias baseadas no modelo XGBoost representam a curva com maior precisão quando comparadas às estratégias que utilizam *Random Forest*, as quais apresentam maiores desvios em relação aos valores de referência em diversos pontos da curva.

## 5. Conclusão

Este trabalho analisou variáveis coletadas através de rede de sensores que influenciam o consumo de energia em embarcações elétricas e avaliou estratégias para estimar o estado de carga das baterias com base em seu desempenho no Rio Xingu. Os resultados demonstraram que a combinação de IA e métodos matemáticos supera abordagens isoladas, destacando-se o uso do XGBoost para corrigir o método de *Coulomb Counting*, gerando estimativas mais precisas. Esses avanços contribuem para maior eficiência operacional, aumento da vida útil dos sistemas e redução de custos, além de fortalecer a adoção de transportes eletrificados mais seguros, sustentáveis e alinhados à transição energética, promovendo mobilidade limpa e de qualidade para a população.



**Figura 8. Comparação dos métodos para os dias de viagem.**

Em trabalhos futuros, é importante analisar a estimativa do SOC considerando o SOH (*State of Health*), índice que indica o estado de saúde da bateria e reflete a redução da capacidade total de carga em decorrência do desgaste causado por efeitos térmicos e pelo envelhecimento ao longo do tempo. Além disso, para ampliar a capacidade de generalização dos modelos desenvolvidos, estudos futuros devem analisar dados coletados em cenários operacionais mais diversos, incluindo diferentes condições ambientais, rotas, perfis de carga e tipos de embarcação. Juntamente a isso, é necessária a validação das estimativas de SOC utilizando múltiplas referências e diferentes métodos de monitoramento, visando aumentar a confiabilidade dos resultados. Também pretende-se investigar técnicas mais avançadas de aprendizado de máquina, análises de importância de variáveis, métodos de validação estatística mais robustos e o custo computacional das abordagens propostas em cenários de inferência embarcada em tempo real.

### Agradecimentos

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES): Código Financeiro 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação Amazônia de Amparo a Estudos e Pesquisas (Fapespa) e P&D ANEEL PD-07427-0223/2023.

## Referências

- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794.
- De Vera, A. M. Z. and Cruz, F. R. G. (2022). Estimation of remaining travel range of electric boat using extended kalman filter. In *2022 IEEE International Power and Renewable Energy Conference (IPRECON)*, pages 1–5. IEEE.
- Harinarayanan, J. and Balamurugan, P. (2025). Soc estimation for a lithium-ion pouch cell using machine learning under different load profiles. *Scientific Reports*, 15(1):18091.
- Mian Qaisar, S. (2020). Event-driven coulomb counting for effective online approximation of li-ion battery state of charge. *Energies*, 13(21):5600.
- Movassagh, K., Raihan, A., Balasingam, B., and Pattipati, K. (2021). A critical look at coulomb counting approach for state of charge estimation in batteries. *Energies*, 14(14):4074.
- Norte Energia (2023). Belo monte: Gigante por natureza. Available at: <https://www.norteenergiasa.com.br/uhe-belo-monte/>. Accessed: 2025-09-27.
- Oyediran, D., Thakur, J., Khalid, M., and Baskar, A. G. (2024). Electrification of marinas in stockholm: Optimizing charging infrastructure for electric boats. *Energy*, 305:132311.
- Pisani Orta, M. A., García Elvira, D., and Valderrama Blaví, H. (2025). Review of state-of-charge estimation methods for electric vehicle applications. *World Electric Vehicle Journal*, 16(2):87.
- Qaisar, S. M., Alboody, A., Aldossary, S., Alhamdan, A., Moahammad, N., and Almaktoom, A. T. (2023). Machine learning assistive state of charge estimation of li-ion battery. In *2023 IEEE 13th International Conference on Electronics and Information Technologies (ELIT)*, pages 157–161. IEEE.
- Sousa, E. C. S. d. and Cortes, J. P. S. d. (2024). Transporte fluvial e desafios no acesso à saúde em comunidades ribeirinhas nas hidrovias tapajós e arapiuns. *Hygeia - Revista Brasileira de Geografia Médica e da Saúde*, 20:e2009.
- Sulaiman, M. H. and Mustafa, Z. (2024). State of charge estimation for electric vehicles using random forest. *Green Energy and Intelligent Transportation*, 3(5):100177.
- Yazvinskaya, N. N., Galushkin, N. E., Ruslyakov, D. V., and Galushkin, D. N. (2021). Analysis of peukert and liebenow equations use for evaluation of capacity released by lithium-ion batteries. *Processes*, 9(10):1753.
- Yuan, H., Liu, J., Zhou, Y., and Pei, H. (2023). State of charge estimation of lithium battery based on integrated kalman filter framework and machine learning algorithm. *Energies*, 16(5):2155.
- Yun, X., Zhang, X., Wang, C., and Fan, X. (2025). A review on state of charge estimation methods for lithium-ion batteries based on data-driven and model fusion. *Journal of Energy Storage*, 129:117389.
- Zhao, L., Yao, W., Wang, Y., and Hu, J. (2020). Machine learning-based method for remaining range prediction of electric vehicles. *Ieee Access*, 8:212423–212441.