

Ygor Barbosa Alves

**Estimação do Estado de Saúde de Baterias de  
Lítion-Íon baseada em Metodologias de Gêmeos  
Digitais, Inteligência Artificial e Computação em  
Nuvem**

João Pessoa, Brazil

14 de maio de 2024

Ygor Barbosa Alves

**Estimação do Estado de Saúde de Baterias de Lítion-Íon  
baseada em Metodologias de Gêmeos Digitais,  
Inteligência Artificial e Computação em Nuvem**

Trabalho de Conclusão de Curso apresentado  
à Universidade Federal da Paraíba como exi-  
gência para a obtenção do título de Bacharel  
em Engenharia Elétrica.

Universidade Federal da Paraíba - UFPB  
Centro de Energias Alternativas e Renováveis - CEAR  
Departamento de Engenharia Elétrica

Orientador: Prof. Dr. Juan Moises Mauricio Villanueva

João Pessoa, Brazil

14 de maio de 2024

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

A474e Alves, Ygor Barbosa.

Estimação do Estado de Saúde de Baterias de  
Lítio-Íon baseada em Metodologias de Gêmeos Digitais,  
Inteligência Artificial e Computação em Nuvem / Ygor  
Barbosa Alves. - João Pessoa, 2024.

50 f. : il.

Orientação: Juan Moisés Maurício Villanueva.  
TCC (Graduação) - UFPB/CEAR.

1. Baterias de Lítio-Íon. 2. Veículos Elétricos. 3.  
Estado de Saúde. 4. Gêmeos Digitais. 5. Inteligência  
Artificial. I. Villanueva, Juan Moisés Maurício. II.  
Título.

UFPB/CT/BSCT

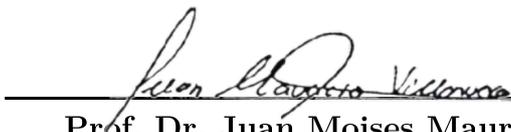
CDU 620.91(043.2)

Ygor Barbosa Alves

# Estimação do Estado de Saúde de Baterias de Lítion-Íon baseada em Metodologias de Gêmeos Digitais, Inteligência Artificial e Computação em Nuvem

Trabalho de Conclusão de Curso apresentado à Universidade Federal da Paraíba como exigência para a obtenção do título de Bacharel em Engenharia Elétrica.

João Pessoa, Brazil, 10 de maio de 2024:

  
Prof. Dr. Juan Moises Mauricio Villanueva  
(Orientador)  
Universidade Federal da Paraíba

  
Profa. Dra. Camila Seibel Gehrke  
(Avaliador)  
Universidade Federal da Paraíba

  
Prof. Dr. Lucas Vinicius Hartmann  
(Avaliador)  
Universidade Federal da Paraíba

João Pessoa, Brazil  
10 de maio de 2024

# Agradecimentos

Expresso, em primeiro lugar, profunda gratidão à minha família, por ter me dado o suporte necessário para que eu me dedicasse aos estudos e me desenvolvesse profissionalmente. Em especial aos meus pais, Waldicélia Barbosa e Ivo Alves e à minha irmã, Yasmin Alves. Os amigos que fiz durante os anos de universidade, que compartilharam momentos desafiadores e de alegria durante esta jornada de crescimento. Também aos meus amigos de antes da universidade e que continuam compartilhando alegrias e dores mesmo após tantos anos. Aos meus professores, em especial ao Professor Juan, que compartilhei de diversos projetos, como o próprio Trabalho de Conclusão de Curso e projetos de pesquisa, também a professora e coordenadora Camila Seibel, a que também realizei diversos projetos e deu suporte em diversos momentos durante o curso. Por fim, agradecer ao professor Euler e os professores da unidade EMBRAPPII, na qual tive ganho imenso de aprendizado tanto pessoal como profissional durante a vigência do projeto. No mais a todos professores e colegas que fizeram parte dessa jornada.

*"Se você pensa que pode  
ou você pensa que não pode  
– você está certo."(Henry Ford)*

# Resumo

Com a rápida ascensão do mercado de veículos elétricos (VEs), a demanda por baterias de lítio-íon tem experimentado um crescimento exponencial, enfatizando a urgência em aperfeiçoar a gestão da capacidade energética destas baterias. Essa demanda destaca não só a necessidade de métodos eficazes para gerenciar essas baterias, mas também a importância de estimar com precisão o Estado de Saúde (SoH), que é vital para otimizar o desempenho energético, garantir a segurança operacional e prolongar a vida útil das baterias. Neste contexto, o presente estudo propõe uma metodologia para estimar o SoH das baterias de lítio-íon, combinando técnicas de gêmeos digitais, inteligência artificial e computação em nuvem, utilizando a plataforma Microsoft Azure. A base de dados empregada, fornecida pela NASA, inclui informações extensivas sobre operações de baterias de lítio-íon, permitindo a análise dessas baterias. A metodologia empregada envolve a gestão e análise do fluxo de dados da bateria, utilizando métricas de erro, como o Erro Médio Absoluto (MAE), modelo de rede neural artificial (RNA) e instâncias computacionais em nuvem da Azure. Os resultados obtidos demonstram que o método desenvolvido supera modelagens físicas convencionais do ponto de vista da precisão, combinada com a robusta arquitetura de Gêmeos Digitais e as capacidades de computação em nuvem. Desse modo, apresentando o potencial para a otimização do desempenho e da segurança operacional das baterias em veículos elétricos, além de possibilitar a utilização dessa arquitetura para outras baterias e até outros sistemas, os quais exigem poder computacional e manipulação de grandes volumes de dados.

**Palavras-Chave:** Baterias de Lítio-Íon. Veículos Elétricos. Estado de Saúde. Gêmeos Digitais. Inteligência Artificial.

# Abstract

With the rapid growth of the electric vehicle (EV) market, the demand for lithium-ion batteries has seen exponential growth, emphasizing the need to enhance the management of these batteries energy capacity. This demand highlights not only the necessity for effective management methods but also the importance of accurately estimating the State of Health (SoH), which is vital for optimizing energy performance, ensuring operational safety, and extending the batteries lifespan. In this context, this study proposes an innovative methodology to estimate the SoH of lithium-ion batteries, combining Digital Twins techniques, artificial intelligence, and cloud computing, utilizing the Microsoft Azure platform. The database used, provided by NASA, includes extensive information on lithium-ion battery operations, enabling the analysis of these batteries. The methodology involves managing and analyzing the battery data flow using error metrics such as Mean Absolute Error (MAE), artificial neural network models, and Azure cloud computational instances. The results demonstrate that the developed method surpasses traditional physical modeling in terms of accuracy, combined with the robust architecture of Digital Twins and cloud computing capabilities. Thus, it presents potential for optimizing performance and operational safety of batteries in EVs and can be applied to other battery systems or systems requiring substantial computational power and data handling.

**Keywords:** Lithium-Ion Batteries. Electric Vehicles. State of Health. Digital Twins. Artificial Intelligence.

# Lista de tabelas

Tabela 1 – MAE obtido após a predição inicial do SoH. . . . .	41
Tabela 2 – Comparação detalhada das métricas de erro antes e após o retreinamento.	43

# Lista de abreviaturas e siglas

SoC	Estado de Carga (State of Charge)
SoH	Estado de Saúde (State of Health)
Li-ion	Íon de Lítio (Lithium-ion)
VEP	Veículos Elétricos Plug-in (Plug-in Electric Vehicles)
IA	Inteligência Artificial (Artificial Intelligence)
BMS	Sistema de Gerenciamento de Bateria (Battery Management System)

# Lista de símbolos

$Q_{\text{atual}}$	Capacidade elétrica atual da bateria
$Q_{\text{nominal}}$	Capacidade total possível da bateria
$C$	Capacidade restante da bateria após $i$ ciclos de carga-descarga
$C_0$	Capacidade inicial da bateria
$i$	Número do ciclo de carga-descarga
$f_d$	Taxa de degradação por ciclo
$t_i$	Tempo de descarga no ciclo
$\delta$	Profundidade de descarga
$\sigma$	Estado médio de carga durante o ciclo
$T_c$	Temperatura da célula durante o ciclo
$k$	Constante empírica
$Q$	Capacidade total da bateria (usada na Contagem de Coulomb)
$I(\tau)$	Corrente no tempo
OCV	Tensão de Circuito Aberto
$V(t)$	Tensão nos terminais da bateria
$I(t)$	Corrente no tempo
$R_s$	Resistência em série
$C$	Capacitância
$\hat{x}_k k$	Estimativa atualizada do estado
$K_k$	Ganho de Kalman
$y_k$	Medidas atuais
$H_k$	Matriz de observação
$P$	Covariância do erro de predição

$R$	Covariância do ruído de medição
$\mathbf{W}$	Pesos de uma rede neural
$\mathbf{x}$	Entradas de uma rede neural
$\mathbf{b}$	Bias de uma rede neural
$f$	Função de ativação de uma rede neural
$h_t$	Estado oculto no tempo
$\mathbf{W}_{ih}$	Pesos das camadas de entrada para oculta em uma RNN
$\mathbf{W}_{hh}$	Pesos das camadas ocultas em uma RNN
$\mathbf{b}_{ih}$	Bias das camadas de entrada para oculta em uma RNN
$\mathbf{b}_{hh}$	Bias das camadas ocultas em uma RNN
$\mathbf{x}_t$	Entrada no tempo t em uma RNN
$y(t)$	Saída predita em um modelo NARX
$u(t)$	Entradas exógenas em um modelo NARX

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	Contextualização e motivação	13
1.2	Objetivos	14
1.3	Organização do Trabalho	15
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>17</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>19</b>
<b>3.1</b>	<b>Baterias de Lítio-Íon</b>	<b>19</b>
3.1.1	Histórico e Desenvolvimento.	19
3.1.2	Princípios de Funcionamento e Características.	20
<b>3.2</b>	<b>Métodos para Estimativa de SoC e SoH</b>	<b>21</b>
3.2.1	Métodos Quantitativos Diretos	22
3.2.2	Métodos Baseados em Modelo Elétrico	22
3.2.3	Métodos Baseados em Dados	23
<b>3.3</b>	<b>Computação em Nuvem</b>	<b>24</b>
<b>3.4</b>	<b>gêmeos digitais</b>	<b>26</b>
3.4.1	Conceito e Desenvolvimento de gêmeos digitais	26
3.4.2	Arquiteturas para Estimação de SoH e SoC	26
<b>4</b>	<b>METODOLOGIA DE GÊMEO DIGITAL PROPOSTA</b>	<b>29</b>
<b>4.1</b>	<b>Base de dados</b>	<b>30</b>
4.1.1	Descrição do Banco de Dados da NASA	30
4.1.2	Variáveis relevantes	31
<b>4.2</b>	<b>Desenvolvimento e Integração do Modelo de Rede Neural com Gêmeo Digital</b>	<b>31</b>
<b>4.3</b>	<b>Computação em Nuvem com Microsoft Azure</b>	<b>32</b>
4.3.1	Serviços utilizados na Azure	32
<b>4.4</b>	<b>Métricas de Avaliação de Desempenho</b>	<b>32</b>
<b>5</b>	<b>RESULTADOS</b>	<b>34</b>
<b>5.1</b>	<b>Dados Utilizados e Processamento</b>	<b>34</b>
5.1.1	Armazenamento e Ingestão de Dados	34
5.1.2	Preparação e Processamento de Dados	34
<b>5.2</b>	<b>Implementação da Rede Neural</b>	<b>37</b>
5.2.1	Análise de Desempenho do Modelo	37

<b>5.3</b>	<b>Serviços na Nuvem</b> . . . . .	<b>38</b>
5.3.1	Azure Blob Storage . . . . .	38
5.3.2	Azure ML Workspace e Azure Web App Container . . . . .	40
<b>5.4</b>	<b>Arquitetura com Gêmeo Digital</b> . . . . .	<b>41</b>
<b>6</b>	<b>CONCLUSÕES</b> . . . . .	<b>46</b>
<b>6.1</b>	<b>Trabalhos Futuros</b> . . . . .	<b>46</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>47</b>

# 1 Introdução

## 1.1 Contextualização e motivação

A demanda por baterias de lítio-íon, essenciais para a operação de veículos elétricos (VEs), tem registrado um aumento expressivo, refletindo o crescimento acelerado deste mercado. Em 2022, a demanda global por estas baterias cresceu aproximadamente 65%, atingindo 550 GWh, impulsionada principalmente por um aumento de 55% nas vendas de carros elétricos de passageiros em comparação ao ano anterior ([International Energy Agency \(IEA\) 2023](#)). Esse aumento foi particularmente notável na China e nos Estados Unidos, onde a demanda por baterias cresceu significativamente, devido à popularização dos VEs e à expansão das infraestruturas de recarga. A Figura 1 ilustra a oferta e demanda globais de lítio para baterias por região de 2016 a 2022.

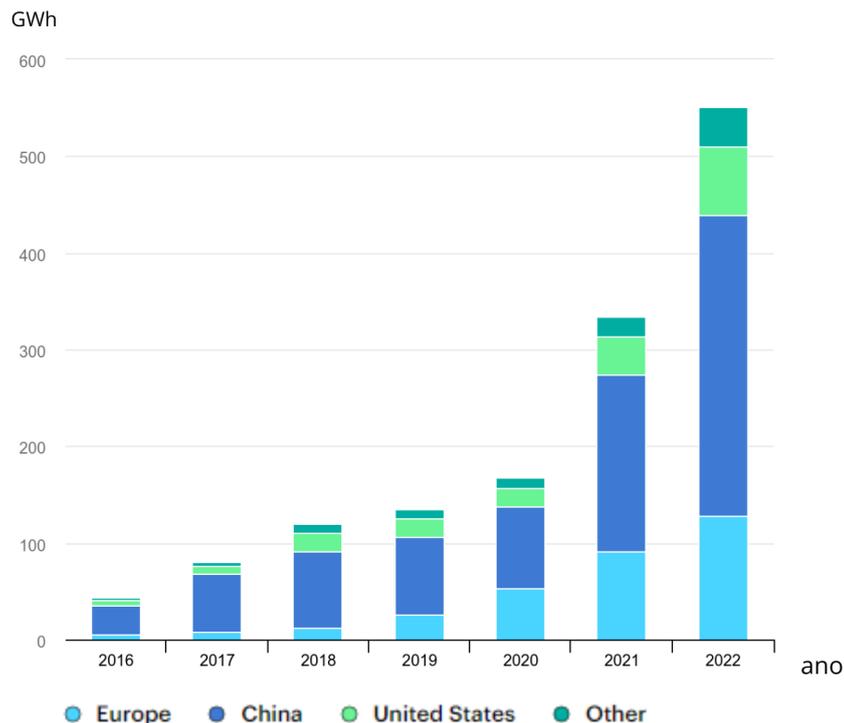


Figura 1 – Oferta e demanda globais de lítio para baterias por região (2016-2022).

No contexto nacional, o crescimento do mercado de VEs tem sido exemplificado pelo sucesso da BYD, que se destacou significativamente em 2023 ([BYD Company Ltd. 2023](#)). A BYD, liderando a produção global de veículos elétricos e híbridos, expandiu quase 70 vezes sua venda de carros elétricos no Brasil, superando todos os concorrentes combinados. Este crescimento notável é evidenciado pelas 17.947 unidades vendidas pela marca, representando

um aumento de 6.900% em comparação com as 260 unidades vendidas em 2022, conforme dados da Associação Brasileira de Veículos Elétricos (ABVE). Este feito histórico da BYD destaca não apenas a aceitação crescente dos VEs no Brasil, mas também a robustez e a confiança nas tecnologias de baterias que esses veículos empregam.

Nesse contexto, as baterias de lítio-íon são relevantes não apenas pela sua capacidade de armazenamento de energia, mas também pela sua eficiência e confiabilidade em aplicações de alta demanda, como nos VEs. Pesquisas estão sendo intensificadas globalmente e no Brasil, focando no desenvolvimento de baterias mais eficientes, duráveis e seguras. Estes estudos abrangem a análise detalhada do comportamento das baterias, especialmente sobre métodos para predição do Estado de Carga (SoC), Estado de Saúde (SoH), e Estado de Função (SoF) das baterias. O SoC é um parâmetro vital que indica a capacidade restante da bateria, essencial para o gerenciamento eficiente da energia, a segurança operacional, e a otimização da vida útil da bateria em VEs. Além disso a análise do SoH possibilita evitar a degradação da bateria e maximiza o desempenho do veículo.

A utilização de soluções como os modelos de Inteligência Artificial, incluindo aprendizado de máquina profundo e redes neurais, os gêmeos digitais, que criam réplicas digitais de sistemas físicos para simular seu comportamento em tempo real, além da computação em nuvem, oferecem um caminho promissor para avanços significativos na tecnologia de baterias. Segundo estudos recentes (Wagle et al. 2023), (Fonso et al. 2022), estas tecnologias têm sido aplicadas com sucesso para a estimativa precisa do SoC e SoH, proporcionando uma abordagem robusta para prever e otimizar o desempenho das baterias de lítio-íon sob diversas condições de uso. Estas inovações estão não só transformando a mobilidade urbana e a gestão de energia, mas também apoiando os objetivos de desenvolvimento sustentável da ONU (SDGs), especialmente os que promovem sistemas de transporte sustentáveis (Objetivo 11) e a mitigação das mudanças climáticas (Objetivo 13) ((UN) 2015).

Assim, este trabalho se propõe a desenvolver e apresentar um método avançado de estimação de SoH das baterias de lítio-íon, utilizando gêmeos digitais. Esta metodologia visa otimizar o uso das baterias em aplicações práticas, contribuindo para a eficiência global dos veículos elétricos. Este método não apenas busca melhorar a gestão de energia nos VEs, mas também prolongar a vida útil das baterias, reduzindo assim os custos operacionais e ambientais associados ao uso intensivo de recursos não renováveis.

## 1.2 Objetivos

O objetivo deste trabalho é desenvolver uma metodologia para a estimação de SoH das baterias de lítio-íon utilizando gêmeos digitais e inteligência artificial. Este método visa otimizar o desempenho e a eficiência dos sistemas de baterias em veículos elétricos,

contribuindo assim para uma gestão de energia mais eficiente e sustentável.

Para atingir o objetivo, os seguintes objetivos específicos foram estabelecidos:

- Revisão da literatura para estimativa de SoH e gêmeos digitais.
- Estimação do SoH de baterias de lítio-íon utilizando uma metodologia de gêmeo digital, integrado com técnicas de aprendizado de máquina para a predição precisa do SoH em baterias de lítio-íon.
- Explorar as implicações da arquitetura utilizada, como precisão e eficiência de recursos, para estimativa do SoH.

### 1.3 Organização do Trabalho

Este trabalho está organizado em seis capítulos principais, além das referências bibliográficas, que fundamentam teoricamente as análises e metodologias empregadas.

Além do capítulo de Introdução já apresentado, o segundo capítulo de Revisão Bibliográfica expõe a literatura existente sobre os temas pertinentes ao trabalho. Foram discutidos estudos anteriores que abordam desde a aplicação de baterias de lítio-íon em veículos elétricos até o uso de modelos de inteligência artificial para monitoramento e estimativa de SoC e SoH, incluindo uma revisão sobre os desenvolvimentos recentes em tecnologias de gêmeos digitais.

No terceiro capítulo, a fundamentação teórica, detalha os conceitos técnicos essenciais para a compreensão das metodologias utilizadas. Este capítulo é dividido em seções sobre as baterias de lítio-íon, os princípios de funcionamento e as características dessas baterias, os métodos convencionais e avançados para estimativa de SoC e SoH, técnicas de inteligência artificial, especialmente redes neurais e metodologia de gêmeos digitais, incluindo o uso da computação em nuvem.

No capítulo 04, é descrita a metodologia desenvolvida para implementar o gêmeo digital, focada na simulação e estimativa do SoH de baterias de lítio-íon. Este capítulo inclui a descrição do banco de dados utilizado da NASA, a seleção de variáveis, a construção e treinamento de modelos de redes neurais, e a configuração da infraestrutura de computação em nuvem para o processamento dos dados e operação do modelo.

No capítulo 05 de resultados é apresentado a estruturação do banco de dados, avaliação dos modelos desenvolvidos, serviços utilizados na nuvem e a arquitetura do gêmeo digital. Além disso, foram apresentadas as análises das métricas de desempenho obtidas e discussões sobre o trabalho realizado.

No sexto capítulo reúnem-se, de forma resumida, as principais descobertas do estudo, discute as implicações dos resultados e oferece recomendações para trabalhos futuros.

## 2 Revisão Bibliográfica

A estimação de SoC e SoH de baterias de lítio-íon é uma área de pesquisa em crescimento, devido a demanda global dessas baterias e devido a contribuição com o gerenciamento e eficiência das baterias, principalmente nos veículos elétricos (EVs). Esta revisão bibliográfica explora diversos estudos que destacam as metodologias, implementações e benefícios da estimação do SoC e SoH, incluindo inteligência artificial, filtro de Kalman, além de gêmeos digitais, fornecendo um contexto abrangente e atualizado sobre o estado da arte nesta área.

Naga Eaty (2023) introduziu uma metodologia utilizando Gêmeo Digital e aprendizagem incremental para aprimorar a manutenção preditiva das baterias de EVs. A técnica inclui o uso de transformadas de *wavelet* e aprendizado contínuo, otimizando os parâmetros SoH e SoC, com a computação sendo realizada na nuvem (Microsoft Azure) para eficiência de recursos. O método alcançou um Erro Quadrático Médio (MSE) de 0.022 na previsão de SoH e utilizou o filtro de Kalman para estimar o SoC, combinando a contagem de Coulomb e a tensão de circuito aberto, resultando em estimativas precisas e eficientes (Eaty e Bagade 2023).

O estudo de Soumya Singh (2021) detalha a implementação de um Gêmeo Digital para células de bateria, ressaltando a importância de modelos como o Doyle-Fuller-Newman para a simulação e avaliação de desempenho. Este trabalho destaca o valor dos Indicadores-chave de Desempenho (KPIs) no monitoramento das fases de operação e fim de vida das baterias. O Gêmeo Digital é apresentado como uma ferramenta capaz de melhorar as funcionalidades de Sistemas de Gerenciamento de Bateria (BMS), avaliando impactos de degradação e otimizando o design e operação das baterias (Singh, Weeber e Birke 2021).

Madhur Wagle (2023) concentrou-se na precisão dos algoritmos de Contagem de Coulomb e Filtro de Kalman Estendido (EKF), usando o gêmeo digital de uma célula modelo 21700 LGM50. O estudo revelou que o EKF, em particular, proporciona estimativas do SoC com alta precisão (RMSE de 1,29), permitindo o desenvolvimento de BMSs mais eficientes sem grandes investimentos iniciais em hardware. A pesquisa empregou o Python Battery Mathematical Modelling (PyBaMM) para simulações, demonstrando a eficácia da tecnologia em reduzir custos e tempos de desenvolvimento (Wagle et al. 2023).

Weihan Li (2020) desenvolveu um sistema de gestão de baterias baseado na nuvem que integra IoT para melhorar a segurança e performance dos sistemas de baterias. Utilizando modelos de circuito equivalente e algoritmos avançados, como o filtro *H-infinity* adaptativo, o estudo ofereceu uma abordagem robusta para estimativa do SoC e SoH. A pesquisa validou a funcionalidade e estabilidade do sistema através de protótipos, enfatizando

as vantagens do monitoramento contínuo e otimização de performance proporcionados pelo Gêmeo Digital (Li et al. 2020).

Roberta Di Fonso (2022) investigou o uso de redes neurais para replicar o comportamento das células de baterias de lítio-íon, enfocando a capacidade de simular a tensão de circuito aberto (OCV) e a impedância interna, importantes para entender o SoC e SoH da bateria. Este Gêmeo Digital foi projetado para testar e validar algoritmos de estimativa de SoC e SoH de forma eficiente, substituindo os custosos testes em laboratório. O estudo demonstrou a capacidade do modelo de simular diversos estados de envelhecimento rapidamente e com alta precisão (baixo MSE), reforçando o papel do Gêmeo Digital como uma ferramenta para o desenvolvimento e otimização de BMSs (Fonso et al. 2022).

Mohammad Waseen (2023) ofereceu uma revisão compreensiva das tecnologias de baterias para EVs, incluindo desafios e perspectivas futuras. O estudo abordou as funcionalidades cruciais do BMS, incluindo estimativa de estado, balanceamento de células, e diagnóstico de falhas, destacando a evolução desde baterias pré-lítio até as avançadas baterias pós-lítio. A pesquisa também explorou as tecnologias de carregamento emergentes e os desafios para a adoção em massa dos EVs, apontando para soluções futuras que poderiam facilitar a transição para uma mobilidade elétrica mais sustentável e eficiente (Waseem et al. 2023).

Esta revisão bibliográfica discutiu as metodologias e tecnologias recentes no campo da estimação do SoC das baterias de Lítio-íon, destacando os avanços significativos e as várias possibilidades de inovação que estas técnicas oferecem para o gerenciamento eficiente de baterias em veículos elétricos, como os gêmeos digitais e inteligência artificial.

## 3 Fundamentação Teórica

A fundamentação teórica deste estudo aborda a evolução das baterias de Lítio-Íon e os princípios que regem seu funcionamento, estabelecendo a base técnica para as metodologias desenvolvidas. Explora-se também o papel dos gêmeos digitais na modelagem e simulação do comportamento das baterias, assim como o uso da computação em nuvem para processar e analisar dados em grande escala. Estas tecnologias são essenciais para implementar soluções de manutenção preditiva e otimização de desempenho em aplicações críticas, como veículos elétricos e sistemas de armazenamento de energia.

### 3.1 Baterias de Lítio-Íon

#### 3.1.1 Histórico e Desenvolvimento.

As baterias elétricas têm sua origem nos experimentos de Benjamin Franklin em 1748 com as garrafas de Leyden, os primeiros dispositivos capazes de armazenar energia elétrica. A evolução significativa ocorreu em 1800 com Alessandro Volta, que desenvolveu a célula voltaica, marcando o nascimento da bateria moderna. Esta célula era composta por discos de cobre e zinco alternados, separados por discos embebidos em solução salina, capazes de converter energia química diretamente em elétrica .

A célula de Daniell, introduzida por John Frederic Daniell em 1836, utilizava zinco e cobre em soluções separadas por um vaso de barro poroso, aumentando a estabilidade das baterias para uso nas emergentes redes de telegrafia. A inovação continuou com Gaston Planté, que em 1859 desenvolveu a primeira bateria recarregável de chumbo-ácido, e com Georges Leclanché, cuja bateria seca em 1866 melhorou a segurança e a praticidade.

A transição para as baterias de Lítio-Íon iniciou nos anos 1970, alcançando viabilidade comercial nos anos 1990 (Zhou et al. 2018). Estas baterias usam lítio, o metal mais leve e altamente eletropositivo, proporcionando vantagens significativas como alta densidade energética, leveza e longa vida útil, características ideais para aplicações modernas desde dispositivos móveis até veículos elétricos. Estas baterias funcionam com base na movimentação de íons de lítio entre o ânodo (carbono) e o cátodo (tipicamente óxido de metal, como óxido de cobalto-lítio, óxido de manganês-lítio ou fosfato de ferro-lítio), através de um eletrólito composto por sais de lítio em solventes orgânicos. Durante a descarga, os íons de lítio fluem do ânodo para o cátodo através do eletrólito, enquanto elétrons fluem pelo circuito externo, gerando energia elétrica. Este processo é revertido durante a carga, recolocando os íons de lítio no ânodo.

### 3.1.2 Princípios de Funcionamento e Características.

As baterias de lítio-íon emergiram como protagonistas no panorama tecnológico atual, dada a sua aplicabilidade extensiva em dispositivos eletrônicos portáteis e veículos elétricos. A relevância dessa tecnologia deriva de características distintas como a baixa taxa de autodescarga, ausência do efeito memória e uma densidade energética superior em comparação às alternativas baseadas em níquel. Contudo, essas baterias requerem cuidados específicos, sendo imprescindível a utilização de BMS para assegurar sua integridade operacional e longevidade (Yi et al. 2022),(Liu et al. 2021).

A compreensão dos parâmetros e definições técnicas, tais como tensão de terminal, capacidade nominal, taxa de carga, SoC e SoH, é fundamental para o desenvolvimento, otimização e aplicação eficazes das baterias de lítio-íon. A capacidade dessas baterias de combinar alta densidade energética com robustez operacional as coloca à frente de alternativas tradicionais, consolidando seu papel relevante nas tecnologias de armazenamento de energia elétrica. O SoC é um indicador da quantidade de carga restante na bateria, calculado pela razão entre a capacidade elétrica atual ( $Q_{\text{atual}}$ ) e a capacidade total possível ( $Q_{\text{nominal}}$ ) da bateria, expresso em percentual:

$$\text{SoC} = \left( \frac{Q_{\text{atual}}}{Q_{\text{nominal}}} \right) \times 100\% \quad (3.1)$$

O conhecimento preciso do SoC e do SoH é vital para o gerenciamento otimizado da carga e descarga, maximizando a vida útil da bateria e prevenindo danos por sobrecarga ou descarga excessiva. O ciclo de vida de uma bateria de Lítio-Íon, definido pelo número de ciclos completos de carga e descarga que a bateria pode suportar antes de sua capacidade cair abaixo de 80% da original, é influenciado pela temperatura, profundidade de descarga e frequência de uso. Com a implementação do gêmeo digital, é possível modelar e simular o comportamento da bateria em diferentes cenários de uso, utilizando dados históricos e algoritmos preditivos para melhorar a precisão das estimativas de SoC e SoH e prolongar o ciclo de vida útil da bateria.

A degradação das células de baterias de Lítio-Íon é influenciada por diversos fatores físico-químicos, resultando na redução progressiva da capacidade de carga. A modelagem deste processo é essencial para a previsão de vida útil e comportamento ao longo do tempo. Assim, a partir da Equação Fundamental da Capacidade de Bateria, a capacidade restante da bateria  $C$  pode ser representada em função da capacidade inicial  $C_0$  e da taxa de degradação linearizada  $f_d$  como segue (Xu et al. 2018):

$$C = C_0 \cdot (1 - f_d \cdot i) \quad (3.2)$$

onde:

- $C$  é a capacidade restante da bateria após  $i$  ciclos de carga-descarga.
- $C_0$  é a capacidade inicial da bateria.
- $i$  é o número do ciclo de carga-descarga.
- $f_d$  é a taxa de degradação por ciclo, que é uma função do tempo de descarga  $t_i$ , a profundidade de descarga  $\delta$ , o estado médio de carga  $\sigma$ , e a temperatura da célula  $T_c$ .

Além disso, a taxa de degradação por ciclo ( $f_d$ ) é definida como uma função dos parâmetros operacionais da bateria (Jin et al. 2018), (Schimpe et al. 2017):

$$f_d = k \cdot t_i \cdot \delta \cdot \sigma \cdot T_c \quad (3.3)$$

onde:

- $k$  é uma constante empírica (e.g.,  $k = 0.13$ ).
- $t_i$  é o tempo de descarga no ciclo  $i$ .
- $\delta$  é a profundidade de descarga.
- $\sigma$  é o estado médio de carga durante o ciclo.
- $T_c$  é a temperatura da célula durante o ciclo.

Os modelos semi-empíricos, como os propostos nas referências citadas, são fundamentais para prever a degradação das baterias de Lítio-Íon com precisão. Eles permitem integrar dados experimentais com teorias fundamentais de degradação, oferecendo uma representação confiável e adaptável para diferentes condições operacionais e tipos de bateria.

## 3.2 Métodos para Estimativa de SoC e SoH

A estimativa precisa do SoC e SoH das baterias de lítio-íon é relevante para o gerenciamento eficaz de energia em aplicações como veículos elétricos e sistemas de armazenamento de energia estacionário. Diversos métodos têm sido desenvolvidos e aprimorados para aumentar a precisão dos indicadores de SoC, essenciais para garantir a operação segura e eficiente do sistema de baterias, evitando condições de risco e otimizando o desempenho do controle.

### 3.2.1 Métodos Quantitativos Diretos

Entre os métodos quantitativos diretos, a Contagem de Coulomb e a Tensão de Circuito Aberto (OCV) são comumente utilizados para a estimação do SoC de baterias de lítio-íon. A Contagem de Coulomb, também conhecida como integração de corrente, é um método que envolve o cálculo da carga transferida através da integração do fluxo de corrente ao longo do tempo. A fórmula básica para a Contagem de Coulomb é dada por:

$$\text{SoC}(t) = \text{SoC}(t_0) + \frac{1}{Q} \int_{t_0}^t I(\tau) d\tau$$

onde  $\text{SoC}(t)$  é o estado de carga no tempo  $t$ ,  $\text{SoC}(t_0)$  é o estado de carga inicial,  $Q$  é a capacidade total da bateria, e  $I(\tau)$  é a corrente no tempo  $\tau$ . Este método proporciona uma medida direta do SoC e é eficaz sob condições ideais; contudo, sua precisão é suscetível a erros acumulativos devido a medições imprecisas da corrente e variações na calibração do sensor, especialmente em ciclos de carga e descarga prolongados ou sob condições extremas de operação (Movassagh et al. 2021).

A estimativa de SoC baseada na Tensão de Circuito Aberto (OCV) aproveita a relação estável entre a tensão de circuito aberto e o SoC, que pode ser mapeada através de tabelas de equivalência pré-definidas. A relação é tipicamente não-linear e varia conforme a química da bateria e o seu envelhecimento. A fórmula para estimar o SoC a partir da OCV é geralmente derivada de curvas caracterizadas experimentalmente:

$$\text{SoC} = f(\text{OCV})$$

onde  $f$  é uma função mapeada a partir de dados experimentais que relacionam a OCV com o SoC. Este método requer que a bateria esteja em um estado de repouso para evitar erros de medição, sendo também influenciado por fatores ambientais como temperatura e envelhecimento da bateria, que podem introduzir histerese na OCV (Liu et al. 2021).

### 3.2.2 Métodos Baseados em Modelo Elétrico

Os métodos baseados em modelos elétricos envolvem o uso de modelos matemáticos e simulações para estimar o SoC, frequentemente empregando técnicas como o filtro de Kalman e redes neurais. Estes modelos são calibrados com base nas características específicas das baterias, incluindo resistência interna, capacitância, e dinâmica de carga/descarga. Como exemplo, o Modelo de Thevenin, amplamente usado devido à sua simplicidade e eficácia. Ele representa a bateria através de uma fonte de tensão e uma resistência em série, juntamente com uma resistência e uma capacitância em paralelo, como mostra a seguinte fórmula:

$$V(t) = \text{OCV} - I(t) \times R_s - \frac{C}{Q} \int I(t) dt$$

onde  $V(t)$  é a tensão nos terminais da bateria,  $\text{OCV}$  é a tensão de circuito aberto,  $I(t)$  é a corrente,  $R_s$  é a resistência em série,  $Q$  é a capacidade da bateria, e  $C$  é a capacitância.

Este modelo ajuda a capturar tanto os efeitos transitórios quanto os de estado estacionário do comportamento da bateria.

O Filtro de Kalman e suas variações, como o Filtro de Kalman Estendido (EKF) e o *Filtro de Kalman Unscented* (UKF), são técnicas avançadas que proporcionam estimativas de SoC corrigindo as previsões baseadas em observações subsequentes. O EKF trata da não linearidade através da linearização das equações do processo em torno dos pontos de operação estabelecidos, enquanto o UKF supera algumas das limitações do EKF ao usar uma amostragem de pontos sigma para capturar melhor a média e a covariância das estimativas de SoC. A exemplo do EKF, o qual ajusta as estimativas do SoC com base na diferença entre as medições reais de tensões, correntes e temperatura da bateria e as previstas pelo modelo, proporcionando alta precisão mesmo sob condições dinâmicas:

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(y_k - H_k \hat{x}_{k|k-1})$$

$$K_k = P_{k|k-1} H_k^\top (H_k P_{k|k-1} H_k^\top + R)^{-1}$$

onde  $\hat{x}_{k|k}$  é a estimativa atualizada do estado,  $K_k$  é o ganho de Kalman,  $y_k$  são as medições atuais,  $H_k$  é a matriz de observação,  $P$  é a covariância do erro de predição, e  $R$  é a covariância do ruído de medição. Este método é particularmente útil para aplicações em veículos elétricos e sistemas de armazenamento de energia, onde as condições podem mudar rapidamente (Wang et al. 2021).

### 3.2.3 Métodos Baseados em Dados

Métodos baseados em dados, especialmente aqueles que utilizam inteligência artificial como redes neurais, têm se mostrado promissores na estimação do SoC de baterias de lítio-íon. Esses métodos são capazes de aprender padrões complexos e não-lineares a partir de grandes conjuntos de dados operacionais, proporcionando estimativas precisas mesmo em condições variáveis.

**Redes Neurais Artificiais (ANNs):** Redes Neurais Artificiais (ANNs) são modelos computacionais inspirados pelo sistema nervoso de organismos biológicos. No contexto de estimação de SoC, ANNs são treinadas com dados históricos de operação da bateria, incluindo tensão, corrente, e temperatura, para aprender a mapear essas entradas para o SoC correspondente. A estrutura típica de uma ANN para este propósito inclui uma camada de entrada, várias camadas ocultas, e uma camada de saída que prediz o SoC. A formulação matemática de uma ANN pode ser representada como:

$$\text{SoC} = f(\mathbf{W} \cdot \mathbf{x} + \mathbf{b})$$

onde  $\mathbf{x}$  são as entradas (tensão, corrente, temperatura),  $\mathbf{W}$  são os pesos,  $\mathbf{b}$  é o bias, e  $f$  é a função de ativação, geralmente uma função não-linear como a sigmoid ou ReLU.

**Redes Neurais Recorrentes (RNNs):** Redes Neurais Recorrentes (RNNs) são particularmente adequadas para dados sequenciais ou temporais, o que é um aspecto comum nas medições de baterias durante operação. RNNs podem capturar dinâmicas temporais complexas ao manter um estado interno que "recorda" informações de pontos de dados anteriores, o que é relevante para prever o SoC em cenários de carga e descarga dinâmicos. Uma variação comum de RNNs usada nesta aplicação é a Long Short-Term Memory (LSTM):

$$h_t = f(\mathbf{W}_{ih} \cdot \mathbf{x}_t + \mathbf{b}_{ih} + \mathbf{W}_{hh} \cdot h_{t-1} + \mathbf{b}_{hh})$$

onde  $h_t$  é o estado oculto no tempo  $t$ ,  $\mathbf{x}_t$  é a entrada no tempo  $t$ , e  $\mathbf{W}$ ,  $\mathbf{b}$  são os pesos e biases das camadas respectivamente (Kim et al., 2020).

**Modelo Não-linear AutoRegressivo com Entrada Exógena (NARX):** O modelo NARX é uma forma de rede neural que é treinada para prever a saída de um sistema baseado nas entradas anteriores e saídas anteriores, o que é ideal para prever o SoC onde as medições passadas de corrente e tensão são indicativos do estado futuro da bateria. A fórmula de um modelo NARX é:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n), u(t-1), u(t-2), \dots, u(t-n))$$

onde  $y(t)$  é a saída predita (SoC),  $u(t)$  são as entradas exógenas (corrente e tensão), e  $n$  é a ordem do modelo. Modelos NARX são poderosos para modelagem de sistemas dinâmicos e podem ser adaptados para incluir condições como a temperatura para melhorar ainda mais a precisão (Smith 2017).

Esses métodos baseados em dados são extremamente úteis para a estimação de SoC em gêmeos digitais de baterias de lítio-íon, onde modelos precisos e adaptativos são necessários para gerenciar a performance e saúde da bateria de maneira eficiente e eficaz.

Cada método para a estimativa de SoC tem suas próprias vantagens e limitações e a escolha depende de fatores como a complexidade do sistema, os recursos computacionais disponíveis, e a precisão necessária na aplicação específica. Adaptar e combinar esses métodos de acordo com as necessidades operacionais e as características específicas das baterias pode oferecer melhorias significativas em performance, segurança, e eficiência energética.

### 3.3 Computação em Nuvem

A computação em nuvem transformou significativamente a forma como armazenamos, processamos e gerenciamos dados em várias indústrias. Este conceito permite o uso de recursos de computação distribuída por meio da internet, proporcionando eficiência, escalabilidade e acessibilidade. Estes recursos incluem armazenamento, processadores, redes, e softwares que são acessíveis remotamente, oferecendo uma alternativa flexível e

escalável às tradicionais infraestruturas físicas de TI. A computação em nuvem é reconhecida por sua custo-efetividade, reduzindo a necessidade de grandes investimentos iniciais em infraestrutura de TI e diminuindo os custos operacionais relacionados à manutenção e atualização de hardware e software. A escalabilidade é outra vantagem, permitindo que capacidades de processamento e armazenamento sejam ajustadas rapidamente para atender às demandas flutuantes, uma funcionalidade especialmente útil em aplicações de gestão de energia para EVs onde as cargas de trabalho podem variar intensamente. A acessibilidade remota facilita o gerenciamento de sistemas e dispositivos distribuídos globalmente, proporcionando a operadores e desenvolvedores acesso a sistemas e dados de qualquer lugar, a qualquer hora, o que é fundamental para a realização de manutenções preditivas e atualizações de software em tempo real, que são componentes chave dos gêmeos digitais (Marston et al. 2011).

Entre os modelos de serviços principais que compõem a computação em nuvem, costam a Infraestrutura como Serviço (IaaS), que fornece a infraestrutura de TI básica, como servidores virtuais e armazenamento em um modelo de pagamento conforme o uso. A Plataforma como Serviço (PaaS), a qual entrega além da infraestrutura, plataformas e ambientes de desenvolvimento que facilitam a criação de aplicações. E o Software como Serviço (SaaS), o qual disponibiliza aplicativos de software através da internet, eliminando a necessidade de instalação e manutenção local. Os modelos de implantação — nuvem pública, privada e híbrida — oferecem diferentes níveis de controle, gestão e personalização, adequando-se a necessidades específicas de segurança, conformidade e operação (Mell e Grance 2011).

Na gestão de baterias de lítio-íon, a computação em nuvem desempenha um papel estratégico ao hospedar e processar o componente de software dos gêmeos digitais. Estes sistemas virtuais analisam continuamente dados coletados em tempo real do BMS (*Battery Management System*) dos veículos para prever o Estado de Saúde (SoH) e estimar o SoC das baterias. Através de modelos avançados de aprendizado de máquina e algoritmos de processamento intensivo, a computação em nuvem permite a execução dessas tarefas complexas com maior rapidez e precisão do que seria possível localmente no veículo (Buyya, Yeo e Venugopal 2009).

Desse modo, a computação em nuvem é uma tecnologia fundamental para o desenvolvimento e a implementação eficaz de gêmeos digitais no contexto da gestão de baterias de lítio-íon. Com suas capacidades de processamento remoto, escalabilidade e eficiência de custos, a computação em nuvem não apenas facilita a manutenção preditiva e a otimização da gestão de energia mas também promove melhorias significativas na segurança e no desempenho dos veículos elétricos. As operações baseadas em nuvem continuarão a ser uma pedra angular para as inovações tecnológicas na indústria automotiva, impulsionando o avanço em direção a soluções de energia mais eficientes e confiáveis.

## 3.4 gêmeos digitais

Esta seção detalha a teoria fundamental dos gêmeos digitais e sua aplicação específica para a estimativa do SoH das baterias de lítio-íon, estabelecendo a base teórica para as metodologias empregadas neste trabalho.

### 3.4.1 Conceito e Desenvolvimento de gêmeos digitais

gêmeos digitais são representações virtuais de sistemas físicos que permitem a simulação, análise e otimização de processos em tempo real. Inicialmente desenvolvidos pela NASA, os gêmeos digitais serviam para prever a vida útil remanescente e gerenciar a saúde de sistemas aeroespaciais complexos. O desenvolvimento de gêmeos digitais começou com foco em produtos durante o ciclo de vida desde sua concepção até o fim de uso, proposto por Grieves em 2003. Desde então, a aplicação se expandiu para áreas como manufatura, saúde e, mais recentemente, para sistemas de baterias de lítio-íon.

Um Gêmeo Digital é estruturado sobre a interação de três componentes principais (Eaty e Bagade 2023), o sistema físico, modelo virtual e interface de dados. O sistema físico refere-se à bateria de lítio-íon em si, incluindo todas as suas características operacionais e ambientais. O Modelo Virtual, o qual é a réplica digital do sistema físico que simula seu comportamento em várias condições. Este modelo é útil para testar cenários em tempo real e prever falhas ou comportamentos adversos antes de ocorrerem no sistema real. E as interfaces de Dados, que são os canais pelos quais os dados são transferidos entre o sistema físico e o modelo virtual. Estas interfaces não apenas fornecem entrada de dados operacionais em tempo real ao modelo virtual, mas também permitem que atualizações do modelo sejam enviadas de volta ao sistema físico para ajustar operações e melhorar a eficiência.

Com o auxílio de tecnologias como Inteligência Artificial (IA), Internet das Coisas (IoT) e computação em nuvem, os gêmeos digitais proporcionam uma base poderosa para decisões de manutenção preditiva e otimização de operações. Esta tecnologia é especialmente útil em aplicações críticas, como em veículos elétricos, onde falhas de bateria podem ter consequências graves (Wang et al. 2021).

### 3.4.2 Arquiteturas para Estimação de SoH e SoC

Dentro do contexto de veículos elétricos (VEs), os gêmeos digitais são utilizados para modelar o complexo sistema de baterias de lítio-íon. A arquitetura de um Gêmeo Digital para tais baterias normalmente incorpora diversos modelos que refletem diferentes aspectos da bateria: modelos eletroquímicos detalham as reações químicas internas, modelos térmicos controlam a dissipação de calor, e modelos que preveem a degradação da bateria ao longo do tempo.

A integração desses modelos com dados sensoriais em tempo real permite não apenas a monitoração contínua do estado da bateria, mas também a otimização de sua operação. Por exemplo, algoritmos avançados de filtragem como o Filtro de Kalman Estendido (EKF) e o Filtro de Partículas são empregados para estimar com precisão o SoC da bateria a partir de dados imprecisos e ruidosos. Esses filtros ajustam continuamente os parâmetros do modelo com base nas leituras dos sensores, melhorando a confiabilidade das estimativas (Wang et al. 2021).

A utilização de gêmeos digitais para estimativa de SoC e SoH proporciona a divisão da carga computacional entre a nuvem e o veículo de forma inteligente. A comunicação contínua entre o veículo e a nuvem permite que o modelo virtual no gêmeo digital seja constantemente atualizado com dados operacionais novos e ajustado através de aprendizado contínuo e transferência de aprendizado. Esta característica é fundamental para a aplicação de controles dinâmicos que respondem instantaneamente às condições de operação, como a gestão térmica ativa, que ajusta parâmetros de operação para manter a temperatura ideal da bateria e prolongar sua vida útil.

Além disso, os gêmeos digitais facilitam a implementação de estratégias de carregamento e balanceamento de células baseadas nas condições reais da bateria, resultando em uma operação mais eficiente e segura. A infraestrutura para esta implementação geralmente reside em plataformas de nuvem, como a Microsoft Azure Cloud, que suportam grandes escalas de dados e computação intensiva. O gêmeo digital atualiza seus modelos com base nos dados recebidos e interage com o BMS para otimizar continuamente a performance da bateria. Na Figura 2, é apresentado um *framework* de gêmeo digital focado em gerenciamento de baterias, adaptado de Wang (2021) (Wang et al. 2021).

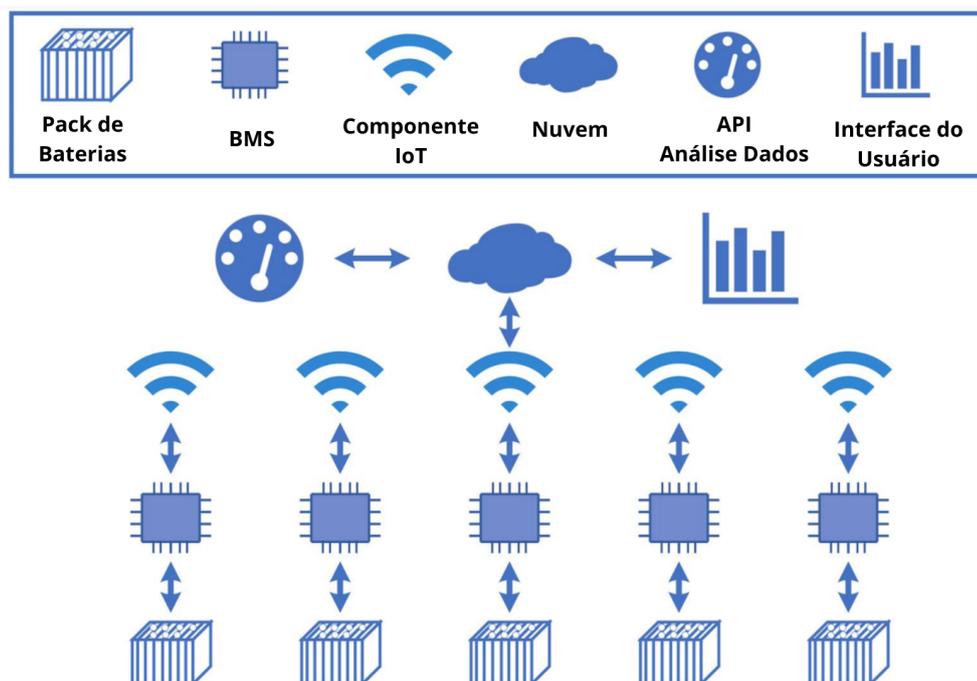


Figura 2 – *Framework* de Gêmeo Digital para gerenciamento de baterias (Wang et al. 2021).

## 4 Metodologia de Gêmeo Digital Proposta

A metodologia empregada para a estimação do SoH das baterias de Lítio-Íon integra avanços em gêmeo digital e inteligência artificial, objetivando um sistema altamente eficiente e adaptativo. A estratégia fundamental deste estudo envolve o uso contínuo de uma rede neural artificial (RNA), que é retreinada automaticamente quando o Erro Absoluto Médio (MAE) ultrapassa um *threshold* específico, garantindo assim a precisão e relevância contínuas das previsões do SoH sob variadas condições operacionais. A seguir, pode-se visualizar o fluxograma das etapas na Figura 3.

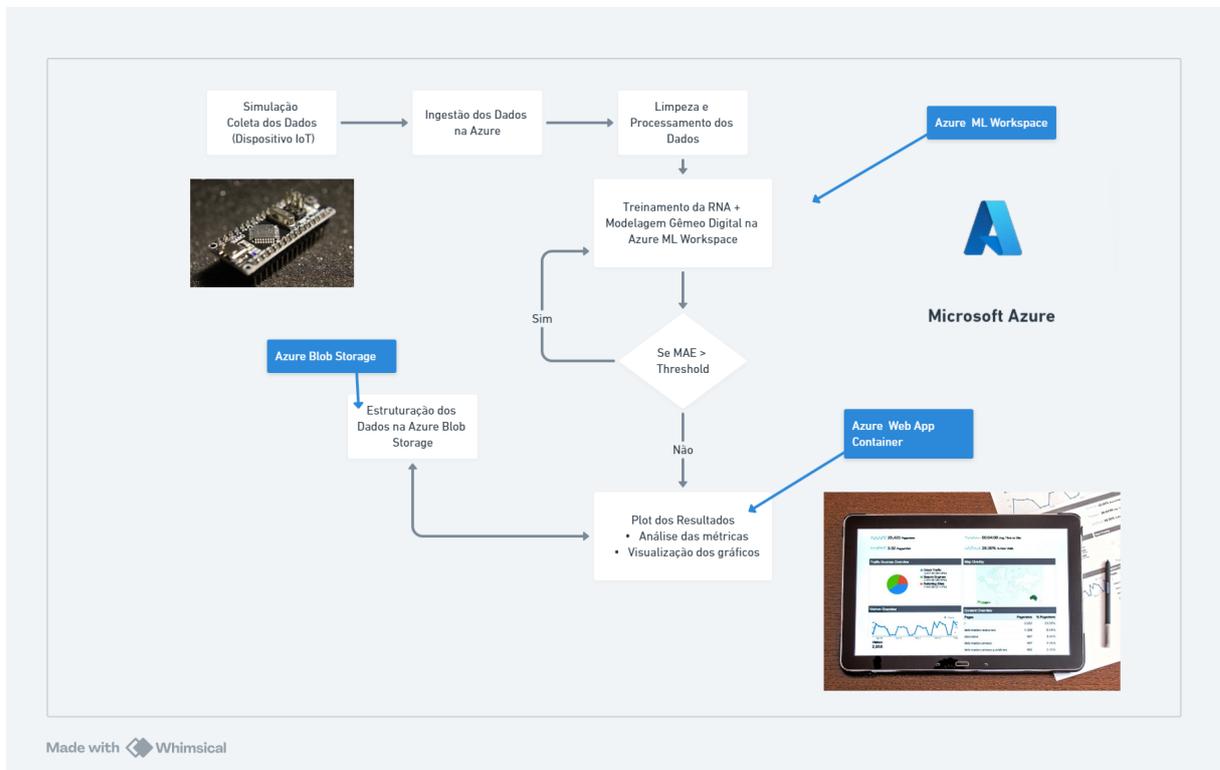


Figura 3 – Fluxograma da metodologia proposta para a estimação do SoH de baterias de Lítio-Íon utilizando gêmeos digitais.

No cenário de uma aplicação industrial, a coleta de dados seria realizada através de dispositivos IoT, para este trabalho, utilizou-se um conjunto de dados fornecido pela NASA, simulando condições operacionais das baterias. Esses dados são enviados para a plataforma Microsoft Azure, onde são gerenciados no Azure Blob Storage. Este serviço proporciona escalabilidade e disponibilidade, essenciais para o acesso e a manipulação eficiente dos dados coletados. Os dados são submetidos a um processo de limpeza e processamento no Azure ML Workspace e no Azure Web App, preparando-os para o

treinamento contínuo da RNA. Esta estrutura permite o retreinamento do modelo com dados operacionais atualizados e facilita a interação com o sistema por meio de *dashboards* interativos no Azure Web App, proporcionando acesso fácil a métricas de desempenho e gráficos analíticos.

A rede neural é essencial para captar o comportamento não-linear dos dados, uma característica crucial para a predição precisa do SoH. Paralelamente, a simulação do comportamento da bateria é realizada através de um gêmeo digital, que replica o estado e comportamento da bateria em tempo real, permitindo um monitoramento efetivo e análise preditiva. As seções seguintes detalharão este processo, destacando a eficácia da metodologia em aplicações práticas.

## 4.1 Base de dados

### 4.1.1 Descrição do Banco de Dados da NASA

A base de dados empregada neste estudo foi fornecida pela NASA e detalhadamente documentada por Saha e Goebel (2011). Este conjunto de dados é derivado de experimentos conduzidos com baterias de íon de lítio do tipo óxido de manganês de lítio (LMO), uma escolha predominante para aplicações que exigem alta durabilidade e eficiência sob condições de carga e descarga repetitivas.

Os dados coletados incluem várias métricas operacionais, tais como corrente de descarga, tensão nos terminais e temperatura operacional, registrados ao longo de numerosos ciclos de descarga. Estes foram obtidos sob uma série de condições de teste, incluindo estados de repouso e dinâmicos, permitindo uma análise detalhada da influência de variáveis operacionais na performance e degradação das baterias ao longo do tempo.

Parâmetros	LMO
Tensão nominal	3.7 V
Tensão máxima	4.2 V
Tensão de corte	2.6 V
Capacidade nominal	6000 mAh
Impedância interna	48 m $\Omega$
Número de ciclos	300
Geometria	Cilíndrica
Diâmetro	18.35 mm
Comprimento	65.10 mm
Massa	45.5g

Fonte: NASA (2021)

Figura 4 – Especificações técnicas - Modelo 18650.

### 4.1.2 Variáveis relevantes

Dentro as variáveis disponíveis, os parâmetros mais influentes na determinação do SoH das baterias, com base na revisão da literatura e na análise exploratória dos dados podem-se citar:

- Corrente de descarga (A): A corrente influencia diretamente a taxa de esgotamento da energia armazenada na bateria e, portanto, é um parâmetro chave para avaliar a capacidade restante da bateria.
- Tensão nos terminais (V): A tensão é um indicador relevante do estado operacional da bateria, refletindo alterações no seu estado químico e elétrico durante os ciclos de carga e descarga.
- Temperatura de operação (°C): Alterações na temperatura afetam a resistência interna e a eficiência química da bateria, impactando diretamente sua capacidade e segurança.

Essas variáveis foram extraídas utilizando procedimentos de pré-processamento de dados, onde foram processadas para compatibilidade com o modelo de inteligência artificial, garantindo que o modelo de gêmeos digitais desenvolvido possua dados representativos para a simulação do comportamento da bateria em condições reais.

## 4.2 Desenvolvimento e Integração do Modelo de Rede Neural com Gêmeo Digital

Neste estudo, utiliza-se o treinamento de redes neurais artificiais, (RNA) configurada com uma arquitetura sequencial, com funções de ativação não-lineares, visando capturar o comportamento não linear que caracterizam o funcionamento das baterias. O processo de treinamento da rede é conduzido utilizando uma divisão estratégica dos dados em conjuntos de treinamento e teste. Esta abordagem assegura que a rede aprenda padrões significativos dos dados e mantenha a capacidade de generalização para novos dados.

Com a integração ao gêmeo digital, o desempenho da RNA é monitorado continuamente por meio da métrica de MAE. Define-se um *threshold* para o MAE, de modo que não comprometa a aplicação e caso o MAE supere o *threshold* é realizado um re-treinamento. Este re-treinamento é realizado utilizando os serviços de computação em nuvem providos pelo Microsoft Azure, o que permite uma gestão eficaz e escalável dos recursos computacionais e dos dados.

A implementação de um processo de re-treinamento automático, baseado no ultrapassamento de um *threshold* de MAE pré-definido, garante que o modelo sempre reflita as

condições mais recentes da bateria. Esta abordagem não somente facilita a manutenção contínua do SoH e da saúde geral da bateria, mas também permite intervenções preventivas que podem prolongar significativamente o ciclo de vida das baterias. Adicionalmente, o gêmeo digital atualiza-se em tempo real, fornecendo uma base sólida para análises preditivas e decisões bem-informadas.

## 4.3 Computação em Nuvem com Microsoft Azure

Utilizamos a plataforma Microsoft Azure para hospedar e gerenciar o gêmeo digital, tirando proveito de sua escalabilidade, segurança e integração com ferramentas de análise de dados.

### 4.3.1 Serviços utilizados na Azure

**Azure Blob Storage:** solução de armazenamento em nuvem do Azure, que será utilizado no projeto no processo de ingestão dos dados da Nasa, além da estrutura deles para geração de *dashboards* e análises.

**Azure ML Workspace:** Após a coleta, os dados são submetidos a processos de limpeza e processamento no Azure, no Azure ML Workspace. Isso pode incluir a remoção de ruídos, a normalização dos dados e a transformação para formatos adequados para análise. Essas operações são cruciais para assegurar a qualidade dos dados para a modelagem posterior, possibilitando, por exemplo a inferência no Modelo de RNA, além da simulação do comportamento da bateria com o gêmeo digital.

**Azure Web App Container:** Esta é a interface de usuário final, onde os resultados da simulação e da estimativa de SoH são apresentados. Utiliza-se um contêiner de aplicativo web Azure para hospedar uma aplicação que permite a visualização e interação com os resultados, através de métricas e gráficos analíticos.

## 4.4 Métricas de Avaliação de Desempenho

- **Erro Absoluto Médio (MAE):** Esta métrica calcula a média das magnitudes absolutas das diferenças entre os valores previstos ( $\hat{y}_i$ ) e os valores observados ( $y_i$ ). É uma medida direta da precisão de um modelo em termos de magnitude do erro. A fórmula para MAE é:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|$$

- **Raiz do Erro Quadrático Médio (RMSE):** Esta métrica eleva ao quadrado os erros antes de calcular a média e, em seguida, tira a raiz quadrada do resultado,

dando maior peso aos erros maiores. É especialmente útil quando é crítico penalizar fortemente grandes desvios. A fórmula para RMSE é:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$

- **Erro Percentual Absoluto Médio (MAPE):** Esta métrica calcula a média dos valores percentuais absolutos das diferenças entre os valores previstos ( $\hat{y}_i$ ) e os valores observados ( $y_i$ ), proporcionais aos valores observados, expressa como porcentagem. Útil para avaliar a magnitude do erro em termos relativos, especialmente quando os valores de referência variam amplamente. A fórmula para MAPE é:

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|$$

Essas métricas são relevantes para avaliar a precisão de um modelo de previsão, especialmente em aplicações críticas como a gestão do estado de carga de baterias de lítio-íon em tecnologias emergentes como gêmeos digitais. A seleção cuidadosa de métricas assegura que o modelo seja avaliado de maneira a destacar os tipos de erros mais significativos para a aplicação específica.

# 5 Resultados

## 5.1 Dados Utilizados e Processamento

A base de dados utilizada neste estudo foi meticulosamente selecionada para garantir uma análise profunda e robusta do comportamento de baterias de íon de lítio ao longo do tempo. Esta base é proveniente de um conjunto de dados público fornecido pela NASA, que inclui registros detalhados de testes realizados em baterias sob diversas condições de operação. A escolha deste conjunto de dados se deve à sua abrangência e relevância para estudos de degradação de baterias, sendo ideal para o desenvolvimento de modelos preditivos de SoH.

### 5.1.1 Armazenamento e Ingestão de Dados

Os dados são armazenados em um contêiner de blob no serviço de armazenamento Azure Blob Storage, facilitando o acesso escalável e controlado através de uma URL específica. Este método de armazenamento não apenas garante a integridade e a segurança dos dados, mas também proporciona uma plataforma robusta para a ingestão e manipulação eficiente de grandes volumes de informações.

`https://tcctwin.blob.core.windows.net/nasa/discharge.csv`

A ingestão dos dados é realizada de maneira automatizada, garantindo que as informações mais recentes estejam sempre disponíveis para análise e modelagem. Isso é essencial para manter o modelo atualizado com as tendências mais recentes observadas nos dados experimentais.

### 5.1.2 Preparação e Processamento de Dados

Após a ingestão, os dados passam por um processo de limpeza e filtragem, onde registros incompletos ou claramente errôneos são removidos. Este passo é crucial para manter a qualidade do modelo e a precisão das previsões. Posteriormente, realiza-se uma seleção criteriosa das variáveis que são fundamentais para a análise da degradação da bateria, tais como: Corrente de descarga (A), Tensão nos terminais (V) e Temperatura de operação (°C).

Com estas variáveis, procede-se à normalização e transformação dos dados, preparando-os para análises mais complexas. A Figura 5 mostra um exemplo do tipo de visualização gerada a partir dos dados processados, onde é possível observar a capacidade de carga da

bateria B0005 ao longo dos ciclos de descarga. Esta visualização não apenas serve como uma verificação da qualidade dos dados, mas também como uma ferramenta preliminar para a análise da tendência de degradação da bateria.

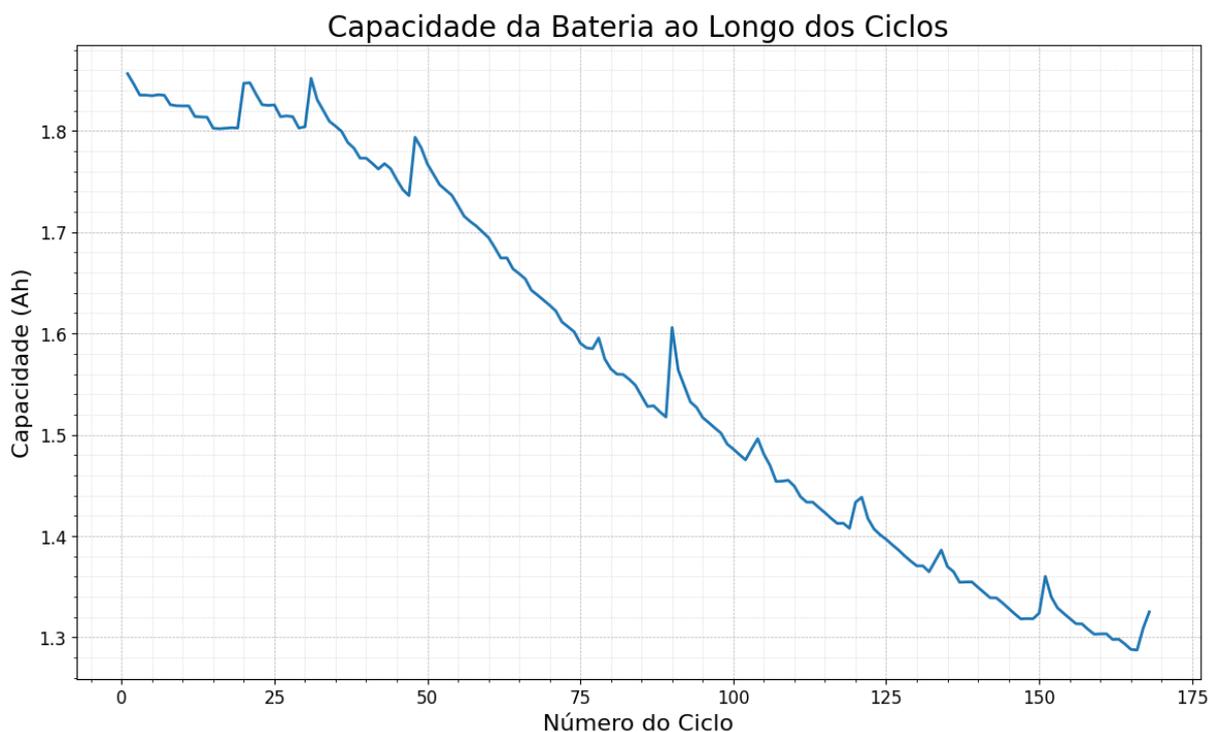


Figura 5 – Capacidade do pack de Bateria B0005 ao Longo dos Ciclos.

A Figura 6 apresenta a temperatura medida do pack de bateria B0005 ao longo dos ciclos de descarga, essencial para entender o comportamento térmico da bateria.

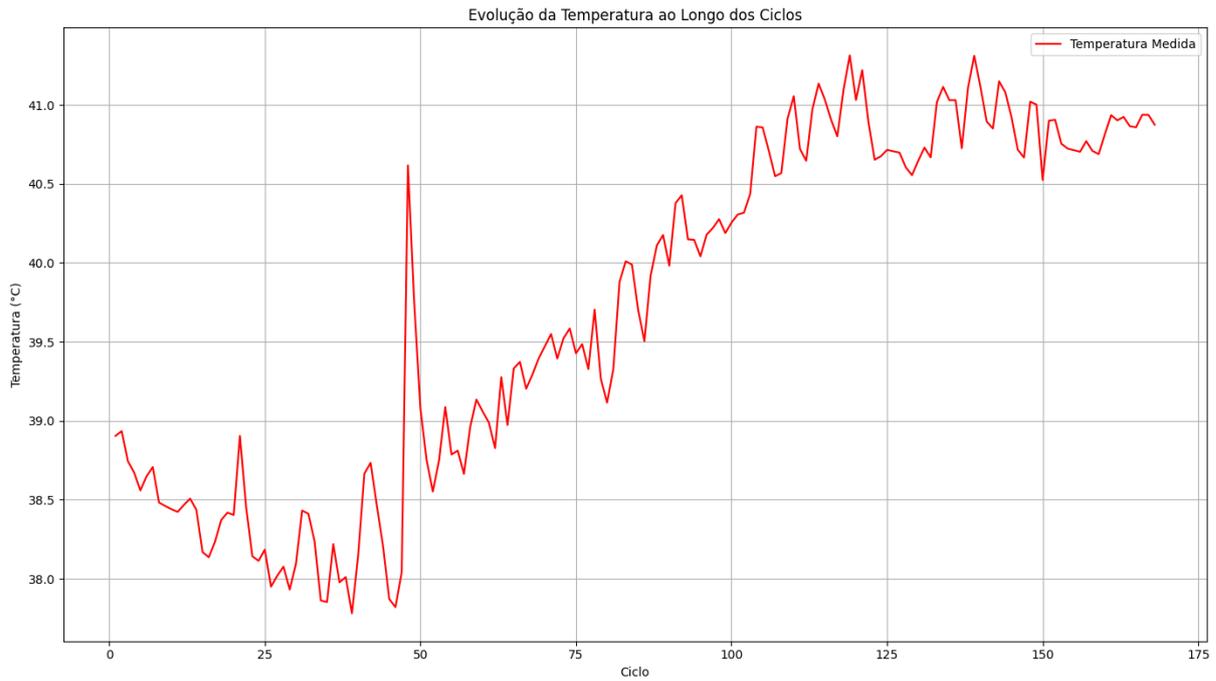


Figura 6 – Temperatura do pack de Bateria B0005 ao Longo dos Ciclos.

A Figura 7 mostra a evolução da tensão medida do pack de bateria B0005 ao longo dos ciclos.

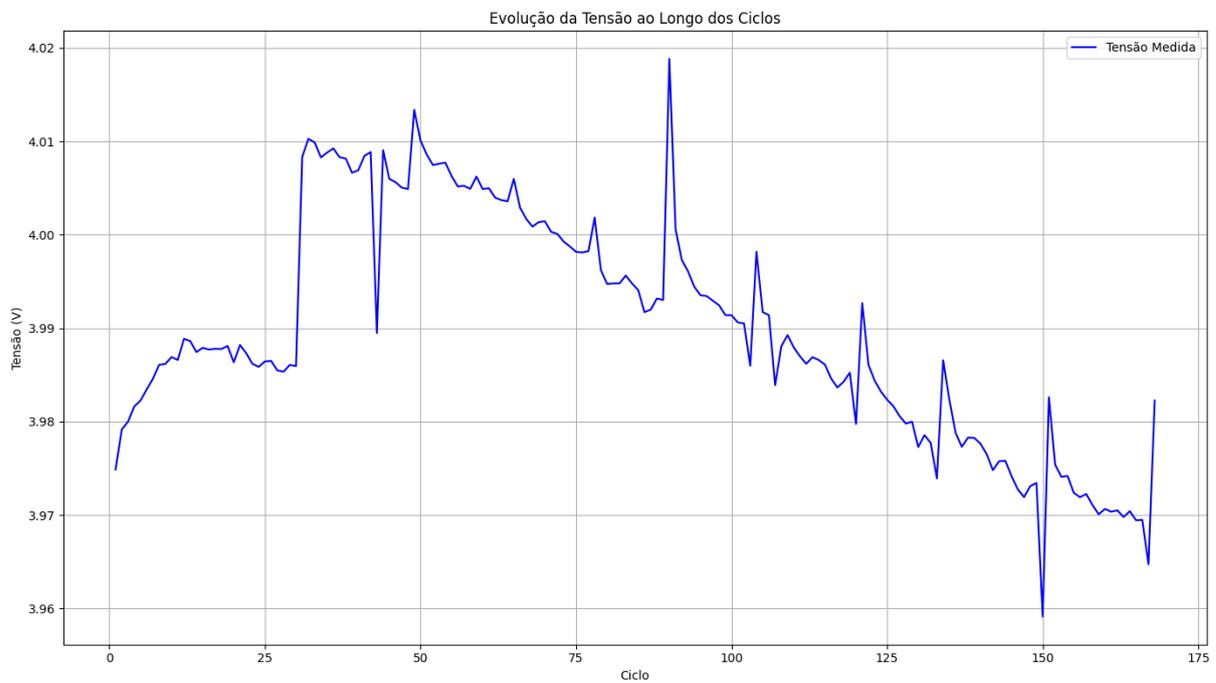


Figura 7 – Tensão do pack de Bateria B0005 ao Longo dos Ciclos.

## 5.2 Implementação da Rede Neural

O modelo de rede neural será projetado para prever a capacidade restante da bateria com base nos dados de entrada dos ciclos de carga e descarga. A arquitetura apresentada nesta seção foi utilizada para o modelo inicial de RNA e para o re-treinamento do modelo quando superado o *threshold* pré-definido. A função de ativação ReLU foi escolhida por sua eficiência em capturar as não linearidades presentes nos dados, sendo amplamente utilizada em modelos de redes neurais devido à sua simplicidade e capacidade de evitar problemas de desvanecimento do gradiente. A quantidade de épocas e o número de neurônios foram determinados por meio de experimentação, garantindo um equilíbrio onde o modelo não sofre de *overfitting* e ainda possui uma boa capacidade de generalização. Segue a arquitetura utilizada:

- **Arquitetura da Rede:** Uma rede neural sequencial com três camadas densas:
  1. Uma **camada de entrada** com 64 neurônios, utilizando a função de ativação ReLU, capaz de modelar a complexidade dos dados de entrada.
  2. Uma **camada oculta** com 32 neurônios, também com ativação ReLU, para aprofundar a aprendizagem dos padrões nos dados.
  3. Uma **camada de saída** com um único neurônio, com ativação linear, destinada a fornecer a estimativa contínua do SoH.
- **Compilação e Treinamento:**
  - Otimizador: Adam com uma taxa de aprendizado padrão do otimizador
  - Função de perda: erro quadrático médio (MSE)
  - Métrica de avaliação: erro absoluto médio (MAE)
  - Número de épocas: 100
  - Tamanho do batch: 20

### 5.2.1 Análise de Desempenho do Modelo

Esta subseção explora a eficácia do modelo por meio da análise de duas métricas principais durante o treinamento: a Perda de Treinamento vs. Validação (MSE) e o MAE. Ambas são críticas para avaliar não apenas a capacidade do modelo de aprender os padrões dos dados mas também sua habilidade em generalizar esses aprendizados para novos conjuntos de dados. As curvas de perda da Figura 8 ilustram uma rápida convergência nos valores iniciais das épocas, seguida por uma estabilização das taxas de perda tanto para o treinamento quanto para a validação, sugerindo que o modelo atingiu uma boa capacidade de generalização sem *overfitting*. A proximidade entre as curvas ao longo das épocas indica

uma resposta consistente e confiável do modelo, fundamental para aplicações críticas como a monitoração da carga de baterias.

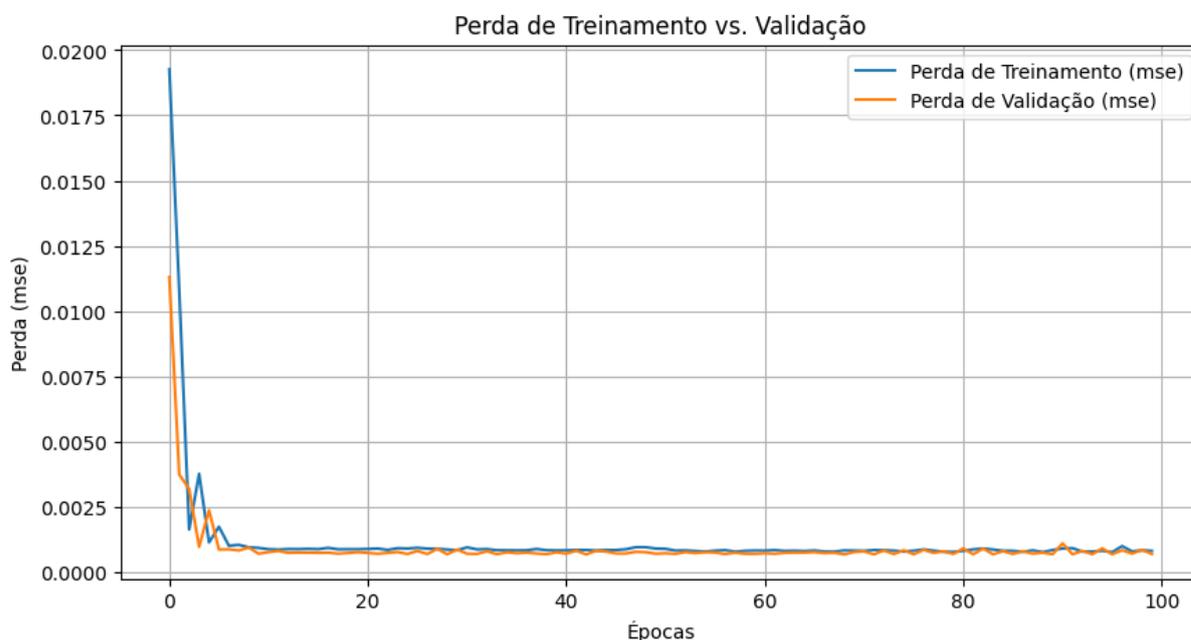


Figura 8 – Perda de Treinamento vs. Validação.

Na Figura 9, é utilizado o MAE para complementar a análise ao oferecer uma visão direta do erro médio que pode ser esperado na prática. A estabilidade dos valores de MAE em um nível baixo ao longo das épocas é indicativo da precisão do modelo. A robustez observada no comportamento do MAE, junto à baixa variação entre treinamento e validação, assegura a confiabilidade do modelo em ambientes operacionais reais.

Os resultados obtidos demonstram um modelo inicial eficaz, uma vez que a convergência rápida das métricas de perda e erro absoluto médio e a manutenção de valores baixos confirmam a aptidão do modelo para ser implementado. Esta mesma configuração apresentada nesta seção será utilizada durante o processo de re-treinamento da rede neural.

## 5.3 Serviços na Nuvem

### 5.3.1 Azure Blob Storage

Azure Blob Storage é empregado como uma solução de armazenamento escalável e segura para os dados de ciclos de carga e descarga das baterias obtidos da NASA. Este serviço não apenas oferece alta durabilidade e disponibilidade, mas também facilita o acesso controlado aos dados por meio de URLs seguras. Na Figura 10 é possível visualizar o container com os dados disponíveis no painel de gerenciamento do Azure Blob Storage.

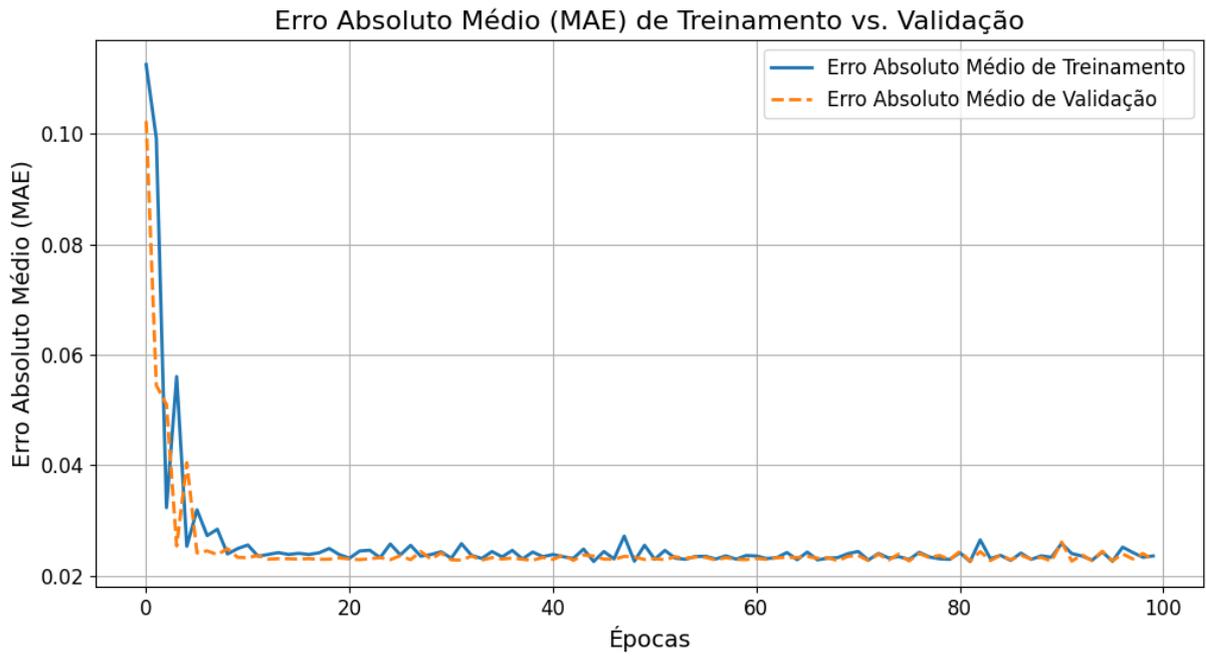


Figura 9 – MAE de Treinamento vs. Validação

Microsoft Azure

Search resources, services, and docs (G+)

Home > tctwin | Containers >

**nasa** Container

Search

Upload Change access level Refresh Delete

**Authentication method:** Access key (Switch to Microsoft Entra user account)  
**Location:** nasa

Search blobs by prefix (case-sensitive)

Add filter

Name	Modified	Access tier
<input type="checkbox"/> charge.csv	4/30/2024, 9:34:27 PM	Hot (Inferred)
<input type="checkbox"/> discharge.csv	4/19/2024, 9:04:16 AM	Hot (Inferred)
<input type="checkbox"/> impedance.csv	4/30/2024, 9:34:52 PM	Hot (Inferred)

Figura 10 – Painel do Container com os dados na Azure Blob Storage.

### 5.3.2 Azure ML Workspace e Azure Web App Container

Como apresentado anteriormente é possível utilizar o Azure ML Workspace com instâncias computacionais da Azure com altos recursos computacionais, assim possibilitando processar grandes volumes de dados, modelos de redes neurais e algoritmos necessários. Junto a isso também é apresentado o Azure Web App Container, utilizado para hospedar a interface de usuário final que interage com os resultados da simulação e estimativas de SoH. A aplicação *Streamlit* hospedada nesse contêiner permite a visualização interativa através de *dashboards*. Nesse aplicativo tem-se um *dashboard* interativo, possibilitando os usuários interagir com os dados e visualizar as métricas de desempenho das baterias. Na Figura 11 pode-se visualizar o *dashboard* no Azure Web App.

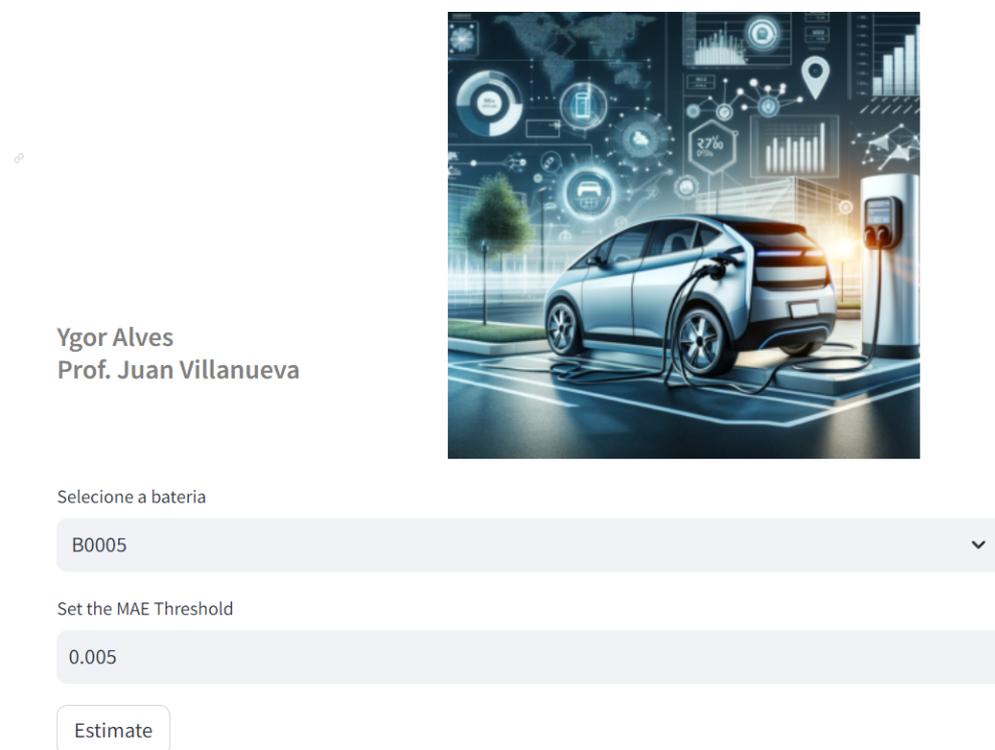


Figura 11 – Imagens do Azure Web APP.

A integração dos serviços do Azure promove uma pipeline de dados desde a ingestão até a visualização dos resultados. A escalabilidade dos serviços na nuvem permite ajustar os recursos conforme necessário, tais como melhores instâncias computacionais e disponibilidade. O *site* tem responsividade tanto para *desktop* como para aplicativos móveis. É possível acessar o *web app* no link: <https://twin.azurewebsites.net/>

## 5.4 Arquitetura com Gêmeo Digital

Este trabalho de conclusão de curso explora a aplicação de gêmeos digitais, inteligência artificial e computação em nuvem para a estimativa do SoH de baterias de lítio-íon. A arquitetura do sistema integra uma RNA treinada com dados coletados das operações da bateria para prever seu SoH, um indicador vital para a gestão eficiente da energia e a manutenção preventiva de sistemas dependentes de baterias.

Inicialmente, a RNA foi configurada e treinada com 70% dos dados disponíveis, correspondente a 118 ciclos, um conjunto significativo que permite ao modelo aprender com uma ampla variedade de condições operacionais. Visando apresentar o funcionamento do re-treinamento, o primeiro set de teste foi aplicado nos 25 ciclos posteriores, quando o MAE atingiu um valor de 0.03. A predição inicial do SoH realizada por esta RNA é demonstrada na Figura 12, onde a precisão do modelo é analisada frente aos dados reais.

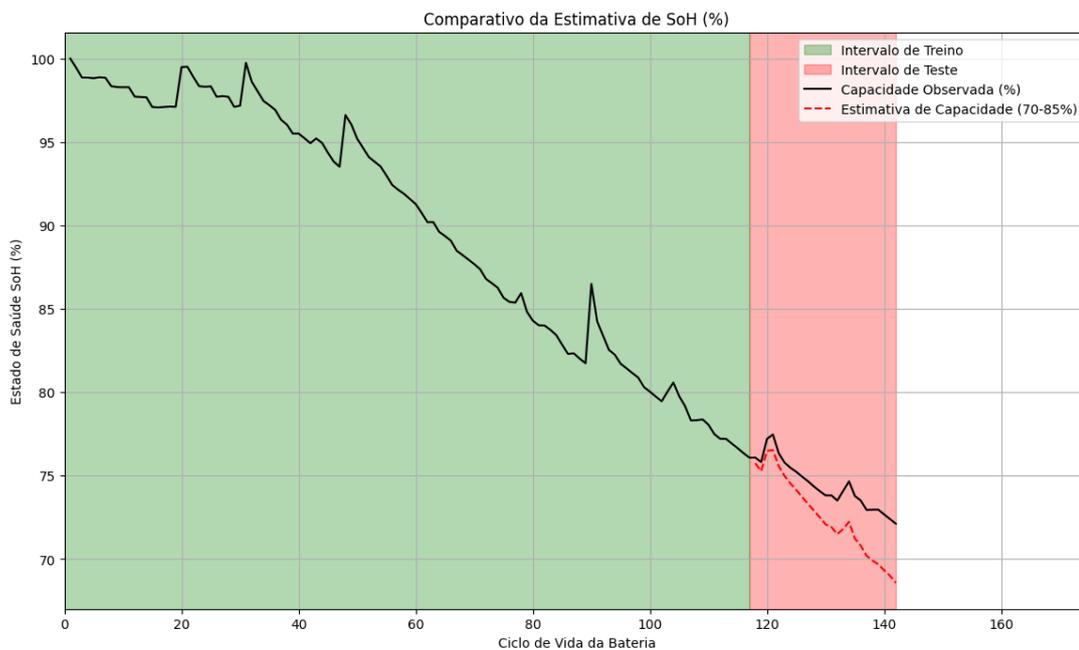


Figura 12 – Predição inicial do Estado de Carga utilizando a RNA treinada com o conjunto inicial de dados.

A precisão da predição inicial foi quantificada pelo MAE, que serve como uma métrica fundamental para avaliar a eficácia do modelo. O MAE calculado neste estágio inicial é registrado na Tabela 1, fornecendo um benchmark para avaliações futuras.

Dataset	Treinamento	Teste	MAE
Inicial	70%	15%	0.03

Tabela 1 – MAE obtido após a predição inicial do SoH.

Dado o objetivo de maximizar a precisão do gêmeo digital e com o objetivo de apresentar o funcionamento da arquitetura, o modelo foi submetido a um processo de retreinamento após análise inicial. O retreinamento utilizou um conjunto adicional de dados, aumentando a quantidade total de dados de treinamento para 85%. Este passo é corroborado com a adaptação do modelo às mudanças nas características da bateria, aprimorando a precisão da predição do SoH.

A nova predição do SoH, realizada após o processo de retreinamento, é mostrada na figura 13. As melhorias na predição são evidentes quando comparadas com os resultados iniciais, indicando uma maior alinhamento do modelo com as condições operacionais reais.

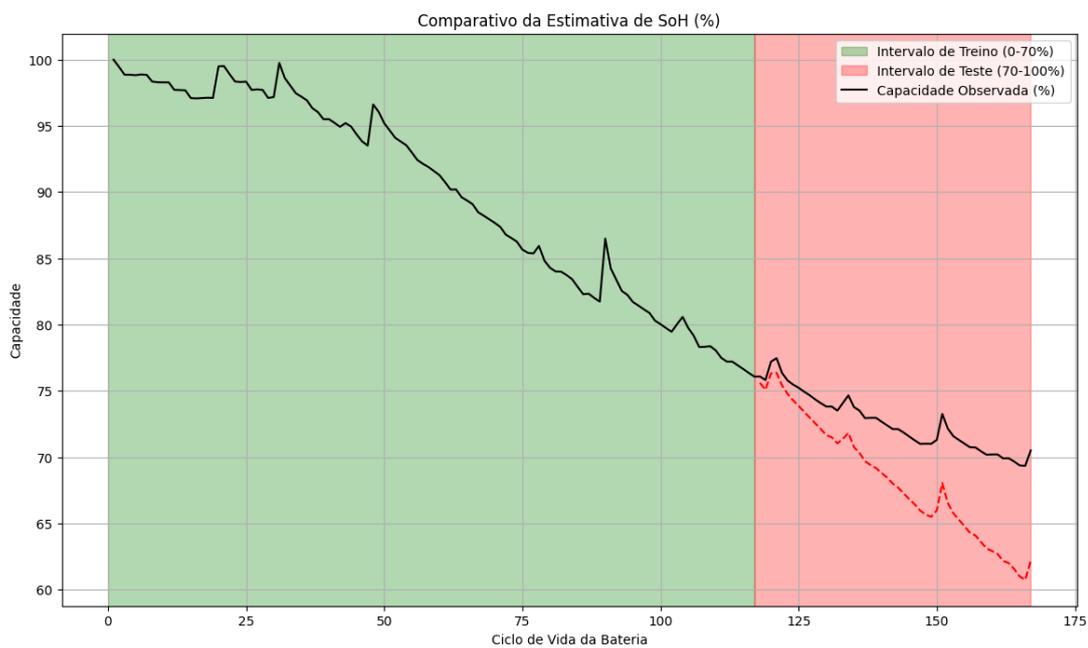


Figura 13 – Comparação da predição do SoH utilizando a RNA após o retreinamento.

A análise comparativa dos resultados pré e pós-retreinamento, apresentada na Figura 14 na Tabela 2, assim validando a eficácia do gêmeo digital em adaptar-se dinamicamente. Este processo demonstra como a arquitetura proposta pode efetivamente ajustar-se para manter a precisão na predição do SoH frente às mudanças nas condições operacionais das baterias.

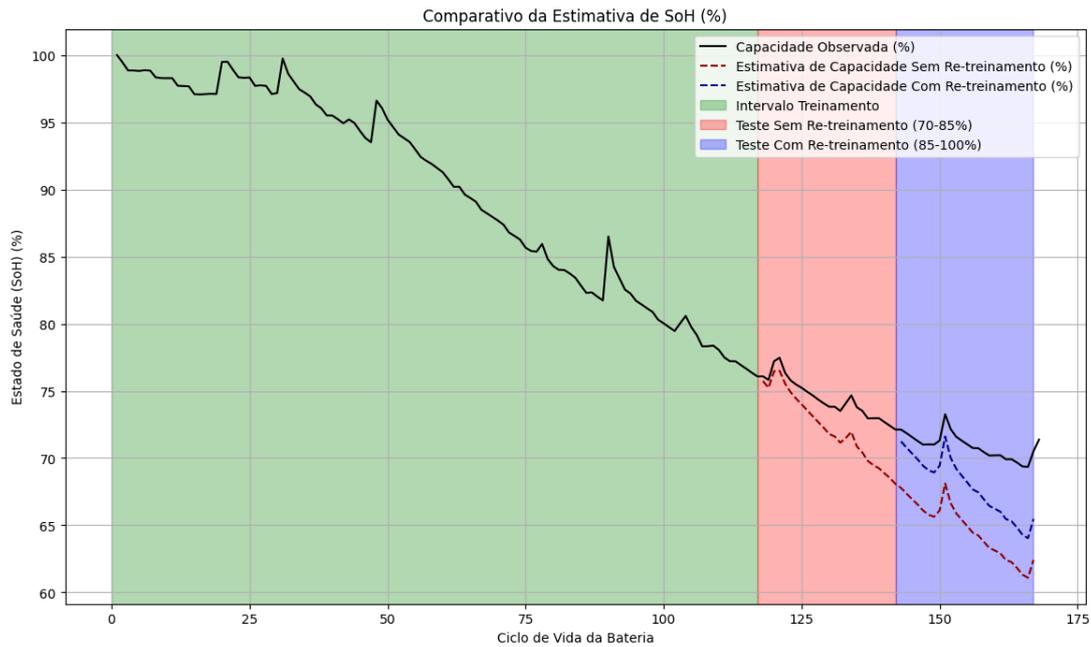


Figura 14 – Gráfico comparativo na predição do SoH antes e após o retreinamento da RNA.

Condição	MAE	MAPE (%)	RMSE
Antes do Retreinamento	0.0621	11.8484	0.0712
Após o Retreinamento	0.0469	8.4378	0.0516

Tabela 2 – Comparação detalhada das métricas de erro antes e após o retreinamento.

É possível observar na Tabela 2 que, antes do retreinamento, o MAE foi registrado em 0.0621, enquanto após o retreinamento, ele melhorou para 0.0469, evidenciando a eficácia do ajuste do modelo em resposta às variações das condições operacionais da bateria. Essa melhoria no desempenho é uma validação da estratégia utilizada de re-treinamento, uma vez que a métrica MAE serve como um indicador contínuo do desempenho do modelo, além das outras métricas de erros também avaliadas no processo. Estes resultados demonstram a eficácia do processo de retreinamento no ajuste da RNA para responder às mudanças nas condições operacionais, garantindo assim a precisão e a relevância contínua do gêmeo digital no monitoramento do SoH.

Além disso, é possível visualizar todo o processo de estimativa e análise por meio de uma interface interativa implementada na Azure Web App. Desenvolvida usando bibliotecas do Python para visualização, é possível visualizar o processamento e análise dos dados, além das métricas de erro, permitindo um acompanhamento das melhorias proporcionadas pelo processo de retreinamento. Os usuários podem definir dinamicamente o *threshold* de MAE desejado e imediatamente visualizar o impacto nas previsões de SoH. Nas Figuras 15 e 16 pode-se visualizar o aplicativo apresentando os resultados.

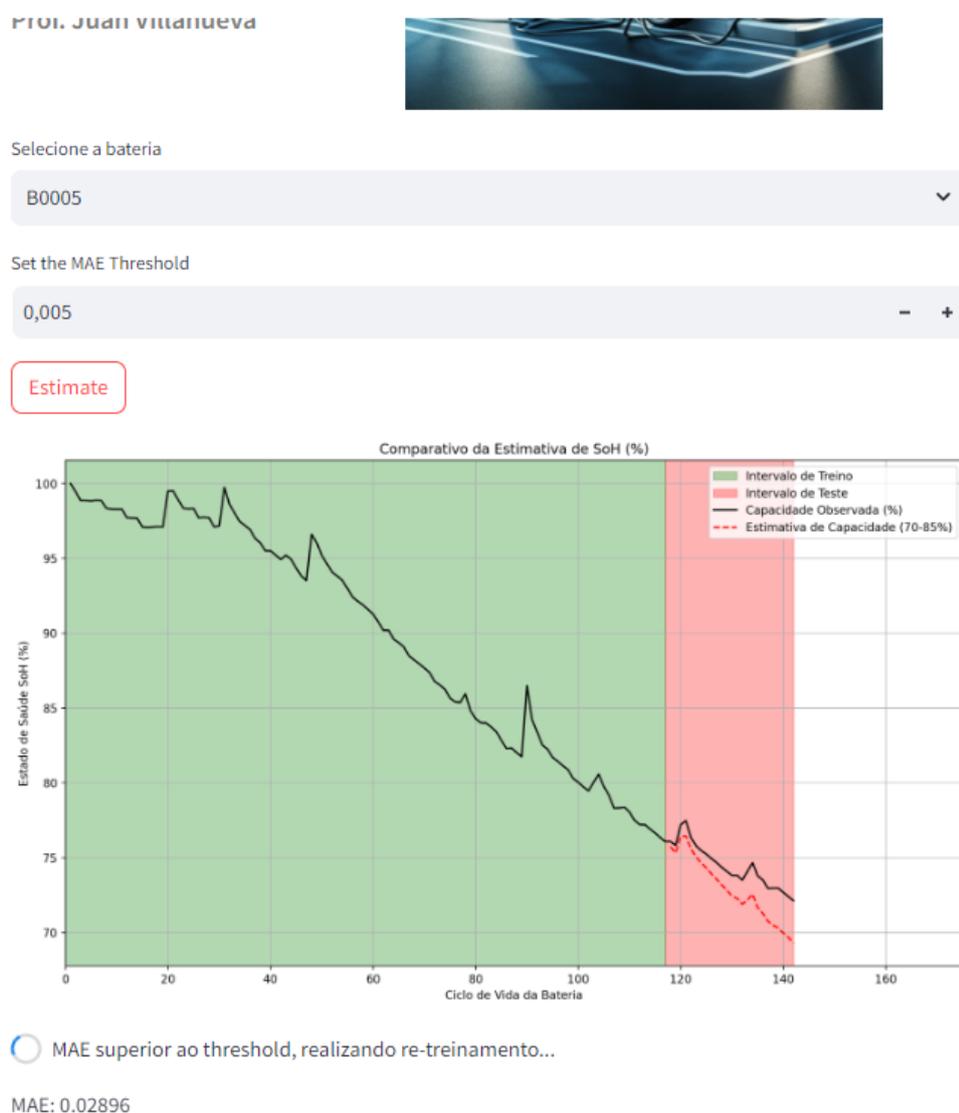


Figura 15 – Interface do Azure Web App apresentando os campos interativos.



Figura 16 – Interface do Azure Web App apresentando os resultados de predição do SoH com e sem retreinamento.

A interface da Azure Web App (Figura 15) foi desenvolvida para destacar os resultados finais e também oferecer uma compreensão detalhada do desempenho do modelo ao longo do tempo. Esse recurso interativo fortalece o valor prático do gêmeo digital, proporcionando aos operadores de sistemas de baterias uma ferramenta em potencial para decisões de manutenção e operação baseadas em dados precisos e atualizados. Além de que essa arquitetura possibilita armazenamento de grandes volumes de dados com o Azure Blob Storage, além de usar instâncias computacionais potentes da Microsoft Azure para treinamentos dos modelos. Este aspecto do sistema é relevante para a gestão de energia eficiente e para a extensão da vida útil das baterias, reforçando a importância de soluções integradas que combinam gêmeos digitais, inteligência artificial e computação em nuvem.

## 6 Conclusões

Este trabalho abordou a estimativa do SoH de baterias de lítio-íon, integrando metodologias de gêmeos digitais, inteligência artificial e computação em nuvem. A metodologia proposta utilizou um modelo de gêmeo digital desenvolvido a partir de dados reais fornecidos pela NASA, permitindo uma simulação adaptativa e uma análise detalhada do comportamento das baterias sob diferentes condições operacionais. A técnica de re-treinamento do modelo, implementada através de um limiar de MAE pré-definido, permitiu ajustes dinâmicos nas previsões do SoH, melhorando significativamente a precisão das estimativas à medida que novos dados eram incorporados. Este processo assegurou que o modelo se adaptasse continuamente às mudanças nas condições de operação das baterias, refletindo a eficácia desta abordagem no tratamento das complexidades inerentes ao comportamento das baterias de lítio-íon.

### 6.1 Trabalhos Futuros

Para avançar neste campo de pesquisa, é recomendável a integração do sistema de gêmeo digital desenvolvido com BMS reais, utilizando dispositivos IoT para coleta contínua de dados operacionais, tais como corrente e temperatura. A conexão com sistemas de gerenciamento de baterias avançados, como o Moura Connect, que monitora o estado das baterias em tempo real, poderia fornecer um fluxo constante de dados operacionais, enriquecendo significativamente o modelo de gêmeo digital. Esta integração permitiria não apenas simulações mais realistas e precisas, mas também facilitaria a implementação prática e impactante da solução proposta.

Além disso, explorar técnicas mais sofisticadas de inteligência artificial, como as redes neurais de *Long Short-Term Memory* (LSTM), e expandir a base de dados para incluir um espectro mais amplo de variáveis operacionais poderiam aprimorar significativamente as capacidades do modelo de gêmeo digital.

# Referências

Buyya, Yeo e Venugopal 2009 BUYYA, R.; YEO, C. S.; VENUGOPAL, S. Market-oriented cloud computing: Vision, hype, and reality for delivering it services as computing utilities. In: IEEE. *Proceedings of the 10th IEEE International Conference on High Performance Computing and Communications*. Seoul, South Korea, 2009.

BYD Company Ltd. 2023 BYD Company Ltd. *Em ano histórico, BYD cresce quase 70 vezes no Brasil e vende mais carros elétricos do que todos os concorrentes somados*. 2023. <<https://byd.com.br/em-ano-historico-byd-cresce-quase-70-vezes-no-brasil-e-vende-mais-carros-eletricos-do-que-todos-os-c>>. Accessed: 2023-04-14.

Eaty e Bagade 2023 EATY, N. D. K. M.; BAGADE, P. Digital twin for electric vehicle battery management with incremental learning. *Expert Systems with Applications*, v. 229, p. 120444, 2023. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417423009466>>.

Fonso et al. 2022 FONSO, R. D. et al. A battery digital twin based on neural network for testing soc/soh algorithms. In: *2022 IEEE 20th International Power Electronics and Motion Control Conference (PEMC)*. [S.l.: s.n.], 2022. p. 655–660.

International Energy Agency (IEA) 2023 International Energy Agency (IEA). *Global EV Outlook 2023*. Paris, 2023. <<https://www.iea.org/reports/global-ev-outlook-2023>>. License: CC BY 4.0.

Jin et al. 2018 JIN, X. et al. Applicability of available li-ion battery degradation models for system and control algorithm design. *Control Engineering Practice*, v. 71, p. 1–9, 2018.

Li et al. 2020 LI, W. et al. Digital twin for battery systems: Cloud battery management system with online state-of-charge and state-of-health estimation. *Journal of Energy Storage*, v. 30, p. 101557, 2020. ISSN 2352-152X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352152X20308495>>.

Liu et al. 2021 LIU, Y. et al. A nonlinear observer soc estimation method based on electrochemical model for lithium-ion battery. *IEEE Transactions on Industry Applications*, v. 57, p. 1094–1104, 2021.

Marston et al. 2011 MARSTON, S. et al. Cloud computing — the business perspective. *Decision Support Systems*, v. 51, n. 1, p. 176–189, 2011.

Mell e Grance 2011 MELL, P.; GRANCE, T. *The NIST Definition of Cloud Computing*. [S.l.], 2011. Recuperado de NIST.

Movassagh et al. 2021 MOVASSAGH, K. et al. A critical look at coulomb counting approach for state of charge estimation in batteries. *Energies*, 2021.

Schimpe et al. 2017 SCHIMPE, M. et al. Comprehensive modeling of temperature-dependent degradation mechanisms in lithium iron phosphate batteries. v. 80, p. 147–170, 2017.

Singh, Weeber e Birke 2021 SINGH, S.; WEEBER, M.; BIRKE, K. P. Implementation of battery digital twin: Approach, functionalities and benefits. *Batteries*, v. 7, n. 4, 2021. ISSN 2313-0105. Disponível em: <<https://www.mdpi.com/2313-0105/7/4/78>>.

Smith 2017 SMITH, G. S. Benjamin franklin and the dissectible capacitor: his observations might surprise you. *European Journal of Physics*, IOP Publishing, v. 38, n. 6, p. 065202, sep 2017. Disponível em: <<https://dx.doi.org/10.1088/1361-6404/aa854d>>.

(UN) 2015 (UN), U. N. Transforming our world: The 2030 agenda for sustainable development. ., 2015. Acesso em 25/04/2021. Disponível em: <<https://sustainabledevelopment.un.org/content/documents/21252030\%20Agenda\%20for\%20Sustainable\%20Development\%20web.pdf>>.

Wagle et al. 2023 WAGLE, M. et al. Estimation of state of charge in electric vehicle using the battery digital twin. In: *2023 3rd International Conference on Intelligent Technologies (CONIT)*. [S.l.: s.n.], 2023. p. 1–7.

Wang et al. 2021 WANG, W. et al. Application of digital twin in smart battery management systems. *Chinese Journal of Mechanical Engineering*, Springer, v. 34, p. 57, 2021. Disponível em: <<https://doi.org/10.1186/s10033-021-00577-0>>.

Waseem et al. 2023 WASEEM, M. et al. Battery technologies and functionality of battery management system for evs: Current status, key challenges, and future prospectives. *Journal of Power Sources*, v. 580, p. 233349, 2023. ISSN 0378-7753. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378775323007255>>.

Xu et al. 2018 XU, B. et al. Modeling of lithium-ion battery degradation for cell life assessment. *IEEE Transactions on Smart Grid*, v. 9, p. 1131–1140, 2018.

Yi et al. 2022 YI, Z. et al. Estimation methods for states of charge and health of lithium-ion battery. *Journal of Physics: Conference Series*, v. 2221, 2022.

Zhou et al. 2018 ZHOU, L. et al. Recent developments on and prospects for electrode materials with hierarchical structures for lithium-ion batteries. *Advanced Energy Materials*, v. 8, 2018.