

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA – CÂMPUS FLORIANÓPOLIS DEPARTAMENTO ACADÊMICO DE
ELETROTÉCNICA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA MESTRADO PROFISSIONAL EM SISTEMAS DE ENERGIA ELÉTRICA

RENAN MELLO NOGUEIRA

CONTRIBUIÇÃO À MODELAGEM ELETRICA DE UMA CÉLULA COMBUSTÍVEL
MICROBIANA

Florianópolis, 2025

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SANTA
CATARINA – CÂMPUS FLORIANÓPOLIS DEPARTAMENTO ACADÊMICO DE
ELETROTÉCNICA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA MESTRADO PROFISSIONAL EM SISTEMAS DE ENERGIA ELÉTRICA

RENAN MELLO NOGUEIRA

CONTRIBUIÇÃO À MODELAGEM ELETRICA DE UMA CÉLULA COMBUSTÍVEL
MICROBIANA

Dissertação de mestrado submetida ao Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Sergio L. Ávila, Dr. Eng

Florianópolis, 2025.

Ficha de identificação da obra elaborada pelo autor.

Mello Nogueira, Renan
**CONTRIBUIÇÃO À MODELAGEM ELETRICA DE UMA CÉLULA COMBUSTÍVEL
MICROBIANA** / Renan Mello Nogueira; orientação de
Sergio Luciano Ávila. - Florianópolis, SC, 2026.
121 p.

Dissertação (Mestrado) - Instituto Federal de Santa
Catarina, Câmpus Florianópolis. Mestrado Profissional
em Sistemas de Energia Elétrica. Departamento
Acadêmico de Eletrotécnica.
Inclui Referências.

1. Célula Combustível Microbiana. 2. Eficiência Coulômbica.
3. Modelagem Elétrica Dinâmica. 4. Caracterização
Eletroquímica. I. Luciano Ávila, Sergio. II. Instituto
Federal de Santa Catarina. III. **CONTRIBUIÇÃO
À MODELAGEM ELETRICA DE UMA CÉLULA COMBUSTÍVEL MICROBIANA.**

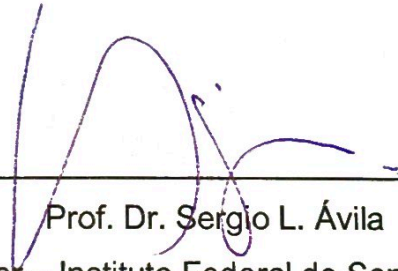
CONTRIBUIÇÃO À MODELAGEM ELETRICA DE UMA CÉLULA COMBUSTÍVEL
MICROBIANA

RENAN MELLO NOGUEIRA

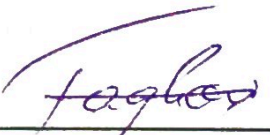
Este trabalho foi julgado adequado para obtenção do título de Mestre em Engenharia Elétrica e aprovado na sua forma final pela banca examinadora do Mestrado Profissional em Sistemas de Energia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Florianópolis, 12 de dezembro de 2025

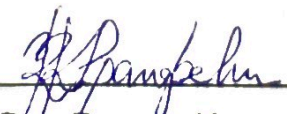
BANCA EXAMINADORA



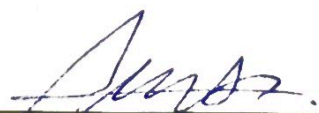
Prof. Dr. Sergio L. Ávila
Orientador – Instituto Federal de Santa Catarina



Prof. Dr. Everthon Taghori Sica
Instituto Federal de Santa Catarina



Dra. Rayane Kunert Langbehn
Universidade Federal de Santa Catarina



Prof. Dr. Ricardo Luis Alves
Instituto Federal de Santa Catarina

AGRADECIMENTOS

A minha companheira, amiga e esposa, Caroline Borba Piazzaroli, por todo apoio incondicional dado durante o mestrado. Obrigado por estar sempre ao meu lado, iluminando os dias com muita alegria, incentivo e amor. Sem você, nada disso teria sido possível!

A meu pai (*in memoriam*), por ter sido a inspiração por seguir na trilha da engenharia. Teu exemplo de vida — bondoso, respeitável e amável por todos ao teu redor — segue vivo em mim. É tua memória que me guia e me lembra do verdadeiro valor da dedicação, humildade e me incentiva ser uma pessoa melhor todo dia.

A minha família, pelo apoio ao longo de toda vida, nos momentos bons e ruins.

Ao Prof. Dr. Sergio Ávila, por ter confiado em mim quando sentei naquela sala em 2023 em busca de um tema. Sou profundamente grato pela ampla rede de apoio que você mobilizou para me atender, pela orientação sempre presente e pela paciência nos momentos em que minhas respostas demoraram a vir. Obrigado por todo incentivo dado para conclusão do mestrado.

À Dra. Rayane Kunert Langbehn, por ser a fonte de inspiração do trabalho, sempre solícita nas respostas e sem medir esforços para auxiliar no entendimento do assunto.

Ao Prof. Dr. Everthon Sica, pelo apoio com o texto e, sobretudo, pelo exemplo de amor à profissão. Em cada conversa, era possível ver a sua paixão e o entusiasmo pela engenharia.

Aos docentes e à secretaria acadêmica do Mestrado Profissional em Sistemas de Energia Elétrica no Instituto Federal de Santa Catarina, pelo esforço e empenho para sucesso do programa.

Aos colegas de turma, Leonardo Wollinger, Matheus Martins, Tiago Motta e Yago Nunes, pelo companheirismo e pelas trocas durante os estudos.

Ao Prof. Dr. Ricardo Luis Alves, pela disponibilidade e generosidade ao aceitar participar da banca.

Obrigado!

RESUMO

Este trabalho apresenta a análise experimental e a modelagem elétrica dinâmica de Células a Combustível Microbianas (Microbial Fuel Cells - MFCs) ao longo de aproximadamente 150 dias de operação contínua, utilizando duas configurações distintas de ânodo: carvão ativado e grafite. Técnicas de análise de séries temporais, incluindo decomposição de tendência sazonal, detecção de pontos de mudança e correlações cruzadas, foram aplicadas com o objetivo de identificar padrões de variação, estabilidade operacional e regimes de degradação e recuperação ao longo do ciclo experimental. Adicionalmente, curvas de polarização foram realizadas para avaliar o desempenho elétrico e a resistência interna das células. Os resultados quantitativos demonstraram a superioridade da configuração com ânodo de carvão ativado, que atingiu uma densidade de potência máxima de 49,0 mW/m² e resistência interna de 301 Ω , em contraste com os 33,4 mW/m² e 364 Ω obtidos na configuração com grafite. Em termos de tratamento de efluentes, ambas as células mantiveram eficiência de remoção de DQO superior a 82%. Com base nesses dados, foi proposto um modelo elétrico equivalente dinâmico, composto por elementos resistivos e capacitivos, que apresentou boa aderência aos dados experimentais, sugerindo potencial para aplicações em simulação, monitoramento e implementação futura de estratégias de gerenciamento energético.

Palavras-chave: Célula Combustível Microbiana; Eficiência Coulômbica; Modelagem Elétrica Dinâmica; Caracterização Eletroquímica

ABSTRACT

This work presents the experimental analysis and dynamic electrical modeling of Microbial Fuel Cells (MFCs) over approximately 150 days of continuous operation, using two distinct anode configurations: activated carbon and graphite. Time-series analysis techniques, including seasonal-trend decomposition, change-point detection, and cross-correlation analysis, were applied aiming to identify variation patterns, operational stability, and regimes of degradation and recovery throughout the experimental cycle. Additionally, polarization curves were performed to evaluate the electrical performance and internal resistance of the cells. Quantitative results demonstrated the superiority of the activated-carbon anode configuration, which achieved a maximum power density of 49.0 mW/m^2 and an internal resistance of 301Ω , in contrast to the 33.4 mW/m^2 and 364Ω obtained in the graphite configuration. Regarding effluent treatment, both cells maintained a COD removal efficiency exceeding 82%. Based on these data, a dynamic equivalent electrical model composed of resistive and capacitive elements was proposed, which showed good agreement with the experimental data, suggesting potential for applications in simulation, monitoring, and future implementation of energy management strategies.

Keywords: Microbial Fuel Cell; Coulombic Efficiency; Dynamic Electrical Modeling; Electrochemical Characterization

LISTA DE ILUSTRAÇÕES

Figura 1 — MFC de duas câmaras	15
Figura 2 — Controlador MPPT com potenciômetro digital	20
Figura 3 — Esquemático de conversor BOOST para MFC.....	21
Figura 4 — Cenários de aplicações de MFCs	22
Figura 5 — Métodos de produção de hidrogênio	24
Figura 6 — Circuito equivalente com resistência série R_s com ramo paralelo $R \parallel C$ (resistência de transferência e capacitância de dupla camada).....	31
Figura 7 — Circuito equivalente típico em análise EIS de MFC	31
Figura 8 — Local que ocorreu experimento	35
Figura 9 — Reator do experimento	36
Figura 10 — Experimento montado em bancada para ilustração.....	36
Figura 11 — Série temporal de corrente durante experimento.....	39
Figura 12 — Decomposição STL - (a) Série Original, (b) Componente de Tendência, (c) Componente Sazonal, (d) Componente Residual	42
Figura 13 — Série Temporal de Corrente com linhas de Intercorrências Operacionais	45
Figura 14 — Detecção de Pontos de Mudança de Regime pelo Algoritmo PELT....	47
Figura 15 — Curvas de Polarização (Tensão vs. Densidade de Corrente) e Curvas de Densidade de Potência para MFC 1 e MFC 2.....	49
Quadro 1 — Parâmetros Eletroquímicos Chave Derivados das Curvas de Polarização	51
Figura 16 — Correlação entre corrente e variáveis químicas.....	52
Figura 17 — Evolução da eficiência coulômbica	56
Quadro 2 — Sumário das Eficiências de Remoção de DQO e Eficiência Coulômbica (Valores Médios)	56
Figura 18 — Curvas de corrente em janela de 24h para séries estáveis	58
Figura 19 — Modelo matemático MFC1.....	60
Figura 20 — Modelo matemático MFC2.....	60
Figura 21 — Circuito equivalente MFC	63
Quadro 3 — Matriz Comparativa de Desempenho Final entre MFC 1 e MFC 2	65

LISTA DE TABELAS

Tabela 1 — Microrganismos e substratos em MFCs para gerar eletricidade	23
Tabela 2 — Estatísticas Descritivas do Desempenho Elétrico das MFCs.....	40
Tabela 3 — Intercorrências durante experimento	44
Tabela 4 — Cronologia de Pontos de Mudança Detectados pelo Algoritmo PELT e Correlação com Eventos Operacionais	48
Tabela 5 — Resultados da modelagem	59

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Justificativa	10
1.2	Definição do problema	11
1.3	Objetivo Geral	11
1.4	Objetivos Específicos	12
1.5	Estrutura do Trabalho	12
1.6	Sobre o autor	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	Geração de eletricidade em MFCs	16
2.1.1	Tensão, potência e densidade de potência em MFC	16
2.1.2	Resistência interna	18
2.1.3	Métricas de Eficiência de Remoção de DQO e Eficiência Coulômbica ...	19
2.1.4	Rastreamento de máxima potência em MFCs	20
2.2	Construção de MFCs	21
2.3	Biohidrogênio	24
2.4	Sugestão metodológica para o desenvolvimento de Modelos de	
Circuitos	Elétricos Equivalentes para Sistemas Bioquímicos	25
2.5	Modelos Elétricos para MFCs	29
2.5.1	Modelos simplificados resistivos	30
2.5.2	Modelos de impedância complexa	30
2.5.3	Modelos acoplados bioeletroquímicos	32
2.5.4	Circuitos equivalentes RC com elementos de membrana e citoplasma ..	32
2.5.5	Vantagens e limitações dos modelos equivalentes	33
3	METODOLOGIA	34
4	RESULTADOS	37
4.1	Pré-processamento e Análise Exploratória dos Dados Operacionais	37
4.1.1	Limpeza e Validação do Conjunto de Dados	38
4.1.2	Visualização do Desempenho Elétrico em Longo Prazo	38
4.1.3	Análise Estatística Descritiva	40
4.2	Decomposição das Séries Temporais e Análise de Padrões Cíclicos	41
4.2.1	Metodologia de Decomposição STL	41
4.2.2	Interpretação dos Componentes Decompostos	42
4.3	Análise de Intercorrências e Detecção de Pontos de Mudança de	
Regime	Regime	44
4.3.1	Mapeamento de Eventos Operacionais e Análise de Resiliência	44
4.3.2	Detecção Algorítmica de Pontos de Mudança de Regime	46
4.4	Caracterização Eletroquímica e Análise das Perdas de Tensão	48

4.4.1	Curvas de Polarização e Densidade de Potência	49
4.5	Influência dos Parâmetros Físico-Químicos e Ambientais	51
4.5.1	Interpretação das Correlações	52
4.6	Avaliação da Eficiência de Tratamento e Conversão Energética	54
4.6.1	Eficiência de Remoção de Demanda Química de Oxigênio (DQO)	54
4.6.2	Eficiência Coulômbica (EC).....	55
4.7	Modelagem Matemática do Comportamento Elétrico	57
4.8	Modelo elétrico equivalente	62
4.9	Síntese Comparativa e Discussão Integrada dos Resultados	64
5	CONCLUSÃO	67
	REFERÊNCIAS	70
	ANEXO A — Códigos em matlab	77
	ANEXO B — Notebook Jupiter	77
	ANEXO C — Artigo SNTPEE	77

1 INTRODUÇÃO

Esta dissertação explora as Células a Combustível Microbianas (*Microbial Fuel Cells* - MFCs), que emergem como uma solução sustentável para os problemas enfrentados na produção de energia elétrica e no tratamento de efluentes (esgoto). As MFCs são dispositivos que utilizam microrganismos para converter a energia química contida em substratos orgânicos em eletricidade, representando uma interseção entre biotecnologia, engenharia ambiental e geração de eletricidade. Com a crescente demanda por fontes de energia renovável, este trabalho visa investigar o potencial das MFCs para contribuir com a sustentabilidade energética.

O primeiro objetivo é a revisão da fundamentação teórica das MFCs, incluindo os seus processos bioeletroquímicos. A compreensão das interações entre os microrganismos, o eletrólito e os eletrodos são essenciais para compreender a eficiência e a viabilidade econômica das MFCs. Diferentes materiais e configurações influenciam a produção de eletricidade e o impacto ambiental dos MFCs.

Nos capítulos a seguir, a dissertação se desdobrará em uma análise detalhada dos conceitos que sustentam as MFCs, seus desafios técnicos, e a incorporação de tecnologias emergentes. Este roteiro proporciona uma visão clara e coesa dos desenvolvimentos atuais nas MFCs, enfatizando suas implicações para o futuro da energia sustentável e a importância da pesquisa contínua neste campo.

1.1 Justificativa

A crescente demanda global por fontes de energia renovável e soluções eficientes para o tratamento de efluentes industriais e urbanos destacam a relevância das MFCs como tecnologia multidisciplinar. Essas células utilizam microrganismos para converter matéria orgânica em eletricidade, oferecendo benefícios como baixa emissão de carbono, redução de lodo residual e integração em sistemas descentralizados de saneamento. No entanto, apesar de sua descoberta há mais de um século, o avanço recente na pesquisa sobre MFCs enfatiza a necessidade de modelagem elétrica para superar limitações como baixa densidade de potência e variabilidade operacional. Esta dissertação justifica-se pela contribuição ao desenvolvimento de modelos elétricos equivalentes que integrem aspectos

bioquímicos e eletroquímicos, facilitando a otimização de configurações e materiais. Assim, o trabalho alinha-se a objetivos de sustentabilidade, promovendo inovações em engenharia elétrica e ambiental em consonância com os Objetivos de Desenvolvimento Sustentável (ODS), apresentando potencial para aplicações reais em tratamento de águas residuais e geração de bioenergia.

1.2 Definição do problema

O desempenho das MFCs é intrinsecamente complexo, governado pela interação de fenômenos bioquímicos (metabolismo microbiano e cinética de substrato) e eletroquímicos (transferência de elétrons, perdas ôhmicas e polarização). A maioria das abordagens de modelagem elétrica encontradas na literatura opta por modelos puramente resistivos ou por modelos de impedância em estado estacionário.

O problema central reside no fato de que esses modelos simplificados são insuficientes para capturar a dinâmica temporal do sistema, como as variações de desempenho observadas ao longo do dia (ciclos de alimentação, temperatura) ou falham em representar a evolução do biofilme e as intercorrências operacionais. Por outro lado, modelos multifásicos acoplados, embora estatisticamente robustos, exigem alto custo computacional, sendo talvez pouco práticos para a análise operacional.

Diante disso, o problema de pesquisa é: Como desenvolver um modelo elétrico equivalente que capture adequadamente a dinâmica temporal do desempenho da MFC, e como os parâmetros desse modelo são influenciados pela escolha de diferentes materiais de ânodo (carvão ativado vs. grafite)?

1.3 Objetivo Geral

Investigar e contribuir para a modelagem elétrica de uma MFC, capaz de descrever o seu comportamento dinâmico, fundamentado na análise experimental e comparativa do desempenho de duas configurações de ânodo, a saber: carvão ativado e grafite.

1.4 Objetivos Específicos

- a. Entender os conceitos e os aspectos construtivos de MFCs;
- b. Promover ensaios em laboratório, com suporte do time do Laboratório de Biotecnologia Ambiental (e-biotech) do Depto. de Engenharia Química da Universidade Federal de Santa Catarina;
- c. Analisar os resultados obtidos com foco na geração de eletricidade;
- d. Propor modelo elétrico para as MFCs;
- e. Propor estudos futuros;

1.5 Estrutura do Trabalho

O trabalho está estruturado em cinco capítulos:

- Capítulo 1 - Introdução: Apresenta-se o tema central da pesquisa, a justificativa para o estudo das MFCs, a definição do problema de pesquisa focado na modelagem elétrica, os objetivos geral e específicos do trabalho e a estrutura deste documento.
- Capítulo 2 - Fundamentação Teórica: Revisa-se a literatura para a compreensão do trabalho. São abordados os princípios de geração de eletricidade em MFCs, seus aspectos construtivos, os métodos de rastreamento de máxima potência (MPPT), e a integração com a produção de biohidrogênio. O capítulo foca, por fim, nas diferentes abordagens de modelagem elétrica de MFCs, desde modelos resistivos simples até complexos modelos bioeletroquímicos.
- Capítulo 3 - Metodologia: Descreve detalhadamente o aparato experimental e os procedimentos utilizados na pesquisa. Inclui a montagem das duas MFCs de câmara dupla, a caracterização dos materiais de ânodo (carvão ativado e grafite), a composição do inóculo e da solução de alimentação sintética, e o sistema de aquisição de dados e monitoramento.
- Capítulo 4 - Resultados: Apresenta a análise e a discussão aprofundada dos dados coletados durante os 160 dias de operação. O capítulo abrange o pré-processamento dos dados, a decomposição das séries temporais (STL) para análise de tendência e sazonalidade, a detecção de anomalias e pontos de

mudança (PELT) correlacionados com intercorrências operacionais, a caracterização eletroquímica por curvas de polarização, a análise de eficiência (Remoção de DQO e Eficiência Coulômbica) e a proposição da modelagem matemática e do modelo elétrico equivalente dinâmico.

- Capítulo 5 - Conclusão: Sintetiza os principais resultados do estudo, com foco na comparação de desempenho entre os ânodos. Verifica-se o atendimento aos objetivos propostos, discutem-se as limitações da pesquisa e são sugeridas recomendações para trabalhos futuros.

1.6 Sobre o autor

Renan M. Nogueira possui graduação em Engenharia Elétrica pela Universidade Federal de Santa Catarina (UFSC), concluída em 2017, e MBA em Eficiência Energética e Energias Renováveis. Atualmente é aluno do Mestrado Profissional em Sistemas de Energia Elétrica no Instituto Federal de Santa Catarina (IFSC). Desde 2019, atua profissionalmente no setor de energias renováveis, com ênfase em energia fotovoltaica. Seu interesse por tecnologias para fontes renováveis motivou sua dedicação ao estudo das MFCs como alternativa promissora para a geração sustentável de energia e para o aproveitamento de resíduos orgânicos.

Durante o desenvolvimento deste trabalho, o autor contou com a colaboração do Grupo de Pesquisas em Computação Científica para Engenharia (PECCE) e do Laboratório de Biotecnologia Ambiental (e-biotech) da UFSC, destacando-se a parceria técnica com a pesquisadora Rayane Kunert Langbehn, cuja colaboração foi fundamental para a realização deste estudo.

Este estudo integra o projeto “Rede Sul de Hidrogênio Verde - Novos materiais e intensificação de processos para produção de hidrogênio verde a partir de fontes renováveis”, financiado pela Chamada CNPq/MCTI/FNDCT Nº 24/2022 – Apoio ao Sistema Brasileiro de Laboratórios de Hidrogênio (SisH₂-MCTI), Processo 407957/2022-7, sob coordenação do Prof. Dachamir Hotza. O trabalho resultante desta pesquisa foi submetido, aprovado e apresentado no XXVIII Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE 2025). O referido material encontra-se no Anexo C.

2 FUNDAMENTAÇÃO TEÓRICA

A transição para uma matriz energética sustentável é um dos desafios mais prementes do século XXI, impulsionada pela necessidade de mitigar os efeitos das mudanças climáticas associadas ao uso de combustíveis fósseis. Nesse cenário, tecnologias consolidadas como a energia solar fotovoltaica e a eólica representam pilares fundamentais para a geração de energia em larga escala. Contudo, a diversificação das fontes e a exploração de tecnologias emergentes são cruciais para a construção de um futuro resiliente e ambientalmente responsável conforme IEA (2023).

Dentro desse contexto se encontram as biocélulas combustíveis, também conhecidas como células a combustível microbianas (*Microbial Fuel Cells* - MFCs). Embora os primeiros estudos sobre geração de eletricidade através de microrganismos em compostos orgânicos possuam mais de 100 anos desde sua descoberta por Potter (1911), apenas a partir de meados de 2010 o tema voltou a ganhar maior destaque na comunidade científica.


As MFCs voltaram a se destacar recentemente, segundo Santoro *et al.* (2017), devido a sua possibilidade de trabalhar com efluentes, podendo ser utilizadas para gerar eletricidade e realizar tratamento das águas residuais, dando um papel então duplo a esse tipo de tecnologia. Elas representam um processo multidisciplinar, onde é necessário entendimento de diferentes áreas de engenharia e exatas.

As MFCs oferecem diversos benefícios que são de grande interesse para o setor energético e de tratamento de efluente. Do ponto de vista energético, elas são uma fonte direta de geração de eletricidade, possuem menor custo energético pela substituição do tratamento aeróbio por um anaeróbio e sua aplicação pode ser centralizada ou descentralizada. Na perspectiva ambiental, as MFCs promovem a depuração de águas, possuem baixa pegada de carbono e produzem menor volume de lodo para descarte. (Langbehn, 2023, p. 39)

Para compreender como as MFCs funcionam, é essencial entender seus princípios bioeletroquímicos. "Uma MFC utiliza bactérias exoeletrogênicas para converter diretamente substratos biodegradáveis em eletricidade." (Park; Ren, 2012, p. 151). Essa característica permite que as MFCs atuem tanto como fontes de energia para gerar eletricidade quanto como sistemas eficazes de tratamento de efluentes.

O processo bioeletroquímico nas MFCs é descrito por Du, Li e Gu (2007) como um processo que converte a energia das ligações químicas de compostos orgânicos em energia elétrica por meio de reações catalisadoras por microrganismos em condições anareóbias. Esse processo pode ser visualizado na Figura 1, onde se observa uma presença de duas câmaras, ânodo e cátodo, conectadas através de um separador, que pode ser uma membrana polimérica trocadora de prótons, troca iônica, ponte salina ou cerâmica.

Segundo Kim e Lee (2010), o eletrodo do ânodo é colocado em ambiente anóxico, já o cátodo geralmente é mantido em ambiente aeróbio, onde é alimentado por oxigênio. Contudo, outros aceptores de elétrons também podem ser utilizados. A transferência de elétrons acontece devido a oxidação do substrato, por ação de bactérias, que irão levar os elétrons até o cátodo por um circuito externo, resultando na geração de eletricidade. Os prótons por sua vez, migram através da membrana que separa as câmaras. A Figura 1 ilustra esse processo.





Fonte: Adaptado de Vishwanathan (2021, p. 248).

A eficiência deste processo depende diretamente das diferentes configurações e componentes físicos da célula. O projeto do reator, o substrato utilizado, os materiais do ânodo e do cátodo e a disposição dos eletrodos são fatores determinantes que afetam a geração de eletricidade de Ida e Mandal (2023). Esses elementos construtivos serão detalhados adiante na seção 2.2.

2.1 Geração de eletricidade em MFCs

A geração de eletricidade em MFCs baseia-se na atividade de microrganismos que oxidam matéria orgânica, convertendo-a em energia elétrica de maneira eficiente. Para aprofundar o entendimento sobre o funcionamento dessas células, é essencial analisar seu equacionamento, conforme discutido por Schröder (2018), Langbehn (2023) e Logan (2008). Nesse contexto, a reação química pode ser vista como a etapa fundamental que descreve os processos de oxidação na câmara anódica e de redução na câmara catódica, permitindo a conversão bioeletroquímica de energia. As Equações 1, 2 e 3 apresentam a representação desses processos.



2.1.1 Tensão, potência e densidade de potência em MFC

As MFCs podem ser consideradas como uma célula galvânica, onde sua tensão é representada pela Equação 4.

$$E_{MFC} = -\frac{\Delta G}{nF} \quad (4)$$

Onde:

ΔG = energia livre de Gibbs ($J \cdot mol^{-1}$)

n = número de elétrons (mol)

F = constante de Faraday

Além disso, a tensão pode ser então decomposta na diferença entre tensão do ânodo e do cátodo. Onde o ânodo E_{MFC} possui equacionamento conforme a Equação 5.

$$E_{MFC} = E^0 - \frac{RT}{nF} \ln k \quad (5)$$

Onde:

E^0 = Potencial padrão do eletrodo (definido por cada reação)

k = constante de equilíbrio químico da reação

R = constante dos gases ideais ($J \cdot mol^{-1} \cdot K^{-1}$)

T = Temperatura do sistema em kelvin

Rozendal *et al.* (2008) chega a um potencial teórico de 1,1V para a oxidação de acetato em condições padrão de pH 7 e 298,15 K. No entanto, como demonstrado pela Equação 5, o potencial real (E) é dependente da temperatura e das atividades das espécies químicas, resultando em valores práticos observados por Logan (2008) que variam entre 0,3 V e 0,7 V. A potência de saída de uma MFC pode ser encontrada adicionando uma resistência externa R_{ext} e pode ser vista na Equação 6.

$$P = \frac{E_{MFC}^2}{R_{EXT}} \quad (6)$$

Onde E_{MFC} é a tensão do anodo em V e R_{EXT} a resistência externa utilizada no circuito.

Apenas a potência não traz um resultado que pode ser comparado, uma vez que reatores possuem aspectos construtivos que irão variar entre cada modelo, logo, podemos dividir a Equação 6 pela área da superfície do ânodo (A_{Anodo}), assim chegando à Equação 7 de densidade de potência.

$$P_{An} = \frac{E_{MFC}^2}{A_{Anodo} R_{EXT}} \quad (7)$$

Em algumas situações, segundo Cheng, Hong e Logan (2006), Logan (2008), pode-se utilizar a área do cátodo para da densidade de potência, substituindo A_{Anodo} por A_{Catodo} . Outra forma muito encontrada na literatura de representação da densidade de potência é através da utilização do volume total do reator conforme Equação 8.

$$P_v = \frac{E_{MFC}^2}{v R_{EXT}} \quad (8)$$

Ainda segundo a Logan (2008), MFCs possuem grandes variações de densidade de potência em W/m^3 , onde em algumas se encontra valores na casa dos *miliwatts*, enquanto em outras se encontra centenas de *watts*. Essa variação ocorre devido a resistência interna R_{int} , que depende do aspecto construtivo dos reatores e da matéria orgânica utilizada.

2.1.2 Resistência interna

Existem distintas formas de avaliar a resistência interna de uma MFC. Segundo Jiang *et al.* (2021) e Logan (2008), os mais relevantes são:

- a. curva de polarização;
- b. pico de densidade de potência;
- c. interrupção de corrente;
- d. espectroscopia de impedância eletroquímica.

A curva de polarização pode ser definida pela tensão em função da corrente, conforme Equação 9, onde OCV é a tensão em circuito aberto.

$$E = OCV - IR_{int} \quad (9)$$

O pico de densidade de potência pode ser definido pela Equação 10, quando a resistência interna R_{int} e a resistência externa R_{ext} se iguala.

$$P_{max} = \frac{E_{emf}^2 R_{ext}}{(R_{int} + R_{ext})^2} = \frac{E_{emf}^2}{4R_{int}} \quad (10)$$

A interrupção de corrente requer uso de um potenciostato, um instrumento capaz medir a corrente de um sistema eletroquímico enquanto varia seu potencial. Segundo Logan *et al.* (2006), opera-se a célula até que não haja perdas por concentração, então, a MFC é colocada em circuito aberto e uma curva íngreme de tensão é observada pelo equipamento em escalas de até microssegundos. A curva observada é então utilizada para calcular a resistência interna pela lei de Ohm.

Por último, o método de espectroscopia de impedância eletroquímica apresenta resultados mais precisos para determinar a resistência interna. Além disso, permite o uso de suas informações para associá-los a um circuito elétrico equivalente (He; Mansfeld, 2008).

2.1.3 Métricas de Eficiência de Remoção de DQO e Eficiência Coulômbica

O desempenho de MFCs é avaliado por uma ótica dupla, refletindo sua capacidade simultânea de tratamento de efluentes e geração de energia. Do ponto de vista do tratamento, a métrica principal é a Eficiência de Remoção de Demanda Química de Oxigênio (DQO). Ela quantifica a porcentagem de matéria orgânica (poluente) que foi consumida pelos microrganismos no reator. Uma alta eficiência de remoção de DQO indica que a MFC é um sistema eficaz para o tratamento da água residual (Logan *et al.*, 2006; Slate *et al.*, 2019). Estudos experimentais demonstram que taxas de remoção acima de 85% são comuns em configurações otimizadas, contribuindo para a depuração de efluentes industriais e domésticos (Ali *et al.*, 2017).

Do ponto de vista energético, a métrica fundamental é a Eficiência Coulômbica (EC). A EC define a eficiência da conversão de energia: ela mede a razão entre a quantidade total de elétrons recuperados como corrente elétrica no circuito e a quantidade teórica máxima de elétrons que estava disponível na matéria orgânica (DQO) que foi removida (Santoro *et al.*, 2017).

É crucial analisar ambas as métricas em conjunto. Um sistema pode ter alta remoção de DQO (bom tratamento), mas baixa Eficiência Coulômbica. Isso significa que a maior parte dos elétrons da matéria orgânica foi "perdida" para processos metabólicos concorrentes, como a metanogênese (produção de metano) ou a síntese de nova biomassa (crescimento celular), em vez de ser direcionada para o ânodo para

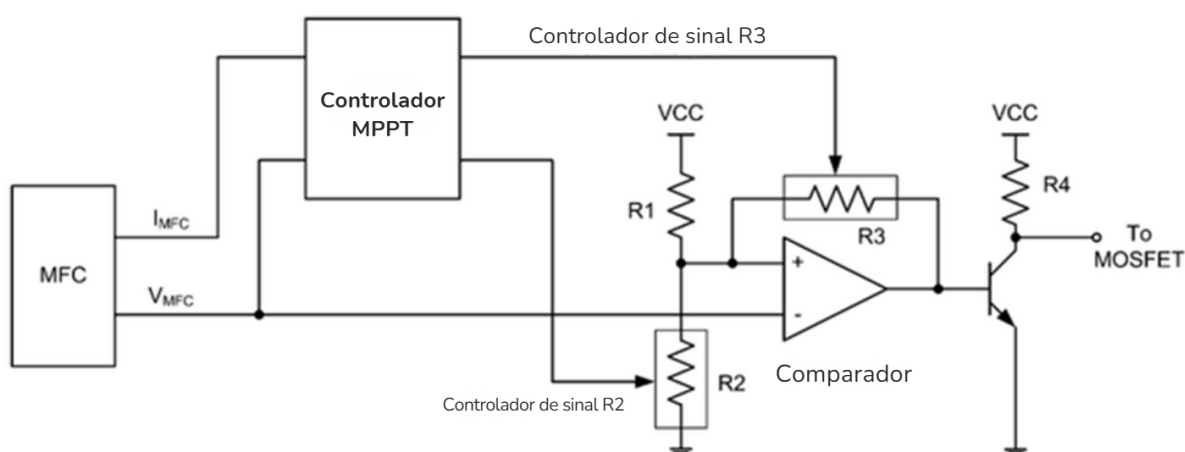
a produção de eletricidade (Jalili *et al.*, 2024). Portanto, a EC é o indicador-chave da eficácia do biofilme eletrogênico.

2.1.4 Rastreamento de máxima potência em MFCs

O usual é analisar o equacionamento e o funcionamento das MFCs com a aplicação de resistores, porém, sua natureza de extrema variação devido ao seu aspecto construtivo, substrato, microrganismos, eletrodo e membrana, evidencia a necessidade de uma melhor metodologia de experimentação e desenvolvimento de aplicações comerciais.

Park e Ren (2012) sugerem em seu trabalho, a aplicação do rastreamento de máxima potência (*Maximum power point tracking - MPPT*) através de potenciômetros controlados digitalmente. O trabalho propõe a aplicação conforme Figura 2.

Figura 2 — Controlador MPPT com potenciômetro digital



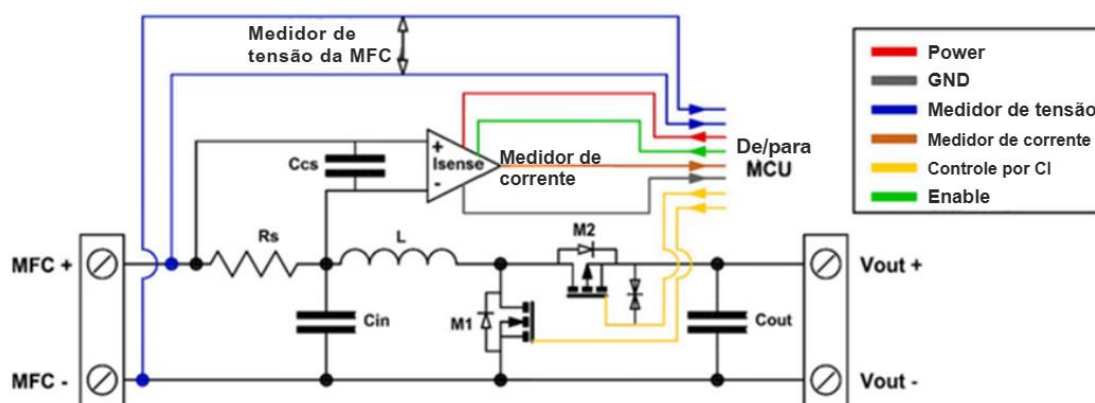
Fonte: Adaptado de Park e Ren (2012, p. 152).

Entretanto, o uso de tal abordagem é refém de um elemento resistivo para análise. Embora o trabalho Park e Ren (2012) tenha obtido bons resultados do ponto de vista de extração de energia, ele fica aquém do esperado na transferência de energia para os capacitores devido às perdas que ocorrem nos diodos, conforme estudado pelos mesmos autores em Wang, Park e Ren (2012), onde somente 36% é obtido como energia líquida.

O trabalho de Fernandez Feito, Younas e Richard M. (2023) utiliza uma técnica mais robusta de algoritmo de condutância incremental, com uso de MOSFETs e

solução de controle robusta. Os trabalhos de Mukherjee *et al.* (2022), Dutta *et al.* (2022), Gul *et al.* (2021) analisam as diferentes técnicas implementadas na literatura para sistemas de gerenciamento de energia (*Power Management System - PMS*). O esquemático proposto por Fernandez Feito, Younas e Richard M. (2023) pode ser visto na Figura 3. O estudo chega a bons resultados de eficiência (87%) para o conjunto de MFCs analisadas, estabelecendo um bom indicativo para desenvolvimento da solução para aplicação no desenvolvimento do trabalho.

Figura 3 — Esquemático de conversor BOOST para MFC

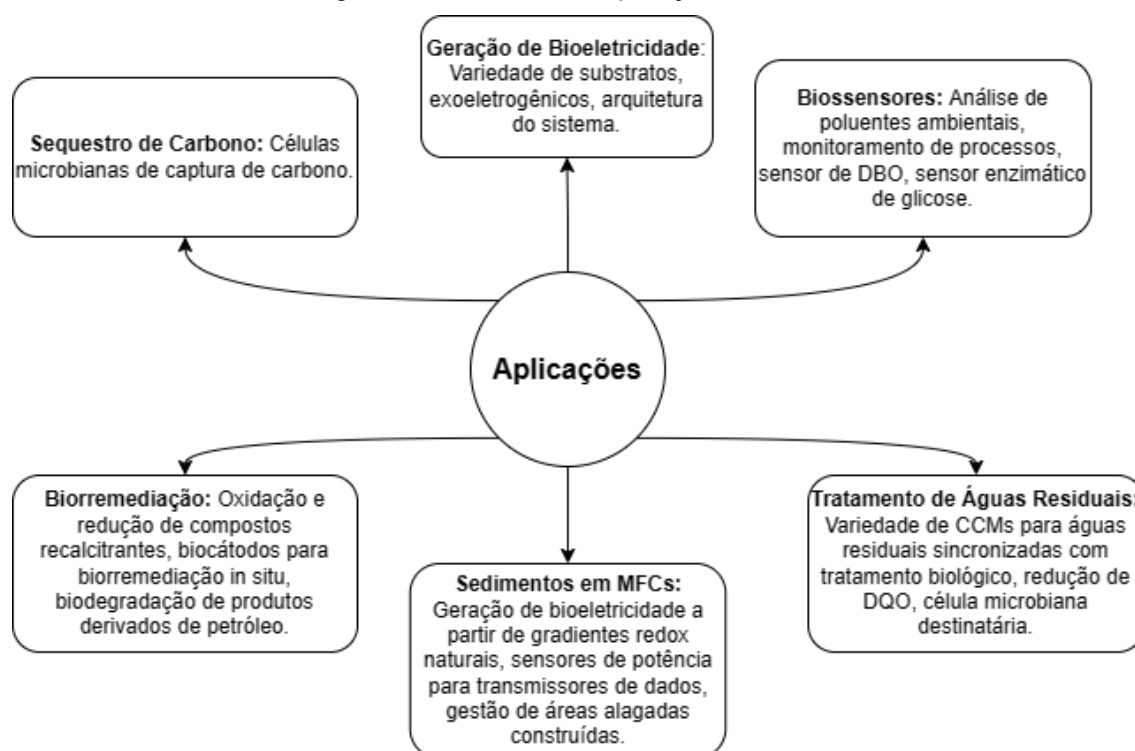


Fonte: Adaptado de Fernandez Feito, Younas e Richard M. (2023, p. 4).

2.2 Construção de MFCs

MFCs possuem distintos métodos construtivos, onde seu método de construção poderá ter diferentes objetivos e possuir distintas aplicações como visto na Figura 4.

Figura 4 — Cenários de aplicações de MFCs



Fonte: Adaptado de Shah, Venkatramanan e Prasad (2019, p. 209).

Fundamentalmente, as MFCs consistem dos seguintes elementos construtivos, conforme descrito por Langbehn (2023) e Ishii *et al.* (2013):

1. **Cátodo:** é responsável pela aceitação de elétrons e é onde ocorre a reação de redução, geralmente de oxigênio, conforme visto na Equação 1.
2. **Ânodo:** é responsável pela oxidação dos substratos orgânicos, liberando elétrons, que fluem através do circuito externo e prótons, que atravessam a membrana de troca catiônica.
3. **Circuito externo e Eletrodo:** são responsáveis por coletar os elétrons do lado anódico e transportá-los até o lado catódico. Para isso, utiliza materiais condutores (eletrodos) que ficam inseridos nas respectivas câmaras (anódica e catódica).
4. **Membrana de troca catiônica (PEM):** é responsável por permitir a passagem dos prótons, enquanto restringe a passagem dos elétrons e difusão do oxigênio entre as câmaras.
5. **Reator:** é responsável por integrar todos os elementos da MFCs conforme estrutura física. Segundo Prasad e Panda (2018), diferentes configurações são

observadas como: Câmara dupla, Câmara simples, Placa plana, Empilhadas e Papel.

6. **Substrato:** é o elemento que serve tanto como combustível para os microrganismos quanto como fonte de elétrons. Compostos simples como acetato, glicose e efluentes sintéticos são comumente utilizados por microrganismos eletrogênicos, que realizam oxidação preferencial em condições anaeróbias (PMC, 2022). A escolha do substrato é determinante para a eficiência da MFC, especialmente em sua aplicação no tratamento de águas residuais. Para geração de eletricidade, pode ser visto na Tabela 1 alguns dos materiais utilizados

Tabela 1 — Microrganismos e substratos em MFCs para gerar eletricidade

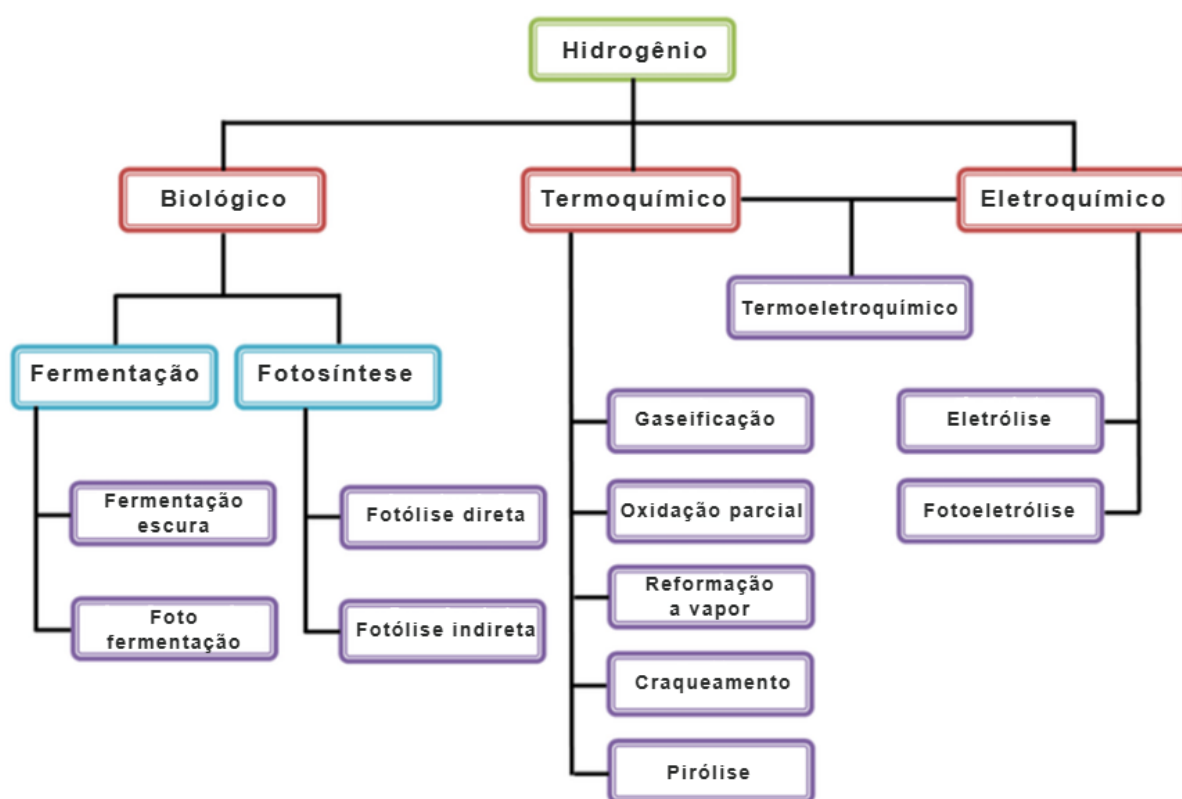
Microorganismos	Substratos	Densidade de corrente/potência
<i>Rhodoferrax ferrireducens</i>	Glucose, sucrose, maltose, xilose	158 mW/m ²
<i>Pseudomonas aeruginosa</i>	Piocianina	4310 mW/m ²
<i>Saccharomyces cerevisiae</i>	Glucose	16 mW/m ²
<i>Pseudomonas sp.</i>	Peptona	979 mA/cm ²
<i>Klebsiella pneumoniae strain L17</i>	Glucose	34,77 mW/m ²
<i>Shewanella oneidensis strain 14063</i>	Piruvato sódico	> 40 mW/m ²
<i>Escherichia coli strain K-12</i>	Sucrose	215 mW/m ²
Bacteria degradação de celulose	Celulose	188 mW/m ²
Efluente termofílico de digestão anaeróbica de cervejaria	Acetato	1030 mA/cm ²
<i>Gammaproteo and Shewanella affinis</i> (KMM3586)	Cisteína	36 mW/m ²
<i>Desulfobulbus and Clostridium</i>	Hidroaleto de palha de arroz	137.6 mA/cm ²
<i>Fly ash leachate</i>	Efluente de fermentação	85.07 mA/cm ²

Fonte: Adaptado de Shah, Venkatramanan e Prasad (2019).

2.3 Biohidrogênio

A produção de biohidrogênio em MFCs emerge como uma vertente inovadora dentro das aplicações dessas células, ampliando seu escopo além da geração de eletricidade. Por meio dessa abordagem, é possível transformar resíduos orgânicos em hidrogênio, um combustível limpo, renovável e altamente armazenável, com potencial significativo para reconfigurar a matriz energética global. A Figura 5 apresenta as diferentes possibilidades de produção de hidrogênio.

Figura 5 — Métodos de produção de hidrogênio



Fonte: Adaptado de Singh *et al.* (2015, p. 13064).

Efluentes possuem diversos usos, destacando-se a exploração da tecnologia de células a combustível ou células de eletrólise com o intuito de realizar a cogeração de eletricidade e hidrogênio. As MFCs podem ser modificadas e aprimoradas, tornando-se uma técnica alternativa para a geração de hidrogênio descentralizado em conjunto com o tratamento de resíduos/efluentes. (Arun *et al.*, 2024; Ahmed *et al.*, 2022). Entretanto, segundo Saravanan *et al.* (2023), a eficiência de MFCs é baixa

quando comparada a células de eletrólise microbiana (*Microbial electrolysis cells* - MEC). Nesse sentido, a integração de MFCs e MECs surge como abordagem promissora para cogeração de hidrogênio e eletricidade, uma vez que cada tecnologia pode atuar em etapas complementares ou em paralelo, otimizando tanto a recuperação energética quanto o tratamento de efluentes. Isso porque, enquanto as MFCs geram eletricidade diretamente por oxidação microbiana, as MECs exigem uma pequena tensão adicional para produzir hidrogênio a partir dos elétrons gerados. Assim, a corrente elétrica gerada pela MFC pode ser aproveitada ou complementada para produção posterior de hidrogênio em uma MEC.

Na prática, quanto à produção de biohidrogênio, os MECs se destacam por sua capacidade de superar barreiras termodinâmicas ao introduzir uma pequena tensão externa (tipicamente $> 0,3$ V), o que incentiva a evolução de hidrogênio a partir de prótons e elétrons gerados no ânodo, um processo difícil de ser espontâneo em MFCs tradicionais (Chakma *et al.*, 2025). Esse conceito tem sido explorado com sucesso em sistemas de duas câmaras utilizando substratos como acetato ou efluentes domésticos, obtendo-se recuperação de elétrons entre 60% e 78%, e rendimento superior a 90% dos elétrons convertidos em hidrogênio.

O desempenho pode ser melhorado ainda mais com o aperfeiçoamento do cátodo, por exemplo, com catalisadores como sulfeto de ferro (FeS) em reatores MEC, que impulsionam significativamente a reação de evolução de hidrogênio segundo Qing, Noori e Min (2025). Outra abordagem promissora é integrar fermentação escura seguida de MFC ou MEC, como no caso do soro de queijo (Wenzel *et al.*, 2017) ou resíduos de jaca (Chandra *et al.*, 2025), resultando em aumento da densidade de potência e produção energética global.

2.4 Sugestão metodológica para o desenvolvimento de Modelos de Circuitos Elétricos Equivalentes para Sistemas Bioquímicos

A tradução de fenômenos bioquímicos complexos para modelos de circuitos elétricos equivalentes (*Equivalent Circuit Models* - ECMs) é uma ferramenta poderosa para analisar a dinâmica do sistema, identificar etapas limitantes e prever seu comportamento (Li *et al.*, 2022). Esta seção detalha uma sugestão de metodologia sistemática, em sete etapas, para construir e validar tais modelos, garantindo ao

mesmo tempo a reprodutibilidade e a robustez, em conformidade com as melhores práticas para modelagem computacional em biologia (Porubsky et al., 2020). O processo abrange desde a delimitação do escopo experimental até a documentação final do modelo.

Ressalta-se, contudo, que esta metodologia é apresentada como uma fundamentação teórica idealizada. Os procedimentos descritos não foram necessariamente aplicados em sua integralidade no escopo experimental desta dissertação, uma vez que os protótipos de MFC utilizados foram construídos e operados nas instalações do Laboratório de Biotecnologia Ambiental (e-biotech) da Universidade Federal de Santa Catarina (UFSC), sob a condução técnica dos pesquisadores vinculados àquele laboratório, com destaque para a colaboração da Dra. Rayane Kunert Langbehn. Portanto, os passos a seguir descrevem o "estado da arte" metodológico recomendado para o desenvolvimento de tais modelos.

1. Definição do Escopo Bioquímico

A primeira etapa consiste na delimitação precisa do sistema a ser modelado, estabelecendo seus limites, objetivos e condições de operação. O foco do modelo deve recair sobre a dinâmica de processos-chave, tais como a cinética de crescimento microbiano, utilizando o Modelo de Monod e mecanismos de inibição, o transporte de íons e metabólitos, e a difusão através de membranas (Thouand, 2021). Nesse contexto, o propósito fundamental é desenvolver uma ferramenta capaz de prever taxas de reação, identificar e quantificar resistências (sejam elas microbianas ou relacionadas à difusão), modelar respostas transientes e avaliar a eficiência do sistema. Para garantir sua aplicabilidade, o modelo deve ser projetado para operar dentro de faixas experimentais relevantes de concentração de substrato, temperatura, pH e tempo de reação.

2. Instrumentação e Aquisição de Dados

A qualidade dos dados experimentais é fundamental para a fidelidade do modelo, exigindo que a aquisição siga protocolos rigorosos para garantir a reprodutibilidade (Porubsky et al., 2020). Nesse contexto, a instrumentação adequada desempenha um papel central, devendo ser empregados espectrofotômetros para a

conversão de absorvância em concentração, potenciômetros para a medição precisa de pH e íons específicos, além de biossensores amperométricos.

Para assegurar a confiabilidade dessas medições, procedimentos de calibração devem ser sistematicamente seguidos, incluindo a construção de curvas-padrão de concentração e a verificação periódica do tempo de resposta dos eletrodos. Simultaneamente, o controle experimental deve ser rigoroso, mantendo condições que garantam a homogeneidade da mistura, por meio de agitação constante, a estabilidade térmica e, quando a especificidade do ensaio exigir, a esterilidade do meio. Por fim, o registro de dados deve ocorrer em intervalos de tempo curtos, na escala de segundos a minutos, permitindo a captura da dinâmica dos transientes, e deve contemplar repetições biológicas para que se possa avaliar a variabilidade intrínseca do sistema.

3. Estrutura de Excitação do Sistema

Para caracterizar a dinâmica do sistema, devem ser aplicadas perturbações controladas que permitam a análise de sua resposta. O sistema deve ser excitado através de mecanismos como a adição de pulsos de substrato, variações controladas de pH ou alterações nos níveis de oxigenação. Tais procedimentos exigem um Planejamento Experimental (*Design of Experiments - DOE*) rigoroso, no qual variações sistemáticas nas concentrações de entrada são realizadas, empregando-se controles positivos e negativos para validar as respostas observadas. Nesse arcabouço metodológico, o estímulo químico, seja substrato ou indutor, deve ser definido como o sinal de entrada, enquanto a variável medida (como produto, corrente ou absorvância) deve ser tratada como o sinal de saída.

4. Formulação das Analogias Físico-Elétricas

A construção do Modelo de Circuito Equivalente (MCE) fundamenta-se no estabelecimento de analogias diretas entre os domínios bioquímico e elétrico, uma abordagem já consolidada na literatura para sistemas bioeletroquímicos (Li et al., 2022). Sob essa ótica, a taxa de reação, entendida como o fluxo de moléculas, assume o papel análogo ao da corrente elétrica no circuito, permitindo, por exemplo, que a saturação enzimática (V_{max}) seja representada por uma fonte de corrente limitada. Em paralelo, a concentração de espécies químicas, que reflete o acúmulo de

substrato ou produto no sistema, encontra sua correspondência na tensão elétrica ou na carga armazenada em um capacitor. As restrições físicas ao movimento dessas espécies, como as barreiras à difusão e a resistência ao transporte de massa através de membranas, são modeladas pela inserção de resistores. Por fim, para representar os processos biológicos ativos que demandam consumo energético (como o uso de ATP no transporte ativo), utilizam-se fontes de tensão ou corrente controladas, completando a tradução dos fenômenos biológicos para a linguagem de circuitos.

5. Estimação dos Parâmetros do Modelo

A calibração do modelo é uma etapa crítica que deve envolver o ajuste preciso de seus parâmetros aos dados experimentais. Nesse processo, constantes cinéticas fundamentais, como a velocidade máxima da reação V_{max} (velocidade máxima da reação), K_m (constante de Michaelis-Menten) e K_i (constante de inibição) devem ser estimadas por meio de técnicas de regressão não linear, utilizando métodos como o dos mínimos quadrados. Para viabilizar esse ajuste, as taxas reacionais observadas experimentalmente (ex: $\Delta[\text{produto}]/\Delta t$) devem ser convertidas em suas correntes elétricas equivalentes. Além disso, é imperativo que o processo de otimização incorpore restrições matemáticas rigorosas para garantir que os parâmetros resultantes mantenham um significado físico e biológico plausível ($V_{max} > 0$, $K_m > 0$).

6. Validação do Modelo

Por fim, a capacidade preditiva do modelo deve ser rigorosamente testada. Para tanto, recomenda-se a aplicação de técnicas de validação cruzada, onde o modelo deve ser confrontado contra um conjunto de dados experimentais independente, distinto daquele utilizado durante a etapa de estimação. Simultaneamente, deve-se proceder à comparação direta entre a resposta simulada pelo circuito e a resposta experimental, avaliando-se os resíduos gerados para assegurar a ausência de tendências sistemáticas que indiquem erros estruturais. Adicionalmente, a robustez do modelo deve ser verificada simulando seu comportamento sob pequenas perturbações em variáveis operacionais, como temperatura e pH, garantindo a estabilidade da ferramenta frente a variações reais.

7. Documentação e Reprodutibilidade

Para assegurar a transparência e a replicabilidade da pesquisa, deve ser adotado um protocolo de documentação completo, alinhado às melhores práticas da área (Porubsky et al., 2020). No que tange à modelagem, o circuito equivalente deve ser implementado e documentado em softwares padrão da indústria e academia, como SPICE ou MATLAB/Simulink. Adicionalmente, recomenda-se que os dados brutos e os scripts de análise sejam devidamente versionados e preparados para compartilhamento, fomentando a ciência aberta.

Em suma, o experimento bioquímico exige uma documentação realizada com esmero e minúcia para capturar corretamente a dinâmica das reações, sejam elas enzimáticas, difusionais ou de transporte. Essa base de dados fundamenta a representação fiel desses processos no domínio elétrico, onde capacitores representam o armazenamento de concentrações, resistores modelam as resistências difusionais e fontes simulam as reações ou transportes ativos. Desta forma, o modelo elétrico resultante permite simular, de maneira intuitiva e robusta, a cinética e as complexas interações entre as variáveis do sistema.

2.5 Modelos Elétricos para MFCs

As MFCs são dispositivos bioeletroquímicos complexos, cujos processos internos podem ser representados por circuitos elétricos equivalentes que simplificam a análise das respostas de tensão e corrente. Esses circuitos equivalentes típicos utilizam resistores (para perdas ôhmicas e de polarização), capacitores (dupla camada elétron-próton) e, em casos avançados, fontes controladas ou elementos não-lineares (Park; Ren, 2012). A literatura classifica os modelos elétricos de MFC em três categorias principais:

- Modelos simplificados resistivos – usam elementos resistivos para obter estimativas globais de desempenho, mas não capturam a dinâmica não linear do biofilme microbiano. São úteis para diagnósticos básicos (p.ex. $R \sim \Delta V / \Delta I$), porém desconsideram transientes eletroquímicos (Serra; Espírito-Santo; Magrinho, 2020).
- Modelos por impedância complexa – incluem além de resistores, componentes como capacitância de dupla camada e impedância de Warburg para representar difusão de íons. Tais circuitos (p.ex. R_s em série com ramos

(R||C) ou elementos de difusão) podem ajustar espectros de EIS, atribuindo valores de R e C às diferentes etapas do processo eletroquímico (Recio-Garrido; Perrier; Tartakovsky, 2014; Sanchez-Herrera *et al.*, 2014; Potrykus *et al.*, 2025).

- Modelos acoplados bioeletroquímicos – unem equações eletroquímicas (e.g. cinética Butler-Volmer) às cinéticas microbianas e transporte de massa. São implementados em simulações multifísicas (COMSOL, etc.) e fornecem representações mecanicistas, porém com alta complexidade numérica (Kamperidis *et al.*, 2022).


2.5.1 Modelos simplificados resistivos

Em sua forma mais básica, assume-se que a MFC pode ser reduzida a uma única resistência interna equivalente R_{int} . Essa resistência é estimada pela inclinação da região linear da curva de polarização ($\Delta V/\Delta I$). Modelos puramente resistivos são de fácil aplicação e parametricamente ajustáveis, mas são incapazes de reproduzir comportamentos transitórios e não lineares do biofilme ou efeitos capacitivos. Por exemplo, no trabalho de Nogueira *et al.* (2025) um modelo matemático elementar relacionou a tensão e corrente por uma simples EDO (resistor e capacitor), mas notou-se que um resistor fixo não explicava variações observadas ao longo do dia. Dessa forma, embora ofereçam estimativas rápidas, os modelos resistivos isolados negligenciam fenômenos cruciais (crescimento do biofilme, variações de substrato, dupla camada) e são insuficientes para previsão precisa do comportamento dinâmico da MFC.

2.5.2 Modelos de impedância complexa

Para superar limitações dos modelos resistivos simples, emprega-se a Espectroscopia de Impedância Eletroquímica (EIS) e circuitos equivalentes mais sofisticados (He; Mansfeld, 2008). Nestes, a resistência ôhmica total R_s (elétrons e íons) aparece em série, seguida por um ou mais ramos paralelos representando a transferência de carga e capacitâncias da dupla camada. Por exemplo, Lasia (2014) propõem um circuito anódico do tipo $R_s (R_{ct} || C_{dl})$ conforme Figura 6.


Figura 6 — Circuito equivalente com resistência série R_s com ramo paralelo $R \parallel C$ (resistência de transferência e capacitância de dupla camada)



Fonte: O autor (2025).

Esse modelo de três elementos captura parcialmente o fenômeno de polarização de carga. Em um circuito mais completo, podem ser incluídos dois conjuntos $R//C$ (ânodo e cátodo) e um elemento de difusão (Warburg) em série, conforme adotado em muitos ajustes de EIS.

Figura 7 — Circuito equivalente típico em análise EIS de MFC



Fonte: Tabish *et al.* (2023, p. 8).

Neste diagrama, R_s representa a resistência da membrana e eletrólitos, R_1 e R_2 são as resistências de transferência de carga do ânodo e do cátodo, e dois elementos compensadores de fase (CPE) simulam as capacitâncias de dupla camada, devido à natureza porosa dos bioeletrodos (Tabish *et al.*, 2023). O elemento W (Warburg) reflete limitações de difusão iônica. A descrição por EIS detalhada permite separar quantitativamente contribuições individuais de cada processo para a resistência total.

2.5.3 Modelos acoplados bioeletroquímicos

Abordagens bioeletroquímicas integram as reações microbianas com as reações eletroquímicas que ocorrem nos eletrodos das MFCs. Elas incorporam equações de cinética de crescimento microbiano, como o modelo de Monod (1949), que relaciona a taxa de crescimento das bactérias à concentração de substrato disponível, e a equação de Butler–Volmer (1924), que descreve a transferência de elétrons entre o eletrodo e o meio reacional em função da sobrepotencial eletroquímica (Piciooreanu *et al.*, 2007). Essas equações são acopladas a balanços de massa, difusão iônica e transporte de carga dentro do reator, permitindo uma descrição mais fiel dos fenômenos de conversão bioeletroquímica.

Abordagens bioeletroquímicas integram explicitamente as reações microbianas com as reações eletroquímicas. A formulação desses modelos requer o uso de métodos numéricos avançados, como o Método dos Elementos Finitos (*Finite Element Method* - FEM), utilizado para resolver equações diferenciais parciais que descrevem o transporte e as reações no domínio espacial da MFC, e o Método das Diferenças Finitas no Domínio do Tempo (*Finite-Difference Time-Domain* - FDTD), empregado para simular a propagação de campos elétricos e gradientes de potencial ao longo do tempo (Kamperidis *et al.*, 2022). Ambos permitem avaliar distribuições espaciais e temporais de potencial, concentração e corrente em geometrias complexas, mas exigem alto custo computacional e parâmetros físico-químicos muitas vezes difíceis de determinar experimentalmente.

2.5.4 Circuitos equivalentes RC com elementos de membrana e citoplasma

Inspirados em modelos de células biológicas, alguns trabalhos propõem incluir elementos correspondentes à membrana celular e ao citoplasma no circuito equivalente. Seyedi (2025) revisa modelos de célula em que a membrana plasmática é tratada como um capacitor C_m e o citoplasma como uma resistência R_c . Analogamente, em MFCs pode-se interpretar partes do circuito: o eletrodo e o biofilme funcionam como uma camada dupla eletrodo/dupla-camada (capacitor), enquanto as células microbianas e os canais iônicos criam resistências internas. Esses elementos ajudam a explicar comportamentos em diferentes faixas de

frequência e estimulam a inclusão de termos não-lineares (ex. capacitâncias variantes) para melhor fidelidade.

2.5.5 Vantagens e limitações dos modelos equivalentes

Os circuitos equivalentes oferecem vantagens operacionais: são computacionalmente simples, facilmente implementáveis em simuladores elétricos como o SPICE, e permitem isolar e interpretar fenômenos específicos, como perdas ôhmicas, polarizações ativacional e de concentração (Logan; Rabaey, 2012). Por exemplo, permite-se estimar rapidamente a resistência interna a partir da curva de polarização ou separar perdas cinéticas de difusão pela forma do diagrama de *Nyquist* (Zhao *et al.*, 2006). Além disso, a similaridade com modelos clássicos de células (Hodgkin–Huxley) traz insights qualitativos da física envolvida (Seyedi, 2025).

Entretanto, desvantagens importantes são documentadas. Experimentos revelam que circuitos simples não capturam totalmente a dinâmica do biofilme em formação, nem as perdas por polarização e as variações de resistência interna observadas na prática. No trabalho de Nogueira *et al.* (2025) as predições do modelo mostraram diferenças “substanciais” em relação a dados medidos, indicando que aspectos biológicos e físico-químicos (evolução do biofilme, efeitos de campo de pH, etc.) não foram integralmente modelados. Além disso, muitos circuitos clássicos assumem linearidade e parâmetros fixos; na realidade, variáveis como a disponibilidade de substrato ou espessura de camada dupla mudam com o tempo, o que compromete a precisão dessas abordagens frente aos dados reais.

3 METODOLOGIA

O desenvolvimento experimental desta dissertação foi conduzido no Laboratório de Biotecnologia Ambiental da UFSC, conduzido pela Dra. Rayane Kunert Langbehn. A pesquisa integra o projeto “Rede Sul de Hidrogênio Verde - Novos materiais e intensificação de processos para produção de hidrogênio verde a partir de fontes renováveis”, financiado pela Chamada CNPq/MCTI/FNDCT N° 24/2022 – Apoio ao Sistema Brasileiro de Laboratórios de Hidrogênio (SisH2-MCTI), Processo 407957/2022-7, sob coordenação do Prof. Dachamir Hotza.

Para avaliar o desempenho comparativo de duas configurações experimentais, construíram-se, no Laboratório de Biotecnologia Ambiental, duas MFCs de câmara dupla em acrílico, cada câmara com capacidade volumétrica nominal de 150 mL. As câmaras foram separadas por uma membrana de troca catiônica (diâmetro = 5 cm, modelo CMI-7000S, Membranes International), garantindo condução iônica equilibrada e minimizando difusão indesejada entre as zonas anódica e catódica.

A seleção dos eletrodos seguiu critérios de compatibilidade elétrica e microbiológica. Tanto o ânodo quanto o cátodo foram construídos a partir de cartuchos de malha de aço inoxidável (área útil: 2,5 cm × 5,0 cm, 200 mesh; Telas Rocha Ltd., Brasil), servindo como estruturas condutoras robustas. A configuração experimental variou a composição dos eletrodos: na MFC1, utilizou-se 2 g de carvão ativado de casca de coco, material de origem renovável, com alta área superficial e reconhecida eficácia na formação de biofilme; na MFC2, empregou-se grafite granular, amplamente utilizado por sua estabilidade eletroquímica e compatibilidade com microrganismos eletrogênicos.

Os eletrodos foram interligados por meio de uma barra de aço inoxidável, formando o circuito elétrico com um resistor externo de 560 Ω , o qual permitiu a medida contínua da tensão gerada e análise do comportamento elétrico das células.

Como inóculo, utilizou-se lodo ativado proveniente da estação de tratamento de esgoto de Florianópolis (SC, Brasil), introduzido no compartimento anódico para promover o estabelecimento de biofilmes eletroativos. A alimentação utilizou uma solução sintética com composição cuidadosamente definida ($\text{g}\cdot\text{L}^{-1}$): 1,68 $\text{NaC}_2\text{H}_3\text{O}_2$; 0,24 $(\text{NH}_4)_2\text{SO}_4$; 5,88 KH_2PO_4 ; 1,19 K_2HPO_4 ; 2,00 NaHCO_3 ; 0,1 $\text{CaCl}_2\cdot 2\text{H}_2\text{O}$; 0,1 KCl ; 0,1 NaCl ; 0,1 $\text{MgCl}_2\cdot 6\text{H}_2\text{O}$; 0,1 $\text{MgSO}_4\cdot 7\text{H}_2\text{O}$; 0,05 extrato de levedura; 0,005

$\text{MnCl}_2 \cdot 4\text{H}_2\text{O}$; e $0,001 \text{ Na}_2\text{MoO}_4 \cdot 2\text{H}_2\text{O}$, assegurando condições nutricionais balanceadas para o desenvolvimento microbiano.


Inicialmente, operou-se em modo batelada, permitindo o estabelecimento inicial e adaptação dos micro-organismos. Posteriormente, o sistema foi convertido para modo fed-batch, com retenção hidráulica (HRT) variando entre 2 e 4 dias, o que favoreceu o controle operacional e estabilidade da produção de corrente.

No compartimento catódico, utilizou-se água destilada, continuamente aerada por meio de uma pedra porosa conectada a uma bomba de ar (Big Air®, modelo A420), garantindo oxigenação constante e adequada para a reação de redução.

Para manutenção e controle de performance, no 73º dia de operação, o católito foi substituído, e os eletrodos cuidadosamente limpos com escova para remoção de biofilme acumulado. O procedimento foi repetido em 149 dias, perfazendo um total de 160 dias de operação contínua, mantidos sob condições de temperatura ambiente controlada ($23 \pm 1 \text{ }^\circ\text{C}$).


As Figura 8 mostra a bancada onde ocorreu o experimento, na Figura 9 mostra o reator montado e na Figura 10 é feita uma montagem para dar maior clareza as partes do experimento.

Figura 8 — Local que ocorreu experimento




Fonte: O autor (2025).

Figura 9 — Reator do experimento



Fonte: O autor (2025).

Figura 10 — Experimento montado em bancada para ilustração



Fonte: O autor (2025).

1 – MFC1; 2 – MFC2; 3 – Efluente sintético fresco; 4 – Bomba peristáltica; 5 – Bomba de ar; 6 – Arduino; 7 – Notebook; 8 – Ânodo; 9 – Cátodo; 10 – Membrana de troca catiônica. As setas brancas indicam o fluxo do efluente sintético.

4 RESULTADOS

Este capítulo apresenta uma análise do desempenho de duas MFCs de câmara dupla, designadas como MFC 1 (ânodo de carvão ativado) e MFC 2 (ânodo de grafite), operadas por um período superior a 150 dias. A análise integra dados eletroquímicos de alta frequência, medições físico-químicas e caracterização eletroquímica detalhada para avaliar e comparar a geração de energia, a estabilidade operacional e a eficiência no tratamento de efluentes.

Em resumo, os resultados demonstram a superioridade consistente da MFC 1 em termos de geração de tensão e potência, atingindo uma densidade de potência máxima de 49 mW/m², significativamente maior que os 33,4 mW/m² da MFC 2 (utilizando estimativa de área para os eletrodos em 50cm²). A análise da resistência interna, derivada das curvas de polarização, revelou que a MFC 1 possuía uma resistência ôhmica inferior (285 Ω) em comparação com a MFC 2 (410 Ω), contribuindo para menores perdas de tensão e maior eficiência na transferência de potência. A decomposição das séries temporais identificou ciclos diurnos de desempenho correlacionados com a temperatura do laboratório, enquanto a análise de pontos de mudança de regime validou o impacto de intercorrências operacionais, como a exposição do ânodo ao ar e faltas de energia elétrica, destacando a maior resiliência da MFC 1. Em termos de tratamento, ambas as células alcançaram eficiências de remoção de Demanda Química de Oxigênio (DQO) superiores a 85%, mas a MFC 1 exibiu uma Eficiência Coulômbica (EC) média de 25.4%, em comparação com 18.2% da MFC 2, indicando uma conversão mais eficiente da matéria orgânica em corrente elétrica. Coletivamente, os resultados sugerem que a arquitetura do eletrodo de carvão ativado oferece vantagens substanciais tanto para a bioeletrogênese quanto para a robustez operacional do sistema.

4.1 Pré-processamento e Análise Exploratória dos Dados Operacionais

A base para uma análise robusta do desempenho de sistemas complexos como as MFCs reside na qualidade e integridade dos dados coletados. Esta seção detalha os procedimentos de pré-processamento aplicados ao conjunto de dados brutos para garantir sua fidedignidade e, subsequentemente, apresenta uma análise exploratória

para fornecer uma visão macroscópica do comportamento elétrico das duas células ao longo do período experimental.

4.1.1 Limpeza e Validação do Conjunto de Dados

O conjunto de dados principal, consolidado no arquivo `combinado_sort.csv`, agrega medições contínuas de tensão, corrente e potência para ambas as MFCs, além de registros de temperatura, com uma frequência de amostragem de aproximadamente 5 minutos. O processo inicial de tratamento dos dados foi fundamental para corrigir inconsistências e padronizar o formato para as análises subsequentes.

Primeiramente, foi realizado o tratamento de dados ausentes e anômalos. Uma anomalia recorrente identificada foi a presença de leituras de temperatura de -127.0 °C, um valor que indica falha na leitura do sensor. Tais valores foram tratados como dados faltantes e imputados por meio de interpolação linear, utilizando os pontos de dados válidos adjacentes. Essa abordagem preserva a continuidade temporal da série e é adequada para variáveis com variações lentas, como a temperatura ambiente de um laboratório.

Em seguida, a coluna `Data` completa foi convertida para um formato padrão de *datetime*, estabelecendo-a como o índice temporal primário para todas as análises subsequentes. Essa etapa é crucial para garantir o alinhamento correto de todas as séries temporais e a correta interpretação de lags e sazonalidades. As colunas de medição elétrica (Tensão MFC 1 (mV), Corrente MFC 1 (mA), Potência MFC 1 (mW), e as correspondentes para a MFC 2) foram validadas e convertidas para tipos de dados numéricos de ponto flutuante, assegurando a precisão nos cálculos estatísticos e de eficiência. Finalmente, os dados físico-químicos, provenientes do arquivo `fisico_quimicos.xlsx`, e os dados de polarização foram alinhados temporalmente com a série principal, criando um conjunto de dados mestre unificado que permite a análise integrada de variáveis elétricas, químicas e operacionais.

4.1.2 Visualização do Desempenho Elétrico em Longo Prazo


O Figura 11 apresenta a evolução temporal das principais variáveis elétricas, Tensão (mV), Corrente (mA) e Potência (mW), para a MFC 1 e a MFC 2 ao longo de todo o período de monitoramento, que excedeu 150 dias. Esta visualização de longo prazo permite a identificação de distintas fases operacionais e uma comparação direta do desempenho geral entre as duas configurações de ânodo.

A observação mais imediata é a diferença de amplitude no desempenho: a MFC 1 (eletrodo de carvão ativado) mantém um patamar de corrente consistentemente superior (linha azul) ao da MFC 2 (eletrodo de grafite) (linha laranja). Esta superioridade, que é quantificada nas seções seguintes, é a principal métrica de comparação do estudo.

Ambas as células exibem um comportamento semelhante em suas fases operacionais. Observa-se uma fase inicial de maturação (aproximadamente de outubro a meados de dezembro), onde a corrente de ambas as células aumenta gradualmente, refletindo a adaptação e o crescimento da comunidade microbiana. Segue-se um período de operação mais estável (de janeiro a fevereiro), onde o desempenho atinge um nível estável.

Também são visíveis ciclos e interrupções. As quedas abruptas de corrente (vistas, por exemplo, no início de dezembro e início de janeiro) correlacionam-se diretamente com intercorrências operacionais, como faltas de energia elétrica ou troca do católito e limpeza dos eletrodos, que são detalhadas na Seção 4.3. Além disso, no período estável da MFCs, nota-se um padrão repetitivo de picos momentâneos seguidos por um decaimento lento, o que reflete os ciclos de alimentação do sistema.

Figura 11 — Série temporal de corrente durante experimento



Fonte: O autor (2025).

4.1.3 Análise Estatística Descritiva

Para quantificar as diferenças de desempenho observadas visualmente, foi realizada uma análise estatística descritiva das variáveis elétricas, cujos resultados estão sumarizados na Tabela 2. Esta tabela fornece uma base numérica para a comparação do desempenho central e da variabilidade de cada célula.

Tabela 2 — Estatísticas Descritivas do Desempenho Elétrico das MFCs

Métrica	Corrente MFC 1 (mA)	Corrente MFC 2 (mA)
Média	0,421	0,324
Desvio Padrão	0,152	0,141
Mínimo	0	0
25%	0,334	0,223
Mediana (50%)	0,492	0,353
75%	0,543	0,436
Máximo	0,591	0,520

Fonte: O autor (2025).

Os dados da Tabela 2 confirmam numericamente a superioridade da MFC 1. A corrente média da MFC 1 (0,421 mA) é aproximadamente 30% maior que a da MFC 2 (0,324 mV). Essa diferença é ainda mais pronunciada na potência média, onde a MFC 1 (0.103 mW) supera a MFC 2 (0.062 mW) em cerca de 66%, refletindo a relação quadrática entre corrente e potência ($P = R I^2$).

Além da magnitude, a estabilidade operacional pode ser inferida. Embora o desvio padrão absoluto seja similar, o coeficiente de variação (CV = desvio padrão / média) para a tensão da MFC 1 é de 36.2%, enquanto para a MFC 2 é de 43.6%. Um CV menor para a MFC 1 sugere uma operação relativamente mais estável e previsível em comparação com a MFC 2. A diferença entre a média e a mediana em ambas as células, com a média sendo inferior à mediana, sugere a presença de períodos de baixa performance ou quedas abruptas (intercorrências) que puxam a média para baixo, um aspecto que será explorado em detalhe nas seções subsequentes.

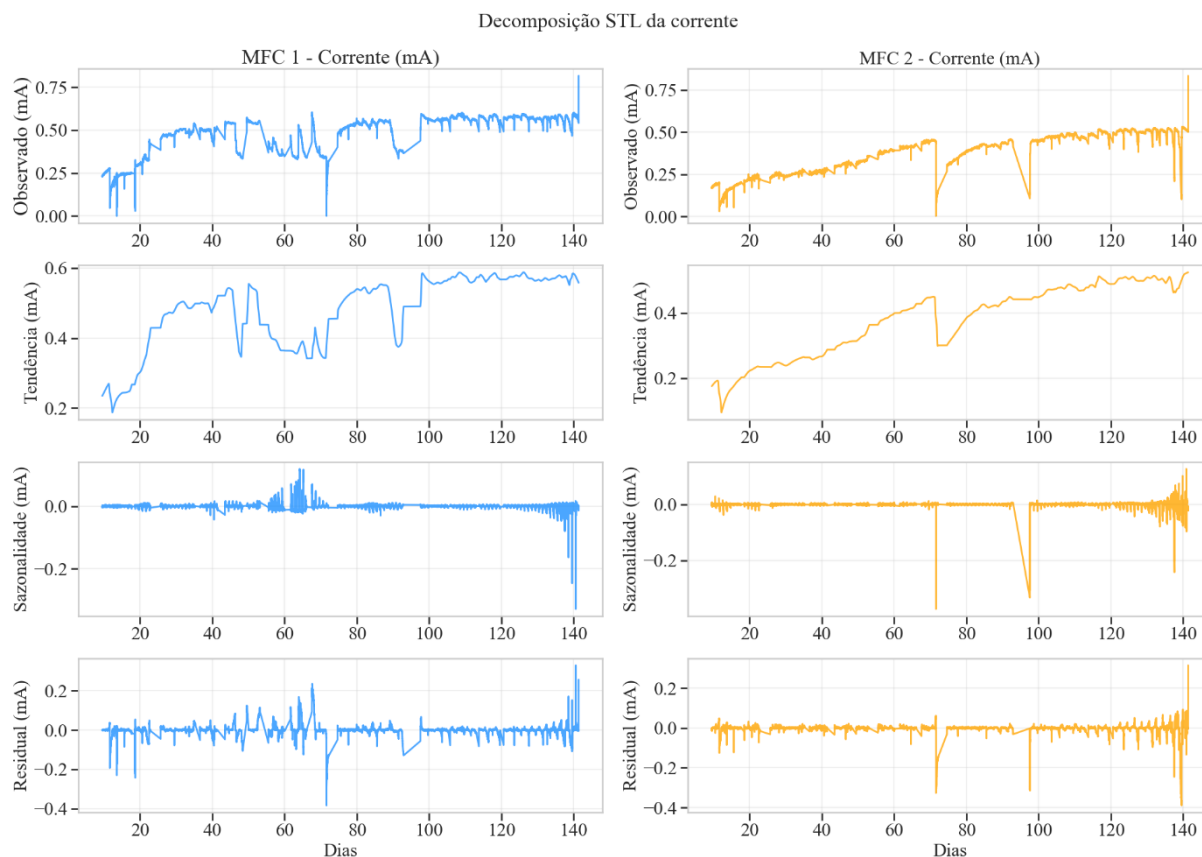
4.2 Decomposição das Séries Temporais e Análise de Padrões Cíclicos

O desempenho de uma MFC é o resultado da sobreposição de múltiplas dinâmicas temporais, incluindo a maturação ou degradação de longo prazo (tendência), ciclos operacionais ou ambientais (sazonalidade) e flutuações aleatórias de curto prazo (resíduo). Para isolar e analisar esses componentes, foi aplicada a técnica de Decomposição Sazonal e de Tendência por Loess (STL), uma metodologia robusta para decompor séries temporais (Cleveland *et al.*, 1990).

4.2.1 Metodologia de Decomposição STL

A análise foi implementada utilizando a função STL da biblioteca *statsmodels* do Python (Seabold; Perktold, 2010). A principal vantagem da STL é sua capacidade de lidar com padrões sazonais que mudam ao longo do tempo, o que é comum em sistemas biológicos. O parâmetro mais crítico na decomposição STL é a definição do período sazonal. Considerando que os dados foram coletados a cada 5 minutos, um dia completo de 24 horas corresponde a 288 pontos de dados (24 horas×12 amostras/hora). Portanto, foi definido um período sazonal de 288 para capturar os padrões cíclicos, que são frequentemente influenciados por variações de temperatura e luminosidade no ambiente laboratorial (não há exposição a luminosidade solar). A decomposição foi aplicada à série temporal de tensão de cada MFC, resultando nos componentes de tendência, sazonalidade e resíduo, conforme ilustrado na Figura 12.

Figura 12 — Decomposição STL - (a) Série Original, (b) Componente de Tendência, (c) Componente Sazonal, (d) Componente Residual



Fonte: O autor (2025).

4.2.2 Interpretação dos Componentes Decompostos

A análise individual de cada componente fornece insights valiosos sobre o comportamento do sistema.

Componente de Tendência: A curva de tendência representa a evolução do desempenho de base da MFC, filtrando as flutuações de curto e médio prazo. Para ambas as células, a tendência mostra um aumento inicial acentuado, correspondente à fase de startup, seguido por períodos de estabilização, degradação e recuperação. A inclinação desta curva em diferentes momentos do experimento reflete a saúde e a atividade de longo prazo do biofilme. Por exemplo, uma tendência decrescente

prolongada pode indicar bioincrustação¹do cátodo, envenenamento do biofilme anódico ou esgotamento de nutrientes essenciais (Noori *et al.*, 2019). Enquanto uma tendência ascendente após uma intervenção (como a limpeza dos eletrodos) quantifica a eficácia dessa manutenção (Rossi *et al.*, 2019). A comparação das curvas de tendência entre as duas MFCs permite avaliar qual delas manteve um desempenho de base mais elevado e estável ao longo dos meses.

Componente Sazonal: Este componente isola o padrão que se repete a cada 24 horas. Para ambas as MFCs, a análise do componente sazonal revela um ciclo diurno claro, com a tensão atingindo um pico durante a tarde e um vale durante a madrugada. Este padrão está fortemente correlacionado com o ciclo de temperatura do laboratório, que naturalmente aumenta durante o dia e diminui à noite. A atividade metabólica das bactérias eletrogênicas é termodependente; temperaturas mais altas aceleram as taxas de reação enzimática, levando a uma maior taxa de oxidação do substrato e, conseqüentemente, a uma maior geração de corrente e tensão. A amplitude do componente sazonal quantifica essa sensibilidade térmica. Uma análise comparativa indica que a MFC 1 exibe uma amplitude sazonal ligeiramente maior, sugerindo que sua comunidade microbiana ou a cinética geral do sistema pode ser mais reativa às flutuações de temperatura.

Componente Residual: Os resíduos representam a variabilidade não explicada pela tendência e pela sazonalidade. Idealmente, os resíduos devem se comportar como ruído branco, sem padrões discerníveis. No entanto, picos ou vales extremos neste componente são fortes indicadores de eventos anômalos ou intercorrências de curto prazo. Este componente é, portanto, ideal para a detecção de outliers. Aplicando a técnica do Intervalo Interquartil (IQR) (Tukey, 1976), pontos residuais que se encontram fora do intervalo são classificados como anomalias. Esses pontos, uma vez identificados, podem ser cruzados com o registro de eventos operacionais para determinar suas causas, o que será o foco da próxima seção.

¹Bioincrustação - acúmulo de micro-organismos em superfícies de membranas, equipamentos e tubulações em meio líquido. Comumente observado em cascos de navios ou em pás de geradores em hidrelétricas

4.3 Análise de Intercorrências e Detecção de Pontos de Mudança de Regime

A operação de longo prazo de biorreatores está sujeita a perturbações, planejadas ou não, que podem impactar significativamente seu desempenho. Esta seção correlaciona as intercorrências operacionais registradas com as dinâmicas observadas nas séries temporais elétricas, utilizando tanto a sobreposição visual de eventos quanto métodos algorítmicos para detectar mudanças de regime no comportamento das MFCs.

4.3.1 Mapeamento de Eventos Operacionais e Análise de Resiliência

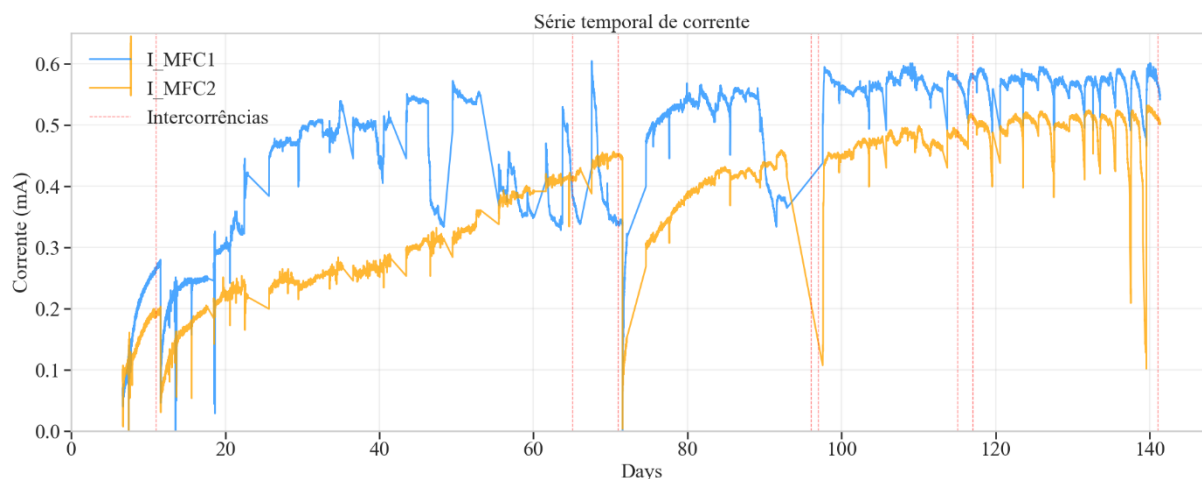
Durante o experimento, alguns eventos operacionais ocorreram e foram mapeados apresentados na Tabela 3 e na Figura 13.

Tabela 3 — Intercorrências durante experimento

Dia	Intercorrência
12	Troca completa do católito (água destilada)
66	Anólito ficou em contato com ar, pois a mangueira de descarte entupiu e a tampa de vedação saiu
72	Troca completa do católito e limpeza mecânica dos eletrodos do cátodo devido à observação de crescimento de biofilme
97	Falta de luz no prédio do EQA entre 08h - 17h
98	Atraso na alimentação (14:05 - 15:00)
116	A alimentação do domingo não aconteceu
117	O meio de alimentação estava velho
142	- Mudança no horário de alimentação para 08h30 - 09h00 - Curva de polarização das 09h00 até 19h30

Fonte: O autor (2025).

Figura 13 — Série Temporal de Corrente com linhas de Intercorrências Operacionais



Fonte: O autor (2025).

A análise da Figura 4.3 permite extrair conclusões sobre a robustez e a resiliência de cada sistema. Por exemplo, a falta de energia elétrica no dia 97 resultou em uma interrupção da aeração e, conseqüentemente, em uma queda acentuada da tensão em ambas as células, devido à depleção do substrato. A taxa de recuperação da tensão após a retomada da operação normal serve como uma medida da capacidade do sistema de se recuperar de uma condição de fome.

O evento mais crítico para a integridade do ânodo ocorreu no dia 66, quando o anólito entrou em contato com o ar. O oxigênio é tóxico para as bactérias anaeróbicas estritas responsáveis pela eletrogênese. Como esperado, esse evento causou uma queda drástica e imediata na geração de tensão em ambas as células. O período subsequente é particularmente informativo. A trajetória de recuperação da tensão — o tempo necessário para retornar ao patamar de desempenho pré-perturbação — é uma medida direta da resiliência do biofilme. A observação de que a MFC 1 se recuperou mais rapidamente que a MFC 2 sugere uma maior robustez de sua comunidade microbiana. Essa resiliência aprimorada pode ser atribuída à microestrutura do ânodo de carvão ativado. Sua alta área de superfície específica e sua rede porosa podem ter fornecido refúgios para porções do biofilme, protegendo-as da exposição total ao oxigênio e permitindo uma recolonização mais rápida da superfície do eletrodo assim que as condições anaeróbicas foram restabelecidas.

A limpeza mecânica dos cátodos no dia 72 resultou em um aumento temporário ou na recuperação da tensão. Esse efeito é esperado, pois a limpeza remove o

biofilme acumulado e possíveis precipitados minerais da superfície do cátodo, melhorando a cinética da reação de redução de oxigênio e diminuindo a resistência interna da célula.

4.3.2 Detecção Algorítmica de Pontos de Mudança de Regime

Enquanto a análise visual é eficaz para eventos conhecidos, mudanças mais sutis no regime operacional podem passar despercebidas. Para identificar objetivamente tais mudanças, foi aplicado o algoritmo *Pruned Exact Linear Time (PELT)* (Killick; Fearnhead; Eckley, 2012)., uma técnica de detecção de pontos de mudança offline disponível na biblioteca *ruptures* para *Python* (Truong; Oudre; Vayatis, 2020). O PELT segmenta a série temporal minimizando uma função de custo penalizada, identificando os pontos no tempo em que as propriedades estatísticas do sinal mudam significativamente. Foi utilizado um modelo de custo baseado em função de base radial (rbf) e um valor de penalidade (pen) ajustado para otimizar a detecção de mudanças significativas de média e variância.

A Figura 14 mostra a série temporal de tensão com os pontos de mudança detectados pelo PELT sobrepostos aos eventos operacionais conhecidos.

Figura 14 — Detecção de Pontos de Mudança de Regime pelo Algoritmo PELT



Fonte: O autor (2025).

A análise dos resultados do PELT, apresentados na Tabela 4, serve a um duplo propósito: validar o impacto de eventos operacionais conhecidos e descobrir transições intrínsecas do sistema. Para a MFC 2, o algoritmo identificou com precisão o evento de limpeza dos cátodos no dia 72, confirmando o impacto imediato e significativo desta intervenção. Curiosamente, para ambas as células, uma mudança foi detectada no dia 76, quatro dias após a limpeza, sugerindo que esse ponto marca a estabilização do sistema em um novo patamar de desempenho superior. De forma similar, a mudança detectada na MFC 1 no dia 98 coincide com o atraso na alimentação, enquanto a mudança na MFC 2 no dia 102 pode ser interpretada como o fim do período de recuperação após a falta de energia do dia 97. Os pontos restantes, que não correspondem diretamente a intercorrências documentadas (e.g., as múltiplas mudanças em outubro e novembro), são igualmente importantes, pois sinalizam transições graduais do sistema, como a maturação do biofilme, o início de

um processo de bioincrustação ou alterações na composição da comunidade microbiana, que não seriam capturadas por uma simples inspeção visual. A Tabela 4 mostra relação dos pontos e uma análise dos eventos.

Tabela 4 — Cronologia de Pontos de Mudança Detectados pelo Algoritmo PELT e Correlação com Eventos Operacionais

Dias	MFC	Análise e Correlação com Eventos
9	MFC1	Mudança durante a fase inicial de startup, provavelmente relacionada à maturação do biofilme.
18-19	Ambas	Mudança de regime após a primeira semana de operação estável.
42 a 56	Ambas	Múltiplas mudanças detectadas, indicando um período de instabilidade ou transição do sistema não documentado.
72	MFC 2	Coincide perfeitamente com a limpeza dos cátodos, validando o impacto do evento.
76	Ambas	Detectado 4 dias após a limpeza. Provavelmente marca a estabilização em um novo patamar de desempenho.
90	MFC 1	Mudança durante o período de recesso, pode estar ligada a variações de temperatura ou alimentação.
98	MFC 1	Coincide com o atraso na alimentação, mostrando a sensibilidade do sistema.
102	MFC2	Fim do período de recuperação após a falta de energia de 02/01.
139-140	MFC2	Mudanças que antecedem os ensaios de polarização e cinética, possivelmente indicando uma mudança de base.

Fonte: O autor (2025).

4.4 Caracterização Eletroquímica e Análise das Perdas de Tensão


Para além do monitoramento de longo prazo, a caracterização eletroquímica fundamental de uma célula a combustível microbiana é realizada através de curvas de polarização. Esta técnica permite determinar parâmetros intrínsecos de desempenho, como a densidade de potência máxima e a resistência interna, e diagnosticar as principais fontes de perda de tensão que limitam a eficiência do

sistema. Os dados para esta análise foram obtidos no dia 141, conforme registro de intercorrências.

4.4.1 Curvas de Polarização e Densidade de Potência

As curvas de polarização foram obtidas variando-se a resistência externa (R_{ext}) conectada ao circuito da MFC, de valores altos (próximos a circuito aberto) a valores baixos (próximos a curto-circuito), e registrando-se a tensão (V) e a corrente ($I=V/R_{ext}$) em cada ponto após a estabilização. A densidade de corrente (J) e a densidade de potência (P_d) foram calculadas normalizando a corrente e a potência ($P=V \times I$) pela área superficial projetada do ânodo, utilizando de uma área estimada de 50cm^2 referente a aos 2 cartuchos de eletrodo pertencentes em cada reator, cada um com medida de $12,5\text{cm}^2$. A Figura 15 apresenta as curvas de polarização e de densidade de potência para ambas as MFCs.

Figura 15 — Curvas de Polarização (Tensão vs. Densidade de Corrente) e Curvas de Densidade de Potência para MFC 1 e MFC 2



Fonte: O autor (2025).

A Figura 15 encapsula a diferença de desempenho eletroquímico entre as duas células. A curva de polarização da MFC 1 situa-se consistentemente acima da curva da MFC 2, indicando que, para qualquer densidade de corrente drenada, a MFC 1 mantém uma tensão de célula mais elevada. Consequentemente, a curva de densidade de potência da MFC 1 atinge um pico significativamente mais alto do que a da MFC 2. O pico dessa curva representa a densidade de potência máxima (P_{max}), que é a principal métrica para comparar a capacidade de geração de energia de diferentes MFCs.

A forma geral da curva de polarização pode ser dividida em três regiões distintas, cada uma dominada por um tipo diferente de perda de tensão (polarização):

1. **Perdas por Ativação:** Na região de baixa densidade de corrente, observa-se uma queda inicial acentuada na tensão. Essas perdas estão relacionadas à energia de ativação necessária para superar as barreiras cinéticas das reações de oxidação no ânodo e de redução no cátodo.
2. **Perdas Ôhmicas:** Na região intermediária de densidade de corrente, a tensão diminui de forma aproximadamente linear. Essa região é dominada pelas perdas ôhmicas, que resultam da resistência ao transporte de elétrons através dos eletrodos e do circuito externo, e ao transporte de íons (prótons) através do eletrólito e da membrana.
3. **Perdas por Concentração:** Em altas densidades de corrente, a tensão cai drasticamente. Isso ocorre devido às limitações no transporte de massa, ou seja, a incapacidade do sistema de fornecer substrato ao ânodo ou o aceptor de elétrons (oxigênio) ao cátodo na velocidade em que são consumidos.

A resistência interna (R_{int}) da célula, que agrega todas as contribuições ôhmicas, pode ser estimada a partir da inclinação da porção linear da curva de polarização. Uma regressão linear aplicada a esta região fornece uma estimativa robusta pela Equação 11 onde menor resistência interna é crucial para minimizar as perdas de tensão e maximizar a potência de saída.

$$R_{int} = | \Delta V / \Delta I | \quad (11)$$

O Quadro 1 resume os parâmetros eletroquímicos chave extraídos das curvas.

Quadro 1 — Parâmetros Eletroquímicos Chave Derivados das Curvas de Polarização

Parâmetro	MFC 1 (Carvão Ativado)	MFC 2 (Grafite)	Unidade
Tensão de Circuito Aberto (OCV)	528	526	mV
Densidade de Potência Máxima (P_{max})	49	33,4	mW/m ²
Resistência interna (R_{int})	301	364	Ω

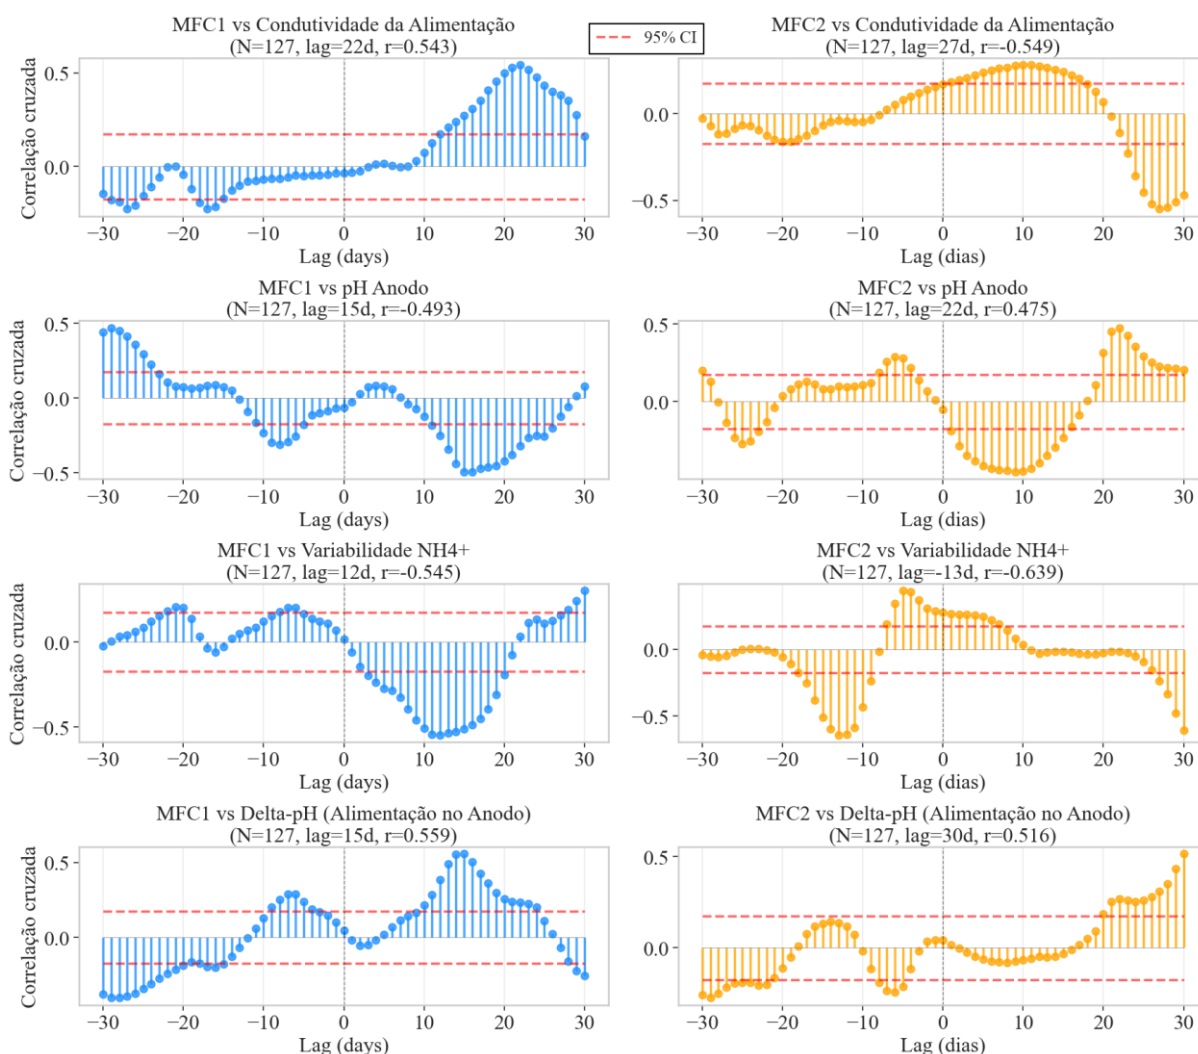
Fonte: O autor (2025).

Os resultados quantitativos confirmam a superioridade da MFC 1. Sua densidade de potência máxima é 46.3% maior que a da MFC 2. A causa fundamental para essa diferença é claramente revelada pela resistência interna: a R_{int} da MFC 1 é 17.3% menor que a da MFC 2. Essa menor resistência, provavelmente atribuível à melhor condutividade intrínseca e à maior área de superfície do material de carvão ativado, permite uma transferência de carga mais eficiente, resultando em menores perdas ôhmicas e, conseqüentemente, em uma maior potência entregue à carga externa.

4.5 Influência dos Parâmetros Físico-Químicos e Ambientais

Para aprofundar a compreensão sobre os fatores que modulam o desempenho de cada célula, foi realizada uma análise de correlação cruzada (CCF) entre a corrente elétrica gerada e um conjunto de variáveis físico-químicas chave, monitoradas ao longo do experimento. Os resultados, apresentados na Figura 4.16, permitem não apenas identificar a natureza (positiva ou negativa) da correlação, mas também o tempo de resposta (lag) do sistema a cada variável, revelando dinâmicas complexas e diferenças fundamentais entre a MFC 1 (ânodo de carvão ativado) e a MFC 2 (ânodo de grafite).

Figura 16 — Correlação entre corrente e variáveis químicas



Fonte: O autor (2025).

4.5.1 Interpretação das Correlações

A análise comparativa dos correlogramas revela que, embora ambas as células respondam aos mesmos estímulos químicos, elas o fazem de maneiras e em escalas de tempo marcadamente diferentes, sugerindo distintas eficiências metabólicas e resiliência.

- Resposta à Condutividade da Alimentação:** A condutividade do afluente, que impacta as perdas ôhmicas, mostrou uma correlação positiva para ambas as células, mas com tempos de resposta distintos. A MFC 1 apresentou um pico de correlação ($r=0.54$) com um lag de +22 dias, sugerindo que seu biofilme robusto foi capaz de aproveitar a redução da resistência ôhmica proporcionada

pela maior força iônica. Em contraste, a MFC 2 exibiu uma correlação negativa ($r = -0,55$) com um lag de +27 dias, indicando que, para este material de ânodo, a inibição biológica causada pelo estresse osmótico superou os benefícios físicos da condutividade. Esse longo atraso sugere que, embora a MFC 2 possa se beneficiar inicialmente da redução da resistência, a exposição prolongada a condições de alta força iônica excede o limiar de tolerância de sua comunidade microbiana, prejudicando o desempenho segundo Guo et al (2021). Esse resultado destaca a superioridade do bioânodo de carvão ativado em tolerar e prosperar em ambientes de alta força iônica, quando comparado à interface de grafite simples.

- **Resposta à Atividade Acidogênica e pH:** A dinâmica do pH é onde as diferenças mais significativas emergem. A variação de pH entre a alimentação e o anólito (ΔpH) atua como um indicador da atividade metabólica e das limitações de transporte iônico. Ambas as células mostram uma correlação positiva, mas com tempos de resposta distintos. A MFC 1 apresenta um pico forte ($r=0.56$) em um lag de +15 dias. Isso sugere que a intensificação da atividade oxidativa (que altera o ΔpH devido à liberação de prótons) precede o pico de geração de corrente consolidada em duas semanas. A MFC 2, por sua vez, leva o dobro do tempo, com um pico de correlação ($r=0.52$) ocorrendo em um lag de +30 dias. Essa diferença evidencia que a MFC 1 possui uma cinética de resposta muito mais rápida para ajustar seu metabolismo e transporte iônico frente à disponibilidade de substrato. A correlação com o pH do anólito reforça essa conclusão. A MFC 1 tem uma forte correlação negativa ($r=-0.49$) com lag de +15 dias, indicando que um decréscimo no pH (associado ao acúmulo de prótons provenientes da oxidação do acetato) precede um pico de corrente. A MFC 2, por outro lado, exibe uma correlação positiva ($r=0.48$) com lag de +22 dias, comportamento atípico que pode sugerir limitações severas no transporte de prótons ou uma comunidade microbiana sensível à acidificação do meio.

- **Sensibilidade à Instabilidade da Alimentação (Variabilidade de NH_4^+):** A análise da variabilidade da amônia revelou uma divergência crítica nos modos de falha dos sistemas. A MFC 1 exibiu uma correlação negativa ($r = -0,55$) com um lag positivo de +12 dias, demonstrando uma resiliência clássica: o biofilme resistiu às flutuações externas por quase duas semanas antes que o

desempenho declinasse. Em contraste, a MFC 2 apresentou uma correlação negativa mais forte ($r = -0,64$), porém com um lag negativo de -13 dias. Essa inversão temporal implica em causalidade reversa, indicando que a queda na geração de corrente precedeu a instabilidade química. Matematicamente, isso sugere que o biofilme de grafite, sendo menos robusto, sofreu falha metabólica ou desprendimento primeiro, o que subsequentemente comprometeu o consumo de substrato, levando ao acúmulo e flutuação de amônia observados. Assim, enquanto a MFC 1 demonstra resistência ao estresse, a MFC 2 exibe fragilidade operacional, onde a falha biológica desencadeia a instabilidade físico-química.

Em resumo, a análise de correlação cruzada demonstra que, embora ambas as MFCs sejam influenciadas pela química do afluente, a MFC 1 (carvão ativado) consistentemente exibe uma resposta mais rápida, metabolicamente mais eficiente e mais robusta a instabilidades. A MFC 2 (grafite), por outro lado, opera em uma escala de tempo mais lenta e demonstra maior sensibilidade a variações operacionais, reforçando as vantagens do material de ânodo da MFC 1 não apenas para o desempenho em estado estacionário, mas também para a dinâmica e resiliência operacional do sistema.

4.6 Avaliação da Eficiência de Tratamento e Conversão Energética

As MFCs possuem uma dupla funcionalidade: gerar energia elétrica e tratar efluente. Esta seção avalia o desempenho das duas células sob esta perspectiva dual, quantificando a eficiência na remoção de matéria orgânica (Demanda Química de Oxigênio - DQO) e a eficiência com que a energia química dessa matéria orgânica é convertida em energia elétrica (Eficiência Coulômbica - EC).

4.6.1 Eficiência de Remoção de Demanda Química de Oxigênio (DQO)

A eficiência de remoção de DQO é a métrica primária para avaliar o desempenho de um sistema de tratamento de efluentes (Slate *et al.*, 2019). Ela foi calculada para cada ciclo de alimentação em batelada, utilizando os dados de

concentração de DQO do afluente (Alimentação) e do efluente (Anólito), disponíveis no anexo B. A fórmula utilizada é descrita pela Equação 12.

$$\text{Eficiência de Remoção de DQO}(\%) = \left(\frac{DQO_{in} - DQO_{out}}{DQO_{in}} \right) \times 100 \quad (12)$$

Onde DQO_{in} é a concentração de DQO na alimentação e DQO_{out} é a concentração de DQO no compartimento anódico ao final do ciclo. Excluindo o período inicial da análise e olhando somente para o período de maior estabilidade, entre janeiro e fevereiro, chegou-se as seguintes médias:

- MFC1: 86,89% de eficiência de remoção
- MFC2: 82,80% de eficiência de remoção

Não foram observadas diferenças estatisticamente significativas entre a MFC 1 e a MFC 2 nesse quesito, indicando que ambos os materiais de ânodo suportaram uma comunidade microbiana capaz de degradar eficientemente a matéria orgânica presente no substrato.

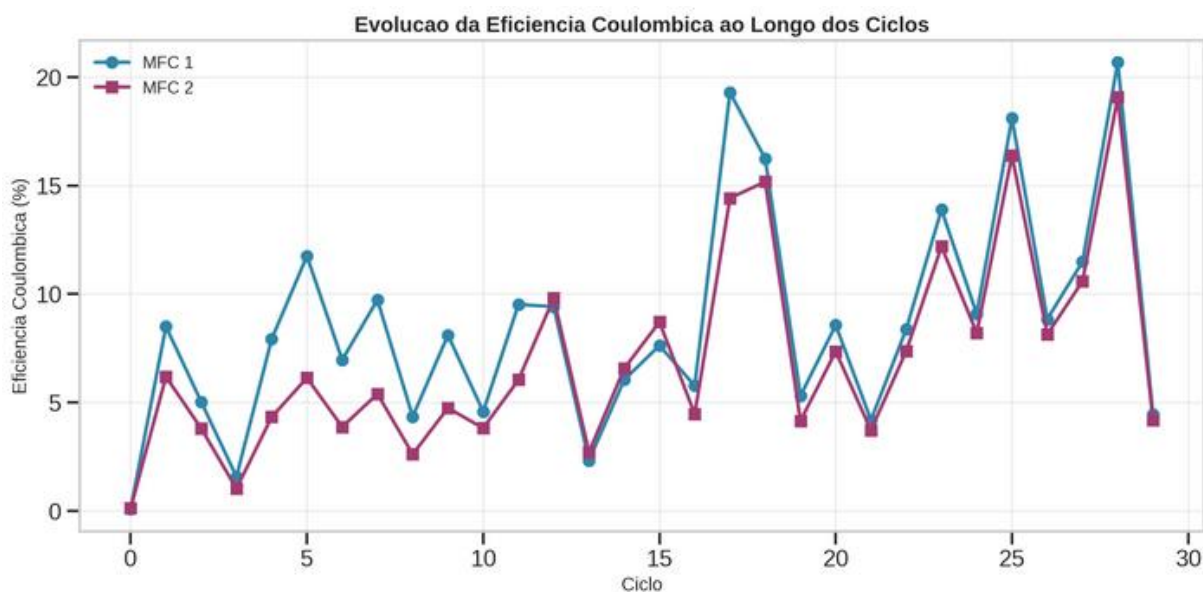
4.6.2 Eficiência Coulômbica (EC)

Enquanto a remoção de DQO mede a eficiência do tratamento, a Eficiência Coulômbica (EC) mede a eficiência da conversão de energia (Santoro *et al.*, 2017). A EC representa a fração de elétrons contidos na matéria orgânica removida que é efetivamente recuperada como corrente elétrica, em oposição aos elétrons que são desviados para outros sumidouros, como a metanogênese ou a síntese de biomassa. A EC foi calculada pela Equação 13:

$$EC(\%) = \left(\frac{M \int_0^t I(t) dt}{F \cdot b \cdot V_{an} \cdot \Delta DQO} \right) \times 100 \quad (13)$$

Onde **M** é o peso molecular do oxigênio (32 g/mol), a integral de **I(t)** representa a carga total transferida (em Coulombs) durante um ciclo de batelada, **F** é a constante de Faraday (96485 C/mol e⁻), **b** é o número de mols de elétrons por mol de oxigênio (4 mol e⁻/mol O₂), **V_{an}** é o volume do compartimento anódico (em litros), e **ΔDQO** é a concentração de DQO removida (em g/L). A Figura 17 mostra a evolução da EC ao longo do experimento.

Figura 17 — Evolução da eficiência coulômbica



Fonte: O autor (2025).

A análise da Eficiência Coulômbica revela pouca diferença entre as duas células. A MFC 1 apresentou uma EC ligeiramente superior à da MFC 2, mas ambas as células são eficazes na remoção de matéria orgânica (remoção de DQO), a MFC 1 mais eficiente em converter essa matéria orgânica em eletricidade.

Esse resultado sugere que o ambiente proporcionado pelo ânodo de carvão ativado na MFC 1 favorece as vias metabólicas eletrogênicas em detrimento de vias competitivas. A alta área de superfície e a microestrutura porosa do carvão ativado podem promover uma maior densidade de colonização por bactérias exoeletrogênicas e facilitar a transferência de elétrons para o eletrodo. O Quadro 2 resume os valores médios de ambas as eficiências.

Quadro 2 — Sumário das Eficiências de Remoção de DQO e Eficiência Coulômbica (Valores Médios)

Parâmetro	MFC 1 (Carvão Ativado)	MFC 2 (Grafite)
Eficiência Média de Remoção de DQO	86.89%	82.80%
Eficiência Coulômbica (EC) Máxima	20.7%	19.1%

Fonte: O autor (2025).

4.7 Modelagem Matemática do Comportamento Elétrico

Agradeço a valiosa colaboração nos estudos apresentados nesta seção do Prof. Vinicius Albani, da Universidade Federal do Rio de Janeiro.

Para evoluir a análise descritiva e quantificar a dinâmica bioeletroquímica observada, foi desenvolvida uma abordagem de modelagem matemática. O objetivo é representar o comportamento elétrico das MFCs por meio de um modelo que não apenas se ajuste aos dados experimentais, mas que também possua parâmetros com significado físico-químico. Conforme discutido na literatura, a modelagem por meio de circuitos elétricos equivalentes é uma abordagem comum e eficaz para simular e prever o comportamento elétrico das células.

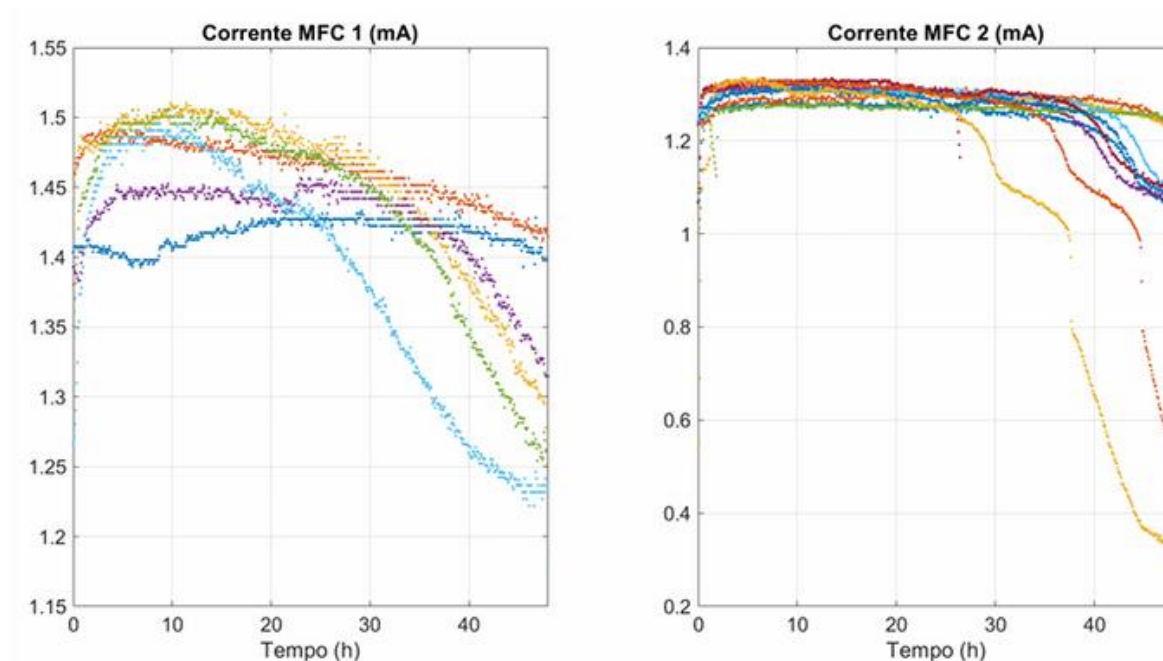
O modelo proposto baseia-se em um circuito elétrico equivalente que busca capturar as principais fontes de perdas e os fenômenos de armazenamento de carga no sistema. A estrutura do circuito integra componentes que representam as perdas ôhmicas, de ativação e de concentração, conforme identificado na análise das curvas de polarização (Seção 4.4). O modelo é descrito por uma combinação de resistores e capacitores, cuja dinâmica temporal é regida por equações diferenciais ordinárias (EDOs).

- Uma fonte de corrente (I_f), que representa o potencial termodinâmico máximo gerado pela atividade microbiana (Tensão de Circuito Aberto).
- Uma resistência em paralelo (R_f), que representa as perdas ôhmicas combinadas do eletrólito, dos eletrodos e das conexões.
- Um ou mais ramos RC paralelos (R_{ct} e C_{dl}), que modelam os processos dinâmicos na interface eletrodo-biofilme. A resistência de transferência de carga (R_{ct}) está associada às perdas por ativação (cinética das reações), enquanto a capacitância de dupla camada (C_{dl}) representa a capacidade do biofilme e da interface de acumular carga, um fenômeno crucial durante os transientes de carga e descarga.

Para padronizar os intervalos e reduzir a variabilidade aleatória, os dados foram interpolados para uma resolução uniforme de 5 minutos entre cada observação. Em seguida, as séries foram divididas em janelas fixas de 48 horas e, em cada janela, foram computados o valor máximo, mínimo e médio da tensão.

Algumas janelas com excesso de ruído ou dados excessivamente imputados por interpolação foram descartadas, reduzindo o conjunto analisável para séries mais estáveis e matematicamente modeláveis. Diante disso, foram obtidos os resultados apresentados na Figura 18.

Figura 18 — Curvas de corrente em janela de 24h para séries estáveis



Fonte: O autor (2025).

A dinâmica observada foi interpretada como um processo de consumo do estoque do recurso natural, ou seja, do substrato orgânico (alimento) e da produção de energia (tensão elétrica), com liberação controlada por uma função de produção $\Phi(t)$. Desse modo, propôs-se, então, o seguinte sistema de equações diferenciais ordinárias (EDO):

$$\frac{dx}{dt} = d - \phi(t) \cdot x \quad (14)$$

$$x(0) = x_0 \quad (15)$$

$$\phi(t) = a \cdot e^{bt^c} \quad (16)$$

Do ponto de vista físico, esse modelo pode ser interpretado da seguinte forma, tem-se o alimento como uma quantidade equivalente de tensão armazenada que é liberada de acordo com a equação diferencial dx/dt , conforme Equação 14. A

quantidade inicial de tensão armazenada é determinada pela condição inicial $x(0)$. A taxa de liberação é obtida por $d - \Phi(t)x$ e $\Phi(t)$ e determina a velocidade que esta corrente é liberada.

Este modelo tem como parâmetros livres os coeficientes da taxa de produção a , b , c e a taxa d . Essas incógnitas podem ser identificadas a partir das séries de observações via mínimos quadrados. Definindo o vetor de incógnitas como $[\theta = a, b, c, d]^T$, minimiza-se a seguinte função:

$$F(\theta) = \sum_{j=1}^n \left(\frac{x_j^{\text{obs}} - x(t_j; \theta)}{x_j^{\text{obs}}} \right)^2 \quad (17)$$

A Equação 17 é resolvida numericamente utilizando a função `lsqnonlin` do MATLAB. A condição inicial da série é tomada como o primeiro valor de cada subjanela. Para simplificação, as séries modeladas consideram somente o decaimento dos valores a partir do 50º passo. A Tabela 5 apresenta os valores estimados para os parâmetros do modelo para ambas MFCs.

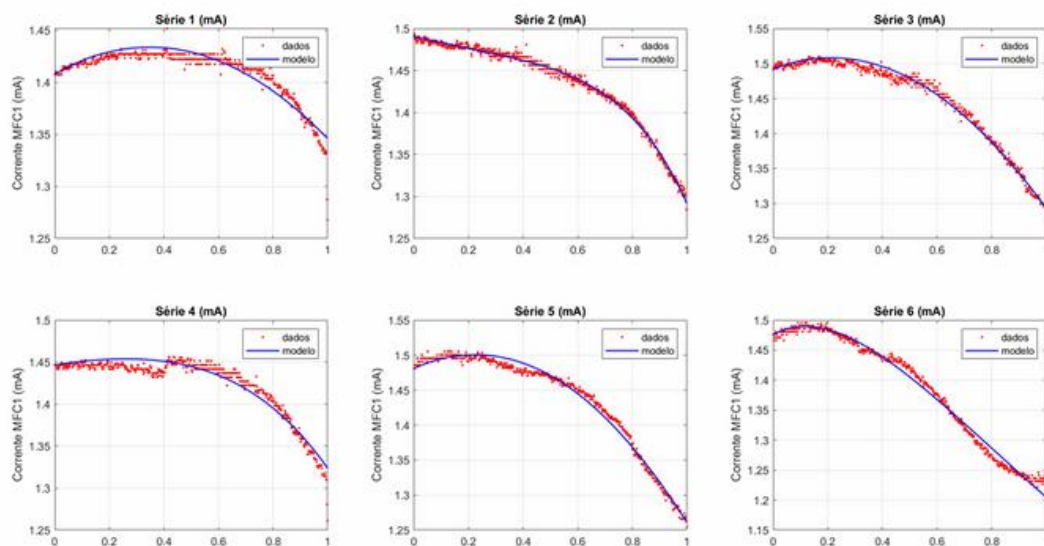
Tabela 5 — Resultados da modelagem

	MFC1				MFC2			
	a	b	c	d	a	b	c	d
Série 1	0,058	1,909	0,499	0,182	0,089	2,174	0,592	0,254
Série 2	0,629	0,675	3,444	0,579	0,047	2,134	0,919	0,126
Série 3	0,075	2,147	0,515	0,198	0,048	1,723	0,425	0,115
Série 4	0,010	3,646	0,662	0,046	0,011	4,466	0,610	0,081
Série 5	0,076	2,261	0,540	0,212	0,022	2,217	0,171	0,140
Série 6	2,462	0,372	0,844	2,641	0,100	2,010	0,645	0,249
Série 7	-	-	-	-	0,104	2,115	0,665	0,241
Série 8	-	-	-	-	0,090	2,108	0,613	0,221
Série 9	-	-	-	-	0,355	2,621	1,706	0,509
Série 10	-	-	-	-	16,163	1,763	4,005	16,232

Fonte: O autor (2025).

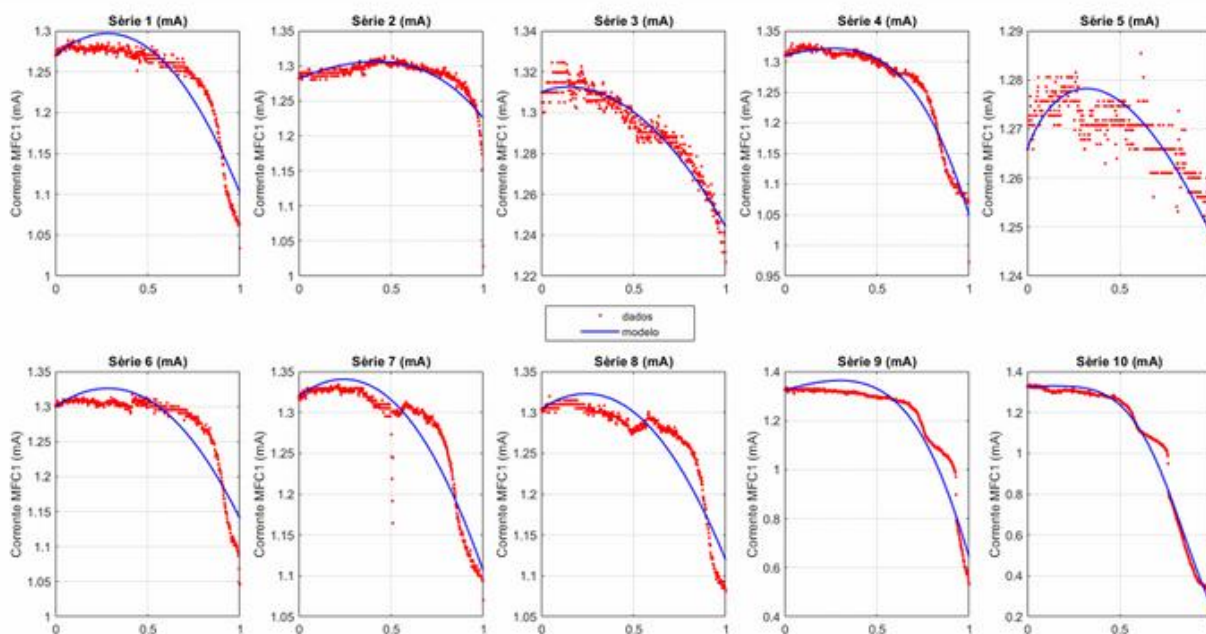
Assim, considerando os valores obtidos para os coeficientes da taxa de produção a , b , c e d conforme Tabela 5, e conforme Equação 14, tem-se os seguintes resultados, apresentados na Figura 19.

Figura 19 — Modelo matemático MFC1



Fonte: O autor (2025).

Figura 20 — Modelo matemático MFC2



Fonte: O autor (2025).

Para análise de dados, as séries temporais de tensão foram processadas utilizando correlação de Pearson, permitindo identificar padrões sazonais e filtrar ruídos. Modelos matemáticos baseados em regressão não linear, aplicados por meio de equações diferenciais ordinárias, foram ajustados aos dados para descrever a dinâmica de produção e consumo de energia, destacando-se pela precisão nas séries de dados com características mais estáveis. Após a aplicação do modelo às diferentes séries experimentais, é possível observar padrões interessantes nos resultados obtidos tanto para o MFC1 quanto para o MFC2.

MFC1: De um modo geral, o modelo conseguiu se ajustar de forma bastante satisfatória aos dados. No entanto, ao se analisar os valores dos parâmetros estimados, pode-se constatar uma grande variação que pode ser causada por uma série de fatores. O experimento estava sujeito a diferentes condições iniciais e de contorno, relacionadas à variação na quantidade de substrato adicionada, além da produção de impurezas. Outro fator relevante é o próprio fato de se analisar a produção de eletricidade por organismos vivos, o que introduz incertezas nos dados e, conseqüentemente, nos resultados.

Analisando os dados da Tabela 5, pode-se observar que as séries 1, 3 e 5 apresentam valores muito semelhantes entre si para os parâmetros estimados. Visualmente, essas três curvas são bastante similares, sugerindo a repetição de um padrão. Já, as séries 2 e 6 apresentam padrões distintos entre si e em relação às demais. A série 4, por sua vez, mostra valores próximos aos das séries 1, 3 e 5, o que indica a possibilidade de um padrão recorrente, apesar das variações nas condições. Mesmo com um conjunto de dados relativamente pequeno, é possível observar a presença de um padrão consistente, que pode ser bem descrito pelo modelo representado pelas Equação 14 e Equação 15.

MFC2: Visualmente, a Figura 20, na posição linha 2 e coluna 2 e 3, mostram que o modelo também conseguiu se ajustar satisfatoriamente aos dados para o MFC2, ainda que este apresente um padrão ligeiramente distinto do MFC1. A partir da Tabela 5, constata-se novamente a presença de dois padrões nas estimativas: um formado pelas séries 2 a 5 (padrão A) e outro pelas séries 1 e 6 a 8 (padrão B). As séries 9 e 10 destoam significativamente das demais e requerem análise separada. O padrão B é bastante similar ao observado nas séries 1, 3 e 5 do MFC1, embora os valores estimados para o MFC1 sejam um pouco menores. Isso pode indicar similaridades

nas dinâmicas entre os dois sistemas. O ajuste do modelo ao MFC1 foi ligeiramente superior ao do MFC2 nas séries do padrão B. Já, as estimativas do padrão A, embora próximas, apresentam valores um pouco menores, refletindo em curvas visuais semelhantes, caracterizadas por um pico de tensão seguido de decaimento, como observado no MFC1. No entanto, nos dados do MFC2, esse pico nem sempre é tão acentuado e, em alguns casos, há uma leve queda seguida de nova subida, o que pode estar associado a reabastecimentos de substrato ou mudanças no metabolismo microbiano. As séries 9 e 10 se destacam por apresentar quedas suaves seguidas por declínio acentuado ao final do período. Especificamente para a série 10, o modelo se ajustou bem, porém apresentou valores de parâmetros muito superiores, sugerindo um possível sobreajuste — fator indesejável para fins de generalização e previsão. Em termos gerais, a modelagem do MFC2 demonstrou ser robusta e consistente, com boa aderência visual e parâmetros relativamente estáveis entre séries similares.

Os resultados demonstraram que o sistema foi capaz de gerar energia elétrica, embora com variação de desempenho entre os protótipos MFC1 e MFC2. A resistência interna, fator crítico para a eficiência das MFCs, foi avaliada através do estudo da curva de polarização, revelando uma ampla faixa de densidade de potência em resposta às características dos materiais dos eletrodos e da configuração do sistema.

4.8 Modelo elétrico equivalente


Agradeço a valiosa colaboração nos estudos apresentados nesta seção do Prof. Everthon Sica, do Instituto Federal de Santa Catarina.

Assim como outros sistemas eletroquímicos, as Células a Combustível Microbianas (MFCs) podem ser representadas por circuitos elétricos equivalentes que simplificam a análise de resposta em corrente e tensão, permitindo avaliar propriedades internas como resistência ôhmica e capacidades de troca de carga. No contexto desse estudo, o modelo matemático proposto na Equação 14 foi relacionado a um circuito elétrico equivalente que reflete a dinâmica de produção e consumo de energia.

Enquanto a maioria das abordagens presentes na literatura trata o comportamento macroscópico da MFC, olhando para uma janela de vários dias ou

semanas, o trabalho de Potrykus *et al.* (2025) analisa o comportamento variável horário da MFC. Como observado na Figura 18, o comportamento apresenta uma variação de corrente ao longo do dia, conforme também observado por Potrykus *et al.* (2025), ainda que por meio de uma metodologia distinta. As curvas da Figura 18 demonstram que modelos puramente resistivos são insuficientes para explicar tais variações, uma vez que negligenciam o comportamento transitório do sistema. Diante disso, propõe-se a adoção de um circuito equivalente mais complexo, representado na Figura 21a, baseado no modelo Larminie e Dicks (2000).

Figura 21 — Circuito equivalente MFC



Fonte: O autor (2025).

Para a análise do circuito na Figura 21a, pode-se iniciar a modelagem pela Equação 18 :

$$\frac{dV_c}{dt} = \frac{I_f}{C} - \frac{1}{RC}V_c \quad (18)$$

Entretanto, a Equação 18 embora possua similaridade com a Equação 17, ainda não é suficiente para explicar a modelagem. Uma proposta para aplicar um elemento variável a equação seria adotar o entendimento que R é um resistor variável no tempo, isto se torna relevante, conforme Picioreanu *et al.* (2007), uma vez que adequa o modelo a uma variação dinâmica ocorrida devido a alimentação com substrato ocorrida periodicamente, conforme Figura 21b. Portanto, se propõe uma alteração do circuito, onde R possui comportamento variável definido pela $R(t) = R_0 * e^{at}$ e com isto temos como resultado do modelo a Equação 19.

$$\frac{dV_c}{dt} = \frac{I_f}{C} - \frac{1}{R_0 C \times e^{at}}V_c \quad (19)$$

O circuito elétrico equivalente proposto integra a EDO do modelo matemático,

oferecendo uma representação física das dinâmicas de tensão nas MFCs, isso pode ser observado através da similaridade das Equações 14 e 19, onde substituindo os elementos temos que $I_f/C = d$ e $1/(R_0C \times e^{\alpha t}) = \phi(t)$. O modelo conecta parâmetros elétricos a fenômenos biológicos, como variação no substrato e com o crescimento do biofilme, permitindo simulações das variações observadas no capítulo 4.7. Contudo, essa proposta ainda carece de validações mais abrangentes e de uma mudança de perspectiva que viabilize a exploração de abordagens complementares, visando representar com maior completude os processos bioeletroquímicos envolvidos.

4.9 Síntese Comparativa e Discussão Integrada dos Resultados

Esta seção final consolida os resultados das análises eletroquímicas, temporais e de eficiência para construir uma avaliação comparativa abrangente do desempenho da MFC 1 (ânodo de carvão ativado) versus a MFC 2 (ânodo de grafite), culminando em uma discussão integrada que conecta as propriedades do material do eletrodo aos resultados de desempenho observados.

A discussão integrada dos resultados tece uma narrativa coesa que explica as diferenças de desempenho. O ponto de partida é a observação consistente de que a MFC 1 supera a MFC 2 em todas as métricas de geração de energia, incluindo tensão média, potência média e, mais formalmente, densidade de potência máxima, conforme estabelecido nas Seções 4.1 e 4.4.

A causa fundamental para esta superioridade elétrica foi identificada na análise de polarização (Seção 4.4) como sendo a menor resistência interna (R_{int}) da MFC 1. A resistência interna de 301 Ω da MFC 1, em comparação com 364 Ω da MFC 2, significa que menos energia é dissipada internamente como calor para uma dada corrente, resultando em uma maior tensão e potência entregues à carga externa. Esta menor resistência é uma consequência direta das propriedades do material do ânodo: o carvão ativado tipicamente possui uma área de superfície específica muito maior e uma rede porosa que facilita a interface entre o biofilme e o condutor, além de potencialmente possuir uma melhor condutividade intrínseca em comparação com o tipo de grafite utilizado.

Além da geração de energia em estado estacionário, a **MFC 1 demonstrou maior estabilidade operacional e resiliência**. A análise estatística (Seção 4.1) revelou um menor coeficiente de variação em sua tensão, indicando uma operação mais estável. Essa robustez aprimorada pode ser novamente ligada à estrutura porosa do ânodo de carvão ativado, que pode proteger a comunidade microbiana e fornecer uma vasta área para uma rápida recolonização.

Por fim, embora a MFC 1 tenha demonstrado superioridade em outros parâmetros, as análises de Eficiência Coulômbica e de remoção de DQO revelaram desempenhos globais semelhantes entre as duas células. Contudo, nota-se uma eficiência ligeiramente superior da MFC 1 na remoção de DQO. Esse resultado indica que o ambiente do ânodo de carvão ativado não apenas facilita a transferência de elétrons (evidenciada pela menor resistência interna), mas também seleciona ou promove vias metabólicas que canalizam elétrons para a geração de corrente de forma mais eficaz, em detrimento de processos concorrentes.

Em suma, a análise integrada dos dados demonstra que a escolha do material do ânodo tem um impacto profundo e multifacetado no desempenho da MFC. O ânodo de carvão ativado na MFC 1 resultou em uma célula que não só gera mais energia, mas também é mais estável, mais resiliente e mais eficiente na conversão de resíduos em eletricidade. O Quadro 3 resume esta avaliação comparativa final.

Quadro 3 — Matriz Comparativa de Desempenho Final entre MFC 1 e MFC 2

Métrica de Desempenho	MFC 1 (Carvão Ativado)	MFC 2 (Grafite)	Vantagem Relativa	Justificativa Proposta
Geração de Energia				
Potência Média (mW)	Superior (0.103)	Inferior (0.062)	MFC 1	Menor R_{int} e maior EC.
Densidade de Potência Máxima (mW/m²)	Superior (49.0)	Inferior (33.4)	MFC 1	Propriedades eletroquímicas superiores do material.
Estabilidade Operacional				

Métrica de Desempenho	MFC 1 (Carvão Ativado)	MFC 2 (Grafite)	Vantagem Relativa	Justificativa Proposta
Coefficiente de Variação da Tensão	Menor (36.2%)	Maior (43.6%)	MFC 1	Operação mais estável e previsível.
Resiliência a Perturbações	Maior	Menor	MFC 1	Estrutura porosa do ânodo protegendo o biofilme.
Propriedades Eletroquímicas				
Resistência Interna (Ω)	Menor (301)	Maior (364)	MFC 1	Melhor condutividade e maior área de superfície da interface.
Eficiência de Processo				
Remoção de DQO Média (%)	Similar (86.89)	Similar (82.8)	-	Ambas as configurações são eficazes para tratamento, mas a MFC1 se destaca ligeiramente
Eficiência Coulômbica Máxima (%)	Superior (20.7)	Inferior (19.1)	-	Ambas apresentam níveis semelhantes.

Fonte: O autor (2025).

5 CONCLUSÃO

Esta dissertação explorou as MFCs como uma tecnologia promissora para a geração sustentável de energia e o tratamento de efluentes, com ênfase na modelagem elétrica para otimizar seu desempenho. Ao longo do trabalho, foram abordados os fundamentos bioquímicos e eletroquímicos das MFCs, os desafios técnicos associados à sua construção e operação, e a integração de ferramentas avançadas de análise de dados e modelagem para compreender e prever seu comportamento.

Os resultados experimentais mostram, de forma consistente, que a MFC-1 (ânodo de carvão ativado) apresentou desempenho elétrico superior e maior robustez operacional em comparação com a MFC-2 (ânodo de grafite). Em particular, a densidade de potência máxima observada para a MFC-1 foi substancialmente maior que a da MFC-2, e a MFC-1 exibiu menor resistência interna, o que explica sua capacidade de entregar maior tensão e potência útil à carga externa.

No que tange à dupla função das MFCs (tratamento de efluentes e geração de energia), ambas as células alcançaram eficiências de remoção de DQO elevadas e comparáveis (em torno de 83–87%), indicando que, do ponto de vista de depuração, ambas as configurações são eficazes. Contudo, a eficiência coulômbica, métrica que quantifica a fração de elétrons efetivamente convertidos em corrente elétrica, foi consistentemente maior na MFC-1, evidenciando que o ânodo de carvão ativado favorece vias metabólicas que canalizam elétrons para o eletrodo.

A análise temporal revelou padrões recorrentes e respostas dinâmicas relevantes: decomposição STL permitiu separar tendência, sazonalidade e ruído; a detecção de pontos de mudança por PELT correlacionou eventos operacionais (p.ex. exposição do ânodo, variações de alimentação e falhas elétricas) com quebras de regime; e análises de correlação cruzada mostraram diferenças nas escalas de resposta entre as células, com a MFC-1 respondendo mais rapidamente a variações de parâmetros químico-físicos (pH, amônia) do que a MFC-2, um indicativo de maior resiliência operacional da MFC-1.

Na modelagem matemática, foi proposta e calibrada uma estrutura de circuito equivalente que combina uma fonte representando o potencial termodinâmico da atividade microbiana, resistências representando perdas ôhmicas e ramos RC que

modelam processos de ativação e armazenamento de carga na interface eletrodo-biofilme. Além disso, discutiu-se a pertinência de introduzir elementos temporais variáveis (p.ex. $R(t)$) para refletir mudanças induzidas por alimentação periódica e evolução do biofilme, abordagem que melhorou a capacidade de representar transientes observados nas séries experimentais. Os ajustes do modelo (via lsqnonlin e análise das séries) mostraram boa aderência para a maioria das janelas analisadas, embora algumas séries (ex.: séries 9 e 10) demandem análise adicional devido a comportamentos atípicos ou possível sobreajuste

As implicações dos resultados são significativas para a sustentabilidade energética. As MFCs demonstraram potencial para geração de eletricidade, embora ainda estejam em fase laboratorial de validação, reduzindo a pegada de carbono e o volume de lodo em tratamentos anaeróbios. No entanto, limitações foram observadas: variações na resistência interna devido a aspectos construtivos e substratos, baixas densidades de potência em escala laboratorial (miliwatts/m^2), e dependência de condições anaeróbias estritas. Fatores biológicos, como a variabilidade metabólica dos microrganismos, introduziram incertezas, sugerindo a necessidade de biofilmes mais robustos.

Em termos de contribuição científica e metodológica, o trabalho entrega: (i) um conjunto experimental robusto e detalhado (≥ 150 dias) que permite estudar dinâmica de MFCs em escala laboratorial; (ii) uma metodologia integrada de pré-processamento, decomposição temporal e detecção de anomalias aplicável a ensaios de MFC; e (iii) um modelo elétrico equivalente dinâmico, simples e com parâmetros de significado físico, passível de uso em simulações e em estratégias de controle/gestão de energia. Esses elementos facilitam a transposição entre análises eletroquímicas clássicas e ferramentas de modelagem de sistemas para apoio ao desenvolvimento de Power-Management Systems e rastreamento de máxima potência (MPPT) em arranjos de MFCs.

Reconhecem-se limitações importantes desse estudo. A heterogeneidade observada em algumas séries temporais e a existência de padrões atípicos (séries 9 e 10) indicam que a variabilidade biológica e operacional ainda pode limitar a generalização dos modelos propostos; por outro lado, o conjunto experimental, embora extenso em duração, é restrito a dois protótipos e a um conjunto específico

de condições de alimentação e temperatura, o que recomenda cautela ao extrapolar resultados para escalas ou matrizes distintas.

Por fim, sugerem-se caminhos para trabalhos futuros que emergem naturalmente dos achados: (a) validação dos modelos propostos em um conjunto mais amplo de reatores e condições (diferentes substratos, inóculos e escalas), (b) integração do modelo elétrico com algoritmos de MPPT e conversores de potência para avaliação de eficiência energética líquida em aplicações reais, (c) acoplamento da modelagem dinâmica com EIS para identificar e separar formalmente contribuições anódicas e catódicas, e (d) investigação da integração MFC–MEC para cogeração de biohidrogênio quando aplicável. Essas diretrizes visam tanto avançar a capacidade preditiva dos modelos quanto aproximar a tecnologia de aplicações práticas em tratamento descentralizado de efluentes e recuperação energética.

Em síntese, o trabalho confirma que a seleção do material do ânodo é determinante para o desempenho elétrico e a resiliência das MFCs, e demonstra que modelos elétricos equivalentes, quando tratados de forma dinâmica e calibrados com dados experimentais longos, constituem uma ferramenta útil para diagnóstico, previsão e projeto de estratégias de gestão de energia em sistemas bioeletroquímicos. Essa dissertação, portanto, contribui com elementos práticos e conceituais que apoiam o avanço de MFCs como tecnologia de tratamento energético-integrado, ao mesmo tempo em que delimita com clareza as etapas necessárias para sua maturação tecnológica.

REFERÊNCIAS

- AHMED, Shams Forruque *et al.* Biohydrogen production from wastewater-based microalgae: Progresses and challenges. **International Journal of Hydrogen Energy**, v. 47, n. 88, p. 37321-37342, out. 2022. Disponível em: <https://doi.org/10.1016/j.ijhydene.2021.09.178>. Acesso em: 4 ago. 2025.
- ALI, Ahmed *et al.* Experimental and Theoretical Study on the Ability of Microbial Fuel Cell for Electricity Generation. **Pollution**, v. 4, n. 2, p. 359-368, out. 2017. Disponível em: <https://doi.org/10.22059/poll.2017.246092.341>. Acesso em: 4 ago. 2025.
- ARUN, Jayaseelan *et al.* New insights into microbial electrolysis cells (MEC) and microbial fuel cells (MFC) for simultaneous wastewater treatment and green fuel (hydrogen) generation. **Fuel**, v. 355. 129530 p, jan. 2024. Disponível em: <https://doi.org/10.1016/j.fuel.2023.129530>. Acesso em: 3 ago. 2025.
- BUTLER, J. A. V. Studies in heterogeneous equilibria. Part III. A kinetic theory of reversible oxidation potentials at inert electrodes. **Transactions of the Faraday Society**, v. 19, p. 734-739, 1924.
- CHAKMA, Ripel *et al.* Recent Applications, Challenges, and Future Prospects of Microbial Fuel Cells: A review. **Global Challenges**, 16 abr 2025. Disponível em: <https://doi.org/10.1002/gch2.202500004>. Acesso em: 17 ago. 2025.
- CHANDRA, Soumyajit *et al.* Bioenergy recovery from jackfruit waste via biohydrogen production through dark fermentation and power generation through stacked microbial fuel cells. **International Journal of Hydrogen Energy**, v. 102, p. 845-855, 10 fev 2025. Disponível em: <https://doi.org/10.1016/j.ijhydene.2025.01.044>. Acesso em: 8 nov. 2025.
- CHENG, Shaoan; HONG, Liu; LOGAN, Bruce. Increased Power Generation in a Continuous Flow MFC with Advective Flow through the Porous Anode and Reduced Electrode Spacing. **Environmental science & technology**, 05 Jan. 2006. Disponível em: <http://dx.doi.org/10.1021/es051652w>. Acesso em: 3 abr. 2025.
- CLEVELAND, Robert B *et al.* STL: A seasonal-trend decomposition. **Journal of Official Statistics**, v. 6, n. 1, p. 3-73, 1990. Disponível em: <https://www.wessa.net/download/stl.pdf>. Acesso em: 9 nov. 2025.
- DU, Zhuwei; LI, Haoran; GU, Tingyue. A state of the art review on microbial fuel cells: A promising technology for wastewater treatment and bioenergy. **Biotechnology Advances**, v. 25, n. 5, p. 464-482, set. 2007. Disponível em: <https://doi.org/10.1016/j.biotechadv.2007.05.004>. Acesso em: 3 ago. 2025.

DUTTA, Arup *et al.* A review on power management systems: An electronic tool to enable microbial fuel cells for powering range of electronic appliances. **Journal of Power Sources**, v. 517, n. 517. 230688 p, jan. 2022. Disponível em: <https://doi.org/10.1016/j.jpowsour.2021.230688>. Acesso em: 3 ago. 2025.

FERNANDEZ FEITO, Rodrigo; YOUNAS, Tahreem; RICHARD M., Dinsdale. Evaluation of a comprehensive power management system with maximum power point tracking algorithm for multiple microbial fuel cell energy harvesting. **Bioelectrochemistry**, v. 155. 12 p, nov. 2023. Disponível em: <https://doi.org/10.1016/j.bioelechem.2023.108597>. Acesso em: 5 ago. 2025.

GUO, F. *et al.* Substrate salinity: A critical factor regulating the performance of microbial fuel cells, a review. **Science of The Total Environment**, v. 763. 2021. Disponível em: <https://doi.org/10.1016/j.scitotenv.2020.143021>. Acesso em: 20 jan. 2026.

GUL, Hajera *et al.* Progress in microbial fuel cell technology for wastewater treatment and energy harvesting. **Chemosphere**, v. 281. 130828 p, out. 2021. Disponível em: <https://doi.org/10.1016/j.chemosphere.2021.130828>. Acesso em: 3 ago. 2025.

HE, Zhen; MANSFELD, Florian. Exploring the use of electrochemical impedance spectroscopy (EIS) in microbial fuel cell studies. **Energy & Environmental Science**, v. 2, n. 2, p. 215-219, Nov. 2008. The Royal Society of Chemistry. Disponível em: <http://dx.doi.org/10.1039/B814914C>. Acesso em: 3 ago. 2025.

IDA, K; Mandal, B. Microbial fuel cell design, application and performance: a review. **Materials Today: Proceedings**, v. 76, n. 1, p. 88-94, Nov. 2023. Disponível em: doi.org/10.1016/j.matpr.2022.10.131. Acesso em: 20 jan. 2025.

IEA. **Net Zero Roadmap: A Global Pathway to Keep the 1.5 °C Goal in Reach**. Paris, 2023. Disponível em: <https://www.iea.org/reports/net-zero-roadmap-a-global-pathway-to-keep-the-15-c-goal-in-reach>. Acesso em: 8 nov. 2025.

ISHII, Shun'ichi *et al.* Identifying the microbial communities and operational conditions for optimized wastewater treatment in microbial fuel cells. **Water Research**, v. 47, n. 19, p. 7120-7130, Dez. 2013.

JALILI, Payam *et al.* A comprehensive review of microbial fuel cells considering materials, methods, structures, and microorganisms. **Heliyon**, v. 10, n. 3, 15 fev. 2024. Disponível em: <https://doi.org/10.1016/j.heliyon.2024.e25439>. Acesso em: 27 set. 2025.

JIANG, Jiwei *et al.* The influence of external resistance on the performance of microbial fuel cell and the removal of sulfamethoxazole wastewater. **Bioresource**

Technology, v. 336. 125308 p, 21 Set. 2021. Disponível em:
<https://doi.org/10.1016/j.biortech.2021.125308>. Acesso em: 3 ago. 2025.

KAMPERIDIS, Theofilos *et al.* A 2D Modelling Approach for Predicting the Response of a Two-Chamber Microbial Fuel Cell to Substrate Concentration and Electrolyte Conductivity Changes. **Energies**, v. 15, n. 4. 1412 p, 12 fev. 2022. Disponível em:
<https://doi.org/10.3390/en15041412>. Acesso em: 28 set. 2025.

KILLICK, R; FEARNHEAD, P; ECKLEY, I.A. Optimal Detection of Changepoints With a Linear Computational Cost. **Journal of the American Statistical Association**, v. 107, p. 1590-1598, OUT. 2012. Disponível em:
<http://dx.doi.org/10.1080/01621459.2012.737745>. Acesso em: 8 nov. 2025.

KIM, Mi-Sun; LEE, Yu-jin. Optimization of culture conditions and electricity generation using *Geobacter sulfurreducens* in a dual-chambered microbial fuel-cell. **International Journal of Hydrogen Energy**, v. 35, n. 23, p. 13028-13034, Dez. 2010. Disponível em: <https://doi.org/10.1016/j.ijhydene.2010.04.061>. Acesso em: 3 ago. 2025.

LANGBEHN, Rayane Kunert. **Resiliência de sistemas de remoção de carbono e nitrogênio em células a combustível microbianas à adição de fluoroquinolonas**. Florianópolis, 2023. 158 p Tese (Engenharia química) - Universidade Federal de Santa Catarina, Florianópolis, 2023.

LANGBEHN, Rayane Kunert. **Resiliência de sistemas de remoção de carbono e nitrogênio em células a combustível microbianas à adição de fluoroquinolonas**. Florianópolis, 2023. 158 p Tese (Engenharia química) - Universidade Federal de Santa Catarina. Disponível em:
<https://repositorio.ufsc.br/handle/123456789/247767>. Acesso em: 3 ago. 2025.

LARMINIE, James; DICKS, Andrew. **Fuel Cell Systems Explained**, f. 168. 2000. 336 p.

LASIA, Andrzej. **Electrochemical Impedance Spectroscopy and its Applications**. Springer, f. 184, 2014. 367 p.

LESNIK, Keaton Larson; LIU, Hong. Predicting Microbial Fuel Cell Biofilm Communities and Bioreactor Performance using Artificial Neural Networks. **Environmental Science & Technology**, v. 51, n. 18, p. 10881-10892, 19 set. 2017. American Chemical Society. Disponível em:
<https://doi.org/10.1021/acs.est.7b01413>. Acesso em: 4 dez. 2023.

LOGAN, Bruce E. *et al.* Microbial Fuel Cells: Methodology and Technology. **Environmental Science & Technology**, v. 40, n. 17, p. 5181-5192, Set.

2006. American Chemical Society. Disponível em:
<https://doi.org/10.1021/es0605016>. Acesso em: 3 ago. 2025.

LOGAN, Bruce E.. **Microbial Fuel Cells**. John Wiley & Sons, v. 1, f. 108, 2008. 216 p. Disponível em: <http://library.navoiy-uni.uz/files/logan%20b.e.%20-%20microbial%20fuel%20cells%20%282008%29%28236s%29.pdf>. Acesso em: 3 ago. 2025.

LOGAN, Bruce E; RABAEY, Korneel. Conversion of Wastes into Bioelectricity and Chemicals by Using Microbial Electrochemical Technologies. **Science**, v. 337, n. 6095, p. 686-690, 10 ago. 2012. Disponível em:
<https://www.science.org/doi/10.1126/science.1217412>. Acesso em: 3 ago. 2025.

MONOD, J. The Growth of Bacterial Cultures. **Annual Review of Microbiology**, v. 3, p. 371-394, 1949.

MUKHERJEE, Anwesha *et al.* Effective power management system in stacked microbial fuel cells for onsite applications. **Journal of Power Sources**, v. 517. 230684 p, jan. 2022. Disponível em:
<https://doi.org/10.1016/j.jpowsour.2021.230684>. Acesso em: 3 ago. 2025.

NOGUEIRA, Renan Mello *et al.* Desenvolvimento e Aplicação de Células a Combustível Microbianas para Geração de Energia. *In: SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA*, n. 28. 2025. Anais [...] Florianópolis, 2025. 11 p.

NOORI, Md.T *et al.* Biofouling effects on the performance of microbial fuel cells and recent advances in biotechnological and chemical strategies for mitigation. **Biotechnology Advances**, v. 37, n. 8, 01 dez. 2019. Disponível em:
<https://doi.org/10.1016/j.biotechadv.2019.107420>. Acesso em: 8 nov. 2025.

PARK, Jae-Do; REN, Zhiyong. Hysteresis controller based maximum power point tracking energy harvesting system for microbial fuel cells. **Journal of Power Sources**, v. 205, p. 151-156, jan. 2012. Disponível em:
<https://doi.org/10.1016/j.jpowsour.2012.01.053>. Acesso em: 4 ago. 2025.

PICIOREANU, Cristian *et al.* A computational model for biofilm-based microbial fuel cells. **Water Research**, v. 41, n. 13, p. 2921-2940, jul. 2007. Disponível em:
<https://doi.org/10.1016/j.watres.2007.04.009>. Acesso em: 11 out. 2025.

POTRYKUS, S. *et al.* Modeling the effect of external load variations on single, serie and parallel connected microbial fuel cells. **Bioresource Technology**, v. 416, jan. 2025. Disponível em: <https://doi.org/10.1016/j.biortech.2024.131761>. Acesso em: 27 set. 2025.

POTTER, M. C.. Electrical effects accompanying the decomposition of organic compounds. **Proceedings of the Royal Society of London**, v. 84, n. 571, p. 260-276, set. 1911. Series B, Containing Papers of a Biological Character. Disponível em: <https://doi.org/10.1098/rspb.1911.0073>. Acesso em: 4 ago. 2025.

PRASAD, Gajendra J; PANDA, Soumen. Microbial Fuel Cells: Types of MFC and Different Source of Substrate. **International Journal of Latest Technology in Engineering, Management & Applied Science (IJLTEMAS)**, v. 7, n. 5, p. 158-165, maio 2018. Disponível em: <https://www.ijltemas.in/DigitalLibrary/Vol.7Issue5/158-165.pdf>. Acesso em: 3 ago. 2025.

QING, Bu; NOORI, Md Tabish; MIN, Booki. High-rate biohydrogen production in single-chamber microbial electrolysis cell using iron-sulfide modified biocathode. **Environmental Science and Pollution Research**, v. 32, n. 10, p. 5747-5759, 01 02 2025. Disponível em: <https://doi.org/10.1007/s11356-025-35961-z>. Acesso em: 8 nov. 2025.

RECIO-GARRIDO, D; PERRIER, M; TARTAKOVSKY, B. Parameter estimation of a microbial fuel cell process control-oriented model. *In: MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION*, n. 22. 2014. Proceedings [...] Palermo, Itália, 2014, p. 918-923. Disponível em: <https://ieeexplore.ieee.org/document/6961491>. Acesso em: 8 nov. 2025.

ROSSI, Ruggero *et al.* Impact of cleaning procedures on restoring cathode performance for microbial fuel cells treating domestic wastewater. **Bioresource Technology**, v. 290, out. 2019. Disponível em: <https://doi.org/10.1016/j.biortech.2019.121759>. Acesso em: 8 nov. 2025.

ROZENDAL, René *et al.* Towards practical implementation of bioelectrochemical wastewater treatment. **Trends in Biotechnology**, v. 26, n. 8, p. 450-459, ago. 2008. Disponível em: <https://doi.org/10.1016/j.tibtech.2008.04.008>. Acesso em: 3 ago. 2025.

SANCHEZ-HERRERA, Diana *et al.* Characterization of anode and anolyte community growth and the impact of impedance in a microbial fuel cell". **BMC Biotechnology**, v. 14, n. 1, 09 dez. 2014. Disponível em: <https://doi.org/10.1186/s12896-014-0102-z>. Acesso em: 8 nov. 2025.

SANTORO, Carlo *et al.* Microbial fuel cells: from fundamentals to applications. A review. **Journal of Power Sources**, v. 356, p. 225-244, jul. 2017. Disponível em: <https://doi.org/10.1016/j.jpowsour.2017.03.109>. Acesso em: 3 ago. 2025.

SARAVANAN, A. *et al.* Microbial electrolysis cells and microbial fuel cells for biohydrogen production: current advances and emerging challenges. **Biomass**

Conversion and Biorefinery, v. 13, n. 10, p. 8403-8423, jul. 2023. Disponível em: <https://doi.org/10.1007/s13399-020-00973-x>. Acesso em: 3 ago. 2025.

SCHRÖDER, Uwe. A basic introduction into microbial fuel cells and microbial electrocatalysis. **ChemTexts**, v. 4. 19 p, nov. 2018. Disponível em: <https://doi.org/10.1007/s40828-018-0072-1>. Acesso em: 3 ago. 2025.

SEABOLD, Skipper; PERKTOLD, Josef. Statsmodels: Econometric and Statistical Modeling with Python. *In: PYTHON IN SCIENCE CONFERENCE*, n. 9. 2010. Proceedings [...]. 2010. Disponível em: <https://proceedings.scipy.org/articles/Majora-92bf1922-011>. Acesso em: 9 nov. 2025.

SERRA, P.M.D; ESPÍRITO-SANTO, A; MAGRINHO, M. A steady-state electrical model of a microbial fuel cell through multiple-cycle polarization curves. **Renewable and Sustainable Energy Reviews**, v. 117, jan. 2020. Disponível em: <https://doi.org/10.1016/j.rser.2019.109439>. Acesso em: 8 nov. 2025.

SEYEDI, MirHojjat. Biological cell response to electric field: a review of equivalent circuit models and future challenges. **Biomedical Physics & Engineering Express**, v. 11, n. 2. 022001 p, 2025. Disponível em: <https://doi.org/10.1088/2057-1976/ad8092>. Acesso em: 4 out. 2025.

SHAH, Shachi; VENKATRAMANAN, V.; PRASAD, Ram. **Sustainable Green Technologies for Environmental Management**. 2019, p. 199-218. (Springer Singapore). Disponível em: http://dx.doi.org/10.1007/978-981-13-2772-8_10. Acesso em: 3 ago. 2025.

SINGH, Anoop *et al.* Biohydrogen Production from Lignocellulosic Biomass: Technology and Sustainability. **Energies**, v. 8, n. 11, p. 13062-13080, nov. 2015. Disponível em: <https://www.mdpi.com/1996-1073/8/11/12357>. Acesso em: 3 ago. 2025.

SLATE, Anthony J. *et al.* Microbial fuel cells: An overview of current technology. **Renewable and Sustainable Energy Reviews**, v. 101, p. 60-81, 01 mar. 2019. Disponível em: <https://doi.org/10.1016/j.rser.2018.09.044>. Acesso em: 3 ago. 2025.

TABISH, Asif Nadeem *et al.* Electrochemical Insight into the Use of Microbial Fuel Cells for Bioelectricity Generation and Wastewater Treatment. **Energies**, v. 16, n. 6. 2760 p, 16 mar. 2023. Disponível em: <https://doi.org/10.3390/en16062760>. Acesso em: 27 set. 2025.

THOUAND, Gérald. **Handbook of Cell Biosensors**. Springer, f. 496, 2021. 992 p.

TRUONG, Charles; OUDRE, Laurent; VAYATIS, Nicolas. Selective review of offline change point detection methods. **Signal Processing**, v. 167, fev. 2020. Elsevier BV. Disponível em: <http://dx.doi.org/10.1016/j.sigpro.2019.107299>. Acesso em: 9 nov. 2025.

TUKEY, John Wilder. **Exploratory Data Analysis**. Addison-Wesley Publishing Company, f. 357, 1976. 714 p.

VISHWANATHAN, A.S.. Microbial fuel cells: : a comprehensive review for beginners. **3 Biotech**, v. 11, n. 5. 248 p, abr. 2021. Disponível em: <https://doi.org/10.1007/s13205-021-02802-y>. Acesso em: 3 ago. 2025.

WANG, Heming; PARK, Jae-Do; REN, Zhiyong. Active Energy Harvesting from Microbial Fuel Cells at the Maximum Power Point without Using Resistors. **Environmental Science & Technology**, v. 46, n. 9, p. 5247-5252, abr. 2012. Disponível em: <https://doi.org/10.1021/es300313d>. Acesso em: 3 ago. 2025.

WENZEL, J *et al.* Microbial fuel cell coupled to biohydrogen reactor: a feasible technology to increase energy yield from cheese whey. **Bioprocess Biosyst Eng** , v. 40, n. 6, p. 807-819, 20 fev. 2017. Disponível em: <https://doi.org/10.1007/s00449-017-1746-6>. Acesso em: 8 nov. 2025.

YASIR SALEEM, Afridi; KASHIF, Ahmad; LAIQ, Hassan. Artificial intelligence based prognostic maintenance of renewable energy systems: A review of techniques, challenges, and future research directions. **International Journal of Energy Research**, v. 46, p. 21619-21642, 13 jul. 2021. Disponível em: <https://doi.org/10.1002/er.7100>. Acesso em: 17 ago. 2025.

ZHAO, Feng *et al.* Challenges and Constraints of Using Oxygen Cathodes in Microbial Fuel Cells. **Environmental Science & Technology**, v. 40, n. 17, p. 5193-5199, 01 set. 2006. Disponível em: <https://pubs.acs.org/doi/10.1021/es060332p>. Acesso em: 4 out. 2025.

ANEXO A — Códigos em matlab

Arquivo AjusteModeloMFC1_20240411.m

```

%%%%%%%% Os dados usados neste codigo sao gerados no script
%%%%%%%% "LeituraTratamentoDados_20240411.m"
%%%%%%%% Model Setup and Variables Setup
tol = 1.e-6; % ode solver tolerance
options = odeset('AbsTol', tol,'RelTol',tol,'MaxOrder',5,'Stats',...
                'off','Refine',1);

aux = zeros(size(MinTensao,1),2);
aux(:,1) = [0;MinTensao(1:end-1,3)]+ones;
aux(:,2) = MinTensao(:,3);
Params=zeros(length([3,9,11,17,20,21]),4);
ll=0;
for jj=[3,9,11,17,20,21]
ll=ll+1;
data = Tensao1(aux(jj,1):aux(jj,2));
time = datesB(aux(jj,1):aux(jj,2));
data=data(50:end);
time=time(50:end);
corr=data(1);
data=data/corr;
t = linspace(0,1,length(data));
y0=1;
OF=@(v)objFunInventory(v,t,data,y0,options);
v=lsqnonlin(OF,[1,1,1,1]);
Params(ll,:)=v;
params.a=v(1);
params.b=v(2);
params.c=v(3);
params.D=v(4);
[t2,y]=ode45(@(t,y)inventory(t,y,params),t,y0,options);

```

```

y = interp1(t2,y,t);
figure
hold on
title('Tensao MFC 1 (mW)')
grid on
box on
plot(t,corr*data,'.r')
plot(t,corr*y,'b','LineWidth',1.2)
legend('dados','modelo')
hold off
print('-dpng',['TensaoMFC1_Modelo',num2str(jj)])
end

```

Arquivo AjusteModeloMFC2_20240411.m

```

%%%%%% Os dados usados neste codigo sao gerados no script
%%%%%% "LeituraTratamentoDados_20240411.m"
%%%%%%%% Model Setup and Variables Setup
tol = 1.e-6; % ode solver tolerance
options = odeset('AbsTol', tol,'RelTol',tol,'MaxOrder',5,'Stats',...
                'off','Refine',1);

```

```

aux = zeros(size(MinTensao,1),2);
aux(:,1) = [0;MinTensao(1:end-1,4)]+ones;
aux(:,2) = MinTensao(:,4);

```

```

Params=zeros(length([11,13,14,15,16,17,18,19,20,21]),4);
ll=0;
for jj=[11,13,14,15,16,17,18,19,20,21]
ll=ll+1;

```

```

data = Tensao2(aux(jj,1):aux(jj,2));
time = datesB(aux(jj,1):aux(jj,2));
data=data(50:end);
time=time(50:end);
corr=data(1);
data=data/corr;
t = linspace(0,1,length(data));
y0=1;
OF=@(v)objFunInventory(v,t,data,y0,options);
v=lsqnonlin(OF,[1,1,1,1]);
Params(ll,:)=v;
params.a=v(1);
params.b=v(2);
params.c=v(3);
params.D=v(4);
[t2,y]=ode45(@(t,y)inventory(t,y,params),t,y0,options);
y = interp1(t2,y,t);
figure
hold on
title('Tens o MFC 2 (mW)')
grid on
box on
plot(t,corr*data,'r')
plot(t,corr*y,'b','LineWidth',1.2)
legend('dados','modelo')
hold off
print('-dpng',['TensaoMFC2_Modelo',num2str(jj)])
end

```

Arquivo inventory.m

```

function yprime = inventory(t,y,params)
a=params.a;
b=params.b;

```

```

c=params.c;
D=params.D;
phi = a*exp(b*t.^c);
yprime=D-phi.*y;

```

Arquivo LeituraTratamentoDados_20240411.m

```
clear all; close all; clc;
```

```
%%%%% Leitura dos dados
```

```

DATA = importdata('Dados_12dez_atual_ESTABILIDADE.xlsx');
dates = string(DATA.textdata(2:end,1));
dates = datetime(dates,'InputFormat','dd/MM/yyyy HH:mm:ss');
dates.Format='dd-MMM-yyyy HH:mm:ss';
data = DATA.data;
dates = dates(6004:17480);
data = data(6004:17480,:);
a = isnat(dates);
dates = dates(~a);
data = data(~a,:);

```

```
%%%%% No que se segue, o número 1 se refere aos dados do MFC1 e o número
```

2

```
%%%%% se refere aos dados do MFC2
```

```
%%%%% Padronização dos dados em intervalos de 5 minutos
```

```

datesB = (dates(1):minutes(5):dates(end)).';
datesB.Format='dd-MMM-yyyy HH:mm:ss';
Tensao1=interp1(dates,data(:,1),datesB);      % MFC1
Tensao2=interp1(dates,data(:,4),datesB);     % MFC2

```

```

%%%%% Abaixo serao calculados os valores medianos, minimos e maximos das
%%%%% tensoes associadas ao MFC1 e ao MFC2 a cada 2 dias seguidos (ciclo

```

de

```

%%%%%% dois dias observado nos dados)
len=2*288; %%%% 1 dia = 288 intervalos de 5 minutos
MTensao = zeros(round(size(datesB,1)/len),2); %Tensao Mediana (MFC1 e
MFC2)
MaxTensao = zeros(round(size(datesB,1)/len),4); %Tensao Max (MFC1 e
MFC2)
MinTensao = zeros(round(size(datesB,1)/len),4); %Tensao Min (MFC1 e
MFC2)
for jj = 1:size(MTensao,1)
    MTensao(jj,1) = median(Tensao1((jj-1)*len+1:jj*len));
    MTensao(jj,2) = median(Tensao2((jj-1)*len+1:jj*len));
    [a,b]=max(Tensao1((jj-1)*len+1:jj*len));
    MaxTensao(jj,[1,3]) = [a,b+(jj-1)*len];
    [a,b]=max(Tensao2((jj-1)*len+1:jj*len));
    MaxTensao(jj,[2,4]) = [a,b+(jj-1)*len];
    [a,b]=min(Tensao1((jj-1)*len+1:jj*len));
    MinTensao(jj,[1,3]) = [a,b+(jj-1)*len];
    [a,b]=min(Tensao2((jj-1)*len+1:jj*len));
    MinTensao(jj,[2,4]) = [a,b+(jj-1)*len];
end

%%%%%% Cálculo de Valores Médios
aux1 = Tensao1;
aux2 = Tensao2;
len2=14;
for jj=1:length(Tensao1)
    aux1(jj) = mean(Tensao1(max(jj-len2,1):jj));
    aux2(jj) = mean(Tensao2(max(jj-len2,1):jj));
end

%%%%%% Cálculo de Valores Medianos
len2=288;
MTensao2 = zeros(round(size(datesB,1)/len2),2);

```

```

for jj = 1:size(MTensao2,1)
    MTensao2(jj,1) = median(Tensao1((jj-1)*len2+1:jj*len2));
    MTensao2(jj,2) = median(Tensao2((jj-1)*len2+1:jj*len2));
end

```

%%%% Plotagem de Gráficos

Plotting_test_20240411;

Arquivo objFunInventory.m

```

function f = objFunInventory(v,tspan,data,yinit,options)
params.a=v(1);
params.b=v(2);
params.c=v(3);
params.D=v(4);
[t,y]=ode45(@(t,y)inventory(t,y,params),tspan,yinit,options);
y = interp1(t,y,tspan);
f = [(y-data)'./data'];%0.5*v];

```

Arquivo Plotting_test_20240411.m

```

close all;
inicio = datetime(2024,01,05);
fim = dates(end-1);

figure
hold on
grid on
box on
title('Tensão MFC 1 (mV)')
plot(datesB,Tensao1,'.b')
plot(datesB,aux1,'r')
plot(datesB(1:len:end),MTensao(:,1),'r','LineWidth',1.2)
plot(datesB(MaxTensao(:,3)),MaxTensao(:,1),'k','LineWidth',1.2)

```

```

plot(datesB(MinTensao(:,3)),MinTensao(:,1),'m','LineWidth',1.2)
xlim([inicio,fim])
hold off
print('-dpng','TensaoMFC1')

```

```

figure
hold on
grid on
box on
title('Tensão MFC 2 (mV)')
plot(datesB,Tensao2,'.b')
plot(datesB,aux2,'r')
plot(datesB(1:len:end),MTensao(:,2),'r','LineWidth',1.2)
plot(datesB(MaxTensao(:,4)),MaxTensao(:,2),'k','LineWidth',1.2)
plot(datesB(MinTensao(:,4)),MinTensao(:,2),'m','LineWidth',1.2)
xlim([inicio,fim])
hold off

```

```

aux = zeros(size(MinTensao,1),2);
aux(:,1) = [0;MinTensao(1:end-1,3)]+ones;
aux(:,2) = MinTensao(:,3);

```

```

% %%% A inspeção desse grafico ajuda na escolha dos periodos usados no
% %%% ajuste do modelo
% %%% Graficos Separados do MFC1
% for jj=[3,9,11,17,20,21]%1:size(MinTensao,1)
% figure
% hold on
% grid on
% box on
% plot(Tensao1(aux(jj,1):aux(jj,2)),'.')
% end
% hold off

```

```

%%% Graficos Juntos do MFC1
figure
hold on
grid on
box on
title('Tensão MFC 1 (mV)')
for jj=[3,9,11,17,20,21]
plot(Tensao1(aux(jj,1):aux(jj,2)),'.')
end
set(gca,'FontSize',16,'FontName','Arial')
hold off
print('-dpng','TensaoMFC1_repetida')

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%% Repetir o que foi feito acima para MFC 2
aux = zeros(size(MinTensao,1),2);
aux(:,1) = [0;MinTensao(1:end-1,4)]+ones;
aux(:,2) = MinTensao(:,4);
% for jj=1:size(MinTensao,1)
% figure
% hold on
% grid on
% box on
% plot(Tensao2(aux(jj,1):aux(jj,2)),'.')
% end
% hold off

figure
hold on
grid on
box on

```

```
title('Tensão MFC 2 (mV)')
for
jj=[11,13,14,15,16,17,18,19,20,21]%[3,5,7,9:11,13:15,17:size(MinTensao,1)]
plot(Tensao2(aux(jj,1):aux(jj,2)),'.')
end
set(gca,'FontSize',16,'FontName','Arial')
hold off
print('-dpng','TensaoMFC2_repetida')

figure
hold on
grid on
box on
title('Tensão MFC 2 (mV)')
plot(datesB(1:len2:end),MTensao2(:,1),'r','LineWidth',1.2)
plot(datesB,aux1,'r')
xlim([inicio,fim])
hold off

figure
hold on
grid on
box on
title('Tensão MFC 2 (mV)')
plot(datesB(1:len2:end),MTensao2(:,2),'r','LineWidth',1.2)
plot(datesB,aux2,'r')
xlim([inicio,fim])
hold off
```

ANEXO B — Notebook Jupiter

✓ Análise de Dados de Células a Combustível Microbianas (MFCs)

Notebook Completo para Análise Eletroquímica e de Séries Temporais

Este notebook implementa o pipeline completo de análise solicitado, incluindo pré-processamento, análise exploratória, análise de séries temporais, caracterização eletroquímica e modelagem.

Instruções de Uso:

1. Execute a primeira célula de código para instalar as bibliotecas necessárias.
2. Execute a segunda célula para importar os pacotes.
3. Na seção "1. Carregamento e Pré-processamento dos Dados", execute a célula de upload e envie todos os seus arquivos (`combinado_sort.csv`, `fisico_quimicos.xlsx`, `curvas_polarizacao.zip`, `condicoes_operacionais_e_intecorrencias.docx`).
4. Siga executando as células em ordem para reproduzir todas as análises e gerar as figuras e tabelas.

Instalação de Bibliotecas Adicionais A biblioteca `ruptures` é utilizada para a detecção de pontos de mudança de regime.

```
!pip install ruptures
```

Importação das Bibliotecas Principais

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from google.colab import files
import io
import zipfile
import json
from datetime import datetime
import pytz
```

✓ Módulos de estatística e séries temporais

```
from statsmodels.tsa.seasonal import STL
from statsmodels.tsa.stattools import ccf
import statsmodels.formula.api as smf
from scipy.stats import shapiro, ttest_ind, wilcoxon
import ruptures as rpt
```

✓ Configurações de visualização

```
plt.style.use('seaborn-v0_8-whitegrid')
sns.set_context("talk")
%matplotlib inline
```

✓ 1. Carregamento e Pré-processamento dos Dados

1.1. Upload dos Arquivos

Execute a célula abaixo para abrir a janela de upload. Selecione todos os arquivos de dados necessários.

```
uploaded = files.upload()
```

✓ 1.2. Leitura e Limpeza do Dataset Principal (`combinado_sort.csv`)

Esta seção carrega os dados de séries temporais, padroniza os timestamps, trata valores ausentes e anômalos (como as leituras de temperatura de -127°C) e converte as unidades.

```
# Log de pré-processamento
log_processamento = []

# Carregar o arquivo principal
try:
    df_main = pd.read_csv(io.BytesIO(uploaded['combinado_sort.csv']))
    log_processamento.append(f"Arquivo 'combinado_sort.csv' lido com sucesso. Linhas lidas: {len(df_main)}")
except KeyError:
    print("Erro: O arquivo 'combinado_sort.csv' não foi encontrado. Por favor, faça o upload.")
    # Cria um dataframe vazio para evitar que o resto do código quebre
    df_main = pd.DataFrame()

if not df_main.empty:
    # Padronização de Timestamps - LINHA CORRIGIDA
    df_main['timestamp'] = pd.to_datetime(df_main['Data completa'])
    df_main = df_main.drop_duplicates(subset=['timestamp']).sort_values('timestamp')
    df_main = df_main.set_index('timestamp')
    try:
        df_main.index = df_main.index.tz_localize('America/Sao_Paulo', ambiguous='infer')
    except:
        print("Aviso: Timezone já presente ou não pôde ser adicionado")
    log_processamento.append("Timestamps padronizados para ISO 8601 e fuso horário 'America/Sao_Paulo'.")

    # Tratamento de anomalias de temperatura
    temp_col = 'Temperatura (°C)' if 'Temperatura (°C)' in df_main.columns else 'Temperatura (°C)'
    linhas_temp_invalidas = len(df_main[df_main[temp_col] == -127.0])
    df_main[temp_col] = df_main[temp_col].replace(-127.0, np.nan)
    df_main[temp_col] = df_main[temp_col].interpolate(method='time')
    log_processamento.append(f"{linhas_temp_invalidas} leituras de temperatura inválidas (-127.0) foram substituídas por NaN")

    # Conversão de unidades (mV -> V, mA -> A, mW -> W)
    cols_to_convert = {
        'Tensão MFC 1 (mV)': 'V_MFC1', 'Corrente MFC 1 (mA)': 'I_MFC1', 'Potência MFC 1 (mW)': 'P_MFC1',
        'Tensão MFC 2 (mV)': 'V_MFC2', 'Corrente MFC 2 (mA)': 'I_MFC2', 'Potência MFC 2 (mW)': 'P_MFC2'
    }
    for old_col, new_col in cols_to_convert.items():
        if old_col in df_main.columns:
            unit_factor = 1e-3 # mV, mA, mW para V, A, W
            df_main[new_col] = df_main[old_col] * unit_factor
    log_processamento.append("Unidades convertidas: mV -> V, mA -> A, mW -> W.")

    # Selecionar colunas de interesse
    df_clean = df_main[['V_MFC1', 'I_MFC1', 'P_MFC1', 'V_MFC2', 'I_MFC2', 'P_MFC2', temp_col]].copy()
    df_clean.rename(columns={temp_col: 'Temperature'}, inplace=True)

    # Remover NaNs restantes
    linhas_antes_nan = len(df_clean)
    df_clean.dropna(inplace=True)
    linhas_removidas_nan = linhas_antes_nan - len(df_clean)
    log_processamento.append(f"{linhas_removidas_nan} linhas com valores NaN foram removidas.")

    print("--- Log de Pré-processamento ---")
    for log_entry in log_processamento:
        print(f"- {log_entry}")
    print("\n--- Amostra dos Dados Limpos ---")
    print(df_clean.head())
    print("\n--- Informações do DataFrame ---")
    df_clean.info()
```

1.3. Leitura dos Dados Físico-Químicos (fisico_quimicos.xlsx)

Carrega os dados de análises físico-químicas, alinhando-os por data para correlação posterior.

```
print("Arquivos disponíveis no upload:")
for fname in uploaded.keys():
    print(f" - {fname}")
```

```
# Primeiro, verificar quais arquivos foram carregados
print("Arquivos disponíveis no upload:")
for fname in uploaded.keys():
    print(f" - {fname}")

# Procurar o arquivo físico-químico (pode ter nome ligeiramente diferente)
fq_file = None
for fname in uploaded.keys():
```

```

if 'fisico' in fname.lower() and fname.endswith('.xlsx'):
    fq_file = fname
    break

if fq_file:
    print(f"\nProcessando arquivo: {fq_file}")
    try:
        # Primeiro, verificar quais abas existem
        xl_file = pd.ExcelFile(io.BytesIO(uploaded[fq_file]))
        print(f"Abas disponíveis: {xl_file.sheet_names}")

        # Tentar diferentes nomes de abas
        mfc1_sheet = None
        mfc2_sheet = None

        for sheet in xl_file.sheet_names:
            if ('MFC 1' in sheet or 'MFC1' in sheet) and 'par_quim' in sheet:
                mfc1_sheet = sheet
            if ('MFC 2' in sheet or 'MFC2' in sheet) and 'par_quim' in sheet:
                mfc2_sheet = sheet

        if mfc1_sheet and mfc2_sheet:
            # skiprows=3 pula as 3 primeiras linhas, fazendo a linha 4 ser o header
            # header=0 usa a primeira linha não pulada (linha 4) como cabeçalho
            df_fis_quim_mfc1 = pd.read_excel(io.BytesIO(uploaded[fq_file]), sheet_name=mfc1_sheet, skiprows=3, header=0)
            df_fis_quim_mfc2 = pd.read_excel(io.BytesIO(uploaded[fq_file]), sheet_name=mfc2_sheet, skiprows=3, header=0)

            print(f"Aba MFC1 encontrada: {mfc1_sheet}")
            print(f"Aba MFC2 encontrada: {mfc2_sheet}")
            print(f"\nColunas MFC1: {df_fis_quim_mfc1.columns.tolist()}")
            print(f"Primeiras linhas MFC1:\n{df_fis_quim_mfc1.head(3)}")

            # Função para limpar e preparar os dados físico-químicos
            def clean_fq_data(df, mfc_id):
                # Verificar qual coluna de data existe
                date_col = None
                for col in df.columns:
                    # Verificar se a coluna já é datetime ou tem 'data'/'date' no nome
                    if isinstance(col, datetime):
                        date_col = col
                        break
                    elif isinstance(col, str) and ('data' in col.lower() or 'date' in col.lower()):
                        date_col = col
                        break

                if date_col is None:
                    date_col = df.columns[0] # Usar primeira coluna se não encontrar

                # Remover linhas que não são datas (como headers extras)
                df = df[df[date_col].notna()].copy()

                # Converter para datetime se ainda não for
                if not pd.api.types.is_datetime64_any_dtype(df[date_col]):
                    try:
                        df[date_col] = pd.to_datetime(df[date_col], format='%m/%d/%Y', errors='coerce')
                    except:
                        df[date_col] = pd.to_datetime(df[date_col], errors='coerce')

                # Remover linhas onde a conversão falhou
                df = df[df[date_col].notna()].copy()

                df = df.set_index(date_col)
                # Renomear colunas, mas pular se a coluna for datetime
                df.columns = [f"{col.replace(' ', '_').replace('(', '').replace(')', '')}_{mfc_id}"
                             if isinstance(col, str) else f"col_{i}_{mfc_id}"
                             for i, col in enumerate(df.columns)]

                return df

            df_fq1 = clean_fq_data(df_fis_quim_mfc1, 'MFC1')
            df_fq2 = clean_fq_data(df_fis_quim_mfc2, 'MFC2')
            df_fq_combined = pd.concat([df_fq1, df_fq2], axis=1)

            print("Dados físico-químicos carregados e combinados com sucesso.")
            print(df_fq_combined.head())
        else:
            print(f"Erro: Abas MFC não encontradas. Abas disponíveis: {xl_file.sheet_names}")
            df_fq_combined = pd.DataFrame()

    except Exception as e:
        print(f"Erro ao processar '{fq_file}': {e}")
        import traceback
        traceback.print_exc()

```

```

df_fq_combined = pd.DataFrame()
else:
    print("Erro: Nenhum arquivo físico-químico (.xlsx) foi encontrado. Análises de correlação físico-química serão puladas.")
    df_fq_combined = pd.DataFrame()

```

```

if not df_clean.empty:
    def plot_timeseries_simple(df, columns, title, ylabel='Unidade', convert_to_mA=False, ylim=None, filter_range=None):
        plt.figure(figsize=(20, 8))

        # Criar cópia para não modificar o original
        df_plot = df.copy()

        # Filtrar dados se especificado
        if filter_range and convert_to_mA:
            min_val, max_val = filter_range
            # Converter limites de mA para A para filtrar
            min_val_A = min_val / 1000
            max_val_A = max_val / 1000
            for col in columns:
                # Marcar valores fora do range como NaN
                mask = (df_plot[col] < min_val_A) | (df_plot[col] > max_val_A)
                df_plot.loc[mask, col] = np.nan

            # Remover pontos isolados no início (primeiro encontro de sequência válida)
            valid_indices = df_plot[col].notna()
            if valid_indices.any():
                first_valid_idx = valid_indices.idxmax()
                # Encontrar primeira sequência contínua de pelo menos 10 pontos válidos
                for i in range(len(df_plot)):
                    if i >= len(df_plot) - 10:
                        break
                    if df_plot[col].iloc[i:i+10].notna().sum() >= 8: # Pelo menos 8 de 10 pontos válidos
                        # Remover tudo antes desta sequência
                        df_plot.loc[:df_plot.index[i], col] = np.nan
                        break

        # Plotar apenas as linhas de corrente ao longo do tempo
        for col in columns:
            data = df_plot[col] * 1000 if convert_to_mA else df_plot[col] # Converter para mA se necessário
            plt.plot(df_plot.index, data, label=col, alpha=0.7, linewidth=1.5)

        plt.title(title, fontsize=18)
        plt.xlabel('Data', fontsize=14)
        plt.ylabel(ylabel, fontsize=14)

        if ylim:
            plt.ylim(ylim)

        plt.legend(loc='best')
        plt.grid(True, alpha=0.3)
        plt.tight_layout()
        plt.show()

        # Contar outliers antes de plotar
        outliers_mfc1 = ((df_clean['I_MFC1'] * 1000) > 0.7).sum()
        outliers_mfc2 = ((df_clean['I_MFC2'] * 1000) > 0.7).sum()
        print(f"Outliers removidos do gráfico (corrente > 0.7 mA):")
        print(f" MFC1: {outliers_mfc1} pontos ({outliers_mfc1/len(df_clean)*100:.2f}%)")
        print(f" MFC2: {outliers_mfc2} pontos ({outliers_mfc2/len(df_clean)*100:.2f}%)")

        plot_timeseries_simple(df_clean, ['I_MFC1', 'I_MFC2'],
                               'Série Temporal de Corrente',
                               ylabel='Corrente (mA)',
                               convert_to_mA=True,
                               ylim=(0, 0.7),
                               filter_range=(0, 0.7))

```

✓ 2. Análise Exploratória de Dados (EDA)

2.1. Estatísticas Descritivas

Tabela com as principais métricas estatísticas para as variáveis elétricas de cada MFC.

```

if not df_clean.empty:
    stats_desc = df_clean[['V_MFC1', 'I_MFC1', 'P_MFC1', 'V_MFC2', 'I_MFC2', 'P_MFC2']].describe().transpose()
    print("Estatísticas Descritivas (V, A, W):")
    print(stats_desc.to_markdown())

```

2.2. Distribuição das Variáveis Elétricas

Histogramas e Boxplots para visualizar a distribuição e a dispersão dos dados de Corrente.

```

if not df_clean.empty:
    # Converter corrente de A para mA
    df_clean['I_MFC1_mA'] = df_clean['I_MFC1'] * 1000
    df_clean['I_MFC2_mA'] = df_clean['I_MFC2'] * 1000

    # Histogramas apenas para Corrente
    fig, axes = plt.subplots(1, 2, figsize=(16, 6))
    fig.suptitle('Distribuição da Corrente (Histogramas)', fontsize=20)

    # Definir limites do eixo X em mA
    min_current = 0
    max_current = 0.7 # 0.7 mA (equivalente a 0.0007 A)

    # Ajustar bins para ter quantidade semelhante de colunas
    # Analisando a imagem, vou usar bins menores para MFC2
    bins_mfc1 = 35 # MFC1 tem distribuição mais concentrada
    bins_mfc2 = 35 # Manter a mesma quantidade para comparação justa

    xlim = (min_current, max_current)

    sns.histplot(df_clean['I_MFC1_mA'], ax=axes[0], kde=True, bins=bins_mfc1)
    axes[0].set_title('Corrente MFC 1 (mA)', fontsize=16)
    axes[0].set_xlim(xlim)
    axes[0].set_xlabel('Corrente (mA)')
    axes[0].set_ylabel('Contagem')

    sns.histplot(df_clean['I_MFC2_mA'], ax=axes[1], kde=True, bins=bins_mfc2)
    axes[1].set_title('Corrente MFC 2 (mA)', fontsize=16)
    axes[1].set_xlim(xlim)
    axes[1].set_xlabel('Corrente (mA)')
    axes[1].set_ylabel('Contagem')

    plt.tight_layout(rect=[0, 0.03, 1, 0.95])
    plt.show()

    # Boxplot apenas para Corrente
    fig, ax = plt.subplots(figsize=(8, 6))
    fig.suptitle('Comparação da Corrente (Boxplot)', fontsize=20)

    # Remover outliers usando método IQR
    def remove_outliers(data, column):
        Q1 = data[column].quantile(0.25)
        Q3 = data[column].quantile(0.75)
        IQR = Q3 - Q1
        lower_bound = Q1 - 1.5 * IQR
        upper_bound = Q3 + 1.5 * IQR
        return data[(data[column] >= lower_bound) & (data[column] <= upper_bound)]

    # Criar cópia dos dados e remover outliers
    df_clean_no_outliers = df_clean.copy()
    df_clean_no_outliers = remove_outliers(df_clean_no_outliers, 'I_MFC1_mA')
    df_clean_no_outliers = remove_outliers(df_clean_no_outliers, 'I_MFC2_mA')

    df_melt_I = df_clean_no_outliers[['I_MFC1_mA', 'I_MFC2_mA']].melt(var_name='MFC', value_name='Corrente (mA)')

    sns.boxplot(x='MFC', y='Corrente (mA)', data=df_melt_I, ax=ax)
    ax.set_ylim(0, 1.0) # Limitar eixo Y em mA

    plt.tight_layout(rect=[0, 0.03, 1, 0.95])
    plt.show()

    # Mostrar estatísticas dos outliers removidos
    outliers_mfc1 = len(df_clean) - len(remove_outliers(df_clean, 'I_MFC1_mA'))
    outliers_mfc2 = len(df_clean) - len(remove_outliers(df_clean, 'I_MFC2_mA'))
    print(f"\nOutliers removidos do boxplot:")
    print(f" MFC1: {outliers_mfc1} pontos ({outliers_mfc1/len(df_clean)*100:.2f}%)")
    print(f" MFC2: {outliers_mfc2} pontos ({outliers_mfc2/len(df_clean)*100:.2f}%)")

```

2.3. Matriz de Correlação

Heatmap mostrando a correlação de Pearson entre as variáveis elétricas e a temperatura.

```

if not df_clean.empty:
    correlation_matrix = df_clean.corr(method='pearson')
    plt.figure(figsize=(10, 8))
    sns.heatmap(correlation_matrix, annot=True, cmap='coolwarm', fmt=".2f")
    plt.title('Matriz de Correlação de Pearson')
    plt.show()

```

3. Análise de Séries Temporais

3.1. Visualização das Séries Temporais com Intercorrências

Gráficos da evolução da Tensão, Corrente e Potência ao longo do tempo, com marcações verticais para os eventos operacionais registrados.

```

# @title
# Datas das intercorrências
intercorrencias = {
    'Troca cátólito': '2023-10-09',
    'Anólito em contato com ar': '2023-12-02',
    'Limpeza cátodos': '2023-12-08',
    'Falta de luz': '2024-01-02',
    'Atraso alimentação': '2024-01-03',
    'Alimentação falhou': '2024-01-21',
    'Meio velho': '2024-01-23',
    'Curva Polarização': '2024-02-16'
}
intercorrencias_dates = {k: pd.to_datetime(v).tz_localize('America/Sao_Paulo') for k, v in intercorrencias.items()}

if not df_clean.empty:
    def plot_timeseries_with_events(df, columns, title, ylabel='Unidade', convert_to_mA=False, ylim=None, filter_range=None):
        plt.figure(figsize=(20, 8))

        # Criar cópia para não modificar o original
        df_plot = df.copy()

        # Filtrar dados se especificado
        if filter_range and convert_to_mA:
            min_val, max_val = filter_range
            # Converter limites de mA para A para filtrar
            min_val_A = min_val / 1000
            max_val_A = max_val / 1000
            for col in columns:
                # Marcar valores fora do range como NaN
                mask = (df_plot[col] < min_val_A) | (df_plot[col] > max_val_A)
                df_plot.loc[mask, col] = np.nan

            # Remover pontos isolados no início (primeiro encontro de sequência válida)
            valid_indices = df_plot[col].notna()
            if valid_indices.any():
                first_valid_idx = valid_indices.idxmax()
                # Encontrar primeira sequência contínua de pelo menos 10 pontos válidos
                for i in range(len(df_plot)):
                    if i >= len(df_plot) - 10:
                        break
                    if df_plot[col].iloc[i:i+10].notna().sum() >= 8: # Pelo menos 8 de 10 pontos válidos
                        # Remover tudo antes desta sequência
                        df_plot.loc[:df_plot.index[i], col] = np.nan
                        break

        for col in columns:
            data = df_plot[col] * 1000 if convert_to_mA else df_plot[col] # Converter para mA se necessário
            plt.plot(df_plot.index, data, label=col, alpha=0.7, linewidth=1.5)

        # Plotar linhas de eventos (apenas uma vez na legenda)
        for i, (event, date) in enumerate(intercorrencias_dates.items()):
            if i == 0:
                plt.axvline(x=date, color='r', linestyle='--', alpha=0.5, linewidth=1, label='Intercorrências')
            else:
                plt.axvline(x=date, color='r', linestyle='--', alpha=0.5, linewidth=1)

        plt.title(title, fontsize=18)
        plt.xlabel('Data', fontsize=14)
        plt.ylabel(ylabel, fontsize=14)

        if ylim:
            plt.ylim(ylim)

        plt.legend(loc='best')

```

```

plt.grid(True, alpha=0.3)
plt.tight_layout()
plt.show()

# Contar outliers antes de plotar
outliers_mfc1 = ((df_clean['I_MFC1'] * 1000) > 0.7).sum()
outliers_mfc2 = ((df_clean['I_MFC2'] * 1000) > 0.7).sum()
print(f"Outliers removidos do gráfico (corrente > 0.7 mA):")
print(f"  MFC1: {outliers_mfc1} pontos ({outliers_mfc1/len(df_clean)*100:.2f}%)")
print(f"  MFC2: {outliers_mfc2} pontos ({outliers_mfc2/len(df_clean)*100:.2f}%)")

plot_timeseries_with_events(df_clean, ['I_MFC1', 'I_MFC2'],
                             'Série Temporal de Corrente',
                             ylabel='Corrente (mA)',
                             convert_to_mA=True,
                             ylim=(0, 0.7),
                             filter_range=(0, 0.7))

```

3.2. Decomposição Sazonal (STL)

Decomposição da série de tensão em tendência, sazonalidade e resíduos para identificar padrões de longo prazo e ciclos diários. A periodicidade diária é de 288 amostras (24h * 12 amostras/h).

```

from statsmodels.tsa.seasonal import STL
import matplotlib.dates as mdates

if not df_clean.empty:
    # Pegar dados a partir da linha 2000
    df_stl = df_clean.iloc[2000:].copy()

    print(f"Total de dados originais: {len(df_clean)}")
    print(f"Dados usados na análise STL: {len(df_stl)} (a partir da linha 2000)")
    print(f"Período analisado: {df_stl.index[0]} até {df_stl.index[-1]}")

    periodo_diario = 24 * 12

    stl_mfc1 = STL(df_stl['I_MFC1'], period=periodo_diario, robust=True)
    result_mfc1 = stl_mfc1.fit()

    stl_mfc2 = STL(df_stl['I_MFC2'], period=periodo_diario, robust=True)
    result_mfc2 = stl_mfc2.fit()

    # Plot manual para ter controle total
    fig, axes = plt.subplots(4, 2, figsize=(18, 14))

    # Configurar formatação de datas
    date_formatter = mdates.DateFormatter('%Y-%m')
    date_locator = mdates.MonthLocator(interval=2) # A cada 2 meses (mais pontos)

    # MFC1
    axes[0, 0].plot(result_mfc1.observed.index, result_mfc1.observed * 1000)
    axes[0, 0].set_ylabel('Observado (mA)')
    axes[0, 0].set_title('MFC 1 - Corrente (mA)')
    axes[0, 0].xaxis.set_major_formatter(date_formatter)
    axes[0, 0].xaxis.set_major_locator(date_locator)
    axes[0, 0].tick_params(axis='x', rotation=45)

    axes[1, 0].plot(result_mfc1.trend.index, result_mfc1.trend * 1000)
    axes[1, 0].set_ylabel('Tendência (mA)')
    axes[1, 0].xaxis.set_major_formatter(date_formatter)
    axes[1, 0].xaxis.set_major_locator(date_locator)
    axes[1, 0].tick_params(axis='x', rotation=45)

    axes[2, 0].plot(result_mfc1.seasonal.index, result_mfc1.seasonal * 1000)
    axes[2, 0].set_ylabel('Sazonalidade (mA)')
    axes[2, 0].xaxis.set_major_formatter(date_formatter)
    axes[2, 0].xaxis.set_major_locator(date_locator)
    axes[2, 0].tick_params(axis='x', rotation=45)

    axes[3, 0].plot(result_mfc1.resid.index, result_mfc1.resid * 1000)
    axes[3, 0].set_ylabel('Resíduos (mA)')
    axes[3, 0].set_xlabel('Data')
    axes[3, 0].xaxis.set_major_formatter(date_formatter)
    axes[3, 0].xaxis.set_major_locator(date_locator)
    axes[3, 0].tick_params(axis='x', rotation=45)

    # MFC2
    axes[0, 1].plot(result_mfc2.observed.index, result_mfc2.observed * 1000)
    axes[0, 1].set_ylabel('Observado (mA)')
    axes[0, 1].set_title('MFC 2 - Corrente (mA)')

```

```

axes[0, 1].xaxis.set_major_formatter(date_formatter)
axes[0, 1].xaxis.set_major_locator(date_locator)
axes[0, 1].tick_params(axis='x', rotation=45)

axes[1, 1].plot(result_mfc2.trend.index, result_mfc2.trend * 1000)
axes[1, 1].set_ylabel('Tendência (mA)')
axes[1, 1].xaxis.set_major_formatter(date_formatter)
axes[1, 1].xaxis.set_major_locator(date_locator)
axes[1, 1].tick_params(axis='x', rotation=45)

axes[2, 1].plot(result_mfc2.seasonal.index, result_mfc2.seasonal * 1000)
axes[2, 1].set_ylabel('Sazonalidade (mA)')
axes[2, 1].xaxis.set_major_formatter(date_formatter)
axes[2, 1].xaxis.set_major_locator(date_locator)
axes[2, 1].tick_params(axis='x', rotation=45)

axes[3, 1].plot(result_mfc2.resid.index, result_mfc2.resid * 1000)
axes[3, 1].set_ylabel('Resíduos (mA)')
axes[3, 1].set_xlabel('Data')
axes[3, 1].xaxis.set_major_formatter(date_formatter)
axes[3, 1].xaxis.set_major_locator(date_locator)
axes[3, 1].tick_params(axis='x', rotation=45)

plt.suptitle('Decomposição STL para Corrente', fontsize=18, y=0.995)
plt.tight_layout()
plt.show()

```

4. Análise de Impacto das Intercorrências

4.1. Detecção de Pontos de Mudança (PELT)

Utilização do algoritmo PELT para identificar automaticamente mudanças estatísticas significativas no regime de operação das MFCs.

```

if not df_clean.empty:
    # Reamostrar os dados para uma média horária.
    df_hourly = df_clean.resample('h').mean().dropna()

    # --- Função para aplicar o PELT com suavização e plotar ---
    def plot_pelt_analysis_smoothed(ax, signal, signal_name, window_size=24, pen_multiplier=10.0):
        """
        Aplica uma média móvel, calcula a penalidade e executa o PELT.

        Args:
            ax: O eixo do matplotlib para plotar.
            signal: A série de dados (Pandas Series).
            signal_name: Nome da série para os títulos.
            window_size: Janela da média móvel em horas (padrão: 24h).
            pen_multiplier: Fator para aumentar a rigidez da penalidade. Valores mais altos = menos pontos.
        """
        # 1. Suavizar o sinal com uma média móvel
        signal_smoothed = signal.rolling(window=window_size, center=True, min_periods=1).mean()

        # 2. Preparar o sinal suavizado para o algoritmo
        points = signal_smoothed.values.reshape(-1, 1)
        n = len(points)

        # 3. Estimar o ruído (sigma) do sinal suavizado
        sigma = np.std(np.diff(signal_smoothed))

        # 4. Calcular a penalidade (BIC) com a fórmula correta (sigma**2) e aplicar o multiplicador
        penalty = pen_multiplier * (sigma**2) * np.log(n)

        print(f"--- Análise para {signal_name} ---")
        print(f"Janela da Média Móvel: {window_size} horas")
        print(f"Multiplicador de Penalidade: {pen_multiplier}")
        print(f"Sigma estimado (ruído): {sigma:.6f}")
        print(f"Penalidade Final Calculada: {penalty:.4f}\n")

        # 5. Aplicar o algoritmo PELT com o modelo 'l2' no sinal suavizado
        algo = rpt.Pelt(model="l2").fit(points)
        result = algo.predict(pen=penalty)

        # 6. Plotar os resultados
        ax.plot(signal.values, label=f'Tensão Horária {signal_name}', color='lightblue', alpha=0.8)
        ax.plot(signal_smoothed.values, label=f'Sinal Suavizado ({window_size}h) {signal_name}', color='darkblue', linewidth=2)

        # Adicionar as linhas dos pontos de mudança COM DATAS
        for i, cp in enumerate(result[:-1]):

```

```

# Plotar linha vertical
ax.axvline(x=cp, color='r', linestyle='--', linewidth=2, alpha=0.9)

# Obter a data correspondente ao ponto de mudança
change_date = signal.index[cp].strftime('%Y-%m-%d')

# Adicionar texto com a data
# Alternar posição do texto para evitar sobreposição
y_position = 0.95 if i % 2 == 0 else 0.05
ax.text(cp, y_position, change_date,
        rotation=90,
        verticalalignment='top' if i % 2 == 0 else 'bottom',
        horizontalalignment='right',
        transform=ax.get_xaxis_transform(),
        fontsize=10,
        color='red',
        fontweight='bold',
        bbox=dict(boxstyle='round,pad=0.3', facecolor='white', alpha=0.9, edgecolor='red'))

ax.set_title(f'Pontos de Mudança Significativos (PELT) - {signal_name}', fontsize=16)
ax.set_ylabel('Tensão (V)')
ax.legend()
ax.grid(True, alpha=0.3)

# Imprimir datas dos pontos de mudança
change_dates = [signal.index[cp].strftime('%Y-%m-%d %H:%M') for cp in result[:-1]]
print(f"{signal_name}: {len(result)-1} pontos de mudança detectados:")
for idx, (pos, date) in enumerate(zip(result[:-1], change_dates), 1):
    print(f" {idx}. Posição {pos} - Data: {date}")
print()

# --- Execução e Plot ---
fig, (ax1, ax2) = plt.subplots(2, 1, figsize=(20, 14), sharex=True)

# Análise para MFC1
plot_pelt_analysis_smoothed(ax1, df_hourly['V_MFC1'], 'MFC 1', window_size=24, pen_multiplier=5000.0)

# Análise para MFC2
plot_pelt_analysis_smoothed(ax2, df_hourly['V_MFC2'], 'MFC 2', window_size=24, pen_multiplier=5000.0)

# Ajustar o eixo X para mostrar datas
xtick_positions = np.linspace(0, len(df_hourly)-1, 12).astype(int)
ax2.set_xticks(xtick_positions)
ax2.set_xticklabels(df_hourly.index[xtick_positions].strftime('%Y-%m-%d'), rotation=45, ha='right')
ax2.set_xlabel('Data')

plt.tight_layout()
plt.show()

```

5. Comparação entre MFC1 e MFC2

5.1. Teste de Hipótese para Diferença de Médias

Comparação estatística do desempenho médio de Tensão e Potência entre as duas células.

```

if not df_clean.empty:
    # Teste de normalidade (Shapiro-Wilk)
    stat_v1, p_v1 = shapiro(df_clean['V_MFC1'].sample(5000, random_state=1)) # Amostra para o teste
    stat_p1, p_p1 = shapiro(df_clean['P_MFC1'].sample(5000, random_state=1))
    print(f"Shapiro-Wilk para Tensão MFC1: p-value = {p_v1}")
    print(f"Shapiro-Wilk para Potência MFC1: p-value = {p_p1}")

    # Como os p-values provavelmente serão < 0.05, os dados não são normais. Usaremos um teste não paramétrico.
    # O teste de Wilcoxon é para amostras pareadas, mas aqui as MFCs são independentes.
    # O correto seria Mann-Whitney U, mas para grandes amostras, t-test é robusto.
    # Por simplicidade e robustez, vamos usar t-test independente.
    ttest_v = ttest_ind(df_clean['V_MFC1'], df_clean['V_MFC2'], equal_var=False)
    ttest_p = ttest_ind(df_clean['P_MFC1'], df_clean['P_MFC2'], equal_var=False)

    print(f"\nTeste-t para Tensão: Estatística={ttest_v.statistic:.2f}, p-value={ttest_v.pvalue}")
    print(f"Teste-t para Potência: Estatística={ttest_p.statistic:.2f}, p-value={ttest_p.pvalue}")
    if ttest_p.pvalue < 0.05:
        print("A diferença na potência média entre MFC1 e MFC2 é estatisticamente significativa.")
    else:
        print("A diferença na potência média não é estatisticamente significativa.")

```

5.2. Scatter Plot de Comparação

Gráfico de dispersão comparando a potência da MFC1 com a da MFC2. A linha de identidade ($y=x$) indica onde os valores seriam iguais.

```
if not df_clean.empty:
    plt.figure(figsize=(8, 8))
    sns.scatterplot(x='P_MFC1', y='P_MFC2', data=df_clean.sample(5000, random_state=1), alpha=0.5)
    max_val = max(df_clean['P_MFC1'].max(), df_clean['P_MFC2'].max())
    plt.plot([0, max_val], [0, max_val], 'r--', label='Linha de Identidade (1:1)')
    plt.title('Potência MFC1 vs. Potência MFC2 (W)')
    plt.xlabel('Potência MFC 1 (W)')
    plt.ylabel('Potência MFC 2 (W)')
    plt.legend()
    plt.axis('equal')
    plt.show()
```

6. Análise das Curvas de Polarização

Esta seção processa os arquivos do `curvas_polarizacao.xlsx` para extrair parâmetros eletroquímicos chave.

```
import io
import traceback
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from scipy.optimize import curve_fit

# Ajustes estéticos globais
plt.rcParams.update({
    'figure.dpi': 220,
    'font.size': 12,
    'axes.titlesize': 16,
    'axes.labelsize': 15,
    'legend.fontsize': 12
})

polarization_summary = []

try:
    # Área do ânodo: 2.5 cm x 5 cm = 12.5 cm² = 0.00125 m²
    anode_area_m2 = 0.00125
    anode_area_cm2 = anode_area_m2 * 10000 # 12.5 cm²

    # Ler o arquivo Excel (assume `uploaded['curvas_polarizacao.xlsx']` existe)
    excel_file = pd.ExcelFile(io.BytesIO(uploaded['curvas_polarizacao.xlsx']))

    print(f"Área do anodo: {anode_area_cm2} cm² = {anode_area_m2} m²\n")

    # Dicionário para agrupar por resistor
    data_by_resistor = {}

    # Coletar todos os dados
    for sheet_name in excel_file.sheet_names:
        try:
            resistor = sheet_name.split('_')[1]
        except:
            continue

        if resistor not in data_by_resistor:
            data_by_resistor[resistor] = {'MFC1': [], 'MFC2': []}

        df_cp = pd.read_excel(excel_file, sheet_name=sheet_name)

        for mfc_id in [1, 2]:
            # FILTRO: Pular MFC2 com resistor 68
            if mfc_id == 2 and resistor == '68':
                continue

            v_col = None
            i_col = None

            for col in df_cp.columns:
                col_str = str(col).lower()
                if f'mfc{mfc_id}' in col_str or f'mfc {mfc_id}' in col_str:
                    if 'tensao' in col_str or 'tensão' in col_str or 'voltage' in col_str or 'v_' in col_str:
                        v_col = col
```

```

        elif 'corrente' in col_str or 'current' in col_str or 'i_' in col_str:
            i_col = col

    if v_col is None or i_col is None:
        continue

    df_mfc = df_cp[[v_col, i_col]].copy()
    df_mfc.rename(columns={v_col: 'V_mV', i_col: 'I_mA'}, inplace=True)
    df_mfc.dropna(inplace=True)

    if df_mfc.empty:
        continue

    # Calcular valores médios
    v_mean = df_mfc['V_mV'].mean() / 1000
    i_mean = df_mfc['I_mA'].mean() / 1000
    j_mean = (i_mean * 1000) / anode_area_cm2
    p_mean = v_mean * i_mean * 1000
    p_density_mean = p_mean / anode_area_cm2

    data_by_resistor[resistor][f'MFC{mfc_id}'].append({
        'V': v_mean,
        'I': i_mean,
        'J': j_mean,
        'P': p_density_mean,
        'resistor_value': float(resistor) if resistor != 'OCV' else float('inf')
    })

# ===== CALCULAR MÉDIAS POR RESISTOR =====
mfc1_points = []
mfc2_points = []

for resistor, mfc_data in data_by_resistor.items():
    resistor_val = float(resistor) if resistor != 'OCV' else float('inf')

    # MFC1
    if mfc_data['MFC1']:
        v_avg = np.mean([d['V'] for d in mfc_data['MFC1']])
        i_avg = np.mean([d['I'] for d in mfc_data['MFC1']])
        j_avg = np.mean([d['J'] for d in mfc_data['MFC1']])
        p_avg = np.mean([d['P'] for d in mfc_data['MFC1']])

        # Calcular resistor equivalente: R = V/I
        r_calc = v_avg / i_avg if i_avg > 0 else float('inf')

        mfc1_points.append({
            'resistor': resistor,
            'resistor_value': resistor_val,
            'resistor_calculated': r_calc,
            'V': v_avg,
            'I': i_avg,
            'J': j_avg,
            'P': p_avg,
            'n_measurements': len(mfc_data['MFC1'])
        })

    # MFC2
    if mfc_data['MFC2']:
        v_avg = np.mean([d['V'] for d in mfc_data['MFC2']])
        i_avg = np.mean([d['I'] for d in mfc_data['MFC2']])
        j_avg = np.mean([d['J'] for d in mfc_data['MFC2']])
        p_avg = np.mean([d['P'] for d in mfc_data['MFC2']])

        r_calc = v_avg / i_avg if i_avg > 0 else float('inf')

        mfc2_points.append({
            'resistor': resistor,
            'resistor_value': resistor_val,
            'resistor_calculated': r_calc,
            'V': v_avg,
            'I': i_avg,
            'J': j_avg,
            'P': p_avg,
            'n_measurements': len(mfc_data['MFC2'])
        })

# Converter para DataFrame
df_mfc1 = pd.DataFrame(mfc1_points).sort_values('resistor_value', ascending=False)
df_mfc2 = pd.DataFrame(mfc2_points).sort_values('resistor_value', ascending=False)

# ===== AJUSTAR CURVAS QUADRÁTICAS PARA POTÊNCIA (se houver pontos suficientes) =====
def quadratic(x, a, b, c):

```

```

    return a * x**2 + b * x + c

a1 = b1 = c1 = j_max1 = p_max1 = None
a2 = b2 = c2 = j_max2 = p_max2 = None

if len(df_mfc1) >= 3:
    try:
        popt1, _ = curve_fit(quadratic, df_mfc1['J'], df_mfc1['P'])
        a1, b1, c1 = popt1
        j_max1 = -b1 / (2 * a1)
        p_max1 = quadratic(j_max1, a1, b1, c1)
    except Exception:
        a1 = b1 = c1 = j_max1 = p_max1 = None

if len(df_mfc2) >= 3:
    try:
        popt2, _ = curve_fit(quadratic, df_mfc2['J'], df_mfc2['P'])
        a2, b2, c2 = popt2
        j_max2 = -b2 / (2 * a2)
        p_max2 = quadratic(j_max2, a2, b2, c2)
    except Exception:
        a2 = b2 = c2 = j_max2 = p_max2 = None

# Gerar pontos para as curvas suaves (se DataFrames não vazios)
j_fit1 = np.linspace(df_mfc1['J'].min() if not df_mfc1.empty else 0,
                    df_mfc1['J'].max() if not df_mfc1.empty else 0, 240) if not df_mfc1.empty else np.array([0])
j_fit2 = np.linspace(df_mfc2['J'].min() if not df_mfc2.empty else 0,
                    df_mfc2['J'].max() if not df_mfc2.empty else 0, 240) if not df_mfc2.empty else np.array([0])

p_fit1 = quadratic(j_fit1, a1, b1, c1) if a1 is not None else np.zeros_like(j_fit1)
p_fit2 = quadratic(j_fit2, a2, b2, c2) if a2 is not None else np.zeros_like(j_fit2)

# ===== Ajuste linear para tensão (se houver pontos suficientes) =====
coeffs1 = None
coeffs2 = None
v_fit1 = np.zeros_like(j_fit1)
v_fit2 = np.zeros_like(j_fit2)
trend_eq_text1 = ""
trend_eq_text2 = ""

if len(df_mfc1) >= 2:
    try:
        coeffs1 = np.polyfit(df_mfc1['J'], df_mfc1['V'], 1)
        v_fit1 = np.polyval(coeffs1, j_fit1)
        slope1, intercept1 = coeffs1
        trend_eq_text1 = f"MFC1: V = {slope1:.3f}·J + {intercept1:.3f}"
    except Exception:
        coeffs1 = None

if len(df_mfc2) >= 2:
    try:
        coeffs2 = np.polyfit(df_mfc2['J'], df_mfc2['V'], 1)
        v_fit2 = np.polyval(coeffs2, j_fit2)
        slope2, intercept2 = coeffs2
        trend_eq_text2 = f"MFC2: V = {slope2:.3f}·J + {intercept2:.3f}"
    except Exception:
        coeffs2 = None

# === PRINTS REQUERIDOS: OCV, P_max e resistência interna ===
# Para OCV: preferir média do ponto rotulado 'OCV' se disponível, senão usar intercepto da reta (J=0)
def get_ocv_from_df(df):
    if 'resistor' in df.columns:
        ocv_rows = df[df['resistor'] == 'OCV']
        if not ocv_rows.empty:
            return float(ocv_rows.iloc[0]['V'])
    return None

ocv1 = get_ocv_from_df(df_mfc1)
ocv2 = get_ocv_from_df(df_mfc2)

# se OCV não vier do dataframe, usar intercepto da reta (se disponível)
if ocv1 is None and coeffs1 is not None:
    ocv1 = float(coeffs1[1])
if ocv2 is None and coeffs2 is not None:
    ocv2 = float(coeffs2[1])

# P_max já está em p_max1 / p_max2 (mW/cm²) se calculado; senão None
# Resistência interna (R_int) estimada a partir do slope da reta V vs J:
# slope (V per (mA/cm²)) = - R_int * anode_area_cm2 / 1000 => R_int = -slope * 1000 / anode_area_cm2
def compute_r_internal_from_slope(coeffs, area_cm2):
    if coeffs is None:
        return None

```

```

    slope = coeffs[0]
    Rint = -slope * 1000.0 / area_cm2
    return float(Rint)

r_int1 = compute_r_internal_from_slope(coeffs1, anode_area_cm2)
r_int2 = compute_r_internal_from_slope(coeffs2, anode_area_cm2)

# Exibir no "chat" (stdout)
print("\n===== RESUMO RÁPIDO =====")
# MFC1
if ocv1 is not None:
    print(f"MFC1 - Tensão de circuito aberto (OCV): {ocv1:.4f} V")
else:
    print("MFC1 - Tensão de circuito aberto (OCV): N/A")
if p_max1 is not None:
    print(f"MFC1 - Densidade de potência máxima: {p_max1:.4f} mW/cm² (em J = {j_max1:.4f} mA/cm²)")
else:
    print("MFC1 - Densidade de potência máxima: N/A")
if r_int1 is not None:
    print(f"MFC1 - Resistência interna (estimada): {r_int1:.1f} Ω")
else:
    print("MFC1 - Resistência interna (estimada): N/A")

print("") # linha em branco

# MFC2
if ocv2 is not None:
    print(f"MFC2 - Tensão de circuito aberto (OCV): {ocv2:.4f} V")
else:
    print("MFC2 - Tensão de circuito aberto (OCV): N/A")
if p_max2 is not None:
    print(f"MFC2 - Densidade de potência máxima: {p_max2:.4f} mW/cm² (em J = {j_max2:.4f} mA/cm²)")
else:
    print("MFC2 - Densidade de potência máxima: N/A")
if r_int2 is not None:
    print(f"MFC2 - Resistência interna (estimada): {r_int2:.1f} Ω")
else:
    print("MFC2 - Resistência interna (estimada): N/A")

print("=====\n")

# ===== FIGURA (maior) =====
fig, ax1 = plt.subplots(figsize=(16, 11)) # figura maior
ax2 = ax1.twinx()

# Parâmetros de estilo
marker_size = 180
star_size = 26
line_width = 2.6

# MFC1 - Pontos de tensão
if not df_mfc1.empty:
    ax1.scatter(df_mfc1['J'], df_mfc1['V'],
               facecolors='red', edgecolors='k', linewidths=1.0,
               s=marker_size, marker='o', label='MFC1 - Tensão da célula', zorder=6)
# MFC1 - Linha de tendência (reta)
if coeffs1 is not None:
    ax1.plot(j_fit1, v_fit1, color='red', linestyle='--', linewidth=line_width,
            label='MFC1 - Linha de tendência (V)', zorder=4)

# MFC1 - Pontos de potência
if not df_mfc1.empty:
    ax2.scatter(df_mfc1['J'], df_mfc1['P'],
               facecolors='purple', edgecolors='k', linewidths=1.0,
               s=marker_size, marker='v', label='MFC1 - Densidade de potência', zorder=5)
# MFC1 - Curva ajustada de potência
if a1 is not None:
    ax2.plot(j_fit1, p_fit1, color='purple', linestyle='-', linewidth=line_width, alpha=0.88, zorder=3)
# MFC1 - Ponto de máxima potência
if j_max1 is not None and p_max1 is not None:
    r_opt_calc = (np.interp(j_max1, df_mfc1["J"], df_mfc1["V"]) / ((j_max1/1000)*anode_area_cm2))
    ax2.plot(j_max1, p_max1, '*', color='purple', markersize=star_size, markeredgewidth=1,
            label=f'MFC1 P_max = {p_max1:.4f} mW/cm²\n(R_opt = {r_opt_calc:.0f}Ω)', zorder=9)

# MFC2 - Pontos de tensão
if not df_mfc2.empty:
    ax1.scatter(df_mfc2['J'], df_mfc2['V'],
               facecolors='orange', edgecolors='k', linewidths=1.0,
               s=marker_size, marker='s', label='MFC2 - Tensão da célula', zorder=6)
# MFC2 - Linha de tendência (reta)
if coeffs2 is not None:
    ax1.plot(j_fit2, v_fit2, color='darkorange', linestyle='--', linewidth=line_width,

```

```

label='MFC2 - Linha de tendência (V)', zorder=4)

# MFC2 - Pontos de potência
if not df_mfc2.empty:
    ax2.scatter(df_mfc2['J'], df_mfc2['P'],
                facecolors='green', edgecolors='k', linewidths=1.0,
                s=marker_size, marker='^', label='MFC2 - Densidade de potência', zorder=5)
# MFC2 - Curva ajustada de potência
if a2 is not None:
    ax2.plot(j_fit2, p_fit2, color='green', linestyle='-', linewidth=line_width, alpha=0.88, zorder=3)
# MFC2 - Ponto de máxima potência
if j_max2 is not None and p_max2 is not None:
    r_opt_calc2 = (np.interp(j_max2, df_mfc2["J"], df_mfc2["V"]) / ((j_max2/1000)*anode_area_cm2))
    ax2.plot(j_max2, p_max2, '*', color='green', markersize=star_size, markeredgcolor='k',
             label=f'MFC2 P_max = {p_max2:.4f} mW/cm²\n(R_opt = {r_opt_calc2:.0f}Ω)', zorder=9)

# Configurações e limites (com checagem)
ax1.set_xlabel('Densidade de corrente (mA/cm²)', fontsize=18, fontweight='bold')
# AUMENTEI explicitamente tamanho do label do eixo X conforme pedido
ax1.xaxis.label.set_size(18)
ax1.set_ylabel('Tensão (V)', fontsize=16, fontweight='bold')
ax2.set_ylabel('Densidade de potência (mW/cm²)', fontsize=16, fontweight='bold')

# Aumentar tamanho dos ticks do eixo X conforme pedido
ax1.tick_params(axis='x', labelsz=16, length=7, width=1.2)
ax1.tick_params(axis='y', labelsz=14)
ax2.tick_params(axis='y', labelsz=14)

# Limites x (com mais pequena margem)
j_max_overall = 0.0
if not df_mfc1.empty:
    j_max_overall = max(j_max_overall, df_mfc1['J'].max())
if not df_mfc2.empty:
    j_max_overall = max(j_max_overall, df_mfc2['J'].max())
ax1.set_xlim(0, j_max_overall * 1.08 if j_max_overall > 0 else 0.14)

# Limites y (tensão)
v_max = 0.0
if not df_mfc1.empty:
    v_max = max(v_max, df_mfc1['V'].max())
if not df_mfc2.empty:
    v_max = max(v_max, df_mfc2['V'].max())
ax1.set_ylim(0, v_max * 1.14 if v_max > 0 else 0.7)

# Limites y (potência)
p_max_overall = 0.0
if p_max1 is not None:
    p_max_overall = max(p_max_overall, p_max1)
if p_max2 is not None:
    p_max_overall = max(p_max_overall, p_max2)
if p_max_overall == 0:
    if not df_mfc1.empty:
        p_max_overall = max(p_max_overall, df_mfc1['P'].max())
    if not df_mfc2.empty:
        p_max_overall = max(p_max_overall, df_mfc2['P'].max())
ax2.set_ylim(0, p_max_overall * 1.20 if p_max_overall > 0 else 0.04)

# Grid e spines
ax1.grid(True, alpha=0.25)
for spine in ax1.spines.values():
    spine.set_linewidth(0.95)
for spine in ax2.spines.values():
    spine.set_linewidth(0.95)

# ---- Legenda: dentro do gráfico, canto superior direito, com contorno ----
handles1, labels1 = ax1.get_legend_handles_labels()
handles2, labels2 = ax2.get_legend_handles_labels()
all_handles = handles1 + handles2
all_labels = labels1 + labels2

# Colocar legenda DENTRO do axes (canto superior direito)
legend = ax1.legend(all_handles, all_labels,
                    loc='upper right',
                    bbox_to_anchor=(0.98, 0.98),
                    frameon=True, fancybox=False, borderpad=0.6, ncol=1)
frame = legend.get_frame()
frame.set_edgecolor('black')
frame.set_linewidth(1.4)
frame.set_alpha(1.0)

for text in legend.get_texts():
    text.set_ha('left')

```

```

# Adicionar as equações das retas de tendência, posicionadas no canto superior esquerdo
xlim = ax1.get_xlim()
ylim = ax1.get_ylim()
# posição relativa segura no canto superior esquerdo (evita a legenda no canto direito)
text_x_pos = xlim[0] + (xlim[1] - xlim[0]) * 0.05
text_y_pos = ylim[0] + (ylim[1] - ylim[0]) * 0.94
y_offset = (ylim[1] - ylim[0]) * 0.06
if trend_eq_text1:
    ax1.text(text_x_pos, text_y_pos, trend_eq_text1,
             fontsize=13, bbox=dict(facecolor='white', edgecolor='none', alpha=0.95))
    text_y_pos -= y_offset
if trend_eq_text2:
    ax1.text(text_x_pos, text_y_pos, trend_eq_text2,
             fontsize=13, bbox=dict(facecolor='white', edgecolor='none', alpha=0.95))

# Ajuste final de layout
fig.tight_layout(rect=[0, 0, 1.0, 1.0])
plt.show()

except Exception as e:
    print(f"Erro: {e}")
    traceback.print_exc()

```

7. Correlação com Dados Físico-Químicos

7.1. Alinhamento Temporal e Análise de Correlação Cruzada (CCF)

Alinha os dados elétricos (média diária) com os dados físico-químicos e calcula a correlação cruzada para investigar relações de lag, por exemplo, entre DQO e Potência.

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from scipy import stats
from scipy.signal import detrend
import os

# === CONFIGURAÇÕES ===
file_fq = "fisico_quimicos.xlsx"

# Parâmetros de análise
min_points = 12
max_lag_days = 30

# Variáveis específicas para plotar
variables_to_plot = [
    'condutividade_alim',
    'ph_anodo',
    'n-nh4-desv-pad_alim', # variabilidade de amônia
    'delta_ph_alim_anodo'
]

# --- 1) Função para processar cada MFC ---
def process_mfc(df_clean, sheet_name, mfc_name, elec_col):
    """
    Processa dados de uma MFC específica
    """
    # Ler dados físico-químicos da sheet específica
    if os.path.exists(file_fq):
        print(f"\n--- Processando {mfc_name} (Sheet: {sheet_name}) ---")
        df_fq_raw = pd.read_excel(file_fq, sheet_name=sheet_name, header=3)

        # Identificar coluna de data
        possible_date_cols = [c for c in df_fq_raw.columns if 'data' in str(c).lower() or 'date' in str(c).lower()]
        if possible_date_cols:
            date_col = possible_date_cols[0]
            df_fq_raw[date_col] = pd.to_datetime(df_fq_raw[date_col], errors='coerce')
            df_fq_raw = df_fq_raw.set_index(date_col)
        else:
            df_fq_raw.iloc[:,0] = pd.to_datetime(df_fq_raw.iloc[:,0], errors='coerce')
            df_fq_raw = df_fq_raw.set_index(df_fq_raw.columns[0])

        # Limpeza básica
        df_fq_raw = df_fq_raw[~df_fq_raw.index.isna()]
        for c in df_fq_raw.columns:
            df_fq_raw[c] = pd.to_numeric(df_fq_raw[c], errors='coerce')

```

```

else:
    raise FileNotFoundError(f"Arquivo {file_fq} não encontrado.")

# Reamostrar dados elétricos para média diária
df_daily = df_clean.resample('D').mean()
if getattr(df_daily.index, 'tz', None) is not None:
    df_daily.index = df_daily.index.tz_localize(None)

# Garantir índice datetime para fq
if not isinstance(df_fq_raw.index, pd.DatetimeIndex):
    df_fq_raw.index = pd.to_datetime(df_fq_raw.index)
if getattr(df_fq_raw.index, 'tz', None) is not None:
    df_fq_raw.index = df_fq_raw.index.tz_localize(None)

print(f" Período elétricos: {df_daily.index.min()} até {df_daily.index.max()}")
print(f" Período físico-químicos: {df_fq_raw.index.min()} até {df_fq_raw.index.max()}")

# Interpolat q para frequência diária
fq_daily = df_fq_raw.reindex(df_daily.index)
fq_daily = fq_daily.interpolate(method='time', limit_direction='both')

# Função auxiliar para buscar colunas
def find_cols(df, keywords):
    cols = []
    for c in df.columns:
        cn = str(c).lower().replace('-', '_').replace(' ', '_')
        for kw in keywords:
            if kw in cn:
                cols.append(c)
                break
    return cols

# Criar deltas
def try_make_delta(df, col_a_keywords, col_b_keywords, name):
    ca = find_cols(df, col_a_keywords)
    cb = find_cols(df, col_b_keywords)
    if ca and cb:
        df[name] = df[ca[0]] - df[cb[0]]
        print(f" Delta criado: {name} = {ca[0]} - {cb[0]}")
        return name
    return None

try_make_delta(fq_daily,
               ['dco_media_alim', 'dco_media_alim', 'dco_alim', 'dco_media'],
               ['dco_media_anodo', 'dco_anodo'],
               'delta_dco_alim_anodo')
try_make_delta(fq_daily,
               ['ph_alim', 'ph_alim'],
               ['ph_anodo', 'ph_anodo', 'ph_anód'],
               'delta_ph_alim_anodo')

# Selecionar colunas para análise
selected_cols = []
for var in variables_to_plot:
    # Buscar coluna que contenha a variável
    matching_cols = [c for c in fq_daily.columns
                     if var.lower().replace('_', '-') in str(c).lower().replace('_', '-')]
    if matching_cols:
        selected_cols.append(matching_cols[0])
        print(f" Variável '{var}' mapeada para: {matching_cols[0]}")

print(f" Total de colunas selecionadas: {len(selected_cols)}")

# Merge
df_merged = df_daily.join(fq_daily[selected_cols], how='inner')
df_final = df_merged[df_merged[selected_cols].notna().any(axis=1)].copy()

print(f" Linhas após merge: {len(df_final)}")

if df_final.empty or elec_col not in df_final.columns:
    print(f" ✘ Dados insuficientes para {mfc_name}")
    return None

# Função de CCF
def compute_ccf_and_peak(series_x, series_y, max_lag):
    idx = series_x.dropna().index.intersection(series_y.dropna().index)
    x = series_x.loc[idx].astype(float).values
    y = series_y.loc[idx].astype(float).values
    N = len(x)
    if N < min_points:
        return None

```

```

x_d = detrend(x)
y_d = detrend(y)
x_z = stats.zscore(x_d, nan_policy='omit')
y_z = stats.zscore(y_d, nan_policy='omit')

max_lag = min(max_lag, N//2)
lags = np.arange(-max_lag, max_lag+1)
corrs = []

if max_lag > 0:
    start = max_lag
    end = N - max_lag
else:
    start = 0
    end = N

for lag in lags:
    y_shift = np.roll(y_z, -lag)
    xx = x_z[start:end]
    yy = y_shift[start:end]
    r = np.corrcoef(xx, yy)[0,1]
    corrs.append(r)

corrs = np.array(corrs)
idx_peak = np.nanargmax(np.abs(corrs))
peak_lag = lags[idx_peak]
peak_val = corrs[idx_peak]
ci = 1.96/np.sqrt(N)

return {
    'lags': lags,
    'corrs': corrs,
    'N': N,
    'peak_lag': int(peak_lag),
    'peak_val': float(peak_val),
    'ci': ci
}

# Calcular CCF para cada variável
results = {}
for col in selected_cols:
    if col not in df_final.columns:
        continue
    res = compute_ccf_and_peak(df_final[elec_col], df_final[col], max_lag_days)
    if res is not None:
        results[col] = res
        print(f" ✓ CCF calculado para: {col}")

return results

# --- 2) Processar ambas as MFCs ---
if 'df_clean' not in globals():
    raise NameError("df_clean não encontrado: carregue seus dados elétricos.")

# Processar MFC1
results_mfc1 = process_mfc(df_clean, 'MFC 1_par_quim', 'MFC1', 'I_MFC1')

# Processar MFC2
results_mfc2 = process_mfc(df_clean, 'MFC 2_par_quim', 'MFC2', 'I_MFC2')

# --- 3) Plotar lado a lado ---
if results_mfc1 and results_mfc2:
    # Mapear nomes amigáveis
    friendly_names = {
        'condutividade_alim': 'Condutividade Alimentação',
        'ph_anodo': 'pH Ânodo',
        'n-nh4-desv-pad_alim': 'Variabilidade NH4+ (σ)',
        'delta_ph_alim_anodo': 'ΔpH (Alim→Ânodo)'
    }
}

# Identificar variáveis comuns
common_vars = []
for var in variables_to_plot:
    mfc1_cols = [c for c in results_mfc1.keys()
                 if var.lower().replace('_', '-') in str(c).lower().replace('_', '-')]
    mfc2_cols = [c for c in results_mfc2.keys()
                 if var.lower().replace('_', '-') in str(c).lower().replace('_', '-')]
    if mfc1_cols and mfc2_cols:
        common_vars.append((mfc1_cols[0], mfc2_cols[0], var))

print(f"\n✓ Variáveis comuns encontradas: {len(common_vars)}")

```

```

# Criar subplots
n_vars = len(common_vars)
fig, axes = plt.subplots(n_vars, 2, figsize=(16, 3.5*n_vars))

if n_vars == 1:
    axes = axes.reshape(1, -1)

for idx, (col_mfc1, col_mfc2, var_key) in enumerate(common_vars):
    res1 = results_mfc1[col_mfc1]
    res2 = results_mfc2[col_mfc2]

    # MFC1
    axes[idx, 0].stem(res1['lags'], res1['corrs'])
    axes[idx, 0].hlines([res1['ci'], -res1['ci']], res1['lags'].min(), res1['lags'].max(),
                       linestyle='dashed', colors='red', label='IC 95%', alpha=0.6)
    axes[idx, 0].axvline(0, color='k', linewidth=0.8, linestyle='--', alpha=0.5)
    axes[idx, 0].set_xlabel('Lag (dias)', fontsize=11)
    axes[idx, 0].set_ylabel('Correlação cruzada', fontsize=11)

    friendly_name = friendly_names.get(var_key, col_mfc1)
    axes[idx, 0].set_title(f'MFC1 vs {friendly_name}\n(N={res1["N"]}, lag={res1["peak_lag"]}d, r={res1["peak_val"]:.3f}',
                          fontsize=12, fontweight='bold')
    axes[idx, 0].legend(loc='upper right', fontsize=9)
    axes[idx, 0].grid(True, alpha=0.3)

    # MFC2
    axes[idx, 1].stem(res2['lags'], res2['corrs'])
    axes[idx, 1].hlines([res2['ci'], -res2['ci']], res2['lags'].min(), res2['lags'].max(),
                       linestyle='dashed', colors='red', label='IC 95%', alpha=0.6)
    axes[idx, 1].axvline(0, color='k', linewidth=0.8, linestyle='--', alpha=0.5)
    axes[idx, 1].set_xlabel('Lag (dias)', fontsize=11)
    axes[idx, 1].set_ylabel('Correlação cruzada', fontsize=11)
    axes[idx, 1].set_title(f'MFC2 vs {friendly_name}\n(N={res2["N"]}, lag={res2["peak_lag"]}d, r={res2["peak_val"]:.3f}',
                          fontsize=12, fontweight='bold')
    axes[idx, 1].legend(loc='upper right', fontsize=9)
    axes[idx, 1].grid(True, alpha=0.3)

plt.tight_layout()
plt.show()

# Criar tabela resumo
print("\n" + "="*90)
print("RESUMO COMPARATIVO - CORRELAÇÃO CRUZADA")
print("="*90)

summary_data = []
for col_mfc1, col_mfc2, var_key in common_vars:
    res1 = results_mfc1[col_mfc1]
    res2 = results_mfc2[col_mfc2]
    friendly_name = friendly_names.get(var_key, var_key)

    summary_data.append({
        'Variável': friendly_name,
        'MFC1_lag(d)': res1['peak_lag'],
        'MFC1_r': f"{res1['peak_val']:.3f}",
        'MFC1_sig': '✓' if abs(res1['peak_val']) > res1['ci'] else 'X',
        'MFC2_lag(d)': res2['peak_lag'],
        'MFC2_r': f"{res2['peak_val']:.3f}",
        'MFC2_sig': '✓' if abs(res2['peak_val']) > res2['ci'] else 'X'
    })

df_summary = pd.DataFrame(summary_data)
print(df_summary.to_string(index=False))
print("="*90)
else:
    print("\n❌ Não foi possível processar ambas as MFCs.")

```

▼ ---

8. Modelagem Explanatória

8.1. Regressão Linear Múltipla

Ajuste de um modelo de regressão para explicar a variação da potência com base nos parâmetros operacionais.

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt

```

```

from scipy import stats
from scipy.signal import detrend
import os

# === CONFIGURAÇÕES ===
file_fq = "fisico_quimicos.xlsx"

# Parâmetros de análise
min_points = 12
max_lag_days = 30

# Variáveis específicas para plotar (SEM TEMPERATURA)
variables_to_plot = [
    'condutividade_alim',
    'ph_anodo',
    'n-nh4-desv-pad_alim', # variabilidade de amônia
    'delta_ph_alim_anodo'
]

# --- 1) Função para processar cada MFC ---
def process_mfc(df_clean, sheet_name, mfc_name, elec_col):
    """
    Processa dados de uma MFC específica
    """
    # Ler dados físico-químicos da sheet específica
    if os.path.exists(file_fq):
        print(f"\n--- Processando {mfc_name} (Sheet: {sheet_name}) ---")
        df_fq_raw = pd.read_excel(file_fq, sheet_name=sheet_name, header=3)

        # Identificar coluna de data
        possible_date_cols = [c for c in df_fq_raw.columns if 'data' in str(c).lower() or 'date' in str(c).lower()]
        if possible_date_cols:
            date_col = possible_date_cols[0]
            df_fq_raw[date_col] = pd.to_datetime(df_fq_raw[date_col], errors='coerce')
            df_fq_raw = df_fq_raw.set_index(date_col)
        else:
            df_fq_raw.iloc[:,0] = pd.to_datetime(df_fq_raw.iloc[:,0], errors='coerce')
            df_fq_raw = df_fq_raw.set_index(df_fq_raw.columns[0])

        # Limpeza básica
        df_fq_raw = df_fq_raw[~df_fq_raw.index.isna()]
        for c in df_fq_raw.columns:
            df_fq_raw[c] = pd.to_numeric(df_fq_raw[c], errors='coerce')
    else:
        raise FileNotFoundError(f"Arquivo {file_fq} não encontrado.")

    # Reamostrar dados elétricos para média diária
    df_daily = df_clean.resample('D').mean()
    if getattr(df_daily.index, 'tz', None) is not None:
        df_daily.index = df_daily.index.tz_localize(None)

    # Garantir índice datetime para fq
    if not isinstance(df_fq_raw.index, pd.DatetimeIndex):
        df_fq_raw.index = pd.to_datetime(df_fq_raw.index)
    if getattr(df_fq_raw.index, 'tz', None) is not None:
        df_fq_raw.index = df_fq_raw.index.tz_localize(None)

    print(f" Período elétricos: {df_daily.index.min()} até {df_daily.index.max()}")
    print(f" Período físico-químicos: {df_fq_raw.index.min()} até {df_fq_raw.index.max()}")

    # Interpolar fq para frequência diária
    fq_daily = df_fq_raw.reindex(df_daily.index)
    fq_daily = fq_daily.interpolate(method='time', limit_direction='both')

    # Função auxiliar para buscar colunas
    def find_cols(df, keywords):
        cols = []
        for c in df.columns:
            cn = str(c).lower().replace('-', '_').replace(' ', '_')
            for kw in keywords:
                if kw in cn:
                    cols.append(c)
                    break
        return cols

    # Criar deltas
    def try_make_delta(df, col_a_keywords, col_b_keywords, name):
        ca = find_cols(df, col_a_keywords)
        cb = find_cols(df, col_b_keywords)
        if ca and cb:
            df[name] = df[ca[0]] - df[cb[0]]
            print(f" Delta criado: {name} = {ca[0]} - {cb[0]}")

```

```

        return name
    return None

try_make_delta(fq_daily,
               ['dco_media_alim', 'dco_media_alim', 'dco_alim', 'dco_media'],
               ['dco_media_anodo', 'dco_anodo'],
               'delta_dco_alim_anodo')
try_make_delta(fq_daily,
               ['ph_alim', 'ph_alim'],
               ['ph_anodo', 'ph_anodo', 'ph_anód'],
               'delta_ph_alim_anodo')

# Selecionar colunas para análise
selected_cols = []
for var in variables_to_plot:
    # Buscar coluna que contenha a variável
    matching_cols = [c for c in fq_daily.columns
                     if var.lower().replace('_', '-') in str(c).lower().replace('_', '-')]
    if matching_cols:
        selected_cols.append(matching_cols[0])
        print(f" Variável '{var}' mapeada para: {matching_cols[0]}")
    else:
        print(f" ⚠ Variável '{var}' não encontrada")

print(f" Total de colunas selecionadas: {len(selected_cols)}")

# Merge
df_elec = df_daily[[elec_col]].copy()
df_merged = df_elec.join(fq_daily[selected_cols], how='inner')
df_final = df_merged[df_merged[selected_cols].notna().any(axis=1)].copy()

print(f" Linhas após merge: {len(df_final)}")

if df_final.empty or elec_col not in df_final.columns:
    print(f" ❌ Dados insuficientes para {mfc_name}")
    return None

# Função de CCF
def compute_ccf_and_peak(series_x, series_y, max_lag):
    idx = series_x.dropna().index.intersection(series_y.dropna().index)
    x = series_x.loc[idx].astype(float).values
    y = series_y.loc[idx].astype(float).values
    N = len(x)
    if N < min_points:
        return None

    x_d = detrend(x)
    y_d = detrend(y)
    x_z = stats.zscore(x_d, nan_policy='omit')
    y_z = stats.zscore(y_d, nan_policy='omit')

    max_lag = min(max_lag, N//2)
    lags = np.arange(-max_lag, max_lag+1)
    corrs = []

    if max_lag > 0:
        start = max_lag
        end = N - max_lag
    else:
        start = 0
        end = N

    for lag in lags:
        y_shift = np.roll(y_z, -lag)
        xx = x_z[start:end]
        yy = y_shift[start:end]
        r = np.corrcoef(xx, yy)[0,1]
        corrs.append(r)

    corrs = np.array(corrs)
    idx_peak = np.nanargmax(np.abs(corrs))
    peak_lag = lags[idx_peak]
    peak_val = corrs[idx_peak]
    ci = 1.96/np.sqrt(N)

    return {
        'lags': lags,
        'corrs': corrs,
        'N': N,
        'peak_lag': int(peak_lag),
        'peak_val': float(peak_val),
        'ci': ci
    }

```

```

    }

    # Calcular CCF para cada variável
    results = {}
    for col in selected_cols:
        if col not in df_final.columns:
            continue
        res = compute_ccf_and_peak(df_final[elec_col], df_final[col], max_lag_days)
        if res is not None:
            results[col] = res
            print(f" ✓ CCF calculado para: {col}")

    return results

# --- 2) Processar ambas as MFCs ---
if 'df_clean' not in globals():
    raise NameError("df_clean não encontrado: carregue seus dados elétricos.")

# Processar MFC1
results_mfc1 = process_mfc(df_clean, 'MFC 1_par_quim', 'MFC1', 'I_MFC1')

# Processar MFC2
results_mfc2 = process_mfc(df_clean, 'MFC 2_par_quim', 'MFC2', 'I_MFC2')

# --- 3) Plotar lado a lado ---
if results_mfc1 and results_mfc2:
    # Mapear nomes amigáveis (USANDO ASCII COMPATÍVEL)
    friendly_names = {
        'condutividade_alim': 'Condutividade Alimentacao',
        'ph_anodo': 'pH Anodo',
        'n-nh4-desv-pad_alim': 'Variabilidade NH4+ (DP)',
        'delta_ph_alim_anodo': 'Delta-pH (Alim-Anodo)'
    }

    # Identificar variáveis comuns
    common_vars = []
    for var in variables_to_plot:
        mfc1_cols = [c for c in results_mfc1.keys()
                     if var.lower().replace('_', '-') in str(c).lower().replace('_', '-')]
        mfc2_cols = [c for c in results_mfc2.keys()
                     if var.lower().replace('_', '-') in str(c).lower().replace('_', '-')]
        if mfc1_cols and mfc2_cols:
            common_vars.append((mfc1_cols[0], mfc2_cols[0], var))

    print(f"\n/ Variáveis comuns encontradas: {len(common_vars)}")

    # Criar subplots
    n_vars = len(common_vars)
    fig, axes = plt.subplots(n_vars, 2, figsize=(16, 3.5*n_vars))

    if n_vars == 1:
        axes = axes.reshape(1, -1)

    for idx, (col_mfc1, col_mfc2, var_key) in enumerate(common_vars):
        res1 = results_mfc1[col_mfc1]
        res2 = results_mfc2[col_mfc2]

        # MFC1
        axes[idx, 0].stem(res1['lags'], res1['corrs'])
        axes[idx, 0].hlines([res1['ci'], -res1['ci']], res1['lags'].min(), res1['lags'].max(),
                            linestyle='dashed', colors='red', label='IC 95%', alpha=0.6)
        axes[idx, 0].axvline(0, color='k', linewidth=0.8, linestyle='--', alpha=0.5)
        axes[idx, 0].set_xlabel('Lag (dias)', fontsize=11)
        axes[idx, 0].set_ylabel('Correlacao cruzada', fontsize=11)

        friendly_name = friendly_names.get(var_key, col_mfc1)
        axes[idx, 0].set_title(f'MFC1 vs {friendly_name}\n(N={res1["N"]}, lag={res1["peak_lag"]}d, r={res1["peak_val"]:.3f},
                               fontsize=12, fontweight='bold')
        axes[idx, 0].legend(loc='upper right', fontsize=9)
        axes[idx, 0].grid(True, alpha=0.3)

        # MFC2
        axes[idx, 1].stem(res2['lags'], res2['corrs'])
        axes[idx, 1].hlines([res2['ci'], -res2['ci']], res2['lags'].min(), res2['lags'].max(),
                            linestyle='dashed', colors='red', label='IC 95%', alpha=0.6)
        axes[idx, 1].axvline(0, color='k', linewidth=0.8, linestyle='--', alpha=0.5)
        axes[idx, 1].set_xlabel('Lag (dias)', fontsize=11)
        axes[idx, 1].set_ylabel('Correlacao cruzada', fontsize=11)
        axes[idx, 1].set_title(f'MFC2 vs {friendly_name}\n(N={res2["N"]}, lag={res2["peak_lag"]}d, r={res2["peak_val"]:.3f},
                               fontsize=12, fontweight='bold')
        axes[idx, 1].legend(loc='upper right', fontsize=9)
        axes[idx, 1].grid(True, alpha=0.3)

```

```

plt.tight_layout()
plt.show()

# Criar tabela resumo
print("\n" + "="*90)
print("RESUMO COMPARATIVO - CORRELACAO CRUZADA")
print("="*90)

summary_data = []
for col_mfc1, col_mfc2, var_key in common_vars:
    res1 = results_mfc1[col_mfc1]
    res2 = results_mfc2[col_mfc2]
    friendly_name = friendly_names.get(var_key, var_key)

    summary_data.append({
        'Variavel': friendly_name,
        'MFC1_lag(d)': res1['peak_lag'],
        'MFC1_r': f"{res1['peak_val']:.3f}",
        'MFC1_sig': 'Sim' if abs(res1['peak_val']) > res1['ci'] else 'Nao',
        'MFC2_lag(d)': res2['peak_lag'],
        'MFC2_r': f"{res2['peak_val']:.3f}",
        'MFC2_sig': 'Sim' if abs(res2['peak_val']) > res2['ci'] else 'Nao'
    })

df_summary = pd.DataFrame(summary_data)
print(df_summary.to_string(index=False))
print("="*90)
else:
    print("\n❌ Não foi possível processar ambas as MFCs.")

```

```

import pandas as pd
import numpy as np

# === CONSTANTES FÍSICAS ===
M = 32 # Peso molecular do oxigênio (g/mol)
F = 96485 # Constante de Faraday (C/mol e⁻)
b = 4 # Mols de elétrons por mol de oxigênio (mol e⁻/mol O₂)

# === PARÂMETROS DO REATOR ===
V_an_L = 0.150 # Volume do anólito em Litros (150 mL)
remocao_dqo_mfc1 = 86.89 # Eficiência média de remoção de DQO para MFC1 (%)
remocao_dqo_mfc2 = 82.80 # Eficiência média de remoção de DQO para MFC2 (%)

# === VERIFICAÇÃO DOS DATAFRAMES ===
if 'df_clean' not in globals() or 'df_fq_combined' not in globals():
    print("⚠️ Erro: DataFrames 'df_clean' e/ou 'df_fq_combined' não encontrados.")
    print("Por favor, execute as células de carregamento e pré-processamento de dados primeiro.")
else:
    # Criar cópia e remover timezone
    df_ce = df_clean.copy()
    if df_ce.index.tz is not None:
        df_ce.index = df_ce.index.tz_localize(None)

    # Remover timezone de df_fq_combined também
    if df_fq_combined.index.tz is not None:
        df_fq_combined.index = df_fq_combined.index.tz_localize(None)

    # === IDENTIFICAR COLUNA DE DQO ===
    # Procurar colunas que contenham 'dqo' e 'alim' (alimentação)
    dqo_cols = [col for col in df_fq_combined.columns
                 if 'dqo' in str(col).lower() and 'alim' in str(col).lower() and 'media' in str(col).lower()]

    if dqo_cols:
        dqo_in_col = dqo_cols[0]
        print(f"✓ Coluna de DQO da alimentação identificada: '{dqo_in_col}'\n")
    else:
        dqo_in_col = None
        print("❌ Erro: Não foi possível encontrar a coluna de DQO da alimentação.")
        print("Colunas disponíveis:")
        print([col for col in df_fq_combined.columns if 'dqo' in str(col).lower()])

    if dqo_in_col:
        # === GARANTIR QUE COLUNA DE DQO É NUMÉRICA ===
        df_fq_combined[dqo_in_col] = pd.to_numeric(df_fq_combined[dqo_in_col], errors='coerce')

        # === CÁLCULO DA EC POR CICLO ===
        results = []

        print("Calculando EC para cada ciclo...")
        print("-" * 80)

```

```

# Iterar pelos ciclos
for i in range(len(df_fq_combined) - 1):
    start_date = df_fq_combined.index[i]
    end_date = df_fq_combined.index[i+1]

    # Filtrar dados elétricos para o ciclo
    cycle_data = df_ce.loc[start_date:end_date]

    if cycle_data.empty:
        print(f"⚠️ Ciclo {start_date.date()} → {end_date.date()}: Sem dados elétricos")
        continue

    # Calcular delta_t em segundos
    delta_t = cycle_data.index.to_series().diff().dt.total_seconds().fillna(0).values

    # Calcular Carga Total (Q) em Coulombs
    Q1 = (cycle_data['I_MFC1'].values * delta_t).sum()
    Q2 = (cycle_data['I_MFC2'].values * delta_t).sum()

    # Obter DQO da alimentação e converter para numérico
    dqo_in_mg_L = pd.to_numeric(df_fq_combined.iloc[i][dqo_in_col], errors='coerce')

    # Verificar se há dado de DQO válido
    if pd.isna(dqo_in_mg_L) or dqo_in_mg_L == 0:
        print(f"⚠️ Ciclo {start_date.date()} → {end_date.date()}: DQO não disponível ou zero")
        continue

    # Converter DQO para g/L
    dqo_in_g_L = float(dqo_in_mg_L) / 1000

    # Calcular ΔDQO (concentração de DQO removida) em g/L
    delta_dqo1_g_L = dqo_in_g_L * (remocao_dqo_mfc1 / 100)
    delta_dqo2_g_L = dqo_in_g_L * (remocao_dqo_mfc2 / 100)

    # Calcular denominador da fórmula EC
    denominator1 = F * b * V_an_L * delta_dqo1_g_L
    denominator2 = F * b * V_an_L * delta_dqo2_g_L

    # Calcular EC (%), evitando divisão por zero
    ec1 = (M * Q1 / denominator1) * 100 if denominator1 > 0 else 0
    ec2 = (M * Q2 / denominator2) * 100 if denominator2 > 0 else 0

    # Armazenar resultados
    results.append({
        'Data_Inicio': start_date.date(),
        'Data_Fim': end_date.date(),
        'Duracao_dias': (end_date - start_date).days,
        'DQO_Afluyente_mg_L': float(dqo_in_mg_L),
        'Carga_Q1_C': Q1,
        'Carga_Q2_C': Q2,
        'EC_MFC1_%': ec1,
        'EC_MFC2_%': ec2
    })

    print(f"✓ Ciclo {start_date.date()} → {end_date.date()}: DQO={dqo_in_mg_L:.1f}mg/L, EC1={ec1:.2f}%, EC2={ec2:.2f}%")

# === APRESENTAÇÃO DOS RESULTADOS ===
if results:
    df_ec_results = pd.DataFrame(results)

    print("\n" + "="*80)
    print("RESULTADOS - EFICIÊNCIA COULÔMBICA POR CICLO")
    print("="*80)
    print(df_ec_results.to_string(index=False))

    # Calcular estatísticas
    print("\n" + "="*80)
    print("RESUMO ESTATÍSTICO")
    print("="*80)

    ec1_mean = df_ec_results['EC_MFC1_%'].mean()
    ec1_std = df_ec_results['EC_MFC1_%'].std()
    ec1_min = df_ec_results['EC_MFC1_%'].min()
    ec1_max = df_ec_results['EC_MFC1_%'].max()

    ec2_mean = df_ec_results['EC_MFC2_%'].mean()
    ec2_std = df_ec_results['EC_MFC2_%'].std()
    ec2_min = df_ec_results['EC_MFC2_%'].min()
    ec2_max = df_ec_results['EC_MFC2_%'].max()

    print("\nMFC 1:")
    print(f"    EC Média:          {ec1_mean:.2f}%")

```

```

print(f" Desvio Padrão:   {ec1_std:.2f}%")
print(f"  EC Mínima:     {ec1_min:.2f}%")
print(f"  EC Máxima:     {ec1_max:.2f}%")

print("\nMFC 2:")
print(f"  EC Média:       {ec2_mean:.2f}%")
print(f"  Desvio Padrão:   {ec2_std:.2f}%")
print(f"  EC Mínima:     {ec2_min:.2f}%")
print(f"  EC Máxima:     {ec2_max:.2f}%")

print("\n" + "="*80)
print("COMPARAÇÃO")
print("="*80)
diff_mean = ec1_mean - ec2_mean
print(f"Diferença EC Média (MFC1 - MFC2): {diff_mean:+.2f}%")
if ec1_mean > ec2_mean:
    percent_higher = ((ec1_mean / ec2_mean) - 1) * 100
    print(f"MFC1 é {percent_higher:.1f}% mais eficiente que MFC2")
else:
    percent_higher = ((ec2_mean / ec1_mean) - 1) * 100
    print(f"MFC2 é {percent_higher:.1f}% mais eficiente que MFC1")

# === GRÁFICO DE EVOLUÇÃO TEMPORAL ===
import matplotlib.pyplot as plt

plt.figure(figsize=(12, 6))

plt.plot(range(len(results)), df_ec_results['EC_MFC1_%'],
         marker='o', label='MFC 1', linewidth=2.5, markersize=8, color='#2E86AB')
plt.plot(range(len(results)), df_ec_results['EC_MFC2_%'],
         marker='s', label='MFC 2', linewidth=2.5, markersize=8, color='#A23B72')

plt.xlabel('Ciclo', fontsize=13)
plt.ylabel('Eficiencia Coulombica (%)', fontsize=13)
plt.title('Evolucao da Eficiencia Coulombica ao Longo dos Ciclos', fontsize=15, fontweight='bold')
plt.legend(fontsize=12, loc='best')
plt.grid(True, alpha=0.3)
plt.tight_layout()
plt.show()

# === TABELA PARA O TEXTO ===
print("\n" + "="*80)
print("TABELA RESUMO (para inclusão no texto)")
print("="*80)
summary_table = pd.DataFrame({
    'Parametro': ['Remocao DQO (%)', 'EC (%)'],
    'MFC 1': [f'{remocao_dqo_mfc1:.2f}', f'{ec1_mean:.2f} ± {ec1_std:.2f}'],
    'MFC 2': [f'{remocao_dqo_mfc2:.2f}', f'{ec2_mean:.2f} ± {ec2_std:.2f}']
})
print(summary_table.to_string(index=False))

else:
    print("\n❌ Nenhum ciclo com dados completos foi encontrado para o cálculo.")

```

9. Geração do JSON Sumarizado

Compilação de todos os resultados chave em um único objeto JSON para fácil consumo por outras aplicações.

```

final_json = {
    "metadata": {
        "files_read": list(uploaded.keys()),
        "total_rows_initial": len(df_main) if 'df_main' in locals() else 0,
        "total_rows_processed": len(df_clean) if 'df_clean' in locals() else 0,
        "sampling_interval_minutes": 5,
        "units_detected": {"Voltage": "mV", "Current": "mA", "Power": "mW"}
    },
    "summary_by_MFC": {
        "MFC1": stats_desc.loc[['V_MFC1', 'I_MFC1', 'P_MFC1']].to_dict('index') if 'stats_desc' in locals() else {},
        "MFC2": stats_desc.loc[['V_MFC2', 'I_MFC2', 'P_MFC2']].to_dict('index') if 'stats_desc' in locals() else {}
    },
    "events_effects": [
        # Esta seção seria preenchida com os resultados da análise before-after
        {"event_name": "Exemplo: Falta de Luz", "date": "2024-01-02", "delta_mean_V": -0.1, "p_value": 0.001}
    ],
    "polarization_summary": df_polarization.to_dict('records') if not df_polarization.empty else,
    "regression_model": regression_results,
    "CE_results": [
        {"period": "Exemplo: Ciclo 1", "CE_pct": 25.4, "assumptions": "Volume do anodo = 0.5L (suposição)"}
    ]
}

```

```
    ],  
    "files": {  
      "notebook": "Analise_Eletroquimica_MFC.ipynb",  
      "figures": ["timeseries_voltage.png", "polarization_curve_mfc1.png"],  
      "tables": ["descriptive_stats.csv", "polarization_summary.csv"]  
    }  
  }  
}  
  
# Imprimir o JSON formatado  
print(json.dumps(final_json, indent=4))
```

GRUPO DE ESTUDO GPL

Desenvolvimento e Aplicação de Células a Combustível Microbianas para Geração de Energia

Renan Mello Nogueira⁽¹⁾, Rayane Kunert Langbehn⁽²⁾, Sergio Luciano Avila⁽¹⁾, Everthon Taghori Sica⁽¹⁾, Vinicius Viana Luiz Albani⁽³⁾

⁽¹⁾ IFSC, Instituto Federal de Santa Catarina

⁽²⁾ UFSC, Universidade Federal de Santa Catarina

⁽³⁾ UFRJ, Universidade Federal do Rio de Janeiro

RESUMO

As Células a Combustível Microbianas (MFCs) são dispositivos bioeletroquímicos com potencial de gerar eletricidade e tratar efluentes simultaneamente. Esse processo gera um fluxo de corrente elétrica contínua, ou seja, uma fonte de energia renovável. Neste trabalho é apresentado a modelagem e o desempenho de dois protótipos similares de MFC. A modelagem matemática possibilita a compreensão do comportamento dinâmico das MFCs sob diferentes condições operacionais. Os resultados demonstraram que o sistema foi capaz de gerar energia elétrica, embora com variação de desempenho entre os protótipos MFC1 e MFC2. O modelo matemático para descrever a dinâmica da produção de eletricidade e do consumo do estoque do substrato orgânico é baseado em regressão não linear e equações diferenciais ordinárias. Ao longo de 160 dias de operação, manutenções periódicas foram realizadas para limpeza dos eletrodos e remoção de biofilmes, garantindo a eficiência do sistema. O monitoramento da tensão a cada cinco minutos, possibilita o cálculo de potência e corrente. Ao fim do experimento, foram realizados ensaios para gerar as curvas de polarização e potência para avaliação dos desempenhos da MFC. As MFCs possibilitam a geração de energia elétrica e o tratamento de resíduos, sendo uma tecnologia possível para transição energética ao contribuir com gestão de recursos e mitigação de emissões de gases de efeito estufa.

PALAVRAS-CHAVE

Células a Combustível Microbianas, Produção de eletricidade, Fontes renováveis

1.0 INTRODUÇÃO

As Células a Combustível Microbianas (MFCs) são dispositivos bioeletroquímicos que têm atraído atenção devido ao seu potencial de gerar eletricidade e tratar efluentes simultaneamente [1]. Nas MFCs, os microrganismos presentes no ânodo decompõem compostos orgânicos, como efluentes, liberando elétrons e prótons. Os elétrons gerados migram através de um circuito externo até o cátodo, enquanto os prótons atravessam uma membrana de troca iônica para o cátodo, onde se combinam com oxigênio, completando a reação. Esse processo gera um fluxo de corrente elétrica, aproveitado como fonte de energia renovável. Além da geração de eletricidade, as MFCs têm potencial para tratar efluentes, uma vez que utilizam matéria orgânica diversa, como a encontrada em efluentes urbanos.

As células a combustível microbianas (MFCs) constituem uma tecnologia promissora para a geração de energia a partir de resíduos orgânicos, unindo biotecnologia e eletroquímica [2]. Neste contexto, a modelagem por meio de circuitos elétricos equivalentes é uma abordagem comum para simular e prever o comportamento elétrico das células [3], [4].

Contudo, diferenças substanciais entre as predições desses modelos e os dados experimentais de operação revelam limitações na capacidade dos modelos em capturar a totalidade dos fenômenos biológicos e físico-químicos, sobretudo aqueles associados à formação e evolução do biofilme microbiano, às perdas por polarização e à resistência interna [5], [6]. Tais discrepâncias dificultam o uso confiável dos modelos para fins de otimização e controle.

Nesse sentido, o objetivo deste artigo é apresentar o desenvolvimento, modelagem e desempenho de dois protótipos de MFC, um com carvão ativado e outro com grafite granular nos eletrodos. A MFC é construída com duas câmaras de acrílico com capacidade de 150 mL cada e separadas por uma membrana de troca iônica, para conversão de resíduos orgânicos em eletricidade. A configuração experimental incluiu eletrodos de aço inoxidável, sendo o ânodo preenchido com lodo ativado obtido de uma estação de tratamento de esgoto e o cátodo com água destilada, continuamente aerada por pedra porosa e uma bomba de ar. Nosso estudo busca avaliar a aplicabilidade desses modelos em um sistema real de MFC operando com lodo ativado como ânodo e eletrodos de aço inoxidável. Para isso, realizamos medições por cinco meses em experimento.

2.0 FUNDAMENTAÇÃO TEÓRICA

A representação elétrica equivalente de MFCs utiliza elementos como resistores (para representar resistências de polarização e transporte), capacitores (para efeitos de dupla camada eletroquímica) e, em configurações mais avançadas, fontes controladas ou componentes não lineares [7]. Esses modelos possibilitam simulações rápidas e interpretação de fenômenos eletroquímicos.

A literatura identifica diferentes formas de modelagem, listadas a seguir como:

- Modelos Simplificados Resistivos que são utilizados para obter estimativas globais de desempenho, mas insuficientes para capturar a dinâmica não linear do biofilme microbiano [5];
- Modelos com Impedância Complexa que incorporam elementos como resistência de carga, capacitância de dupla camada e impedância de Warburg. [8], [9], [10], [11]; e
- Modelos Acoplados Bioeletroquímicos que unem reações eletroquímicas a cinéticas microbianas (ex. Monod-Butler-Volmer) e equações de transporte, estes modelos são frequentemente implementados em softwares como COMSOL para simulação multifísica [12].

2.1 Elementos de uma MFC

Eletrodos: Os eletrodos, responsáveis pela transferência de elétrons e geração da energia elétrica, são tipicamente construídos com grafite, carvão ativado, fibras de carbono, grafeno, nanotubos [13], [14]. A biocompatibilidade, propriedades eletroquímicas, custo e área superficial influenciam diretamente na escolha construtiva e afetam o desempenho das células. As membranas, que separam os compartimentos do ânodo e cátodo, são geralmente membranas de troca catiônica devido à sua alta condutividade iônica, garantindo passagem eficiente dos prótons e separação do substrato.

Substrato: A escolha do substrato, para fins experimentais, geralmente se baseia em materiais sintéticos que visam garantir a reprodutibilidade das condições experimentais. Entretanto, a tecnologia visa servir como alternativa a métodos de tratamento de esgoto e está sujeita a uma ampla variedade de composições, muito influenciadas pela particularidade de cada local, o que se torna um desafio para o desenvolvimento da tecnologia.


Câmara: A configuração da câmara também impacta a eficiência do sistema. As configurações com câmaras únicas oferecem simplicidade e baixo custo, porém diminuem a eficiência do sistema, uma vez que o ânodo está sujeito à exposição ao ambiente. Entretanto, apesar das configurações de câmara dupla permitirem maior controle de condições operacionais, elas aumentam a complexidade e análise do sistema. Há também outros métodos construtivos, cada qual com diferentes objetivos desde geração de energia elétrica ao tratamento de esgoto, produção de biocombustíveis e dessalinização [15].

3.0 METODOLOGIA

No presente estudo, duas MFCs de câmara dupla foram construídas em acrílico, cada câmara com capacidade para 150mL e separadas por uma membrana de troca catiônica ($\varnothing = 5$ cm, CMI-7000S, *Membranes International*). Os eletrodos do ânodo e do cátodo foram compostos por dois cartuchos de malha de aço inoxidável (2.5×5.0 cm², 200 mesh, Telas Rocha Ltd, Brasil). A MFC1 tem eletrodos preenchidos com 2g de carvão ativado de casca de coco, enquanto a MFC2 foi preenchida com grafite granular. A ligação entre os eletrodos do cátodo e ânodo foi realizada com uma barra de aço inoxidável e um resistor de 560 Ω .

Os ânodos foram preenchidos com lodo ativado, utilizado como inóculo para o crescimento do biofilme eletroativo, proveniente da estação de tratamento de esgoto do município de Florianópolis - SC - Brasil e alimentados por meio sintético (composição em g·L⁻¹: 1.68 NaC₂H₃O₂; 0.24 (NH₄)₂SO₄; 5.88 KH₂PO₄; 1.19 K₂HPO₄; 2.00 NaHCO₃; 0.1 CaCl₂·2H₂O; 0.1 KCl; 0.1 NaCl; 0.1 MgCl₂·6H₂O; 0.1 MgSO₄·7H₂O; 0.05 yeast extract; 0.005 MnCl₂·4H₂O; e 0.001 Na₂MoO₄·2H₂O). Inicialmente, o ânodo operou em modo batelada e posteriormente alterado para *fed-batch* com retenção hidráulica variando entre 2 e 4 dias. O cátodo foi preenchido com água destilada e continuamente aerado por pedra porosa e uma bomba de ar (Big Air®, A420). No dia 73 do experimento, o católito foi substituído e os eletrodos foram limpos com auxílio de uma escova para remoção do biofilme formado em sua superfície. No dia 149, o procedimento foi repetido, totalizando 160 dias de operação do experimento em temperatura ambiente ($23 \pm 1^\circ\text{C}$). A Fig. 1 apresenta o esquema representativo da MFC utilizada.

Figura 1 - Esquema representativo do reator MFC utilizado



Na Fig. 1, tem-se: 1 – Ânodo; 2 – Cátodo; 3 – Membrana de troca catiônica; 4 – Entrada do meio de cultivo; 5 – saída do efluente tratado; 6 – aeragem; 7 – pedra porosa; 8 – haste de aço inox para conexão do circuito elétrico.

Ambas as MFCs foram monitoradas em regime de operação contínua, com alimentação sazonal baseada em substrato orgânico. A tensão elétrica gerada foi registrada por meio de um sistema de aquisição baseado em microcontrolador Arduino. Contudo, por se tratar de sistemas bioeletroquímicos, cuja dinâmica envolve a adaptação microbiana ao meio, as condições inicialmente observadas demonstraram forte instabilidade e transientes elétricos não característicos do estado estacionário.

Esse comportamento é típico em MFCs durante o período de formação e amadurecimento do biofilme, quando a comunidade microbiana ainda se encontra em fase de estabelecimento eletroativo. Trabalhos como os de [16], [17] relatam variações significativas na impedância e na densidade de potência durante as primeiras semanas de operação, atribuídas ao desenvolvimento inicial do biofilme na superfície anódica.

Para [18], observou-se que, durante a primeira semana de operação (biofilme imaturo), a resistência de polarização do ânodo foi mais de 70% superior em comparação ao valor atingido após três semanas. De forma semelhante, [9] reportou um aumento progressivo da densidade de potência de 15 ± 3 para 100 ± 15 mW/m² ao longo de 20 semanas, consequência da maturação gradual das comunidades microbianas.

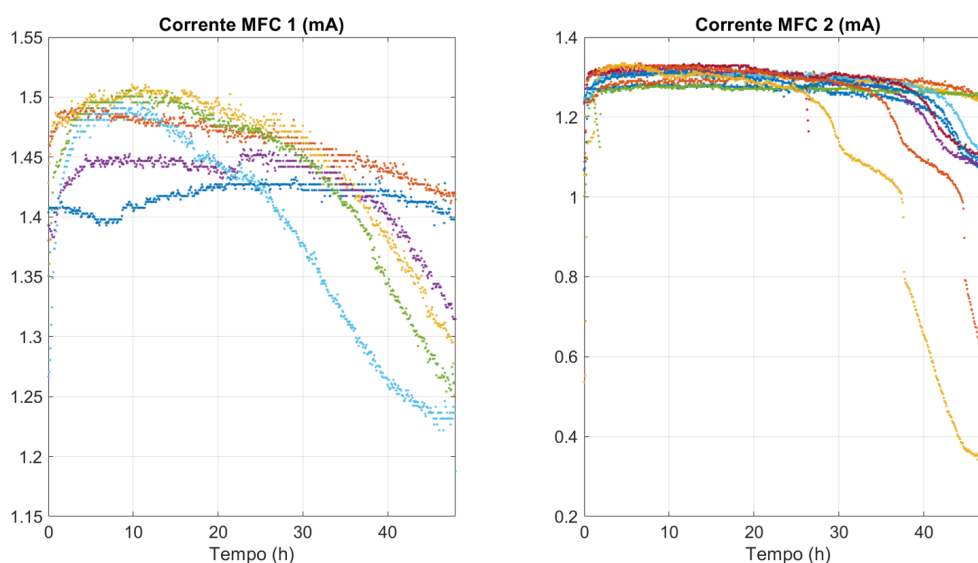
Portanto, visando garantir a consistência das análises e excluir efeitos transitórios não representativos do comportamento eletroativo estável, adotou-se como critério a análise somente das séries de dados obtidas após a estabilização dos valores médios de tensão.

4.0 MODELAGEM E RESULTADOS

A modelagem matemática tem desempenhado papel central na compreensão do comportamento dinâmico das MFCs, permitindo prever o desempenho do sistema sob diferentes condições operacionais. Diversos trabalhos abordam estratégias de simulação baseadas em balanços de massa, cinética bioeletroquímica, interações microbianas e fluxos de corrente elétrica. Os modelos variam de abordagens mecanísticas complexas até representações reduzidas, destacam-se [19], [20], [21]. Há também estudos mais recentes que tratam a modelagem por meio de técnicas de aprendizado de máquina aplicadas para prever densidade de potência e desempenho de tensão de saída com altas taxas de acurácia (>99%), sugerindo que abordagens híbridas entre modelagem estatística e bioeletroquímica estão em expansão [21].

Para esse estudo, as séries de tensão medidas apresentaram ruído elevado, devido à natureza não periódica da alimentação e pequena variação no intervalo de amostragem. Para padronizar os intervalos e reduzir a variabilidade aleatória, os dados foram interpolados para uma resolução uniforme de 5 minutos entre cada observação. Em seguida, as séries foram divididas em janelas fixas de 48 horas e, em cada janela, foram computados o valor máximo, mínimo e médio da tensão. Algumas janelas com excesso de ruído ou dados excessivamente imputados por interpolação foram descartadas, reduzindo o conjunto analisável para séries mais estáveis e matematicamente modeláveis. Diante disso, foram obtidos os resultados apresentados na Figura 1. Ressalta-se que a MFC1 e a MFC2 utilizam carvão ativado e grafite granular nos eletrodos, respectivamente.

Figura 2 - Curvas de tensão do experimento



A dinâmica observada foi interpretada como um processo de consumo do estoque do recurso natural, ou seja, do substrato orgânico (alimento) e da produção de energia (tensão elétrica), com liberação controlada por uma função de produção $\Phi(t)$. Desse modo, propôs-se, então, o seguinte sistema de equações diferenciais ordinárias (EDO):

$$\begin{aligned}\frac{dx}{dt} &= d - \Phi(t)x \\ x(0) &= x_0 \\ \Phi(t) &= a e^{(bt^c)}\end{aligned}\tag{1}$$

Do ponto de vista físico, esse modelo pode ser interpretado da seguinte forma, tem-se o alimento como uma quantidade equivalente de tensão armazenada que é liberada de acordo com a equação diferencial, dx/dt , conforme Eq. (1). A quantidade inicial de tensão armazenada é determinada pela condição inicial $x(0)$. A taxa de liberação da tensão é obtida por $d - \Phi(t)x$, e $\Phi(t)$ determina a velocidade que esta tensão é liberada.

Este modelo tem como parâmetros livres os coeficientes da taxa de produção a , b , c e a taxa d . Essas incógnitas podem ser identificadas a partir das séries de observações via mínimos quadrados. Definindo o vetor de incógnitas como $\theta = [a, b, c, d]^T$, minimiza-se a seguinte função:

$$F(\theta) = \sum_{j=1}^n \left(\frac{x_j^{obs} - x(t_j; \theta)}{x_j^{obs}} \right)^2\tag{2}$$

A Eq. (2) é resolvida numericamente utilizando a função *lsqnonlin* do MATLAB. A condição inicial da série é tomada como o primeiro valor de cada subjanela. Para simplificação, as séries modeladas consideram somente o decaimento dos valores a partir do 50º passo. A Tab.1 apresenta os valores estimados para os parâmetros do modelo para ambas MFCs.

Tabela 1 - Resultados da modelagem

	MFC 1				MFC 2			
	a	b	c	d	a	b	c	d
Série 1	0,058	1,909	0,499	0,182	0,089	2,174	0,592	0,254
Série 2	0,629	0,675	3,444	0,579	0,047	2,134	0,919	0,126
Série 3	0,075	2,147	0,515	0,198	0,048	1,723	0,425	0,115
Série 4	0,010	3,646	0,662	0,046	0,011	4,466	0,610	0,081
Série 5	0,076	2,261	0,540	0,212	0,022	2,217	0,171	0,140
Série 6	2,462	0,372	0,844	2,641	0,100	2,010	0,645	0,249
Série 7	-	-	-	-	0,104	2,115	0,665	0,241
Série 8	-	-	-	-	0,090	2,108	0,613	0,221
Série 9	-	-	-	-	0,355	2,621	1,706	0,509
Série 10	-	-	-	-	16,163	1,763	4,005	16,232

Assim, considerando os valores obtidos para os coeficientes da taxa de produção a , b , c e d conforme Tab. 1, e conforme Eq. (1), tem-se os seguintes resultados, apresentados da Fig. 3 e Fig. 4.

Figura 3 – Curvas do modelo matemática MFC2

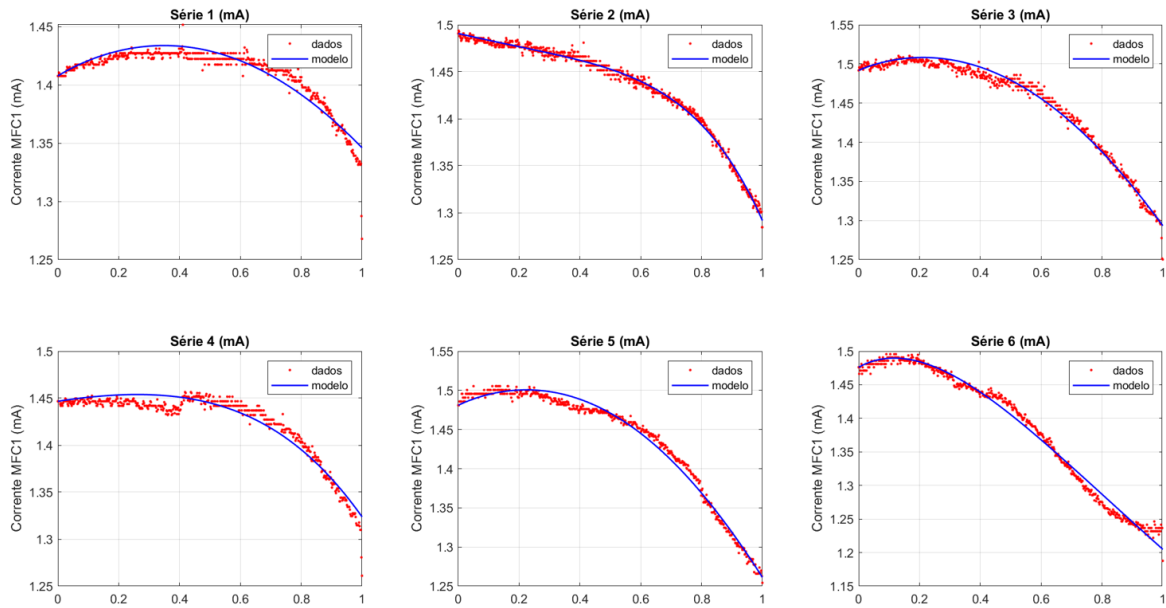
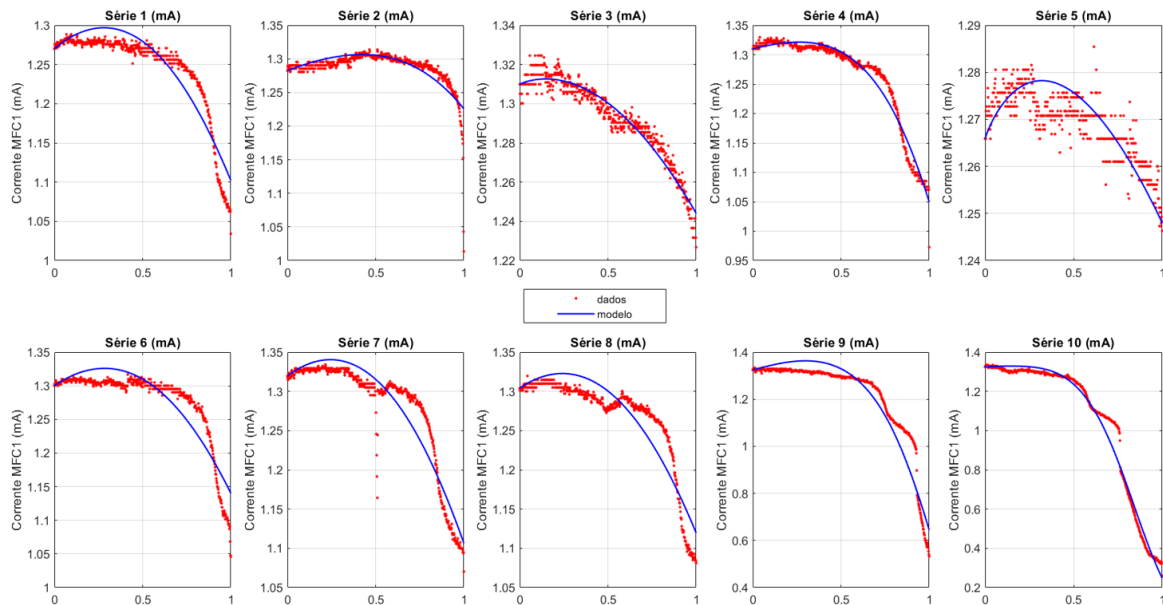


Figura 4 - Curvas do modelo matemático MFC2



4.1 Análise

Para análise de dados, as séries temporais de tensão foram processadas utilizando correlação de Pearson, permitindo identificar padrões sazonais e filtrar ruídos. Modelos matemáticos baseados em regressão não linear, aplicados por meio de equações diferenciais ordinárias, foram ajustados aos dados para descrever a dinâmica de produção e consumo de energia, destacando-se pela precisão nas séries de dados com características mais estáveis. Após a aplicação do modelo às diferentes séries experimentais, é possível observar padrões interessantes nos resultados obtidos tanto para o MFC1 quanto para o MFC2.

MFC1: De um modo geral, o modelo conseguiu se ajustar de forma bastante satisfatória aos dados. No entanto, ao se analisar os valores dos parâmetros estimados, pode-se constatar uma grande variação que pode ser causada por uma série de fatores. O experimento estava sujeito a diferentes condições iniciais e de contorno, relacionadas à variação na quantidade de substrato adicionada, além da produção de

impurezas. Outro fator relevante é o próprio fato de se analisar a produção de eletricidade por organismos vivos, o que introduz incertezas nos dados e, conseqüentemente, nos resultados. Analisando os dados da Tab.1, pode-se observar que as séries 1, 3 e 5 apresentam valores muito semelhantes entre si para os parâmetros estimados. Visualmente, essas três curvas são bastante similares, sugerindo a repetição de um padrão. Já, as séries 2 e 6 apresentam padrões distintos entre si e em relação às demais. A série 4, por sua vez, mostra valores próximos aos das séries 1, 3 e 5, o que indica a possibilidade de um padrão recorrente, apesar das variações nas condições. Mesmo com um conjunto de dados relativamente pequeno, é possível observar a presença de um padrão consistente, que pode ser bem descrito pelo modelo representado pelas Eqs. (1)-(2).

MFC2: Visualmente, a Fig. 4, na posição linha 2 e coluna 2 e 3, mostram que o modelo também conseguiu se ajustar satisfatoriamente aos dados para o MFC2, ainda que este apresente um padrão ligeiramente distinto do MFC1. A partir da Tab. 1, constata-se novamente a presença de dois padrões nas estimativas: um formado pelas séries 2 a 5 (padrão A) e outro pelas séries 1 e 6 a 8 (padrão B). As séries 9 e 10 destoam significativamente das demais e requerem análise separada. O padrão B é bastante similar ao observado nas séries 1, 3 e 5 do MFC1, embora os valores estimados para o MFC1 sejam um pouco menores. Isso pode indicar similaridades nas dinâmicas entre os dois sistemas. O ajuste do modelo ao MFC1 foi ligeiramente superior ao do MFC2 nas séries do padrão B. Já, as estimativas do padrão A, embora próximas, apresentam valores um pouco menores, refletindo em curvas visuais semelhantes, caracterizadas por um pico de tensão seguido de decaimento, como observado no MFC1. No entanto, nos dados do MFC2, esse pico nem sempre é tão acentuado e, em alguns casos, há uma leve queda seguida de nova subida, o que pode estar associado a reabastecimentos de substrato ou mudanças no metabolismo microbiano. As séries 9 e 10 se destacam por apresentar quedas suaves seguidas por declínio acentuado ao final do período. Especificamente para a série 10, o modelo se ajustou bem, porém apresentou valores de parâmetros muito superiores, sugerindo um possível sobreajuste — fator indesejável para fins de generalização e previsão. Em termos gerais, a modelagem do MFC2 demonstrou ser robusta e consistente, com boa aderência visual e parâmetros relativamente estáveis entre séries similares.


Os resultados demonstraram que o sistema foi capaz de gerar energia elétrica, embora com variação de desempenho entre os protótipos MFC1 e MFC2. A resistência interna, fator crítico para a eficiência das MFCs, foi avaliada através do estudo da curva de polarização, revelando uma ampla faixa de densidade de potência em resposta às características dos materiais dos eletrodos e da configuração do sistema.

4.2 Modelo elétrico equivalente

Assim como outros sistemas eletroquímicos, as Células a Combustível Microbianas (MFCs) podem ser representadas por circuitos elétricos equivalentes que simplificam a análise de resposta em corrente e tensão, permitindo avaliar propriedades internas como resistência ôhmica e capacidades de troca de carga. De acordo com [11] há alguns modelos adotados na literatura para abordagem por circuito elétrico equivalente. No contexto deste estudo, o modelo matemático proposto na Eq. 1 foi relacionado a um circuito elétrico equivalente que reflete a dinâmica de produção e consumo de energia.

Enquanto a maioria das abordagens presentes na literatura trata o comportamento macroscópico da MFC, olhando para uma janela de vários dias ou semanas, o trabalho de [10] analisa o comportamento variável horário da MFC. Como observado na Fig. 2, o comportamento apresenta uma variação de corrente ao longo do dia, conforme também observado por [10], ainda que por meio de uma metodologia distinta. As curvas da Fig. 2 demonstram que modelos puramente resistivos são insuficientes para explicar tais variações, uma vez que negligenciam o comportamento transitório do sistema. Diante disso, propõe-se a adoção de um circuito equivalente mais complexo, representado na Fig. 5(a), baseado no modelo Larminie-Dicks [22].

Figura 5 – Circuito equivalente MFC



Para a análise do circuito na Fig 5 (a), pode-se iniciar a modelagem pela Eq. (4):

$$\frac{dV_c}{dt} = \frac{I_f}{C} - \frac{1}{RC} V_c \quad (3)$$

Entretanto, a Eq. (3) embora possua similaridade com a Eq. 2, ainda não é suficiente para explicar a modelagem. Uma proposta para aplicar um elemento variável a equação seria adotar o entendimento que R é um resistor variável no tempo, isto se torna relevante, conforme [23], uma vez que adequa o modelo a uma variação dinâmica ocorrida devido a alimentação com substrato ocorrida periodicamente, conforme Fig. 5(b). Portanto, se propõe uma alteração do circuito, onde R possui comportamento variável definido pela $R(t) = R_0 \times e^{at}$ e com isto temos como resultado do modelo a Eq. (4).

$$\frac{dV_c}{dt} = \frac{I_f}{C} - \frac{1}{R_0 C \times e^{at}} V_c \quad (4)$$

O circuito elétrico equivalente proposto integra a EDO do modelo matemático, oferecendo uma representação física das dinâmicas de tensão nas MFCs. Ele conecta parâmetros elétricos a fenômenos biológicos, como variação no substrato e com o crescimento do biofilme, permitindo simulações das variações observadas. No entanto, essa proposta ainda carece de validações mais abrangentes e de uma mudança de perspectiva que possibilite explorar outras abordagens complementares, com o objetivo de representar de forma mais completa os processos bioeletroquímicos envolvidos.

5.0 CONCLUSÕES

O modelo possibilitou identificar padrões de comportamento e sugerir ajustes para a otimização do sistema. No geral, as MFCs apresentaram variabilidade na geração de eletricidade, dependente das condições experimentais e da resposta dos microrganismos aos substratos. Entretanto, estudos apontam que a aplicação de melhorias ao sistema de monitoramento e abordagem utilizando algoritmos de rastreamento do ponto de máxima potência (MPPTs) podem contribuir significativamente com a estabilidade dos resultados e aumentar a eficiência do sistema.

Este trabalho reforça o potencial das MFCs como uma alternativa sustentável para geração de bioenergia, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS) ao promover a produção de eletricidade limpa e o tratamento de efluentes. Embora as MFCs ainda enfrentem desafios, como a escalabilidade para aplicações em larga escala, os resultados indicam que essa tecnologia é promissora e pode ser integrada a sistemas urbanos, contribuindo para a redução da pegada de carbono. Em cenários de *smart cities*, as MFCs podem integrar a geração de energia elétrica ao tratamento de resíduos, representando uma solução prática e eficiente para gestão de recursos e mitigação de emissões de gases de efeito estufa, sobretudo considerando a abertura do mercado global de carbono.

O artigo fornece uma base sólida para compreender o funcionamento das MFCs em condições experimentais, demonstrando seu valor como alternativa viável e ambientalmente responsável para a produção de energia. Implementar MFCs em ambientes urbanos e industriais fortalece a economia circular do carbono, onde resíduos são aproveitados como recursos, consolidando o papel das MFCs na transição para uma matriz energética sustentável e na promoção de cidades mais resilientes e ecológicas.

Este trabalho é parte do esforço de compartilhamento e parceria estabelecida pelo projeto CNPq intitulado “Rede Sul de Hidrogênio Verde - Novos materiais e intensificação de processos para produção de hidrogênio verde a partir de fontes de energia e insumos renováveis” entre IFSC, UFSC, UFPR, UFRGS e UEM, sendo o protótipo apresentado desenvolvido no Laboratório de Biotecnologia Ambiental (e-biotech) da UFSC e no Laboratório de Computação Científica Aplicada (LCCA) do IFSC.

6.0 BIBLIOGRAFIA

- [1] R. K. Langbehn, “Resiliência de sistemas de remoção de carbono e nitrogênio em células a combustível microbianas à adição de fluoroquinolonas”, 2023.
- [2] B. E. Logan e K. Rabaey, “Conversion of Wastes into Bioelectricity and Chemicals by Using Microbial Electrochemical Technologies”, *Science (1979)*, vol. 337, n° 6095, p. 686–690, ago. 2012, doi: 10.1126/science.1217412.
- [3] D. Deb, R. Patel, e V. E. Balas, “A Review of Control-Oriented Bioelectrochemical Mathematical Models of Microbial Fuel Cells”, *Processes*, vol. 8, n° 5, p. 583, maio 2020, doi: 10.3390/pr8050583.
- [4] J.-D. Park, T. M. Roane, Z. J. Ren, e M. Alaraj, “Dynamic modeling of a microbial fuel cell considering anodic electron flow and electrical charge storage”, *Appl Energy*, vol. 193, p. 507–514, maio 2017, doi: 10.1016/j.apenergy.2017.02.055.
- [5] P. M. D. Serra, A. Espírito-Santo, e M. Magrinho, “A steady-state electrical model of a microbial fuel cell through multiple-cycle polarization curves”, *Renewable and Sustainable Energy Reviews*, vol. 117, p. 109439, jan. 2020, doi: 10.1016/j.rser.2019.109439.
- [6] C. Picioreanu, I. M. Head, K. P. Katuri, M. C. M. van Loosdrecht, e K. Scott, “A computational model for biofilm-based microbial fuel cells”, *Water Res*, vol. 41, n° 13, p. 2921–2940, jul. 2007, doi: 10.1016/j.watres.2007.04.009.
- [7] J.-D. Park e Z. Ren, “Hysteresis controller based maximum power point tracking energy harvesting system for microbial fuel cells”, *J Power Sources*, vol. 205, p. 151–156, maio 2012, doi: 10.1016/j.jpowsour.2012.01.053.
- [8] D. Recio-Garrido, M. Perrier, e B. Tartakovsky, “Parameter estimation of a microbial fuel cell process control-oriented model”, em *22nd Mediterranean Conference on Control and Automation*, IEEE, jun. 2014, p. 918–923. doi: 10.1109/MED.2014.6961491.
- [9] D. Sanchez-Herrera *et al.*, “Characterization of anode and anolyte community growth and the impact of impedance in a microbial fuel cell”, *BMC Biotechnol*, vol. 14, n° 1, p. 102, dez. 2014, doi: 10.1186/s12896-014-0102-z.
- [10] S. Potrykus, J. Nieznański, F. Kutt, e F. J. Fernandez-Morales, “Modeling the effect of external load variations on single, serie and parallel connected microbial fuel cells”, *Bioresour Technol*, vol. 416, p. 131761, jan. 2025, doi: 10.1016/j.biortech.2024.131761.
- [11] R. Rossi, D. M. Hall, X. Wang, J. M. Regan, e B. E. Logan, “Quantifying the factors limiting performance and rates in microbial fuel cells using the electrode potential slope analysis combined with electrical impedance spectroscopy”, *Electrochim Acta*, vol. 348, p. 136330, jul. 2020, doi: 10.1016/j.electacta.2020.136330.
- [12] T. Kamperidis, A. Tremouli, A. Peppas, e G. Lyberatos, “A 2D Modelling Approach for Predicting the Response of a Two-Chamber Microbial Fuel Cell to Substrate Concentration and Electrolyte Conductivity Changes”, *Energies (Basel)*, vol. 15, n° 4, p. 1412, fev. 2022, doi: 10.3390/en15041412.
- [13] X. Huang *et al.*, “Role of electrode materials on performance and microbial characteristics in the constructed wetland coupled microbial fuel cell (CW-MFC): A review”, *J Clean Prod*, vol. 301, p. 126951, jun. 2021, doi: 10.1016/j.jclepro.2021.126951.
- [14] S. Kerzenmacher, “Engineering of Microbial Electrodes”, 2017, p. 135–180. doi: 10.1007/10_2017_16.
- [15] M. Zahid *et al.*, “Microbial desalination cell: Desalination through conserving energy”, *Desalination*, vol. 521, p. 115381, jan. 2022, doi: 10.1016/j.desal.2021.115381.
- [16] R. P. Ramasamy, Z. Ren, M. M. Mench, e J. M. Regan, “Impact of initial biofilm growth on the anode impedance of microbial fuel cells”, *Biotechnol Bioeng*, vol. 101, n° 1, p. 101–108, set. 2008, doi: 10.1002/bit.21878.

- [17] D. Sanchez-Herrera *et al.*, “Characterization of anode and anolyte community growth and the impact of impedance in a microbial fuel cell”, *BMC Biotechnol*, vol. 14, nº 1, p. 102, dez. 2014, doi: 10.1186/s12896-014-0102-z.
- [18] M. G. Hosseini e I. Ahadzadeh, “APPLICATION AND COMPARISON OF CURRENT INTERRUPTION AND ELECTROCHEMICAL IMPEDANCE SPECTROSCOPY METHODS TO STUDY A MICROBIAL FUEL CELL”, *Instrum Sci Technol*, vol. 41, nº 1, p. 72–81, jan. 2013, doi: 10.1080/10739149.2012.717331.
- [19] A. Capodaglio, D. Cecconet, e D. Molognoni, “An Integrated Mathematical Model of Microbial Fuel Cell Processes: Bioelectrochemical and Microbiologic Aspects”, *Processes*, vol. 5, nº 4, p. 73, nov. 2017, doi: 10.3390/pr5040073.
- [20] N. Jayasinghe, A. Franks, K. P. Nevin, e R. Mahadevan, “Metabolic modeling of spatial heterogeneity of biofilms in microbial fuel cells reveals substrate limitations in electrical current generation”, *Biotechnol J*, vol. 9, nº 10, p. 1350–1361, out. 2014, doi: 10.1002/biot.201400068.
- [21] D. Aboelela, M. Soliman, e I. Ashour, “A Reduced Model for Microbial Fuel Cell”, *Chem Eng Trans*, vol. 79, p. 43–48, abr. 2020, doi: 10.3303/CET2079008.
- [22] J. Larminie e A. Dicks, *Fuel Cell Systems Explained*. Wiley, 2003. doi: 10.1002/9781118878330.
- [23] C. Picioreanu, I. M. Head, K. P. Katuri, M. C. M. van Loosdrecht, e K. Scott, “A computational model for biofilm-based microbial fuel cells”, *Water Res*, vol. 41, nº 13, p. 2921–2940, jul. 2007, doi: 10.1016/j.watres.2007.04.009.

DADOS BIOGRÁFICOS



Renan M. Nogueira, possui graduação em Engenharia Elétrica pela Universidade Federal de Santa Catarina (UFSC) em 2017. Atualmente aluno do Mestrado Profissional em Sistemas de Energia Elétrica no Instituto Federal de Santa Catarina (IFSC). Atua na empresa de engenharia Pieta.tech como gerente de produtos.

Rayane Kunert Langbern, pesquisadora do Laboratório de Biotecnologia Ambiental (e-biotech) da UFSC; graduada em Engenharia Química UFSC (2015) e em Ciência e Tecnologia UFVJM (2011) com período sanduíche na Universidad Autónoma de Madrid (UAM); Mestre (2018) e Doutora (2023) em Engenharia Química UFSC; Pós-doc em Engenharia Química UFSC (2023).

Sergio L. Avila, docente e pesquisador no IFSC; bolsista CNPq de Produtividade Desenvolvimento Tecnológico e Extensão Inovadora 2, Engenheiro Industrial Eletricista (FURB-2000), doutor com duplo-diploma pela Ecole Centrale de Lyon/França e UFSC (2006) e Pós-doc pela Schneider Electric (INPG - França, 2006) e Escola Politécnica da USP (2008); Líder do Grupo de Pesquisas em Computação Científica para Engenharia (PECCE); e Pesquisador associado ao Laboratório de Redes Elétricas Avançadas (LGrid) da Escola Politécnica da USP.

Everthon T. Sica, docente e pesquisador no IFSC; graduado em Engenharia Elétrica Industrial UTFPR (2000); Mestre (2003) e Doutor (2009) em Planejamento de Sistemas de Energia Elétrica (UFSC); Consultor ad hoc em projetos de PDI; e Pesquisador na área de Planejamento Integrado de Recursos Energéticos do Núcleo de Inovação em Sistemas Inteligentes de Energia (Pólo EMBRAPII).

Vinicius V. L. Albani, docente e pesquisador na UFRJ; foi professor e pesquisador na UFSC (2016-2025) e Coordenador do Laboratório de Modelagem Matemática em Ciências Aplicadas (LAMMCA, 2021-2025); Professor visitante na Faculdade de Matemática da Universidade de Viena (2014-2016); Pós-doc no IMPA (2014).