



Universidade Federal
de São João del-Rei

UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI
CAMPUS ALTO PARAPEBA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA AVALIAÇÃO DA
PERFORMANCE DE CÉLULAS DE ENERGIA MICROBIANA**

MARCO AURÉLIO ANDRADE CACHEADO

OURO BRANCO - MG

2024

UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI
CAMPUS ALTO PARAÓPEBA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

MARCO AURÉLIO ANDRADE CACHEADO

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA AVALIAÇÃO DA
PERFORMANCE DE CÉLULAS DE ENERGIA MICROBIANA

Dissertação apresentada à Universidade Federal de São João del-Rei como parte das exigências do Programa de Pós-Graduação em Engenharia Química para a obtenção do título de Mestre em Engenharia Química.

Orientador: Prof. Dr. Edson Romano Nucci

OURO BRANCO – MG

2024

Ficha catalográfica elaborada pela Divisão de Biblioteca (DIBIB)
e Núcleo de Tecnologia da Informação (NTINF) da UFSJ,
com os dados fornecidos pelo(a) autor(a)

C119a Cacheado, Marco Aurélio Andrade.
Aplicação de Redes Neurais Artificiais na Avaliação
da Performance da Células de Energia Microbiana /
Marco Aurélio Andrade Cacheado ; orientador Edson
Romano Nucci. -- Ouro Branco, 2024.
80 p.

Dissertação (Mestrado - Programa de Pós-Graduação em
Engenharia Química) -- Universidade Federal de São
João del-Rei, 2024.

1. redes neurais artificiais. 2. célula
combustível microbiana. 3. modelagem.. I. Nucci,
Edson Romano, orient. II. Título.

MEMBROS DA BANCA EXAMINADORA DA DEFESA DO PROJETO DE DISSERTAÇÃO DE MESTRADO DE **MARCO AURÉLIO ANDRADE CACHEADO**, APRESENTADA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA DA UNIVERSIDADE FEDERAL DE SÃO JOÃO DEL-REI, EM 16 DE AGOSTO DE 2024.

BANCA EXAMINADORA:

Prof. Dr. Edson Romano Nucci
(DQBIO/UFSJ - PPGEQ) -
Orientador

Prof. Dr. André Aguiar Mendes
(IRN/UNIFEI - PPGBiotec)

Profa Dra. Ana Paula Fonseca
Maia de Urzedo
(DQBIO/UFSJ - PPGEEnBIO)

Prof. Dr. Juan Canellas Bosch Neto
(DEQUI/UFSJ - PPGEQ)

Agradecimentos

Agradeço, em primeiro lugar, a Deus, por me proporcionar sabedoria, força e direção ao longo desta jornada do mestrado. A Ele dedico todo o meu esforço e conquistas.

Aos meus pais, expresso minha profunda gratidão pelo amor incondicional, apoio constante e pelos valores que me guiaram até aqui. Sua presença e incentivo são fundamentais em todos os momentos. À minha família, agradeço por compreender as demandas e desafios deste percurso acadêmico, oferecendo compaixão e encorajamento nos momentos de dificuldade.

Aos professores que contribuíram para o meu desenvolvimento acadêmico, meu reconhecimento pelo compartilhamento de conhecimento e pela inspiração transmitida em cada aula e orientação.

Ao meu orientador, Prof. Dr. Edson Romano Nucci, agradeço por sua orientação perspicaz, apoio incansável e pela confiança depositada em meu trabalho. Sua dedicação e expertise foram fundamentais para o amadurecimento do meu projeto.

Agradeço também aos professores Dr. Juan Canellas Bosch Neto, Dra. Isabel Cristina Braga Rodrigues, Dr. André Aguiar Mendes e Dra. Ana Paula Fonseca Maia de Urzedo, membros da banca de Qualificação e Defesa de Mestrado, pelos conselhos, sugestões e interesse em contribuir para o desenvolvimento deste projeto

Agradeço à CAPES e à UFSJ pelo apoio fundamental na realização desta dissertação.

A todos que, de alguma forma, contribuíram para este processo, meu sincero agradecimento. Este é um passo significativo, e cada pessoa mencionada desempenhou um papel essencial em minha jornada acadêmica.

“Que os vossos esforços desafiem as impossibilidades.
Lembrai-vos de que as grandes coisas do homem foram
conquistadas do que parecia impossível”

Charles Chaplin

Resumo

A crescente geração de efluentes industriais e domésticos, aliada ao crescimento populacional e à proposta de legislação ambiental mais rigorosa, surgiu a necessidade de soluções inovadoras. Isto inclui a integração de preocupações como a geração de energia e o tratamento de águas residuárias por meio de Células de Energia Microbiana (CEM). As CEM utilizam micro-organismos para converter energia química em energia elétrica durante a degradação da matéria orgânica. Para avaliar e determinar os parâmetros de utilização de CEM, foi proposto o uso de Redes Neurais Artificiais (RNAs) e sistemas Neuro-Fuzzy. As RNAs são modelos computacionais treinados com base em informações fornecidas e constantemente atualizadas para otimizar a identificação de padrões e fornecer respostas rápidas sobre um determinado sistema. O sistema neuro-fuzzy utilizado foi o sistema ANFIS (*Adaptive Network-based Fuzzy Inference System*) que consiste de rede neural do tipo MLP (*Multi Layer Perceptron*) *feedforward* que usa algoritmos de aprendizagem da rede neural e regras fuzzy para mapear um espaço de entrada a um espaço da saída. Para a aplicação e avaliação de RNAs nas CEM, foi utilizado um modelo de RNA *feedforward* com diversas configurações entre camadas ocultas, número de neurônios e funções de ativação. As variáveis de entrada foram a área do ânodo (cm^2), a resistência elétrica externa (Ω) e o volume (mL), enquanto a variável de saída foi a Densidade de Potência (mWm^{-2}). O melhor desempenho para RNAs foi uma rede com 120 neurônios nas camadas ocultas, utilizando a função de ativação tansig com 19 interações, resultando em um R^2 de 0,89562 no conjunto de treinamento, 0,74617 na validação, 0,90633 no ajuste com todos os dados experimentais e um erro aproximado de 0,0845. Da mesma forma, para RNAs com uma camada oculta, os resultados mais promissores foram obtidos com 90 neurônios, a função de ativação tansig, 22 interações e um R^2 de 0,92628 no conjunto de treinamento, 0,82224 na validação, 0,91009 no ajuste com todos os dados experimentais, e um erro aproximado de 0,0168. Considerando o sistema Neuro-Fuzzy ANFIS, os melhores resultados foram alcançados com 27 neurônios na camada oculta, utilizando um algoritmo de treinamento híbrido e função de pertinência gaussiana. Concluindo, a utilização de Redes Neurais Artificiais e do sistema Neuro-Fuzzy ANFIS no contexto de células de energia microbiana apresentou resultados promissores, principalmente com o tipo de rede MLP no caso de RNAs.

Palavras-chaves: redes neurais artificiais, célula combustível microbiana, modelagem.

Abstract

The increasing generation of both industrial and domestic effluents, combined with population growth and proposed stricter environmental legislation, has prompted the need for innovative solutions. This includes the integration of concerns such as energy generation and wastewater treatment through Microbial Energy Cells (MECs). These cells use microorganisms to convert chemical energy into electrical energy during the degradation of organic matter. Additionally, MECs are self-sustainable as they produce a potential difference that powers the system. To evaluate and determine the parameters for using MECs, the use of Artificial Neural Networks (ANNs) and Neuro-Fuzzy systems has been proposed. ANNs are computational models trained to optimize pattern recognition and provide quick insights into a system. In this case, the Adaptive Network-based Fuzzy Inference System (ANFIS) was utilized, employing a feedforward neural network of the Multi-Layer Perceptron (MLP) type. A feedforward ANN model was used with various configurations for the application and evaluation of ANNs in MEC. The input variables were the anode area (cm^2), external electrical resistance (Ω), and volume (mL), while the output variable was Power Density (mWm^{-2}). The best-performing configuration for ANNs was observed to be a network with 120 neurons in the hidden layers, using the tansig activation function with 19 interactions, resulting in an R^2 of 0.89562 in the training set, 0.74617 in validation, 0.90633 in the fit with all experimental data, and an approximate error of 0.0845. Similarly, for ANNs with one hidden layer, the most promising results were obtained with 90 neurons, the tansig activation function, 22 interactions, and an R^2 of 0.92628 in the training set, 0.82224 in validation, 0.91009 in the fit with all experimental data, and an approximate error of 0.0168. Considering the Neuro-Fuzzy ANFIS system, the best results were achieved with 27 neurons in the hidden layer, using a hybrid training algorithm and Gaussian membership function. In conclusion, the use of Artificial Neural Networks and the Neuro-Fuzzy system ANFIS in microbial energy cells has shown promising results, particularly with the MLP network type in the case of ANNs.

Keywords: neural networks, microbial fuel cell, modeling.

Lista de Figuras

Figura 1: Desenvolvimento da pesquisa sobre o tratamento bioeletroquímico de águas residuárias no século XXI. (Palavras-chave para pesquisa: “microbial fuel cells” and “wastewater” em 12 de julho de 2024). Fonte: ScienceDirect.	18
Figura 2: Esquema representativo de uma Célula de Combustível Microbiana. Fonte: próprio autor.	20
Figura 3: Mecanismos de transferência de elétrons do micro-organismo para o eletrodo em CEM. a. transferência direta via proteínas de membrana ou periplasmáticas. b. transferência por meio de nanofios; c. transferência por meio de mediador redox, adicionado ao meio ou produzido como metabólito intermediário. Fonte: próprio autor.	27
Figura 4: Representação esquemática de uma Rede Neural <i>Perceptron</i> . Fonte: Próprio autor.	34
Figura 5: Representação esquemática de uma Rede Neural Adaline. Fonte: Próprio autor.	34
Figura 6: Representação esquemática de uma Rede Neural MLP, com duas camadas ocultas com cinco neurônios em cada camada. Fonte: Próprio autor.	35
Figura 7: Representação gráfica da função de ativação linear binária. Fonte: Próprio autor.	37
Figura 8: Representação gráfica da função de ativação linear por partes. Fonte: Próprio autor.	38
Figura 9: Representação gráfica da função de ativação sigmoidal. Fonte: Próprio autor.	38
Figura 10: Representação gráfica da função de ativação tangente hiperbólica. Fonte: Próprio autor.	39
Figura 11: Exemplificação de graus de pertinência para entrada Tamanho com as variáveis linguísticas (a) Pequeno, (b) Médio e (c) Grande. Fonte: próprio autor.	43
Figura 12: Arquitetura ANFIS genérica. Fonte: NUCCI et al. (2007).	45
Figura 13: Interface inicial do <i>Neuro-fuzzy ANFIS</i>	49

Figura 14: Arranjo para Rede Neural Artificial com duas camadas oculta. Fonte: Adaptado de Mathworks, 2002.....	50
Figura 15: Ajustes de a) treinamento, b) validação e c) total da rede neural com 2 camadas, 120 neurônios e função de ativação do tipo <i>tansig</i>	51
Figura 16: Ajustes de a) treinamento, b) validação e c) total da rede neural com 2 camadas, 25 neurônios e função de ativação do tipo <i>logsig</i>	51
Figura 17: Arranjo para Rede Neural Artificial com uma camada oculta. Fonte: Adaptado de Mathworks, 2002.	52
Figura 18: Ajustes de a) treinamento, b) validação e c) total da rede neural com 1 camada, 90 neurônios e função de ativação do tipo <i>tansig</i>	53
Figura 19: Ajustes de a) treinamento, b) validação e c) total da rede neural com 1 camada, 90 neurônios e função de ativação do tipo <i>logsig</i>	54
Figura 20: Gráfico do erro quadrado médio da rede neural com 2 camadas, 25 neurônios e função de ativação do tipo <i>logsig</i>	55
Figura 21: Gráfico dos dados experimentais e resposta da rede neural com 2 camadas, 25 neurônios e função de ativação do tipo <i>logsig</i>	55
Figura 22: Representação gráfica da função de ativação linear binária. Fonte: Próprio autor.	56
Figura 23: Resultados dos ajustes das funções de pertinência triangular de entrada do sistema <i>fuzzy</i> realizado pelo ANFIS.	57
Figura 24: Resultados dos ajustes das funções de pertinência trapezoidal de entrada do sistema <i>fuzzy</i> realizado pelo ANFIS.	57
Figura 25: Resultados dos ajustes das funções de pertinência gaussiana de entrada do sistema <i>fuzzy</i> realizado pelo ANFIS.	58

Lista de Tabelas

Tabela 1: Principais parâmetros operacionais, limites e porcentagem de ocorrência. ...	47
Tabela 2: Resultados das arquiteturas de redes neurais encontrados com 2 camadas ocultas.....	50
Tabela 3: Resultados das arquiteturas de redes neurais encontrados com 1 camada oculta.	53
Tabela 4: Resultados das arquiteturas sistema neuro- <i>fuzzy</i> para 27 dados.....	58

Lista de Abreviaturas

ANFIS - *Adaptive Network-Based Fuzzy Inference System*

CEM - Célula de Energia Microbiana

DQO - Demanda Química de Oxigênio

FIS - Sistema de Inferência *Fuzzy*

MLP - *Multilayer Perceptrons*

MO – Micro-organismo

PGA - *Penicillin G acylase*

RAFA - Reator Anaeróbico de Fluxo Ascendente

RNA - Rede Neural Artificial

SCMFC - *Single Chamber Microbial Fuel Cell*

SMFC - *Sediment Microbial Fuel Cell*

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVO	16
2.1	Objetivo Geral	16
2.2	Objetivos Específicos.....	16
3	REVISÃO BIBLIOGRÁFICA	17
3.1	Bioeletricidade	17
3.2	Células de Energia Microbiana	17
3.2.1	Tipos e Funcionalidades	20
3.2.2	Eletrodos.....	21
3.2.3	Resistência Elétrica Externa na geração de potência nas CEM.....	23
3.2.4	Membranas	24
3.2.5	Microbiologia das Células de Energia Microbianas.....	25
3.3	Tratamento de Efluentes.....	28
3.4	Otimização das CEM	30
3.5	Redes Neurais Artificiais	32
3.5.1	Tipos de Redes	33
3.5.2	Perceptron Multicamadas	35
3.5.3	Algoritmo de Treinamento de RNAs Backpropagation	36
3.5.4	Funções de Ativação.....	37
3.5.5	Exemplo de Aplicações de Redes Neurais Artificiais	39
3.6	Sistemas <i>Fuzzy</i>	41
3.6.1	Regras dos Sistemas <i>Fuzzy</i>	43
3.7	Sistemas de Inferência <i>Fuzzy</i> Baseado em Redes Adaptativas (ANFIS)	44
4	METODOLOGIA.....	47
4.1	Implementação das Redes Neurais Artificiais	47

4.2	Implementação do Sistema Neuro <i>Fuzzy</i> - ANFIS	48
5	RESULTADOS E DISCUSSÃO	50
5.1	Redes Neurais Artificiais	50
5.2	Sistema Neuro- <i>Fuzzy</i>	55
6	CONCLUSÃO.....	63
7	ESTUDOS FUTUROS	64
8	PUBLICAÇÕES	65
9	REFERÊNCIAS BIBLIOGRÁFICAS	66

1 INTRODUÇÃO

A geração e consumo de energia até então, principalmente não renováveis, é tratado recorrentemente pelas limitações das fontes e recursos, elevando a necessidade de obtenção por meio de outras fontes. Atualmente, muitas fontes de energias limpas já são viáveis economicamente, porém correspondem apenas 14% da matriz energética mundial (BRASIL, 2019).

A crescente geração de efluentes, tanto industriais quanto domésticos, também é objeto de preocupação, corroborado pelo crescimento populacional e pelas diversas propostas de políticas públicas relacionadas ao tema, principalmente legislações ambientais mais restritivas para destinação das águas residuárias (NATH et al., 2021). Os principais impactos estão relacionados à segurança da saúde pública e, conseqüentemente, ao meio ambiente.

Uma forma de convergir os dois pontos à uma só solução foi proposto, inicialmente observada por Potter (1911), no qual tem-se registro de geração de energia elétrica por micro-organismos durante a degradação de matéria orgânica. Desde sua descoberta, estudos relacionados foram despontando e em 1931 por Barnet Cohen, deu-se a primeira Célula a Combustível Microbiana (CEM), como ficou posteriormente conhecida. CEMs são definidas como reatores contendo micro-organismos capazes de converter energia química em energia elétrica.

A forma mais comum da CEM é composta por duas câmaras separadas por uma membrana de trocadora de prótons, uma denominada anódica e a outra catódica (RACHINSKI et al., 2010). Ao passar dos anos, foram sendo publicados outros arranjos e configurações com novas aplicações. Cita-se as células de fluxo ascendente, que foram propostas para combinar as vantagens do reator anaeróbico de fluxo ascendente (RAFA) com os requisitos de uma CEM de dupla câmara, para utilização no tratamento de águas residuárias (HE et al., 2005). Cita-se como principal aplicação das CEMs são diversas ao tratamento de efluentes, no qual o substrato dos micro-organismos é a matéria orgânica proveniente de águas residuárias para converter esta energia em eletricidade. A diferença de potencial gerada ainda não é grandiosa para abastecimento de equipamentos, mas é capaz de reduzir os custos operacionais nesses processos de tratamento, podendo ser aproveitada para auxiliar em etapas menores dos processos. Em suma, a CEM é considerada uma tecnologia autossustentável pois além de tratar efluente, gera diferença de potencial que abastece o próprio sistema (MAYEN et al., 2018).

As CEMs são tecnologias inovadoras com potencial para resolver dois dos problemas da sociedade atualmente: a crise energética e o tratamento de efluentes. A energia química do substrato é transformada em energia elétrica por micro-organismos em uma CEM e isto é possível quando, em circunstâncias específicas, alguns micro-organismos transmitem os elétrons gerados durante a sua atividade metabólica para um eletrodo (ânodo) em vez de para um receptor natural de elétrons, como por exemplo, o oxigênio. Este processo tem sido exaustivamente explorado em CEMs com cátodos abióticos, que produzem eletricidade em pequena escala (DU et al., 2007), e contribui para a quebra da matéria orgânica representada como substrato ou combustível (PANT et al., 2010).

Como as CEMs produzem menos CO_2 do que qualquer outra tecnologia atual que utiliza combustíveis fósseis para gerar energia, as poucas emissões deste gás não precisam de ser tratadas: porque funcionam eficientemente à temperatura ambiente e mesmo a temperaturas muito baixas; porque não requerem entrada de energia desde que o cátodo abiótico seja aerado passivamente ou seja um biocátodo; e porque podem ser utilizados em zonas remotas onde haja necessidade de eletricidade. A utilização da biomassa encontrada no esgoto de fontes domésticas e comerciais pode resultar na produção de energia limpa. A água residuária pode ser purificada usando o material orgânico dela mesma como combustível enquanto gera energia (HUANG et al., 2011).

Como aplicabilidade, cita-se o robô Eco Bot II, que pode executar funções como mobilidade, detecção, processamento e comunicação. Para alcançar um sistema eletricamente autônomo, este dispositivo combina uma CEM (DU et al., 2008), biossensores (KIM et al., 2003) e tratamento de águas residuárias em pequena escala (HE et al., 2017) para remover proteínas e outros tipos de compostos químicos da água.

Biorremediação *in situ*, redução de cromo, remoção de cloro de vários solventes clorados, redução de perclorato e redução de nitrato junto com compostos orgânicos e produção de hidrogênio estão entre as aplicações potenciais de CEMs de biocátodo (Huang et al., 2011). Rabaey e Verstraete (2005) revisam os dados sobre o metabolismo energético e características de bactérias que utilizam o ânodo como acceptor de elétrons. Ha et al. (2008) investigam o desempenho e o consórcio bacteriano em uma CEM alimentada com formiato, avaliando a eficiência da célula na geração de energia elétrica, destacando o papel das bactérias no processo de conversão de formiato em eletricidade. Logan et al. (2006) apresentam o design, caracterização e desempenho de CEMs.

A modelagem matemática, por sua vez, pode ser uma ferramenta útil, em suas diferentes abordagens, para simulação e otimização dos processos, avaliação de parâmetros e neste caso, na avaliação da performance das CEMs utilizando Sistemas Inteligentes, como as Redes Neurais Artificiais (RNAs) e Sistema Neuro-*Fuzzy*. As RNAs são mecanismos de modelagem empírica inspirados nos sistemas nervosos biológicos, na habilidade de processamento e aprendizagem do cérebro humano (MATHWORKS, 2002; HAYKIN, 2007). As características de habilidade em aprender, a não-linearidade e o seu poder de generalização fazem com que as RNAs possam ser aplicáveis em resolução de problemas complexos, (HAYKIN, 2007). Já os Sistema Neuro-*Fuzzy* possuem características semelhantes a RNA, mas usa lógica *fuzzy* para lidar com o reconhecimento de padrões. Quando se trabalha com um problema com conjunto de dados de entrada/saída, o Sistema Neuro-*Fuzzy* tenta criar um sistema de inferência difuso. Os sistemas de inferência difusos empregam uma associação de funções para aprender com os dados da modelagem, apresentando uma técnica de aprendizagem adaptativa (PETKOVIC et al. 2015). Até o momento, não foram identificados na literatura estudos que empreguem Redes Neurais Artificiais em Células de Combustível Microbiana, destacando a inovação e singularidade desta pesquisa.

2 OBJETIVO

2.1 Objetivo Geral

Avaliar a aplicação de Redes Neurais Artificiais (RNAs) e Sistema Neuro-*Fuzzy* no desempenho e performance das Células de Energia Microbianas (CEM).

2.2 Objetivos Específicos

- Aplicar as RNA para simular o desempenho de CEM em diferentes condições operacionais e em diferentes arquiteturas, camadas intermediárias, quantidade de neurônios, função de transferência e algoritmo de aprendizagem;
- Aplicar o Sistema Neuro-*Fuzzy* ANFIS para simular o desempenho de CEM em diferentes condições operacionais e em diferentes arquiteturas;
- Comparar os resultados da RNA com o sistema ANFIS na performance das CEM.

3 REVISÃO BIBLIOGRÁFICA

3.1 Bioeletricidade

Quando Luigi Galvani viu que as pernas das rãs se contraíam após serem expostas a uma descarga de corrente elétrica no final do século XVIII, foi quando a palavra bioeletricidade apareceu pela primeira vez (BULLEN et al., 2006; DANIEL et al., 2009). A criação de energia elétrica por culturas vivas de *Escherichia coli* e *Saccharomyces* utilizando eletrodos de platina foi demonstrada em 1911 por Potter. Esta ideia, no entanto, foi inicialmente desconsiderada e descartada como apenas uma curiosidade científica (GAJDA et al., 2018).

Existem três processos diferentes de transformar biomassa em energia elétrica, são elas: combustão direta, pirólise e gaseificação; sendo cada um desses três processos com métodos e usos diferentes. A biomassa pode ser queimada diretamente, como nas caldeiras, essa queima produz vapor que alimenta turbinas para gerar eletricidade, utilizando a energia térmica que produz. A biomassa pode ser tratada de forma semelhante à combustão direta quando se trata de pirólise, gerando gases inflamáveis quando aquecido em ambiente regulado. Esses gases podem ser convertidos em bio-óleo, cuja queima em caldeiras ou motores alternativos pode fornecer gases que podem alimentar turbinas para gerar energia. A pirólise e a gaseificação são combinadas num método mais sofisticado. Neste caso, a biomassa é pré-tratada por pirólise para criar bio-óleo. Depois disso, o bio-óleo é gaseificado para produzir gases combustíveis que podem alimentar turbinas a gás combustível ou outros motores, auxiliando na produção de energia. Esses métodos oferecem opções flexíveis para a produção de energia elétrica a partir de biomassa, atendendo a diversos requisitos e cenários de uso (VIRMOND, 2011).

Além das tecnologias para o uso da biomassa na produção de energia elétrica, outra metodologia vem sendo estudada da possibilidade de gerar eletricidade a partir do metabolismo de micro-organismos chamados bioeletrolíticos, que são capazes de converter a matéria orgânica, presente nas águas residuárias em eletricidade. Estes dispositivos são chamados de células de energia microbianas (CEM).

3.2 Células de Energia Microbiana

As primeiras observações da geração de corrente elétrica bacteriana são datadas do início do século XX (POTTER, 1911), porém, o avanço na comunidade científica se deu anos depois, após a noção de vincular o tratamento de resíduos e a geração de

eletricidade que só foi desenvolvida aproximadamente 80 anos depois por Habermann e Pommer (1991). A definição inicial dada por Potter (1911) traz que CEM é um dispositivo capaz de coletar a energia, na forma de energia elétrica, oriunda da degradação biológica de compostos orgânicos, sendo redefinida como uma tecnologia que representa uma proposta para geração de eletricidade usando o metabolismo de bactérias que são capazes de transferir elétrons para um eletrodo sólido (LOGAN, 2008).

Os primeiros estudos experimentais investigando o uso de águas residuárias domésticas e industriais como fonte de energia em células de energia microbianas (CEM) começaram no início do século XXI (SANTORO et al., 2017). Desde então, tem havido um aumento notável no interesse em sistemas bioeletroquímicos utilizados para tratamento de águas residuárias, corroborado pelo aumento notável nas publicações relativas a estes sistemas, conforme mostrado na Figura 1.




Figura 1: Desenvolvimento da pesquisa sobre o tratamento bioeletroquímico de águas residuárias no século XXI. (Palavras-chave para pesquisa: “microbial fuel cells” and “wastewater” em 12 de julho de 2024). Fonte: ScienceDirect.

Este desenvolvimento ao longo do tempo mostra como a bioeletroquímica e o tratamento de resíduos se uniram para formar uma área de estudo florescente, estimulante e extremamente relevante em muitos campos científicos.

Em uma configuração de CEM padrão, tem-se um reator separado em dois compartimentos, denominados câmara anódica e catódica, separadas por uma membrana permeável seletiva e ligadas num circuito externo elétrico. A câmara anódica é normalmente o compartimento que recebe a matéria orgânica.

Por meio de processos metabólicos, as bactérias deste compartimento oxidam materiais orgânicos, liberando elétrons e íons hidrogênio (H^+). Os íons H^+ interagem com cofatores de enzimas em sistemas microbianos, enquanto os elétrons participam de uma série de processos dentro da cadeia de transporte de elétrons. Eventualmente, esses elétrons encontram um acceptor final, que pode ser uma molécula orgânica ou inorgânica em ambientes anaeróbicos ou anóxicos, ou oxigênio em condições aeróbicas (MERCER, 2017).

Para que os elétrons sejam transmitidos do micro-organismo para o eletrodo sólido (ânodo), que está conectado a um circuito externo, preferencialmente, deve haver falta de aceitadores finais de elétrons no CEM, principalmente oxigênio (JOHN; LOPES, 2013). Apenas micro-organismos classificados como eletrogênicos podem mover elétrons para esse tipo de acceptor (LOGAN, 2009), conforme representado na Figura 2.

Os prótons gerados na reação de oxidação da matéria orgânica são transferidos através de uma membrana permeável seletiva. Estes íons H^+ seguem para a câmara catódica, onde participam de processos de redução e produzem produtos reduzidos de acordo com o receptor presente neste compartimento, podendo ser água, nos casos de oxigênio como acceptor, ou hidrogênio molecular. Os produtos gerados dependem da composição do meio da câmara catódica (LIMA, 2010).




Figura 2: Esquema representativo de uma Célula de Combustível Microbiana. **Fonte: próprio autor.**

3.2.1 Tipos e Funcionalidades

Há diversos modelos e tipos de montagens já relatados na literatura para células de energia microbiana. O modelo mais relatado é o mencionado no item anterior, com duas câmaras separadas por uma membrana permeável, conforme mostrado por Min et al., (2005) e Kao et al., (2015). Outro modelo já utilizado é o de câmara única, denominado SCMFC (*Single Chamber Microbial Fuel Cell*), que possui apenas uma câmara anódica enquanto o cátodo permanece exposto ao ar (DU et al., 2007). Traz como vantagem o menor custo de montagem e maior eficiência na transferência de massa para o cátodo, melhorando a performance energética (LIU et al., 2005).

Já foram relatados também os modelos mais avançados com suas aplicabilidades específicas. Conhecidas como células de combustível microbianas sedimentares (SMFC

- *Sediment Microbial Fuel Cell*) ou *Soil-Based* são CEMs que utilizam sedimentos, solos ou lamas para gerar energia elétrica, utilizando-os como substrato para os microorganismos. Possuem diversas aplicabilidades, como monitoramento do solo através de sensores de toxicidade de poluente específicos ou atividade microbiana no solo (GUAMBO et al., 2017); como remediadoras do solo, na remoção de contaminantes como fenol (HUANG et al., 2011), hidrocarbonetos de petróleo (ZHANG et al., 2015; LIU et al., 2019) e diesel (LU et al., 2014); ou ainda, com o objetivo de reduzir as emissões de metano provenientes do solo (ZHONG et al., 2017). A desvantagem desta metodologia é a baixa eficiência energética pelas limitações da resistência interna do solo (LI et al., 2019; JIANG et al., 2016). A utilização de uma célula de energia microbiana como fonte de energia para uma aplicação de baixo consumo de energia foi feita pela primeira vez por Tender et al. (2008). Os autores criaram uma boia meteorológica que mede a temperatura do ar, a pressão atmosférica, a umidade relativa e a temperatura da água é exatamente a aplicação que está sendo discutida, utilizando os conceitos de CEM.

Outra metodologia muito relatada é a associação de dispositivos, ou seja, pesquisadores ligam várias unidades de células em série ou em paralelo, aumentando a tensão e a corrente, de acordo com a conexão (AELTERMAN et al., 2006; CALL & LOGAN, 2011; WU et al., 2016; ESTRADA-ARRIAGA et al., 2018). Wilkinson (2000) provou ser viável alimentar dispositivos elétricos independentes combinando CEMs pela criação de um robô cuja energia se dava pela associação de três células conectadas. As rodas traseiras do vagão dianteiro eram acionadas por um pequeno motor elétrico alimentado por um conjunto de seis sistemas de CEM que carregavam uma bateria de Níquel - Cádmio (Ni-Cd).

3.2.2 Eletrodos

As CEMs dependem fortemente de seus eletrodos, que precisam atender a certas especificações para funcionar corretamente. De um modo geral, os materiais à base de carbono e metal são os que melhor satisfazem os requisitos essenciais, como boa condutividade elétrica, estabilidade química, biocompatibilidade, ampla área superficial e resistência mecânica suficiente são algumas dessas necessidades fundamentais (RAHIMNEJAD et al., 2015).

Materiais à base de metal, como placas de titânio, folhas de prata, níquel, cobre ou ouro e folhas, malhas ou esponjas de aço inoxidável, estão entre os tipos mais

populares de materiais de eletrodo usados em CEMs. Folhas de grafite, grafite granular ou carvão ativado, papelão carbonizado, varetas, papel, tecido, malha, feltro, véu ou escova de carbono e carbono vítreo reticulado são exemplos de materiais comumente usados que são à base de carbono (SANTORO et al., 2017). A seleção de materiais e tamanho do eletrodo é essencial para a eficácia e desempenho das CEMs, uma vez que impacta diretamente a transmissão de elétrons e as interações com os micro-organismos participantes do processo. Consequentemente, o objetivo da pesquisa e desenvolvimento contínuos nesta área é maximizar o design e a seleção dos eletrodos, a fim de aumentar a eficácia da célula (SANTORO et al., 2017).

A eficácia desses materiais em CEMs depende de vários aspectos, como espaçamento entre eletrodos, condutividade da solução e tipo de substrato (WANG et al., 2009). Eletrodos feitos de metal são notáveis por suas qualidades mecânicas e forte condutividade elétrica. Quando usados como ânodos em CEMs, certos metais nobres, como ouro e platina, demonstraram ter muito sucesso na geração de biofilmes, favorecendo a transferência de elétrons dos micro-organismos para o eletrodo (LI et al., 2017).

Micro-organismos exoeletrogênicos, capazes de transferir elétrons para fora da membrana plasmática diretamente para um condutor externo, podem colonizar efetivamente as superfícies da prata e do cobre, apesar de esses metais serem amplamente conhecidos por suas qualidades antimicrobianas (BAUDLER et al., 2015). A capacidade dos micro-organismos de formar biofilmes em metais como cobre e prata enfatiza a intrincada relação entre os materiais usados como eletrodos e os micro-organismos nos CEMs, ressaltando a importância de levar em consideração uma variedade de fatores ao escolher os melhores materiais para aplicações específicas das células.

A fim de melhorar ainda mais o desempenho dos CEMs, personalizando a seleção de materiais e condições operacionais para atender aos requisitos exclusivos de cada aplicação, pesquisas em andamento neste campo tentam compreender e otimizar essas interações. O carbono tem condutividade elétrica duas a três ordens de grandeza inferior à dos metais. Além disso, o grafite possui uma resistividade elétrica particular que pode ser até três ordens de grandeza superior à dos metais, o que diminui a potência que a célula produz. Porém, este apresenta propriedades notáveis que o tornam um material de eletrodo muito útil para células de energia microbianas. Excelente capacidade de adesão microbiana, alta porosidade e área superficial específica, forte estabilidade mecânica,

química e térmica, propriedades elétricas ajustáveis, baixo peso e custo razoável são algumas dessas qualidades. Eletrodos de carbono são uma opção popular para montagem de CEM devido a essas características. Além disso, as atividades bioeletroquímicas, incluindo a oxidação e redução de citocromos da membrana externa, são facilitadas por eletrodos de carbono (BAUDLER et al., 2015; LI et al., 2017). Autores como Liu et al. (2004), Marcon (2011) e Uggetti & Puigagut (2016) utilizaram várias hastes de grafite unidas como eletrodo devido à sua excelente condutividade elétrica e estabilidade química, apesar de possuir baixa porosidade e baixa área de superfície para adsorção de micro-organismos (ZHOU et al., 2011).

Algumas alternativas mais econômicas têm sido propostas: Wang et al. (2011) usaram como ânodo partículas granulares produzidas pela trituração de resíduos de pneus, com revestimento condutivo de grafite. Vários tipos de biomassa também têm sido amplamente empregados, como toranja (CHEN et al., 2012c), linho (CHEN et al., 2012a), papelão carbonizados (CHEN et al., 2012b) e bucha (YUAN et al., 2013) (WU, G. et al., 2018). Zhang et al. (2014) desenvolveram um tubo de carvão vegetal de bambu obtido por meio da carbonização natural da planta. Já Karthikeyan et al. (2015) usaram cogumelo rei, cogumelo selvagem e caule de milho para fabricação de eletrodos macroporosos e Chen et al. (2018) usaram casca de castanha.

Wu et al. (2018) utilizaram o Sargassum, um tipo de alga marinha, barata, fácil de reproduzir e coletar, juntamente com o polipirrol para modificar uma esponja de aço inoxidável.

Materiais à base de algodão também têm sido reportados e mostraram-se bastante promissores. Zeng et al. (2018) construíram um eletrodo poroso, biocompatível e altamente condutor usando material de fibra de algodão modificado com polidopamina carbonizada. Os pesquisadores conseguiram não só reduzir consideravelmente os custos de construção da CEM, mas como também alcançaram uma densidade de potência 80,5% maior do que a obtida com eletrodo de feltro de carbono comercial. As alternativas propostas além de economizar recursos, são matérias-primas recicladas, podendo assim reduzir também problemas de poluição ambiental.

3.2.3 Resistência Elétrica Externa na geração de potência nas CEM

É destacado no referencial teórico que o ápice da densidade de potência em Células de Energia Microbiana pode ser extraído quando a resistência externa da fonte de

energia elétrica é igual à resistência interna do dispositivo, quando a resistência externa é maior ou menor, a densidade resultante é diminuída (del Campo et al., 2014). Apesar do amplo reconhecimento desta teoria, a resistência interna não é medida em muitos outros estudos. Estas circunstâncias mostram que a geração de energia no CEM pode ser otimizada em níveis intermediários de resistência externa, uma vez que a potência aumenta com o aumento da resistência até um certo ponto e depois diminui à medida que a resistência aumenta ainda mais.

Zhang et al. (2011) descobriram que aumentar a resistência externa de 10 para 50 Ω melhorou a potência gerada na CEM, entretanto, aumentar a resistência externa de 50 para 1000 Ω resultou em perda de potência. Este comportamento foi explicado pelo aumento da geração de biomassa ativa na superfície do eletrodo quando a resistência externa foi ajustada para 50 Ω . Por outro lado, Wang et al. (2010) e Song et al. (2010) mostraram que a densidade de potência aumentou à medida que a resistência elétrica externa aumentou, corroborando com a complexidade desse tipo de sistema.

3.2.4 Membranas

Um material precisa atender a alguns requisitos para ser qualificado para uso como membrana em células de energia microbianas, como a capacidade de ser quimicamente inerte, adequadamente resistente e duradouro, bem como seletivamente permeável (KHAN et al., 2017; SANTORO et al., 2017).

As pesquisas inicialmente se concentraram principalmente na aplicação de membranas de troca iônica, como Nafion® (WANG, Y. et al., 2011), Ultrex® (CLAUWAERT et al., 2007), Zirfon® (ELMEKAWY et al., 2014) e Hyflon® (IEROPOULOS et al., 2010), que podem ser catiônicas, aniônicas ou bipolares.

No entanto, vários estudos começaram a procurar substitutos para as membranas devido ao alto custo destes materiais, mostrando um reflexo do esforço para encontrar materiais de membrana com preços mais razoáveis que possam, no entanto, aumentar a eficiência da célula. A variedade de materiais investigados enfatiza ainda mais a necessidade de identificar substitutos econômicos, aumentando assim as aplicações potenciais desta tecnologia. Vários materiais substitutos têm sido sugeridos, como tecidos (FAN et al., 2007), fibras de nylon (ZHANG et al., 2010), fibra de vidro (ZHANG et al., 2009), cerâmica (BEHERA et al., 2010), sacolas biodegradáveis (WINFIELD et al., 2013a), membranas de filtração microporosa (ZUO et al., 2007), lona (ZHUANG et al.,

2009), membrana infundida com nylon (HERNÁNDEZ-FERNÁNDEZ et al., 2015a), papel de fotocópia (WINFIELD et al., 2015), borracha natural (WINFIELD et al., 2013b) e até luvas de laboratório (WINFIELD et al., 2014).

A membrana Nafion® é ainda a membrana mais usada em CEMs por ter alta condutividade de prótons, baixa resistência ôhmica, estabilidade química e térmica. No entanto, seu custo contribui com cerca de 35% do custo total de uma CEM e, além disso, é suscetível ao vazamento de oxigênio do cátodo para o ânodo, perda de substrato, transporte e acúmulo de cátions diferentes dos prótons e incrustação biológica. A Nafion® 112, mais fina, apresenta menor resistência ôhmica e a Nafion® 117, mais espessa, menor permeabilidade ao oxigênio (ANGIONI et al., 2016).

3.2.5 Microbiologia das Células de Energia Microbianas

Como foi dito anteriormente, os produtos químicos orgânicos podem ser convertidos em eletricidade pelos micro-organismos que são cruciais para o funcionamento das células de energia microbianas (CEM). Mas em muitos dos micro-organismos, a camada mais externa é composta de lipopolissacarídeos, peptidoglicanos, membrana lipídica não condutora, que atuam como barreiras para impedir que os elétrons vão direto da fonte para o ânodo (DU et al., 2007).

Os pesquisadores de células de energia microbianas usaram inicialmente organismos que não conseguem transmitir com eficiência os elétrons produzidos durante o metabolismo central para o ambiente extracelular. Acredita-se que os processos de oxidação abiótica eram o meio pelo qual os elétrons eram transferidos para o ânodo (SHUKLA et al., 2004; RABAEY & VERSTRAETE, 2005). Posteriormente, estudos comprovaram que a fermentação não era eficiente quando se trata de conversão de produtos químicos orgânicos em energia. Isso aconteceu porque a maioria dos elétrons encontrados na matéria orgânica ficaram retidos nos produtos da fermentação (LOVLEY, 2006).

A fim de aumentar a densidade e a potência da corrente, os pesquisadores começaram a adicionar mediadores artificiais às CEMs na década de 1980. Esses mediadores incluíam corantes e compostos metal-orgânicos. No entanto, a necessidade de adicioná-los regularmente, aliada à sua toxicidade e instabilidade, apresentou sérios obstáculos a esta estratégia, tornando-a impraticável e incompatível com a abordagem sustentável pretendida para as CEMs (DU et al., 2007; LEHNEN, 2014).

Kim et al. (1999) mostraram que bactérias anaeróbicas podem ser usadas em células de energia microbiana para reduzir sais metálicos como Fe (III) e Mn (IV), uma vez que poderiam fazer contato direto com o eletrodo sem a necessidade de um mediador, isto porque tem capacidade de transmitir elétrons do interior de suas células para materiais insolúveis encontrados fora delas. Esses elétrons são produzidos quando a matéria orgânica se oxida (ROZENDAL et al., 2008). Foram descobertas essas funcionalidades que poderiam transportar elétrons direto para o eletrodo, o que foi um grande avanço no campo da pesquisa de células de energia microbianas.

Essas bactérias altamente capazes de transferir elétrons para o meio extracelular foram classificadas como exoeletrogênicas (XU & LIU, 2011), tendo alguns exemplos já identificados como *Rhodospseudomonas* (XING et al., 2008), *Ochrobactrum* (ZUO et al., 2008), *Acidiphilium* (MALKI et al., 2008), *Rhodoferax* (CHAUDHURI & LOVLEY, 2003), *Shewanella* (KIM et al., 2002), *Pseudomonas* (RABAEY et al., 2005), *Klebsiella* (ZHANG et al., 2008), *Enterobacter* (REZAEI et al., 2009), *Aeromonas* (PHAM et al., 2003), *Geobacter* (BOND & LOVLEY, 2003), *Geopsychrobacter* (HOLMES et al., 2004b), *Desulfuromonas* (BOND et al., 2002), *Desulfobulbus* (HOLMES et al., 2004a), *Arcobacter* (FEDOROVICH et al., 2009), *Clostridium* (PARK et al., 2001), *Thermincola* (WRIGHTON et al., 2008), *Geothrix* (BOND & LOVLEY, 2005), *Propionibacterium* (WANG et al., 2008). Algumas espécies como *Shewanella putrefaciens* (KIM et al., 2002), *Shewanella oneidensis* (GORBY et al., 2006), *Geobacteraceae sulfurreducens* (BOND & LOVLEY 2003), *Geobacteraceae metallireducens* (BOND et al., 2002), *Rhodoferax ferrireducens* (CHAUDHURI & LOVLEY, 2003), *Pseudomonas aeruginosa* (RABAEY et al., 2004), *Aeromonas hydrophila* (PHAM et al., 2003) e *Clostridium butyricum* (PARK et al., 2001) já foram abundantemente reportadas em células de energia microbiana.

A transferência dos elétrons (Figura 3) resultantes das reações de oxidação para o ânodo pode se dar através de quatro processos diferentes: transferência direta, através de *pilli* ou nanofios, mediadores redox adicionados ao meio ou mediadores excretados pela célula.




Figura 3: Mecanismos de transferência de elétrons do micro-organismo para o eletrodo em CEM. a. transferência direta via proteínas de membrana ou periplasmáticas. b. transferência por meio de nanofios; c. transferência por meio de mediador redox, adicionado ao meio ou produzido como metabólito intermediário. **Fonte: próprio autor.**

Na transferência direta, o micro-organismo utiliza proteínas de membrana ou periplasmáticas, como o complexo de proteínas do citocromo C, para transferir elétrons diretamente para o eletrodo, estando a membrana plasmática em contato direto com o anodo, como as *Geobacter spp.*, *Shewanella spp.* e *Rhodoferrax ferrireducens* (RISSO et al., 2009). Outros seres são capazes de sintetizar nanofios, isto é, *pilli* condutores de eletricidade produzidos por bactérias aderidas à superfície do eletrodo. Outra forma é a utilização de mediadores redox adicionados à mistura com a finalidade de conduzir os elétrons até o anodo, ou através de intermediários metabólicos liberados pelos micro-organismos do consórcio, que funcionam como mediadores (ISHII et al., 2005, LOGAN, 2009, HE et al., 2017).

Geobacter spp., *Shewanella spp.* também podem produzir nanofios condutores de eletricidade e, diferentemente das *Geobacter spp.*, as *Shewanella spp.* também são capazes de autoproduzir compostos mediadores como flavinas, que realizam transferência de elétrons de modo indireto, bem como as *Pseudomonas aeruginosa* que excretam pigmentos semelhantes a fenazina para transportar elétrons (GORBY et al., 2006. MARSILI et al., 2008; LUO et al., 2013).

Organismos exoeletrogênicos podem ser encontrados em uma ampla variedade de ambientes, como sedimentos de água doce, solos, lodos ativados, águas residuárias e sedimentos marinhos. (LOGAN & REGAN, 2006; DU et al., 2007; WATANABE, 2008).

São característicos por formar um biofilme na superfície do ânodo e demonstrar atividade bioeletroquímica. Os biofilmes são sistemas biológicos altamente organizados, compostos por organismos individuais da mesma espécie ou de espécies distintas que se aderem uns aos outros e se acumulam em uma superfície. Através desta técnica, eles criaram uma matriz extracelular de polissacarídeos que se liga permanentemente a uma superfície, seja biótica ou abiótica, e a mantém unida em uma interface. Comunidades coordenadas, estruturadas e funcionalmente engajadas são criadas como resultado dessa interação (DAVEY & O'TOOLE, 2000).

Embora sejam capazes de completar a oxidação de compostos orgânicos em dióxido de carbono, as bactérias redutoras de íons metálicos são mais frequentemente encontradas em consórcios que também contêm micro-organismos fermentadores e redutores de óxidos metálicos. Fatores termodinâmicos são a causa desta ligação (RACHINSKI et al., 2010). Assim, pensa-se que para transformar eficientemente a matéria orgânica em eletricidade, devem ser formados consórcios e outras vias cooperativas (LOVLEY, 2006). Por afetar diretamente a eficiência da conversão de matéria orgânica em energia, esta interação entre vários grupos de micro-organismos é um fator importante no estudo e desenvolvimento de CEMs. Assim, otimizar o desempenho destas tecnologias requer uma compreensão da dinâmica dos consórcios microbianos, bem como a promoção de abordagens cooperativas. Portanto, consórcios microbianos mistos oferecem benefícios significativos em relação às culturas bacterianas puras para a operação de células de combustível microbianas (CEMs). São uma opção mais prática, pois estimulam a variedade microbiológica no uso dos substratos e dispensam procedimentos de esterilização. Além disso, devido ao seu alto custo, as culturas puras não são viáveis para uso (NEVIN et al., 2008; JIANG et al., 2010; LIN et al., 2013; YU et al., 2014).

Esses fatores enfatizam o quão crucial é compreender a dinâmica das interações entre os micro-organismos e a superfície do eletrodo nas células, a fim de maximizar sua eficácia e desempenho em diversos ambientes e aplicações.

3.3 Tratamento de Efluentes

A exploração dos recursos naturais está indissociavelmente ligada ao desenvolvimento econômico das sociedades, e este processo leva a um aumento inevitável na geração de resíduos e efluentes. O tratamento eficaz desses efluentes antes

de sua reintrodução no meio ambiente é necessário para reduzir os efeitos ambientais causados pelo crescimento populacional e industrial (MANZANO-AGUGLIARO et al., 2013).

Atualmente, existem diversos métodos de tratamento de resíduos (MARQUES, 2014), com foco no tratamento de efluentes líquidos: tratamentos biológicos ou físico-químicos (PARANYCHIANAKIS e ANGELAKIS, 2006). Os tratamentos biológicos são aqueles desenvolvidos e realizados por biotecnologia, se enquadram nas categorias de processos aeróbios e anaeróbios e são cruciais para o tratamento de efluentes líquidos, principalmente aqueles que contêm poluentes biodegradáveis (VON SPERLING, 2014).

Cada processo possui suas vantagens e desvantagens. Na ausência de oxigênio, ocorrem reações anaeróbicas, oxidando a matéria orgânica e produzindo CO_2 , metano e outras moléculas orgânicas restritas. Este método é vantajoso porque requer menos espaço para instalação e mecanização, produz menos lodo e tem despesas mínimas de implementação e manutenção. Porém, comparado aos tratamentos aeróbios, sua eficácia na eliminação de matéria orgânica é menor, sendo a produção de odores uma preocupação típica (LIMA, 2010, FARRUGIA, 2012). A mineralização da matéria orgânica em processos aeróbicos é possibilitada pela presença de oxigênio, sendo que este será o aceptor final de elétrons nas reações de oxidação, produzindo CO_2 e água. No entanto, a instalação de reatores aeróbios exige um gasto financeiro significativo, além de maiores necessidades energéticas para aeração dos reatores e alta produção de lodo que precisa de tratamento posterior, o que torna as estações de tratamento mais complexas (FRANCO, 2014).

Conseqüentemente, há uma busca constante por tecnologias de tratamento de efluentes que possam reduzir custos de produção, aumentar a eficiência de remoção de contaminantes e melhorar a relação custo-benefício (MANSOOR et al., 2013). Nesse quadro, surgiram estudos focados na criação de células de energia microbiana, oferecendo a possibilidade de potencializar tratamentos anaeróbios sem exigir o gasto energético significativo vinculado aos tratamentos aeróbios (ZHOU et al., 2013). Essas células também possuem o benefício adicional de produzir bioeletricidade (MARQUES, 2014, LI et al., 2016).

Esses sistemas bioeletroquímicos podem ser usados para remover e/ou recuperar produtos químicos metálicos ou metalóides (LI et al., 2016), bem como diminuir a quantidade de matéria orgânica em vários tipos de efluentes (RACHINSK et al., 2010).

Pesquisas como Mayen et al. (2018) mostraram quão bem as células de energia microbiana funcionavam no tratamento de águas residuárias, destacando a eficiência na redução de DQO e como a bioeletricidade foi produzida. Outros estudos, como o realizado por Elakkiya e Matheswaran (2013), concentraram-se no emprego de células eletroquímicas de membrana de duas câmaras para produzir energia a partir de resíduos do setor lácteo. Os resultados mostraram alta densidade de potência e eficiência de eliminação de DQO. Além disso, pesquisas como a feita por Zhou et al. (2018) examinaram o uso de células eletroquímicas para eliminação de matéria orgânica, com resultados promissores.

Estudos adicionais, como os conduzidos por Zhang et al. (2015) e Zhang et al. (2018), examinaram a remoção de matéria orgânica, nitrificação, desnitrificação e fósforo, demonstrando a eficiência das células de energia microbiana no alcance de uma variedade de objetivos de tratamento de águas residuárias.

Estes estudos sublinham a importância das células de energia microbiana como um método potencialmente eficaz de tratamento de águas residuárias que combina a remoção eficaz de emissões com a geração de energia. Também abordam as preocupações ambientais e financeiras associadas ao tratamento de resíduos industriais e urbanos.

Uma aplicação de tratamento foi realizada pela Rodrigues (2021), que estudou CEM visando a remoção de sulfato e concomitante geração de potencial elétrico e remoção de DQO. Demonstrou a versatilidade dos sistemas bioeletroquímicos, em especial das células de energia microbianas no tratamento de efluentes complexos concomitante à geração direta de eletricidade.

3.4 Otimização das CEM

As CEM ganharam muita atenção e reconhecimento recentemente, mas é importante lembrar que esta tecnologia ainda está em desenvolvimento e envolve sistemas intrincados que combinam processos químicos, biológicos e físicos (OLIVEIRA et al., 2013). Por isso, é fundamental realizar pesquisas e estudos contínuos para aprender e se manter atualizado sobre o assunto e suas aplicações. A otimização destes sistemas permitirá a exploração completa de todo o potencial da CEM (TRAPERRO et al., 2017; RACHINSKI, 2010).

A criação de um modelo matemático busca representar de alguma forma um determinado fenômeno ou circunstância real, é o primeiro passo no processo de

modelagem matemática (BIEMBENGUT & HEIN, 2003). Corroborando com o dito, a modelagem computacional apresenta-se como um dos pilares essenciais do avanço científico moderno (VEIT & ARAÚJO, 2010). Como dito pelos autores a realização de pesquisas em áreas como biologia, química e física seria quase impossível sem o uso de computadores e, mais especialmente, de modelagem computacional. Esses escritores afirmam que a frase "modelagem computacional" é normalmente usada para se referir à aplicação da computação ao desenvolvimento de simulações computacionais que abordam questões desafiadoras originadas em vários campos de estudo.

Um modelo é uma idealização da realidade, representando suas características essenciais. Com o avanço das técnicas de inteligência artificial, desenvolvimento de novas estratégias, destacando-se as Redes Neurais Artificiais (RNAs), que foram inspiradas em sistemas nervosos biológicos e são compostas por uma ou múltiplas camadas de neurônios. Uma camada inclui a combinação de pesos (na forma de uma matriz que multiplica a força das entradas), e o somatório ponderado das entradas com um vetor de ajuste (bias) - similar a um peso, porém possui um valor de entrada constante igual a 1 - forma o argumento para a função de transferência (em geral do tipo sigmoideal ou linear). A ideia principal das redes neurais é que estes parâmetros (pesos e bias) podem ser ajustados (ou treinados) de forma que uma determinada entrada leve a uma saída específica (AKISUE, 2022; HAYKIN, 2007)

A modelagem é uma ferramenta útil em suas diferentes abordagens, para simulação e otimização dos processos, avaliação de parâmetros e neste caso, na avaliação da performance das CEMs. Dentre as diversas metodologias utilizáveis, cita-se Cardozo et al (2023), que empregou a lógica *fuzzy* aliada à técnica de planejamento experimental para avaliar estatisticamente como os parâmetros de operação das CEM impactam sua performance, concluindo-se que as variáveis de entrada área do anodo, resistência elétrica externa e volume do dispositivo foram estatisticamente mais significativas para as saídas estudadas.

O interesse no campo da inteligência artificial aumentou significativamente nas últimas décadas. As redes neurais artificiais (RNAs) estão sendo utilizadas em uma ampla gama de campos e desafios, desde controle até modelagem e previsão, devido à sua capacidade de aprendizagem e à sua capacidade de mapear problemas complicados e não lineares (NAGY, 2007).

3.5 Redes Neurais Artificiais

Inspirada em sistemas neurológicos, uma rede neural artificial (RNA) é um modelo computacional não linear. Uma RNA é composta por um conjunto de neurônios conectados, que imita as funções de aprendizagem, associação e generalização humanas (CROSS et al., 1995). Uma rede neural é um processador que foi criado simplificando a forma como os neurônios funcionam. Também tem a capacidade de aprender e, assim, generalizar, ou seja, da capacidade da RNA de estimar saídas coerentes para dados de entrada que não foram apresentados durante a fase de aprendizagem (HYAYKIN, 1998). Isso justifica o status das RNAs como aproximadores universais, permitindo-lhes lidar com questões desafiadoras em uma variedade de domínios de aplicação, incluindo processamento de sinais, aproximação de funções, previsão de séries temporais, otimização, classificação e reconhecimento de padrões (FLECK, 2016).

O modelo mais básico de RNA foi proposto por McCulloch e Pitts (1943) e utiliza apenas um neurônio, conhecido como *Perceptron*. O sinal de entrada x neste modelo é acoplado aos seus pesos sinápticos correspondentes w . Depois que as entradas são somadas e ponderadas pelas sinapses entre os neurônios, o combinador linear produz, como descrita na Equação 1:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (1)$$

o *bias* ou viés b_k de um neurônio é um parâmetro extra que ele usa para expandir o número de graus de liberdade da função que executa. Junto com a soma ponderada das entradas do neurônio, ela é utilizada para modificar a saída. Dito de outra forma, a polarização é uma constante que permite um ajuste mais preciso da saída em relação ao valor pretendido para a entrada fornecida (HAYKIN, 2001).

A função $\varphi(\cdot)$ do neurônio é responsável por limitar a amplitude da saída, causando não linearidade no processamento que o neurônio faz. Depois de aplicar a função de ativação genérica, a solução de saída de um neurônio é geralmente representada pela Equação 2:

$$y_k = \varphi(v_k) \quad (2)$$

Todas as variáveis, independentes de valores passados, são normalmente submetidas a uma função algébrica, a fim de preservar a simplicidade nas unidades de processamento de uma RNA, ou neurônio. Esta função normalmente mostra uma não linearidade conectada ao efeito de saturação (HAYKIN, 2001).

As RNAs são capazes de desenvolver correlações mais complexas do que aquelas que são meramente lineares entre variáveis dependentes e independentes devido ao mapeamento não linear entre entradas e saídas nos neurônios. Isto se torna particularmente importante nas camadas ocultas das RNAs. As funções de ativação nas camadas de saída podem ter usos especializados, dependendo dos requisitos do problema específico que a rede neural está tentando resolver (HAYKIN, 1998).

A necessidade de que as funções de ativação sejam diferenciáveis é uma de suas propriedades essenciais. Isto é necessário para apoiar o uso de estratégias de otimização de propagação, que calculam perdas ou erros em relação aos pesos da rede e depois otimizam esses pesos usando técnicas como gradiente descendente ou outras estratégias de otimização para reduzir erros (SHARMA e GHANGREKAR, 2017).

Redes Neurais Artificiais (RNAs) possuem diversas aplicações em engenharia, incluindo compressão de dados, reconhecimento de padrões e predição (GERSHENSON, 2003). Um extenso conjunto de treinamento é necessário devido ao enorme número de pesos que precisam ser estimados, mas as RNAs não exigem conhecimento profundo da fonte de dados para especificação do modelo (HAYKIN, 1998). Os modelos de redes neurais são incrivelmente eficazes e úteis, principalmente quando as características dos processos são difíceis de explicar com equações físicas tradicionais (SANTOS, 2001).

3.5.1 Tipos de Redes

Conforme dito anteriormente, o *Perceptron* é uma das redes neurais mais conhecidas, é considerado um excelente modelo inicial devido à sua arquitetura simples, podendo ser representado pela Figura 4.




Figura 4: Representação esquemática de uma Rede Neural *Perceptron*. **Fonte: Próprio autor.**

Em 1960, Widrow e Hoff propuseram a rede neural Adaline, também conhecida como *Adaptive Linear Neuron* em inglês. Sua estrutura é idêntica à do *Perceptron*; as únicas diferenças estão nas saídas bipolares que produz e na técnica de treinamento conhecida como Regra Delta, ou seja, a arquitetura é de uma rede de uma única camada disposta linearmente com um neurônio, porém, possui retroalimentação na sua saída (WIDROW, 1962), conforme mostrado na Figura 5.




Figura 5: Representação esquemática de uma Rede Neural Adaline. **Fonte: Próprio autor.**

O modelo mais utilizado na literatura é o *Multilayer Perceptrons* (MLP), nas quais podem ser utilizadas várias camadas ocultas com a quantidade de neurônios também variáveis. Esta foi a metodologia aplicada neste trabalho devido à versatilidade deste tipo de rede e a possibilidade de comparação variando a quantidade de camadas e neurônios, e será mais bem discutida no item seguinte.

3.5.2 Perceptron Multicamadas

Uma RNA é composta por vários neurônios dispostos em camadas interconectadas para lidar com desafios mais complicados. RNAs *multilayer perceptrons* têm se mostrado eficazes na resolução de uma variedade de problemas com altos graus de não linearidade. A estrutura das RNAs multicamadas é definida pela presença de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, como ilustrada pela Figura 6. Nesta configuração, as unidades nas camadas vizinhas estão diretamente conectadas entre si, mas não diretamente às unidades dentro da mesma camada.




Figura 6: Representação esquemática de uma Rede Neural MLP, com duas camadas ocultas com cinco neurônios em cada camada. **Fonte: Próprio autor.**

Cada camada pode ter um número diferente de neurônios, como ilustrado pela Figura 6 (HAYKIN, 1998). Como exemplo, tem-se uma RNA de três camadas ocultas, a primeira camada recebe o vetor de entrada $x = [x_1, \dots, x_M]^T$, a camada intermediária tem L neurônios, podemos escrever a saída de uma unidade (um neurônio) da camada de saída como descrita pela Equação 3:

$$y_k(x, w, b) = \varphi^2 \left(\sum_{l=1}^L w_{kl}^{(2)} \varphi^{(1)} \left(\sum_{i=1}^M w_{li} x_i + b_j^{(1)} \right) + b_k^{(2)} \right) \quad (3)$$

O objetivo da rede neural é minimizar a diferença entre a saída produzida para o conjunto de entrada x e a saída da rede. Isso deve ser feito para um conjunto de amostras de entrada-saída $\{x_n, y_n\}, n = 1 \dots N$. Para isso devemos treinar a rede, atualizando os

pesos w e os vieses b para que o erro seja mínimo, segundo o critério desejado. Este treinamento é do tipo supervisionado, pois conhecem-se as saídas que devem ser produzidas de acordo com os parâmetros de entrada. Um algoritmo muito popular para isso é o *backpropagation* com otimização do erro usando descida do gradiente estocástico ou variações deste (KINGMA, 2014; AMARI, 1993).

3.5.3 Algoritmo de Treinamento de RNAs *Backpropagation*

Inicialmente, uma entrada é apresentada à rede neural. O erro entre a saída produzida e a saída desejada é calculado. Com base nesses erros, os pesos são ajustados na direção oposta, atualizando-os da camada de saída para a camada de entrada. É assim que funciona o algoritmo *Backpropagation*. Baseia-se em uma regra de aprendizagem que realiza correções de erros durante o treinamento (HECHT-NIELSEN, 1992).

A retropropagação do erro pode ser dividida em duas fases principais: *feedforward*, que é a fase funcional de propagação do sinal, e retropropagação, que é a fase de retropropagação do erro. Um vetor x_n é injetado nas unidades de entrada durante a fase de propagação e, como resultado, seu impacto se espalha camada por camada por toda a rede, produzindo um conjunto de saídas \hat{y}_n como resposta da rede. Os pesos da conexão não variam ao longo deste estágio. Uma função de perda que contrasta a saída gerada \hat{y}_n com a saída pretendida y_n é então usada para determinar o erro. Uma regra de correção de erros é usada para modificar os pesos durante a fase de retropropagação do erro (HECHT-NIELSEN, 1992).

Em aplicações de algoritmo de retropropagação do mundo real, todas as amostras do conjunto de treinamento são apresentadas repetidamente à rede neural artificial (RNA) para facilitar o aprendizado. Durante o processo de aprendizagem, cada repetição onde todo o conjunto de treinamento é apresentado é chamada de “época”. Época após época, o processo de aprendizagem é repetido até que o erro quadrático médio do conjunto de treinamento convirja para um valor baixo e a combinação de pesos e limites se aproxime da estabilidade. Apresentar as amostras em ordem aleatória entre épocas é uma boa prática, pois oferece à busca no espaço de pesos uma qualidade estocástica ao longo dos ciclos de treinamento.

Um dos hiperparâmetros que precisa ser especificado no modelo é o tamanho do lote, que controla quantas amostras de treinamento são usadas em uma época. A natureza da busca no espaço de conexão é influenciada pela seleção do tamanho do lote. A pesquisa

torna-se estocástica com um tamanho de lote limitado, o que reduz a probabilidade de o algoritmo ficar preso em mínimos locais. Porém, uma estimativa mais precisa do gradiente pode ser obtida escolhendo o tamanho máximo do lote (HAYKIN, 1998).

3.5.4 Funções de Ativação

A não-linearidade em sua saída pode ser incorporada pelo modelo de cada unidade na rede e deve ser considerada. A função de ativação exerce um papel importante na definição do próximo estado de ativação da unidade, já que representa o efeito da entrada interna e do estado atual de ativação. De acordo com Haykin (2001), há vários tipos de funções de ativação, entre as mais conhecidas são: função linear, função sigmoideal, função tangente, entre outras.

A função linear geralmente restringe a saída do RNA a valores binários [0,1]. A saída do neurônio assume valor 0 quando seu resultado é negativo e 1 no caso oposto, representado pela Equação 4:

$$f(u) = \begin{cases} 1, & u \geq 0 \\ 0, & u < 0 \end{cases} \quad (4)$$

A representação gráfica da função linear binária pode ser observada na Figura 7.




Figura 7: Representação gráfica da função de ativação linear binária. **Fonte: Próprio autor.**

Uma variação desta função de ativação é a função linear por partes, na qual assume-se que o fator de amplificação dentro da região linear de operação é a unidade. Esta função pode ser vista como um combinador linear se a região linear de operação for mantida sem saturação, ou reduzida à função limiar se o fator de amplificação da região linear for infinitamente grande (HAYKIN, 2001), conforme Equação 5:

$$f(u) = \begin{cases} 1, & u \geq +1/2 \\ u, & -1/2 > u > -1/2 \\ 0, & u \leq -1/2 \end{cases} \quad (5)$$

A representação gráfica da função linear por partes pode ser observada na Figura 8.




Figura 8: Representação gráfica da função de ativação linear por partes. **Fonte: Próprio autor.**

Um outro tipo de função de ativação é a função sigmoidal. Esta é a função mais comum, caracterizada por um comportamento crescente com um equilíbrio apropriado entre o linear e o não linear, assumindo valores no intervalo de 0 a 1 (HAYKIN, 2001). Um exemplo é a função logística, representada pela Figura 9 e definida pela Equação 6:

$$f(u) = \frac{1}{1 + \exp(-au)} \quad (6)$$

onde a é o parâmetro de inclinação da função sigmóide, determinando a inclinação da curva.




Figura 9: Representação gráfica da função de ativação sigmoidal. **Fonte: Próprio autor.**

Outra função muito utilizada é a função tangente hiperbólica, que substitui a função logística em muitos casos, pois preserva a forma sigmoidal, mas assume valores tanto positivos quanto negativos (HAYKIN, 2001). A função tangente hiperbólica é dada pela Equação 7:

$$f(u) = \tanh \tanh (u) \quad (7)$$

Permitir que uma função de ativação sigmoidal assumira valores negativos, como descrito pela Equação 7 e representado na Figura 10, pode trazer benefícios analíticos em alguns casos (HAYKIN, 2001).




Figura 10: Representação gráfica da função de ativação tangente hiperbólica. **Fonte: Próprio autor.**

3.5.5 Exemplo de Aplicações de Redes Neurais Artificiais

Ferreira (2003) realizou uma abordagem estatística e computacional na otimização de meios de cultura para produção de antibióticos: o caso da cefalosporina C. A autor verificou os efeitos das variáveis concentração de glicose, acetato de amônio, DL-metionina, fósforo, ácido oléico e solução de sais na velocidade específica máxima de crescimento (μ_{\max}), assim como sacarose e DL-metionina na velocidade específica de produção do antibiótico cefalosporina C (μ_p), pelo fungo *Cephalosporium acremonium* ATCC 48272, usando como ferramenta estatística a técnica de planejamento experimental e análise por superfície de resposta. Desenvolveu-se também um modelo

baseado na técnica de redes neurais para a simulação de todo o domínio das concentrações de glicose, acetato de amônio, DL-metionina, fósforo, ácido oléico e solução de sais na velocidade específica máxima de crescimento. O melhor resultado foi obtido com uma rede neural do tipo *feedforward* com três camadas e 22 neurônios na camada oculta, treinada com algoritmo *backpropagation*.

Nucci et al. (2007) compararam duas arquiteturas de redes neurais para inferência on-line da massa celular de *B. megaterium* em um biorreator de tanque agitado aerado. Os resultados indicaram que um sistema de inferência neuro-*fuzzy* apresentou melhor desempenho para inferir concentrações celulares, quando comparado a redes *perceptrons* multicamadas.

Mantovanelli et al. (2007) avaliaram um procedimento para o desenvolvimento de um modelo matemático robusto para um processo industrial de fermentação alcoólica. Utilizaram um modelo neural híbrido para descrever a cinética e demonstraram ter uma boa capacidade de aproximação não linear, embora a estimativa dos seus pesos seja linear. Consideraram o efeito da temperatura na cinética permitindo acompanhar o comportamento do sistema quando ocorrem mudanças nas condições operacionais, obtendo resultados satisfatórios.

Tendo em vista a natureza complexa do processo de produção de enzimas microbianas em biorreatores, que engloba atributos como resistência ao transporte de massa e redes metabólicas, Silva et al. (2008) abordaram o uso de redes neurais para inferir o estado do biorreator. Esta ideia é uma forma convincente de abordar a dinâmica não linear da síntese proteica e do aumento da biomassa. O tempo de execução e a quantidade de dióxido de carbono no fluxo de exaustão foram os parâmetros de entrada utilizados na investigação do estudo de uma MLP. A capacidade do algoritmo de inferir com segurança valores de concentração de células e produtos até o final da fase de crescimento exponencial foi demonstrada pelos resultados obtidos, o que é uma informação importante para a tomada de decisões em operações industriais.

Ahmad et al. (2016) compararam a eficácia das RNA e do Sistema de Inferência Neuro-*Fuzzy* Adaptativo (ANFIS) quanto à sua utilidade na estimativa da produção de biossurfactantes, redução da tensão superficial e emulsificação sob diferentes parâmetros ambientais e médios. Concluíram, dentre outras coisas, que a RNA proposta obteve valores de R^2 entre 0,95 e 0,99 para o conjunto de treinamento e de 0,89 a 0,98 para o conjunto de teste.

3.6 Sistemas *Fuzzy*

As primeiras formações de sistemas *fuzzy* foram descritas por um professor da Universidade de Berkley, Lotfali Askar Zadeh em 1965. Zadeh observou que tanto no plano físico (mundo real), quanto no plano matemático, existiam conjuntos que não possuíam um critério de pertinência claramente definidos. Conjuntos como “temperatura alta” ou “pressão baixa”, definidos até então pela lógica clássica – em que um elemento pode pertencer ou não a um determinado conjunto – eram extremamente imprecisos e ainda tinham um papel fundamental nas comunicações, abstrações e reconhecimento de padrões. Assim, ele estabeleceu que um conjunto nebuloso seria uma classe com diversos graus de pertinência.

A lógica *fuzzy*, às vezes chamada de lógica difusa, é uma abordagem de resolução de problemas que se aproxima mais da intuição humana ao incluir frases linguísticas além de valores numéricos (MATHWORKS, 2016), utilizando uma técnica onde valores extremos significam limites, permitindo que a variável assuma valores dentro do intervalo $[0, 1]$. Isso contrasta com a teoria clássica dos conjuntos, onde a participação ou ausência de um elemento em um conjunto implica que uma afirmação é verdadeira (valor 1) ou falsa (valor 0) (HASHMI & KHAN, 2015; NELLES, 2001; GOMIDE & GUDWIN, 1994). A lógica *fuzzy* leva em consideração a experiência, a intuição, a experiência do operador de processo e a imprecisão das observações humanas, este método fornece uma maneira de converter declarações verbais em valores numéricos, no que se denomina variáveis linguísticas (HASHMI & KHAN, 2015; SIMÕES & SHAW, 2007).

Como discutem Nelles (2001) e Simões e Shaw (2007), variáveis linguísticas e valores linguísticos são cruciais para a lógica *fuzzy*, os quais esses valores linguísticos são utilizados para nomear entradas e saídas, substituindo números reais por descrições verbais para indicar certas circunstâncias e resultados. As funções de pertinência definem matematicamente esses valores, também chamados de “valores *fuzzy*”.

Segundo Zadeh (1973), variáveis linguísticas são definidas como valores que são transmitidos por meio de frases em linguagem informal e natural, atribuindo termos linguísticos como “alta”, “baixa” ou “muito baixa” nos sistemas numéricos. Em sistemas *fuzzy*, o universo de entrada é representado por U e todas as entradas potenciais $u(x)$ que podem ocorrer fazem parte do conjunto de entradas $U = u(x)$. Dentro do universo

discursivo U , uma entrada é representada como uma variável linguística $u(x)$ (ZADEH, 1973).

Cada variável linguística dentro de um sistema *fuzzy* é caracterizada por uma função de pertinência μ_A , que assume valores no intervalo $[0,1]$, onde 0 denota exclusão total e 1 indica pertinência completa, caracteriza um conjunto difuso em um universo discursivo. (GOMIDE & GUDWIN, 1994). O conjunto *fuzzy* é representado por um conjunto de pares ordenados $\{(\mu_A(x), x)\}$, em que x é compatível com o conjunto A . Determinado elemento x pode pertencer à conjuntos difusos diferentes, com valores definidos para grau de pertinência (TANSCHHEIT, 2007).

As funções de pertinência se assemelham as funções de probabilidade, que descrevem a probabilidade relativa de uma variável de tomar certo valor. Porém, há diferenças conceituais expressivas, principalmente nas regras de combinação das funções de pertinência. As funções de pertinência podem assumir diversas formas: quadradas, retangulares e trapezoidais (estas podem levar a perda de informações em regiões onde sua inclinação é igual a 0), triangulares, da forma-Z ou da forma-S (que são formas mais suaves e reduzem a perda de informações), entre outras (NELLES, 2001).

Cada entrada é analisada com sistema *fuzzy* diferente, obtendo gráficos de variáveis linguísticas e funções de pertinência específicos.

Como exemplo, tem-se uma entrada hipotética tamanho, no qual pode assumir variáveis linguísticas “PEQUENO”, “MÉDIO” e “GRANDE”. Os graus de pertinência, ou graus de importância que caracterizam cada valor linguístico para a variável de temperatura estão representados na Figura 11.

Por exemplo, 15 cm é caracterizado como um tamanho pequeno com um grau de pertinência de 0,5 e em médio com grau de pertinência de 0,5, enquanto tamanhos iguais ou superiores a 20 cm são considerados pequenos com grau de pertinência igual a 0, com 20 cm é caracterizado como médio com grau de pertinência igual a 1.

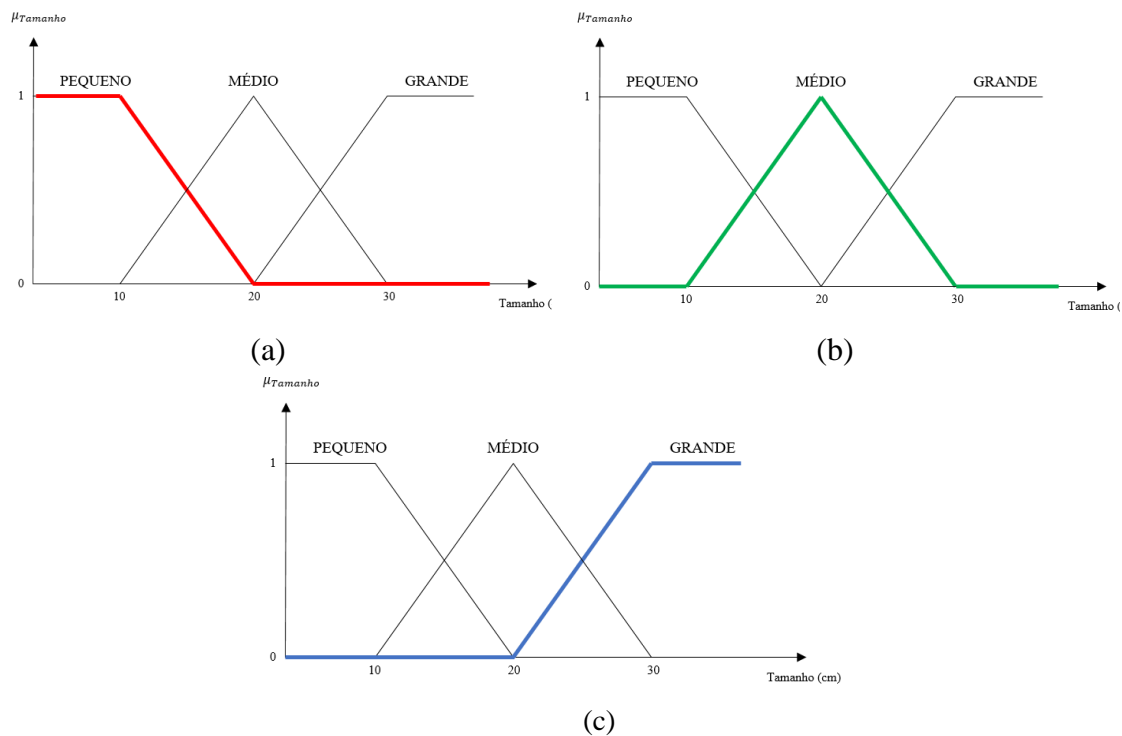


Figura 11: Exemplificação de graus de pertinência para entrada Tamanho com as variáveis linguísticas (a) Pequeno, (b) Médio e (c) Grande. **Fonte: próprio autor.**

3.6.1 Regras dos Sistemas Fuzzy

As regras dos sistemas difusos são criadas convertendo as observações vagas do operador em operações lógicas. No contexto da função de entrada-saída, uma seção refere-se matematicamente a uma parte da função que reflete um intervalo de valores, em vez de fornecer um valor preciso em um determinado ponto. Cada região é definida por uma regra, mais comumente regras se-então (SIMÕES & SHAW, 2007). As regras SE-ENTÃO são expressas da seguinte forma com base em expressões de linguagem descrita na Equação 8.

$$\text{SE } \langle A \rangle \text{ então } \langle B \rangle \quad (8)$$

onde “A” é a condição (antecedente ou premissa) e “B” é o resultado da regra (consequência) (HASHMI & KHAN, 2015; SIMÕES & SHAW, 2007). As variáveis na consequência são as saídas do modelo, e as variáveis na condição são as entradas do modelo. Todas as combinações potenciais entre variáveis de entrada são abordadas por um conjunto abrangente de regras (NELLES, 2001).

A análise de sistemas *fuzzy* envolvem três etapas principais, sendo elas a *Fuzzificação*, inferência *fuzzy* e *defuzzificação*. As variáveis de entrada são transferidas para conjuntos *fuzzy* usando funções de pertinência durante o estágio de *fuzzificação*. Isso faz com que os valores das variáveis de entrada se tornem conjuntos *fuzzy*, ou valores *fuzzificados* (GOMIDE & GUDWIN, 1994; NELLES, 2001). A fase de inferência avalia os dados de entrada *fuzzy* juntamente com as regras para criar ações de controle ou inferir a saída do modelo de processo (MATHWORKS, 2016; NELLES, 2001). A ativação das saídas das regras, que são conjuntos *fuzzy* representados por funções de pertinência, é então determinada usando os graus de ativação.

Por último, o processo de *defuzzificação* utiliza o conjunto *fuzzy* produzido pela análise e o transforma em um valor preciso (MATHWORKS, 2016). Certos sistemas podem não necessitar da etapa de *defuzzificação*, isso quando a saída *fuzzy* é entendida de forma qualitativa (SIMÕES & SHAW, 2007).

3.7 Sistemas de Inferência *Fuzzy* Baseado em Redes Adaptativas (ANFIS)

O sistema ANFIS é uma rede do tipo MLP do tipo *feedforward* que usa o algoritmo de aprendizagem da rede neural e o raciocínio *fuzzy* para mapear um espaço de entrada a um espaço da saída. As conexões SE-ENTÃO permitem que uma base de regras em um sistema *fuzzy* represente o comportamento de um sistema com base em observações feitas por operadores humanos. No entanto, se um conjunto de dados experimentais representa o comportamento do processo, então sistemas de redes neurais artificiais treinados nesses dados podem ser usados para produzir automaticamente a base de regras necessária para o sistema *fuzzy*, que inclui as funções de pertinência e seus parâmetros (SIMÕES & SHAW 2007). Essa abordagem é demonstrada por meio da ferramenta *Adaptive-Network-Based Fuzzy Inference System* - ANFIS. Seu desempenho é semelhante à técnica de aprendizado de rede neural, na qual o sistema de inferência *fuzzy* mapeia entradas em saídas por meio do sistema neural modificando os parâmetros da função de pertinência. Usando algoritmos de retropropagação de erros, que são frequentemente acoplados a técnicas de estimativa de mínimos quadrados, esses parâmetros de função de pertinência são revisados (MATHWORKS, 2016).

Para aplicabilidade desse sistema, é criada primeiramente uma estrutura de modelo hipotética que conecta as entradas e saídas às funções de pertinência das regras. Depois disso, os dados de entrada e saída são usados para treinar o ANFIS, a fim de criar

um sistema de inferência *fuzzy* (FIS) que imita o conjunto de treinamento. Em última análise, conjuntos de dados de entrada e saída não relacionados ao treinamento são empregados para o processo de validação. Quando o modelo de inferência é ajustado durante o treinamento, há uma tendência de o erro de predição diminuir até que o *overfitting* seja detectado, momento em que o erro de predição começa a aumentar (MATHWORKS, 2016).

ANFIS possui uma boa potencialidade de aprender, de construir, de prever e de classificar. Tem a vantagem de permitir a extração de regras *fuzzy* dos dados numéricos ou do conhecimento de especialistas e também construir uma base de regras adaptativas. O inconveniente principal do modelo ANFIS é o tempo de treinamento da estrutura e do ajuste dos parâmetros, que em muitos casos pode exigir muito tempo, dependendo da complexidade na construção do sistema levando em consideração o número de pontos e o número de variáveis de entrada (JANG, 1993).

Esta rede é baseada no treinamento supervisionado, ou seja, a rede é treinada por meio do fornecimento de valores e seus respectivos valores de saída desejados (*training pair*), geralmente efetuados através do processo de minimização do erro calculado na saída (JANG, 1993). A Figura 12 apresenta a arquitetura ANFIS.

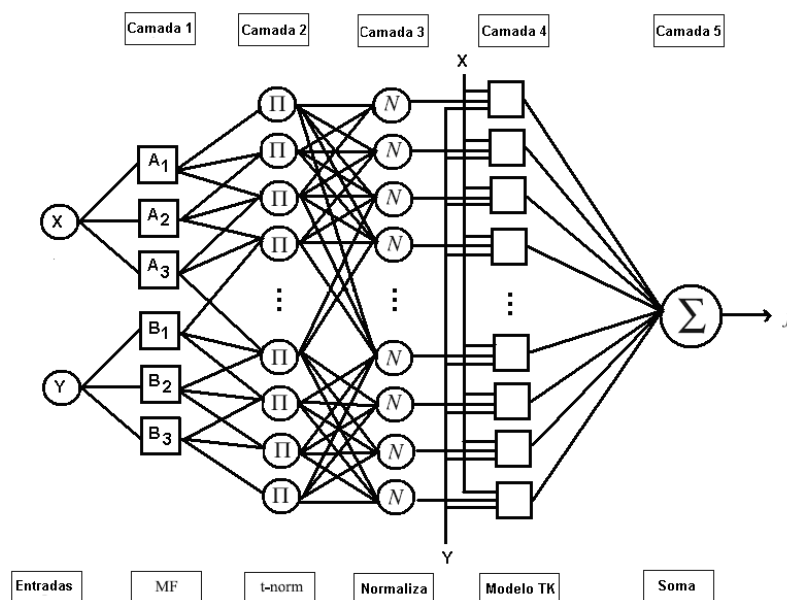


Figura 12: Arquitetura ANFIS genérica. Fonte: adaptado de NUCCI et al. (2007).

Camada 1: As saídas das unidades desta camada são os valores de pertinência das entradas em relação aos termos (conjuntos *fuzzy*) nas premissas das regras;

Camada 2: As saídas das unidades desta camada (II) são os valores de ativação das regras. Haverá tantas unidades na camada dois quanto o número de regras. Todo nó dessa camada é circular (sem parâmetros ajustáveis) e tem como saída o produto dos sinais de entrada, o que permite que o sistema seja continuamente diferenciável favorecendo a otimização dos parâmetros;

Camada 3: Todo nó dessa camada é circular. Nesta camada (N), o principal objetivo é calcular os valores normalizados dos valores de ativação das regras, ou seja, a saída do neurônio é o valor normalizado do grau de ativação da regra, igual a razão do grau de ativação da regra associada ao neurônio pela soma dos graus de ativação de todas as regras;

Camada 4: As saídas das unidades desta camada representam a contribuição de cada regra na saída total e são calculadas pelo valor da função no consequente da regra ponderada pelo valor normalizado de ativação da regra;

Camada 5: O único nó desta camada é circular. Nesta camada, a saída parcial de cada regra é somada para o cálculo da saída total, produzindo a saída do modelo de Takagi-Sugeno (JANG, 1993).

4 METODOLOGIA

Foi realizada uma busca na literatura para analisar as principais variáveis operacionais aplicadas em pesquisas com célula de energia microbiana. Utilizou-se a plataforma *Google Acadêmico*, *Web of Science*, *Scopus* como fonte de informações. A busca por materiais foi em português, inglês ou espanhol publicados entre 2013 e 2023. Por fim, os materiais foram selecionados e seus resumos avaliados. Aqueles julgados condizentes com a pesquisa tiveram seu conteúdo analisado e suas informações registradas. De acordo com o levantamento, 27 trabalhos se enquadraram nos quesitos definidos e 5 parâmetros operacionais mais recorrentes e que se alinham aos objetivos da pesquisa foram identificados, sendo eles: *área do anodo*, *densidade de corrente*, *densidade de potência*, *resistência elétrica externa* e *volume do dispositivo*. A Tabela 1 descreve os limites superiores e inferiores dos parâmetros encontrados na literatura.

Tabela 1: Principais parâmetros operacionais, limites e porcentagem de ocorrência.

Variável	Limite inferior	Limite Superior
Área do anodo (cm^2)	0,04	64
densidade de corrente (mA/m^2)	10	40000
resistência elétrica externa (Ω)	47	1000
volume do dispositivo (L)	0,04	34
densidade de potência (mW/m^2)	0,57	3610

4.1 Implementação das Redes Neurais Artificiais

A implementação das redes neurais foi realizada por meio do *toolbox neural network* do MATLAB® v.15. (MATHWORKS) com base na revisão de Beale et al. (2010). Em primeiro lugar, foi realizado o treinamento da rede para avaliar a performance das CEM. Para a aplicação e avaliação das RNAs nas CEM, foi utilizada rede neural do tipo *feedforward* e todo o treinamento empregou o algoritmo *Levenberg–Marquardt*. Foram utilizadas duas funções de ativação neste trabalho, ou seja, as funções *tansig* e *logsig* e um fator de precisão de 10^{-5} . Os dados utilizados para treinamento e validação para a RNA foram obtidos por meio de busca na literatura.

Cada vez que uma rede neural é treinada, uma solução diferente é obtida. Isto é decorrente da diferença entre os valores iniciais dos parâmetros e da alocação aleatória dos dados nos três subconjuntos (treinamento, validação e teste).

Segundo Cardozo (2023), as variáveis que mais interferem nas CEM são: a área do anodo (cm^2), resistência elétrica externa (Ω) e volume (mL) e estas foram as escolhidas como variáveis de entrada para as RNAs; e como variável de saída, foi escolhida a variável Densidade de Potência (mW/m^2).

Foram utilizados, para testes, redes com uma e duas camadas ocultas, com 10, 25, 40, 50, 75, 90, 100, 120, 150 e 200 neurônios para cada função de ativação, totalizando 40 ensaios para avaliar a melhor performance, com melhores ajustes de treinamento, validação e ajuste total e menores erros associados. Avaliou-se também o gráfico de respostas experimentais e respostas do modelo ótimo.

4.2 Implementação do Sistema Neuro Fuzzy - ANFIS

O desenvolvimento do sistema de neural fuzzy (que envolve o estabelecimento das variáveis linguísticas, das funções de pertinência e das regras de controle) foi realizado por meio da ferramenta computacional *Adaptive Neuro-Fuzzy Inference System* (ANFIS), que pertence ao *Fuzzy Logic toolbox* do MATLAB. O *toolbox* prevê um conjunto de funções e aplicações em MATLAB para análise, *design* e simulação de sistemas baseados na lógica nebulosa. Ele permite a modelagem de sistemas de comportamento complexo que se utilizam de regras lógicas simples, para assim implementá-las em um sistema de inferência nebuloso (MATHWORKS, 2018).

Criado por Jang (1993), o ANFIS é uma técnica de aprendizagem por meio de dados. Sua estrutura é similar à de uma rede neural. O *software* computa os parâmetros das funções de pertinência que permitem o mapeamento das entradas com as saídas por meio de um sistema de inferência nebuloso. Os ajustes nos valores dos parâmetros permitem ao sistema de inferência aprender com os dados conforme são apresentados durante o treinamento. Esta é a principal característica do ANFIS (AL-HMOUZ et al., 2012; JANG, 1993).

Os ajustes nos parâmetros das funções de pertinência são feitos por um algoritmo de propagação retrograda do erro ou *backpropagation* (via gradiente descendente), ou um algoritmo híbrido de *backpropagation* (associado aos parâmetros da função de

pertinência de entrada) com um método dos mínimos quadrados (associado aos parâmetros da função linear de saída) (MATHWORKS, 2018).

A abordagem de modelagem do *ANFIS* é similar as técnicas de identificação de sistemas. Primeiro configura-se a estrutura de um modelo (relacionando entradas e saídas com as funções de pertinência e construindo as regras nebulosas). Em seguida, treina-se o *ANFIS* com dados de entrada e saída, para que possa gerar um sistema de inferência nebuloso que emule os dados utilizados no treinamento. A Figura 13 ilustra a interface inicial do *Neuro-fuzzy ANFIS*, onde é possível realizar a etapa de treinamento, teste e validação dos dados, além das definições das funções de pertinência e erro.

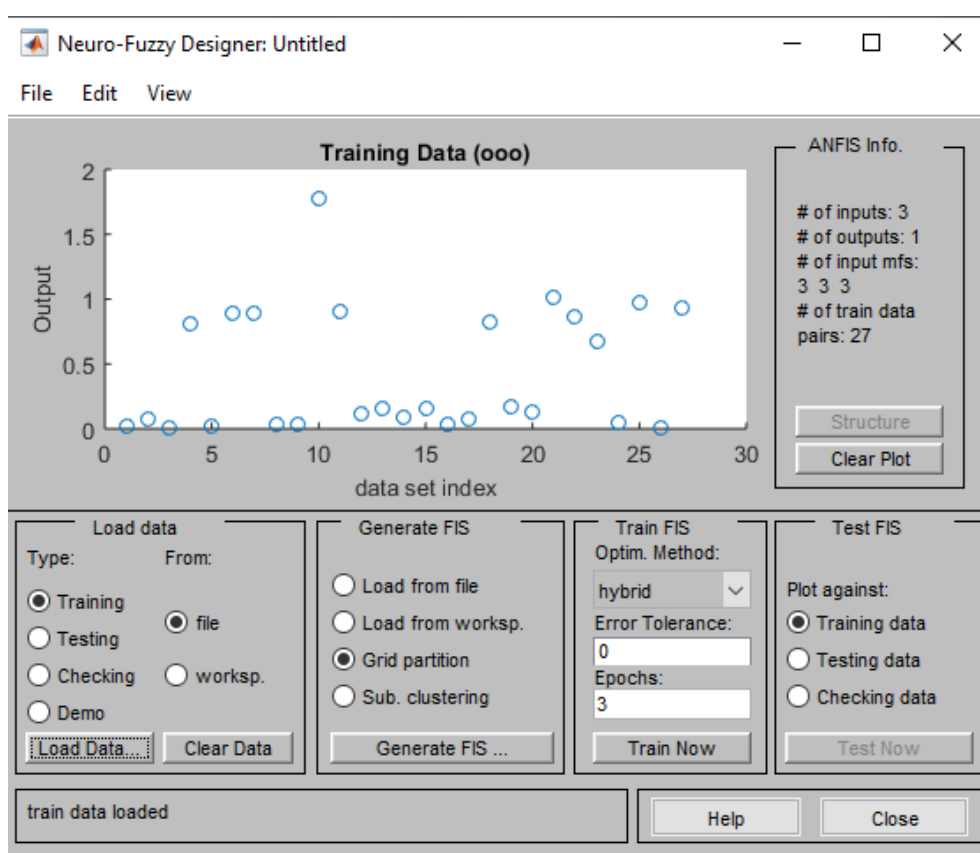


Figura 13: Interface inicial do *Neuro-fuzzy ANFIS*. Fonte: adaptado de MATHWORKS (2018)

5 RESULTADOS E DISCUSSÃO

5.1 Redes Neurais Artificiais

Na criação das redes neurais para as configurações contendo duas camadas ocultas, obteve-se arranjo conforme Figura 14 e os dados dispostos na Tabela 2. Quando se observa os valores demonstrados na Tabela 2, observa-se que os experimentos 08 e 12 obtiveram melhores resultados, ou seja, melhores ajustes de validação, treinamento e ajuste total, com erro associado baixo.




Figura 14: Arranjo para Rede Neural Artificial com duas camadas oculta. **Fonte:** Adaptado de Mathworks, 2002.

Tabela 2: Resultados das arquiteturas de redes neurais encontrados com 2 camadas ocultas.

Rede	n° de neurônios	Função	R Trei ^[1]	R Vali ^[2]	R total	Erro	It ^[3]
1	10	<i>tansig</i>	0,83197	0,5367	0,73267	0,0401	15
2	25	<i>tansig</i>	0,57709	0,99913	0,56951	0,876	48
3	40	<i>tansig</i>	0,94009	0,76851	0,78053	0,0156	14
4	50	<i>tansig</i>	0,85726	0,95557	0,58734	0,00613	27
5	75	<i>tansig</i>	0,52785	0,97309	0,6041	0,00751	27
6	90	<i>tansig</i>	0,92441	0,85688	0,52902	0,00516	34
7	100	<i>tansig</i>	0,60336	0,097237	0,56605	0,0059	24
8	120	<i>tansig</i>	0,89562	0,74617	0,90633	0,0845	19
9	150	<i>tansig</i>	0,93558	0,7032	0,70001	0,507	9
10	200	<i>tansig</i>	0,0731	0,9041	0,26301	0,0857	6
11	10	<i>logsig</i>	0,8696	0,99178	0,786	0,142	19
12	25	<i>logsig</i>	0,94957	0,97742	0,89138	0,00051	72
13	40	<i>logsig</i>	0,77443	0,15438	0,68034	0,0425	8
14	50	<i>logsig</i>	0,27857	0,26182	0,52845	0,0752	8
15	75	<i>logsig</i>	0,89048	0,98654	0,60283	0,0106	76
16	90	<i>logsig</i>	0,90461	0,0008512	0,81672	0,116	11
17	100	<i>logsig</i>	0,85169	0,96091	0,50281	0,00243	57
18	120	<i>logsig</i>	0,90226	0,0041535	0,50361	0,042	12
19	150	<i>logsig</i>	0,6036	0,31263	0,38212	0,0251	7
20	200	<i>logsig</i>	0,17229	0,89561	0,10234	0,0449	7

^[1] R do ajuste de Treinamento. ^[2] R do ajuste de Validação. ^[3] Número de Interações.

Os gráficos de ajuste das redes 08 e 12 são mostrados na Figura 15 e Figura 16. Para a configuração de 2 camadas ocultas (uma camada com 120 neurônios e a outra camada de saída), função de ativação *tansig*, observou-se 19 interações, com R quadrático de 0,89562 no ajuste do treinamento, 0,74617 no ajuste da validação e 0,90633 no ajuste com todos os dados experimentais avaliados, respectivamente, obtendo um erro aproximado de 0,0845. Para a configuração de 2 camadas ocultas (uma camada com 25 neurônios e a outra camada de saída) e função de ativação *logsig*, após 108 interações observou-se R quadrático de 0,94957 no ajuste do treinamento, 0,97742 no ajuste da validação e 0,89138 no ajuste com todos os dados experimentais avaliados, respectivamente, obtendo um erro aproximado de 0,00051.

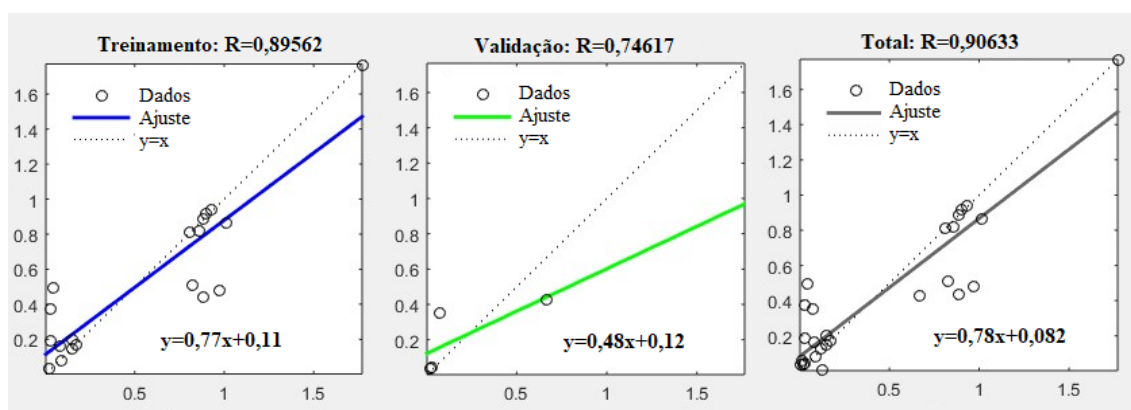


Figura 15: Ajustes de a) treinamento, b) validação e c) total da rede neural com 2 camadas, 120 neurônios e função de ativação do tipo *tansig*.




Figura 16: Ajustes de a) treinamento, b) validação e c) total da rede neural com 2 camadas, 25 neurônios e função de ativação do tipo *logsig*.

Silva et al. (2008) utilizaram apenas 10 neurônios em uma única camada oculta para validação do estado de um biorreator, em crescimento bacteriano, concluindo-se que cada modelo e amostragem é ajustado em uma configuração diferente da rede, mostrando

a versatilidade do modelo computacional. O que é corroborado com Nucci et al. (2007) que compararam duas arquiteturas de redes neurais para inferência on-line da massa celular bacteriana, também utilizando 10 neurônios na única camada oculta de sua arquitetura.

Até o momento, não foram identificados na literatura estudos que empreguem Redes Neurais Artificiais em Células de Combustível Microbiana, destacando a inovação e singularidade desta pesquisa.

Na criação das redes neurais para as configurações contendo apenas uma camada oculta, obteve-se arranjo conforme disposto na Figura 17 e os dados dispostos na Tabela 3.

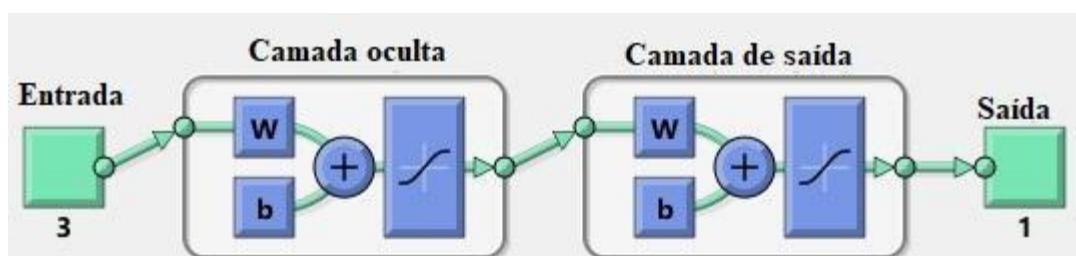


Figura 17: Arranjo para Rede Neural Artificial com uma camada oculta. **Fonte:** Adaptado de Mathworks, 2002.

Nestes casos, observa-se diferentes comportamentos nas redes neurais. Quando se observa os valores demonstrados na Tabela 3, observa-se que os experimentos 26 e 36 obtiveram melhores resultados, ou seja, menor erro associado, com melhores ajustes de validação, treinamento e ajuste total. Os gráficos de ajuste das redes destacadas são mostrados na Figura 18 e Figura 19.

Para a configuração de 1 camada oculta, com 90 neurônios e função de ativação *tansig*, após 22 interações, observou-se R quadrático de 0,92628 no ajuste do treinamento, 0,82224 no ajuste da validação e 0,91009 no ajuste com todos os dados experimentais avaliados, respectivamente, obtendo um erro aproximado de 0,0168.

Para a configuração de uma única camada, com 90 neurônios e a outra camada de saída, função de ativação *logsig* com 82 interações e R² de 0,0,99361 no ajuste do treinamento, 0,89527 no ajuste da validação e 0,68667 no ajuste com todos os dados experimentais avaliados, respectivamente, com um erro aproximado de 0,0207.

Tabela 3: Resultados das arquiteturas de redes neurais encontrados com 1 camada oculta.

Rede	n° de neurônios	Função	R Trei ^[1]	R Vali ^[2]	R total	Erro	It ^[3]
21	10	tansig	0,093757	0,98888	0,72501	0,019	24
22	25	tansig	0,19172	0,55364	0,22874	0,0474	23
23	40	tansig	0,69833	0,7701	0,402	0,0244	7
24	50	tansig	0,93536	0,54545	0,74405	0,0257	19
25	75	tansig	0,9004	0,96041	0,80679	0,0167	19
26	90	tansig	0,92628	0,82224	0,91009	0,0168	22
27	100	tansig	0,8571	0,74427	0,54506	0,0251	10
28	120	tansig	0,13824	0,9943	0,13224	0,0503	6
29	150	tansig	0,94971	0,7651	0,82841	0,46	46
30	200	tansig	0,37496	0,59911	0,39611	0,0265	6
31	10	logsig	0,031853	0,5596	0,20317	0,00287	8
32	25	logsig	0,51874	0,59175	0,49793	0,00893	12
33	40	logsig	0,61269	0,99556	0,60901	0,00843	6
34	50	logsig	0,17604	0,53451	0,27002	0,0916	7
35	75	logsig	0,83323	0,69683	0,75062	0,0228	11
36	90	logsig	0,99361	0,89527	0,68667	0,0207	82
37	100	logsig	0,87821	0,93674	0,70179	0,00373	15
38	120	logsig	0,84433	0,25469	0,51284	0,0163	7
39	150	logsig	0,90394	0,4811	0,59184	0,00874	9
40	200	logsig	0,95455	0,16981	0,56929	0,16	8

^[1] R do ajuste de Treinamento. ^[2] R do ajuste de Validação. ^[3] Número de Interações.




Figura 18: Ajustes de a) treinamento, b) validação e c) total da rede neural com 1 camada, 90 neurônios e função de ativação do tipo *tansig*.




Figura 19: Ajustes de a) treinamento, b) validação e c) total da rede neural com 1 camada, 90 neurônios e função de ativação do tipo *logsig*.

Comparando estas duas, observa-se como a função de ativação influencia na criação da rede, uma vez que estas possuem as mesmas camadas, como observado por Gomes (2010).

Dentre os destacados, observa-se que a melhor performance foi identificada na rede 12, com 25 neurônios na camada oculta para uma função *logsig* de ativação.

Nos casos apresentados, pode-se observar também que, quando se utilizou 150 e 200 neurônios na camada oculta na etapa de treinamento, os resultados na etapa de validação foram inferiores quando se compara com a utilização até 120 neurônios. Esta característica pode ser justificada quando ocorre um *overtraining* e a rede neural perde a capacidade de generalizar, conforme discutido por Calôba et al. (2002).

A Figura 20 apresenta o resultado da média dos erros quadrados de treinamento, validação e teste a cada época da rede neural otimizada (Rede 12, Tabela 2). Em análise aos dados, observa-se uma diminuição destes erros ao longo das interações, conforme esperado. Ainda, próximo à interação de número 72 tem-se o ótimo dos erros, no qual a média não apresenta mais variações significativas.

A Figura 21 apresenta os resultados pela RNA otimizada, em comparação dos dados utilizados no treinamento e com a resposta do modelo obtido na rede neural. O gráfico corrobora com os dados obtidos anteriormente pela proximidade dos resultados da rede quando comparados aos dados experimentais.




Figura 20: Erro quadrado médio da rede neural com 2 camadas, 25 neurônios e função de ativação do tipo *logsig*.




Figura 21: Dados experimentais e resposta da rede neural com 2 camadas, 25 neurônios e função de ativação do tipo *logsig*.

5.2 Sistema Neuro-Fuzzy

Para os sistemas neuro-fuzzy, foi utilizado o sistema ANFIS com os mesmos dados iniciais para treinamento das redes neurais e obteve-se o arranjo conforme Figura 22.

A complexidade do ANFIS utilizado neste trabalho é bastante elevada: tem um total de 27 regras com três variáveis de entrada. As variáveis de entrada para o sistema

ANFIS também foram a área do anodo (cm^2), resistência elétrica externa (Ω) e volume (mL). Todas as regras incluem todas as três variáveis de entrada, cada uma associada a três conjuntos difusos: área do anodo – baixa, média e alta; resistência elétrica externa – baixa, média e alta e volume – baixa, média e alta.

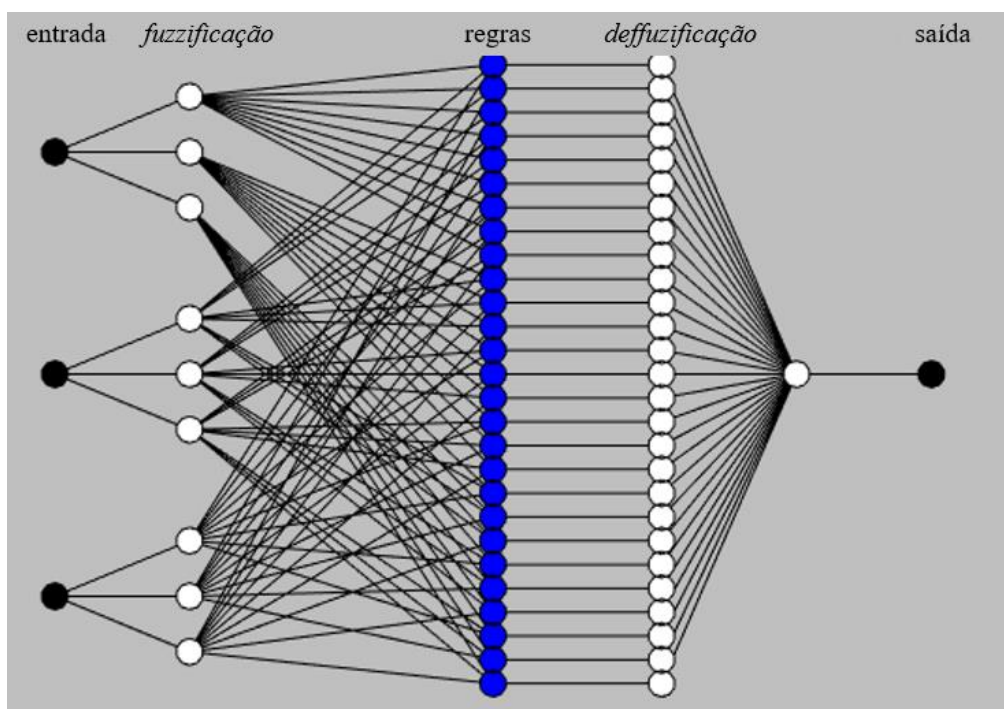


Figura 22: Representação gráfica da função de ativação linear binária. **Fonte:** Próprio autor.

A variável de saída, foi a variável Densidade de Potência (mW/m^2) e está associada a quatro conjuntos difusos, ou seja, baixa, baixa média, média alta e alta. Os gráficos resultados das funções de pertinência são apresentados a seguir para função triangular (Figura 23), trapezoidal (Figura 24) e gausseana (Figura 25).

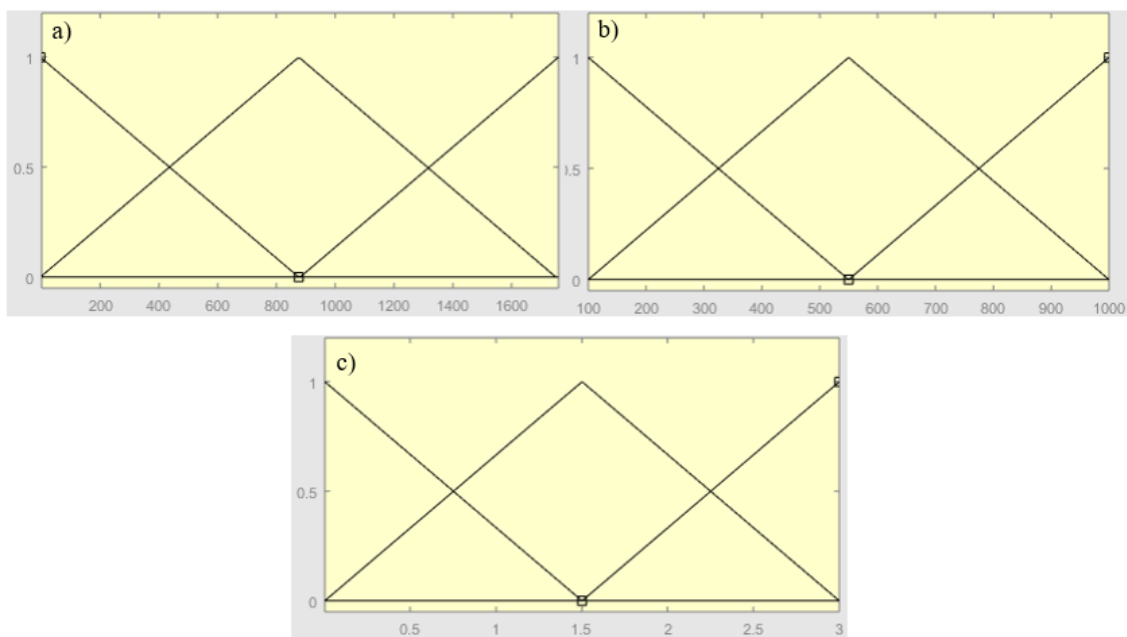


Figura 23: Resultados dos ajustes das funções de pertinência triangular de entrada do sistema *fuzzy* realizado pelo ANFIS: a) área do anodo (cm^2), b) resistência elétrica externa (Ω) e c) volume (mL).

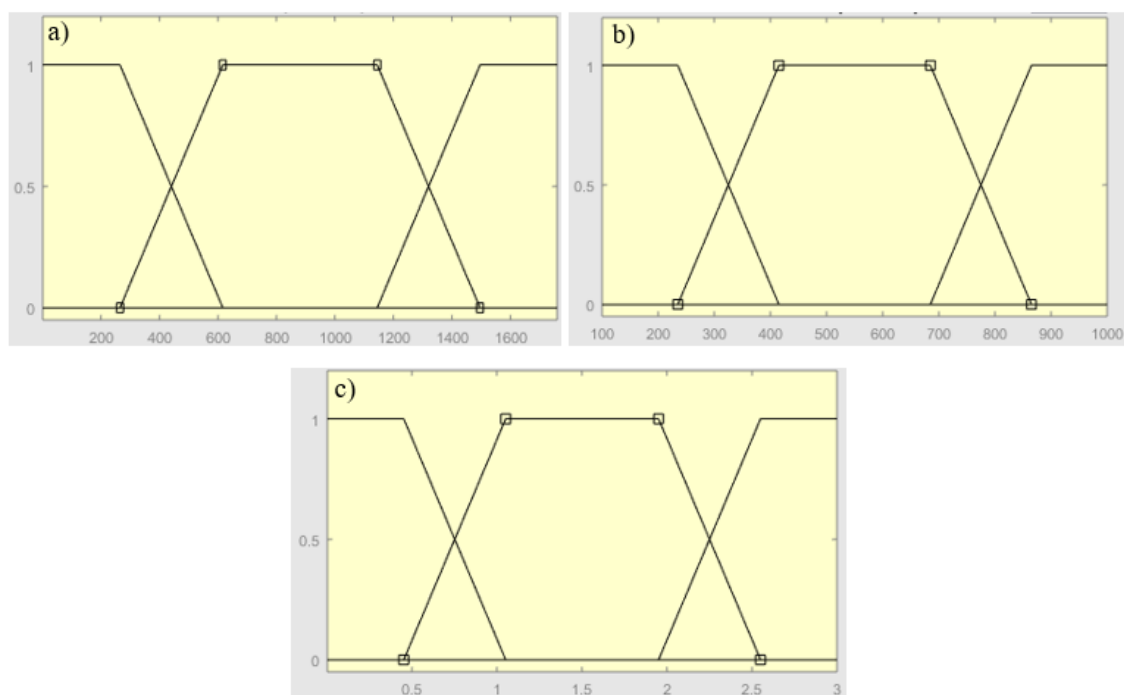


Figura 24: Resultados dos ajustes das funções de pertinência trapezoidal de entrada do sistema *fuzzy* realizado pelo ANFIS: a) área do anodo (cm^2), b) resistência elétrica externa (Ω) e c) volume (mL).

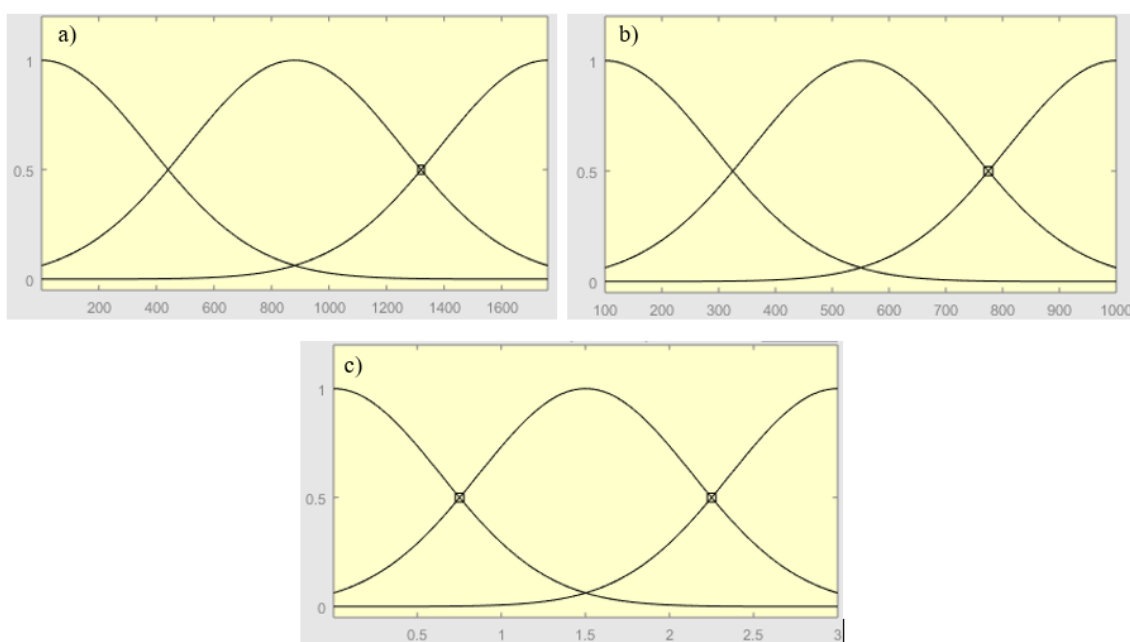


Figura 25: Resultados dos ajustes das funções de pertinência gaussiana de entrada do sistema *fuzzy* realizado pelo ANFIS: a) área do anodo (cm^2), b) resistência elétrica externa (Ω) e c) volume (mL).

Para a rede ANFIS o número de neurônios ocultos é determinado pelo número de variáveis de entrada e termos linguísticos, ou seja, como cada variável de entrada contém três termos linguísticos cada, o número de neurônios foi de 3^3 num total de 27 (JANG, 1993). Os dados obtidos dos sistemas neuro-*fuzzy* são dispostos na Tabela 4.

Tabela 4: Resultados das arquiteturas sistema neuro-*fuzzy* para 27 dados.

Sistema	Função de pertinência	Saída	Treinamento	Erro
1	Triangular	Linear	Híbrido	0,17985
2	Triangular	Linear	<i>Backpropagation</i>	63,0806
3	Triangular	Constante	Híbrido	0,24989
4	Triangular	Constante	<i>Backpropagation</i>	0,27423
5	Trapezoidal	Linear	Híbrido	0,1993
6	Trapezoidal	Linear	<i>Backpropagation</i>	80,6644
7	Trapezoidal	Constante	Híbrido	0,41821
8	Trapezoidal	Constante	<i>Backpropagation</i>	0,41856
9	Gausseana	Linear	Híbrido	0,16612
10	Gausseana	Linear	<i>Backpropagation</i>	60,6141
11	Gausseana	Constante	Híbrido	0,26612
12	Gausseana	Constante	<i>Backpropagation</i>	0,30739

As melhores configurações foram observadas nos sistemas 1, 5 e 9, cujo treinamento se deu de forma híbrida e função de saída linear. A função de pertinência para os sistemas destaques foram os três modelos, ou seja, triangular, trapezoidal e gausseana. Por outro lado, quando se utilizou a combinação de função de saída linear com treinamento *Backpropagation*, observou-se que os erros associados eram muito elevados, caracterizando como sistemas não ajustáveis.

A Figura 26 ilustra os resultados do ANFIS, em comparação dos dados utilizados no treinamento e com a resposta do modelo obtido pelo sistema neuro-*fuzzy*. Os resultados corroboram com os dados obtidos anteriormente pela proximidade dos resultados da rede quando comparados aos dados experimentais. Pode-se observar que o sistema ANFIS se ajusta aos pontos experimentais em quase todos os pontos.

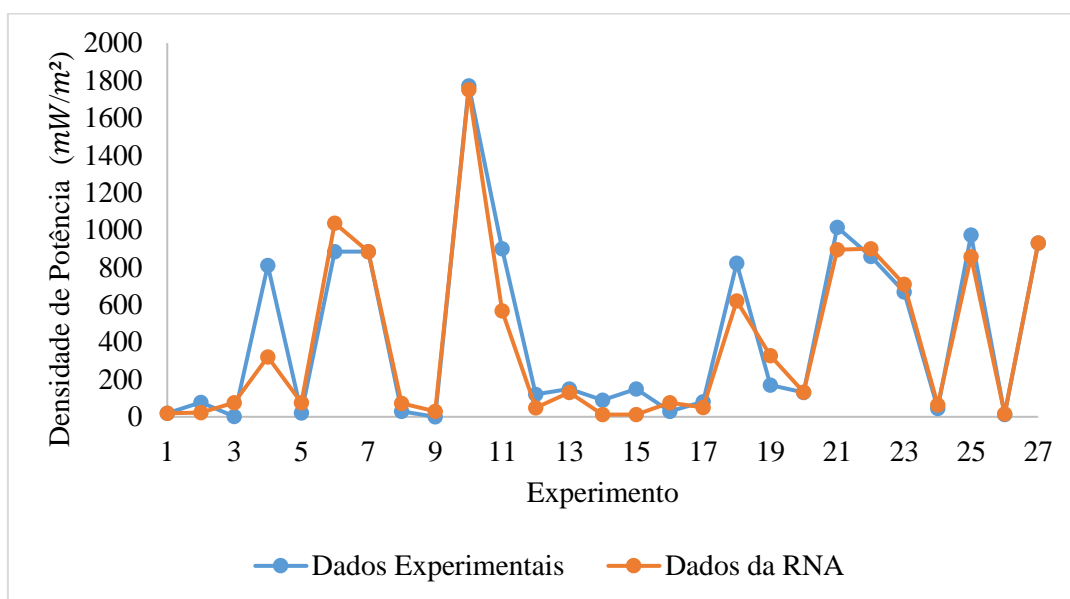


Figura 26: Dados experimentais e resposta do Sistema Neuro *Fuzzy* ANFIS utilizando a função de pertinência Gausseana.

Araújo-Bravo et al. (2004) propuseram automatizar o processo de produção de penicilina utilizando um controle adaptativo baseado no sistema *neuro-fuzzy*. Deste modo os autores desejavam conduzir todo o processo automaticamente, eliminando a necessidade de um operador humano. Os autores relatam que os resultados obtidos para a concentração de biomassa, viscosidade e penicilina foram relativamente precisos.

Chang e Chang (2005) propuseram um sistema *neuro-fuzzy* ANFIS para predição do nível de controle de um reservatório. Os autores desenvolveram dois algoritmos: um com decisão do especialista como saída do sistema e o outro sem esta decisão. De acordo com os resultados, os autores concluíram que os algoritmos ANFIS desenvolvidos foram aplicados com sucesso, promovendo alto grau de confiança no controle do nível do reservatório. Relataram também que o modelo com decisão humana como saída apresentou um desempenho superior do que o modelo sem esta saída.

Nucci et al. (2007) propuseram a utilização do sistema *Neuro-Fuzzy* ANFIS no processo de produção da penicilina G acilase (PGA). PGA é uma importante enzima usada na produção industrial de antibióticos β -lactâmicos. Os autores utilizaram três variáveis de entrada (tempo de cultivo, fração molar de dióxido de carbono e a velocidade de agitação) e como saída, a inferência da concentração de células e a produção da atividade enzimática no processo, além de testar diferentes funções de pertinências. Os melhores resultados foram obtidos quando se utilizou a função gaussiana, apresentando um erro de 7,57 e 225 épocas. Já quando se utilizou a função triangular, o erro encontrado foi de 8,38 e somente 8 épocas na etapa de treinamento. Resultados esses que estão de acordo com os obtidos neste trabalho.

Tendo em vista os resultados obtidos na etapa de treinamento e validação, foi feita uma análise comparativa dos dados experimentais e os dados inferidos pelo sistema ANFIS e pela rede MLP. Observa-se pela Figura 27 que o sistema ANFIS apresentou um melhor ajuste aos pontos se comparado com a rede MLP na inferência da Densidade de Potência.

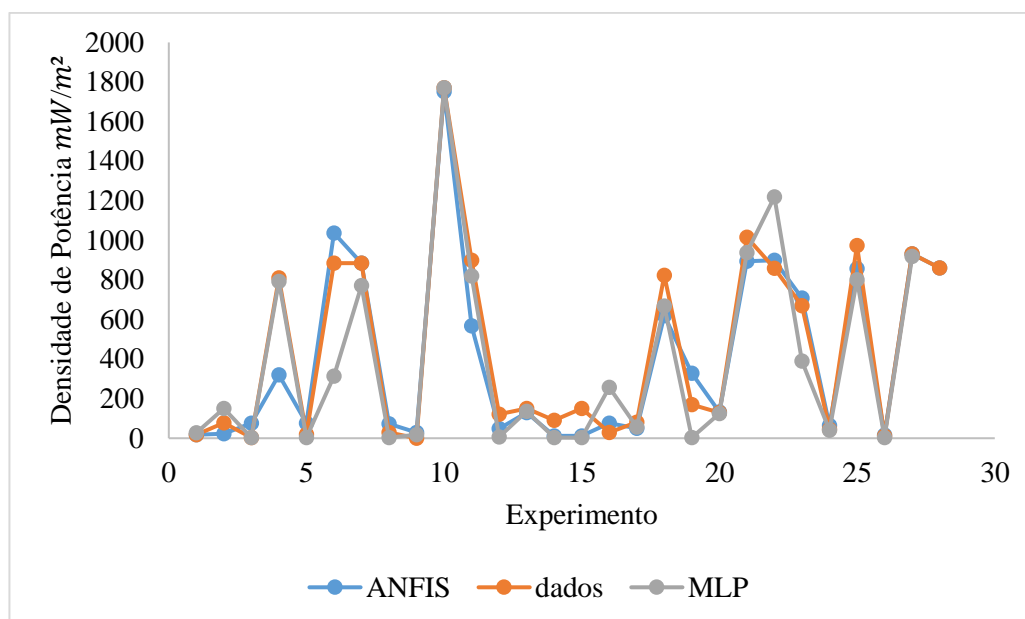


Figura 27: Dados experimentais e resposta da rede MLP e Sistema ANFIS na inferência do valor da Densidade de Potência.

Já na Figura 28, levando em consideração somente os valores do sistema ANFIS dos resultados obtidos na etapa de treinamento e validação, observa que por meio dos valores preditos e os experimentais, foi possível obter um valor de R^2 de 0,9539 para os ajustes dos dados. Quando se faz a mesma análise para os resultados da MLP (Figura 29), se observa um resultado inferior aos ajustes dos pontos, chegando ao final com um valor de R^2 de 0,8899.




Figura 28: Valores experimentais e inferidos da Densidade de Potência para o sistema ANFIS.

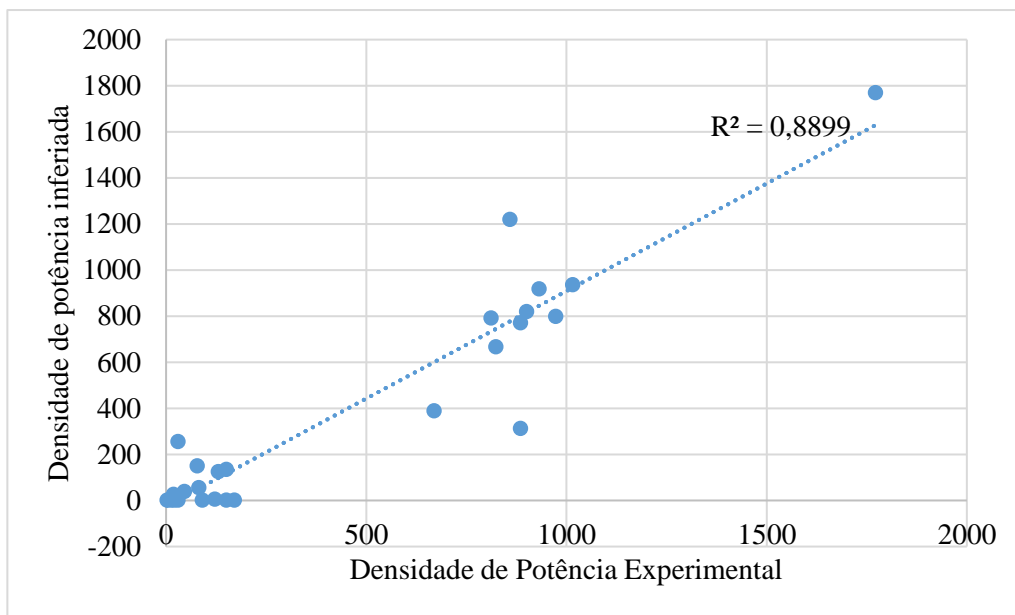


Figura 29: Valores experimentais e inferidos da Densidade de Potência para a rede MLP.

6 CONCLUSÃO

Os resultados obtidos nesta pesquisa sugerem que a implementação de redes neurais artificiais na otimização de células de energia microbiana é uma abordagem eficaz e promissora. Em particular, os *Multilayer Perceptrons* (MLPs) demonstraram ser uma escolha robusta e promissora para a modelagem desse contexto complexo. Essa constatação destaca o potencial dessas redes neurais em aprimorar o desempenho e a eficiência de células de energia microbiana, abrindo portas para avanços significativos na aplicação prática dessa tecnologia inovadora.

O melhor resultado obtido utilizando as RNAs com duas camadas ocultas foi observado na rede identificada como 12, contendo 25 neurônios, função de ativação do tipo *logsig* e obtendo um erro associado de $5,93 \cdot 10^{-4}$ e 72 iterações.

Para a configuração de 1 camada oculta, foi possível identificar os melhores ajustes quando se utilizou 90 neurônios, função de ativação *tansig* com 22 interações, obtendo um erro aproximado de 0,0168.

Levando em consideração o Sistema Neuro-*Fuzzy* ANFIS, pode-se observar um melhor ajuste dos pontos inferidos pelo sistema, quando se utilizou a função de pertinência Gausseana, 27 neurônios na camada oculta e um erro de 0,1661.

Na comparação das duas metodologias utilizadas, pode-se observar um melhor ajuste aos pontos experimentais utilizando o sistema ANFIS se comparado com o MLP, chegando a um valor de R^2 de 0,9539 na análise comparativa dos dados experimentais e os dados inferidos pelo sistema ao invés dos 0,8899 quando se utilizou a Rede MLP.

7 ESTUDOS FUTUROS

Como trabalhos e prospecções futuras cita-se:

- Avaliação e validação dos resultados obtidos computacionalmente por meio de ensaios laboratoriais nas melhores condições encontradas nas simulações;
- Busca por maior número de dados experimentais na literatura;
- Utilizar uma função “*spline*” nos dados experimentais obtidos na literatura afim de gerar um número maior de pontos para o treinamento, teste e validação das RNAs.

8 PUBLICAÇÕES

- CACHEADO, M.A.A; RODRIGUES, I.C.B; NUCCI, E.R. Aplicação da Análise de Redes Neurais Artificiais na previsão do desempenho de Células de Energia Microbiana. *Revista de Gestão Social e Ambiental*, 1-17p, 2024.
- CACHEADO, M.A.A; RODRIGUES, I.C.B; NUCCI, E.R. Aplicação de Redes Neurais Artificiais na performance de Células de Energia Microbiana. *II Simpósio de Engenharia de Bioprocessos e Biotecnologia (II SIMBIO)*, Ouro Branco – MG, 1-3p, 2023.

9 REFERÊNCIAS BIBLIOGRÁFICAS

- AELTERMAN, P.; RABAEY, K.; PHAM, H.T.; BOON, N.; VERSTRAETE, W. Continuous electricity generation at high voltages and currents using stacked microbial fuel cells. *Environmental Science & Technology*, v. 40, n.10, p. 3388-3394, 2006.
- AHMAD, Z., ARSHAD, M., CROWLEY, D., KHOSHNEVISAN, B., YOUSEFI, M., IMRAN, M., & HUSSAIN, S. Comparative efficacy of ANN and ANFIS models in estimating biosurfactant production produced by *Klebsiella* sp. FKOD36. *Stochastic environmental research and risk assessment*, v. 30, p. 353-363, 2016.
- AL-HMOUZ, A. et al. Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning. *IEEE Transactions on Learning Technologies*, v. 5, n. 3, p. 226–237, Jul. 2012.
- AMARI, S. Backpropagation and stochastic gradient descent method. *Neurocomputing*, Elsevier, v. 5, n. 4-5, p. 185–196, 1993.
- AMARI, S. I. Backpropagation and stochastic gradient descent method. *Neurocomputing*, Elsevier, v. 5, n. 4-5, p. 185–196, 1993.
- ANGIONI, S.; MILLIA, L.; BRUNI, G.; TEALDI, C.; MUSTARELLI, P.; QUARTARONE, E. Improving the performances of Nafion™-based membranes for microbial fuel cells with silica-based, organically-functionalized mesostructured fillers. *Journal of Power Sources*, v. 334, p. 120-127, 2016.
- ARAÚJO-BRAVO, M.J.; CANO-IZQUIERDO, J.M.; GÓMEZ-SANCHEZ, E.; LÓPEZ-NIETO, M.J.; DIMITRIADIS, Y.A.; CORONADO, J.L. Automatization of a Penicillin Production Process with Soft Sensors and an Adaptive Controller Based on Neuro Fuzzy Systems. *Control Engineering Practice*, 12, 1073-1090, 2004.
- BEALE, M.H.; HAGAN, M.T.; DEMUTH, (2010). H.B. *Neural Network Toolbox: User's Guide*, 7th ed.; MathWorks: Natick, MA, USA.
- BAUDLER, A.; SCHMIDT, I.; LANGNER, M.; GREINER, A.; SCHRÖDER, U. Does it have to be carbon? Metal anodes in microbial fuel cells and related bioelectrochemical systems. *Energy & Environmental Science*, v. 8, n. 7, p. 2048-2055, 2015.
- BIEBENGUT, M. S., & Hein, N. *Modelagem matemática no ensino*. Editora Contexto, 2000.
- BIEMBENGUT, M. S; HEIN, N. *Modelagem matemática no ensino*. 3 ed. São Paulo: Contexto, 2003, 127p.
- BOND, D. R.; HOLMES, D. E.; TENDER, L. M.; LOVLEY, D. R. Electrode-reducing microorganisms that harvest energy from marine sediments. *Science*, v. 295, n. 5554, p. 483-485, 2002.

- BOND, D. R.; LOVLEY, D. R. Electricity production by *Geobacter sulfurreducens* attached to electrodes and applied and Environmental Microbiology, v. 69, n. 3, p. 1548-1555, 2003.
- BOND, D. R.; LOVLEY, D. R. Evidence for the involvement of an electron shuttle in electricity generation by *Geothrix fermentans*. Applied and Environmental Microbiology, v. 71, n. 4, p. 2186-2189, 2005.
- BRASIL. Empresa de Pesquisa Energética. Ministério de Minas e Energia. Matriz Energética e Elétrica. Disponível em: Acesso em: 01 de setembro de 2022.
- BULLEN, R. A.; ARNOT T. C.; LAKEMAN J. B.; WALSH F. C. Biofuel cells and their development. Biosensors and Bioelectronics, v.21, n. 11, p 2015-2045. Maio 2006.
- CALL, D. F.; LOGAN, B. E. A method for high throughput bioelectrochemical research based on small scale microbial electrolysis cells. Biosensors and Bioelectronics, v. 26, n. 11, p. 4526-4531, 2011.
- CALÔBA, G. M., CALÔBA, L. P., & SALIBY, E. Cooperação entre redes neurais artificiais e técnicas' clássicas' para previsão de demanda de uma série de vendas de cerveja na Austrália. Pesquisa Operacional, v. 22, p. 345-358, 2002.
- CARDOZO, M. H. A. NUCCI, E. R. RODRIGUES, I. C. B. Estudo Da Influência De Parâmetros Operacionais Em Células De Energia Microbiana. Revista De Engenharia E Tecnologia, v. 15, n. 1, 2023.
- CHANG, F.-J.; CHANG, Y.-T. Adaptative neuro-fuzzy inference system for prediction of water level in reservoir. *Advances in Water Resources*, 2005.
- CHAUDHURI, S. K.; LOVLEY, D. R. Electricity generation by direct glucose oxidation in mediatorless microbial fuel cells. Nature Biotechnology, v. 21, n. 10, p. 1229, 2003.
- CHEN, Q.; PU, W.; HOU, H.; HU, J.; LIU, B.; LI, J.; YANG, J. Activated microporous-mesoporous carbon derived from the chestnut shell as a sustainable anode material for high-performance microbial fuel cells. Bioresource Technology, v. 249, p. 567-573, 2018.
- CHEN, S.; HE, G.; HU, X.; XIE, M.; WANG, S.; ZENG, D.; HOU, H.; SCHRÖDER, U. A three-dimensionally ordered macroporous carbon derived from a natural resource as anode for microbial bioelectrochemical systems. ChemSusChem, v. 5, n. 6, p. 1059-1063, 2012a.
- CHEN, S.; HE, G.; LIU, Q.; HARNISCH, F.; ZHOU, Y.; CHEN, Y.; HANIF, M.; WANG, S.; PENG, X.; HOU, H.; SCHRÖDER, U. Layered corrugated electrode macrostructures boost microbial bioelectrocatalysis—Energy & Environmental Science, v. 5, n. 12, p. 9769-9772, 2012b.
- CHEN, S.; LIU, Q.; HE, G.; ZHOU, Y.; HANIF, M.; PENG, X.; WANG, S.; HOU, H. Reticulated carbon foam derived from a sponge-like natural product as a high-performance anode in microbial fuel cells. Journal of Materials Chemistry, v. 22, n. 35, p. 18609-18613, 2012c.

- CLAUWAERT, P.; RABAEY, K.; AELTERMAN, P.; SCHAMPHELAIRES, L.; PHAM, T. H.; BOECKX, P.; BOON, N.; VERSTRAETE, W. Biological denitrification in microbial fuel cells. *Environmental Science & Technology*, v. 41, n. 9, p. 3354-3360, 2007.
- CROSS JR, W. E. The psychology of nigrescence: Revising the Cross model. 1995.
- CROSS, S.; HARRISON, R.; KENNEDY, R. Introduction to neural networks "The Lancet"; vol. 346, no. 8982. [S.l.]: October, 1995.
- CROSS, S.; HARRISON, R.; KENNEDY, R. Introduction to neural networks "The Lancet"; vol. 346, no. 8982. [S.l.]: October, 1995.
- DANIEL D. K.; MANKIDY B. DAS; AMBARISH K.; MANOGARI R. Construction and operation of a microbial fuel cell for electricity generation from wastewater. *International Journal of Hydrogen Energy*, v. 34, n. 17, p. 7555-7560. 2009.
- DATA SCIENCE ACADEMY (2019). Deep Learning Book. Disponível em: <http://www.deeplearningbook.com.br/>. Acesso: 15 nov. 2023.
- DAVEY, M. E.; O'TOOLE, G. A. Microbial Biofilms: from Ecology to Molecular Genetics. *Microbiology and Molecular Biology Reviews*, v. 64, n. 4, p.847 - 867, 2000.
- DEL CAMPO, A. G., PEREZ, J. F., CAÑIZARES, P., RODRIGO, M. A., FERNANDEZ, F. J., & LOBATO, J. Study of a photosynthetic MFC for energy recovery from synthetic industrial fruit juice wastewater. *International journal of hydrogen energy*, v. 39, n. 36, p. 21828-21836, 2014.
- DU Z.; LI H. GU T. 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. Outubro 2007.
- DU Z.; LI Q.; TONG M.; LI S.; LI H. Electricity Generation Using Membrane-less Microbial Fuel Cell during Wastewater Treatment. *Chinese Journal of Chemical Engineering*. v. 15, n. 5, p 772-777. Outubro 2008.
- DU, Z.; LI, H.; GU, T. 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, 2007.
- ELAKKIYA, E.; MATHESWARAN, M. Comparison of anodic metabolisms in bioelectricity production during treatment of dairy wastewater in Microbial Fuel Cell. *Bioresource Technology*, v.136, p.407-412, 2013.
- ELMEKAWY, A.; SRIKANTH, S.; VANBROEKHOVEN, K.; WEVER, H.; PANT, D. Bioelectro-catalytic valorization of dark fermentation effluents by acetate oxidizing bacteria in the bioelectrochemical system (BES). *Journal of Power Sources*, v. 262, p. 183-191, 2014.

- ESTRADA-ARRIAGA, E. B.; HERNÁNDEZ-ROMANO, J.; GARCÍA-SÁNCHEZ, L.; GARCÉS, R. A. G.; BAHENA-BAHENA, E. O.; GUADARRAMA-PÉREZ, O.; CHAVEZ, G. E. M. Domestic wastewater treatment and power generation in continuous flow air-cathode stacked microbial fuel cell: Effect of series and parallel configuration. *Journal of Environmental Management*, v. 214, p. 232-241, 2018.
- FAN, Y.; HU, H.; LIU, H. Enhanced Coulombic efficiency and power density of air-cathode microbial fuel cells with an improved cell configuration—*Journal of Power Sources*, v. 171, n. 2, p. 348-354, 2007.
- FARRUGIA, B. Sistemas biológicos para tratamento de efluentes. *Revista TAE especializada em tratamento de água e efluentes*, n. 5, 2012.
- FAYKIN, S. *Neural networks: a comprehensive foundation*. [S.l.]: Prentice Hall PTR, 1998.
- FEDOROVICH, V.; KNIGHTON, M. C.; PAGALING, E.; WARD, F. B.; FREE, A.; GORYANIN, I. Novel electrochemically active bacterium phylogenetically related to *Arcobacter butzleri*, isolated from a microbial fuel cell and applied and *Environmental Microbiology*, v. 75, n. 23, p. 7326-7334, 2009.
- FLECK, L. et al. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v. 1, n. 13, p. 47–57, 2016.
- FLECK, L. et al. Redes neurais artificiais: Princípios básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, v. 1, n. 13, p. 47–57, 2016.
- FRANCO, Maione Wittig. Avaliação da qualidade ambiental no entorno de áreas de mineração e análise da exposição da cianobactéria *Synechococcus nidulans* a oxianions de arsênio. 2014, 111 f. Tese (Doctor Scientiae) – Universidade Federal de Minas Gerais, Belo Horizonte, 2014.
- GAJDA, I.; GREENMAN, J.; IEROPOULOS, I. A. Recent advancements in real-world Microbial Fuel Cells applications. *Current Opinion in Electrochemistry*, 2018.
- GALVANI L. *De bononiensi scientiarum et artium instituto atque academia. Comentarrii 1791*; 7:363–418.
- GERSHENSON, C. *Artificial Neural Networks for Beginners*. 2015. Disponível em: <[https://datajobs.com/data-science-repo/Neural-Net-\[CarlosGershenson\].pdf](https://datajobs.com/data-science-repo/Neural-Net-[CarlosGershenson].pdf)>. Acesso em: 15 nov. 2015.
- GERSHENSON, C. *Artificial neural networks for beginners*. arXiv preprint cs/0308031, 2003.
- GOMES, G. S. S. Novas funções de ativação em redes neurais artificiais *multilayer perceptron*. 2010. Tese (Doutorado). Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Pernambuco, Recife, 2010.
- GORBY, Y. A.; YANINA, S.; MCLEAN, J. S.; ROSSO, K. M.; MOYLES, D.; DOHNALKOVA, A.; BEVERIDGE, T. J.; CHANG, I. S.; KIM, B. H.; KIM, K. S.;

- CULLEY, D. E.; REED, S. B.; ROMINE, M. F.; SAFFARINI, D. A.; HILL, E. A.; SHI, L.; ELIAS, D. A.; KENNEDY, D. W.; PINCHUK, G.; WATANABE, K.; ISHII, S.; LOGAN, B.; NEALSON, K. H.; FREDRICKSON, J. K. Electrically conductive bacterial nanowires produced by *Shewanella oneidensis* strain MR-1 and other microorganisms. *Proceedings of the National Academy of Sciences*, v. 103, n. 30, p. 11358-11363, 2006.
- GUAMBO, A.; PAÑA, S.; CALDERÓN, C.; ECHEVERRÍA, M.; RECALDE, C. Environmental Biosensor Potential of Microbial Fuel Cells for Nitrate Reduction. *Sensors & Transducers*, v. 217, n. 11, p. 23-27, 2017.
- HA, P. T., TAE, B., & CHANG, I. S. Performance and a bacterial consortium of microbial fuel cell fed with formate. *Energy & Fuels*, v. 22, n. 1, p. 164-168, 2008.
- HABERMANN, W. e POMMER, E. H. Biological fuel cells with sulfide storage capacity. *Applied Microbiology and Biotechnology*, v.35, n.1, p.128-133. 1991.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. [S.l.]: Prentice Hall PTR, 1994.
- HAYKIN, S. *Redes Neurais: Princípios e Prática*. 2 ed., Porto Alegre: Bookman, 2007.
- HAYKIN, S. *Redes Neurais: Princípios e prática*; trad. Paulo Martins Engel. 2a ed. Porto Alegre, Bookman, 2001.
- HAYKIN, Simon. *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1998.
- HAYKIN, Simon. *Redes neurais: princípios e prática*. Bookman Editora, 2001.
- HE, L., DU, P. et al. Advances in microbial fuel cells for wastewater treatment. *Renewable and Sustainable Energy Reviews*, v.71, p.388-403. 2017.
- HE, L., DU, P., CHEN, Y., LU, H., CHENG, X., CHANG, B., & WANG, Z. Advances in microbial fuel cells for wastewater treatment. *Renewable and Sustainable Energy Reviews*, v. 71, p. 388-403, 2017.
- HE, Z.; MINTEER, S. D.; ANGENENT, L. T. Electricity generation from artificial wastewater using an up-flow microbial fuel cell. *Environmental Science & Technology*, v. 39, n. 14, p. 5262-5267, 2005.
- HECHT-NIELSEN, R. Theory of the backpropagation neural network. In: *Neural networks for perception*. [S.l.]: Elsevier, 1992. p. 65–93.
- HECHT-NIELSEN, R. Theory of the backpropagation neural network. In: *Neural networks for perception*. [S.l.]: Elsevier, 1992. p. 65–93.
- HERNÁNDEZ-FERNÁNDEZ, F. J.; DE LOS RÍOS, A. P.; MATEO-RAMÍREZ, F.; GODÍNEZ, C.; LOZANO-BLANCO, L. J.; MORENO, J. I.; TOMÁS-ALONSO, F. New application of supported ionic liquids membranes as proton exchange membranes in a microbial fuel cell for wastewater treatment. *Chemical Engineering Journal*, v. 279, p. 115-119, 2015a.

- HOLMES, D. E.; BOND, D. R.; LOVLEY, D. R. Electron transfer by *Desulfobulbus propionicus* to Fe (III) and graphite electrodes. *Applied and Environmental Microbiology*, v. 70, n. 2, p. 1234-1237, 2004a.
- HOLMES, D. E.; NICOLL, J. S.; BOND, D. R.; LOVLEY, D. R. Potential role of a novel psychrotolerant member of the family Geobacteraceae, *Geopsychrobacter electrodiphilus* gen. nov., sp. nov., in electricity production by a marine sediment fuel cell. *Applied and Environmental Microbiology*, v. 70, n. 10, p. 6023-6030, 2004b.
- HUANG, D. Y.; ZHOU, S. G.; CHEN, Q.; ZHAO, B.; YUAN, Y.; ZHUANG, L. Enhanced anaerobic degradation of organic pollutants in a soil microbial fuel cell. *Chemical Engineering Journal*, v. 172, n. 2-3, p. 647-653, 2011.
- IEROPOULOS, I.; GREENMAN, J.; MELHUIH, C.; HORSFIELD, I. EcoBot-III: A Robot with Guts. In: *Proceedings of the Alife XII Conference*, Odense, Denmark, p. 733-740, 2010.
- ISHII, S. I. et al. Coaggregation Facilitates Interspecies Hydrogen Transfer between *Pelotomaculum thermopropionicum* and *Methanothermobacter thermautotrophicus*. *Applied and Environmental Microbiology*, v.71, n.12, p.7838-7845. 2005.
- JANG, J-S. R., ANFIS: Adaptive Network-Based Fuzzy Inference System. *IEEE Transaction on Systems, Man, and Cybernetics*, 23, p. 665-683, 1993.
- JIANG, D.; LI, B.; JIA, W.; LEI, Y. Effect of inoculum types on bacterial adhesion and power production in microbial fuel cells. *Applied Biochemistry and Biotechnology*, v. 160, n. 1, p. 182, 2010.
- JIANG, Y. B.; ZHONG, W. H.; HAN, C.; DENG, H. Characterization of electricity generated by soil in microbial fuel cells and the isolation of soil source exoelectrogenic bacteria. *Frontiers in Microbiology*, v. 7, n. 1776, p. 1-10, 2016.
- JOHN, A. M. S.; LOPES, B. C. V. Acompanhamento da geração de potencial elétrico por célula combustível microbiana. 2013. 72f. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná, Curitiba, 2013.
- KAO, S.; WU, J.; WANG, C.; WANG, Y. Effect of Fe²⁺, Mn²⁺ catalyst on the performance of Bio-electro-Fenton microbial fuel cells. *Journal of Biostatistics and Biometric Applications*, v. 1, n. 1, p. 1-6, 2015.
- KARTHIKEYAN, R., WANG, B., XUAN, J., WONG, J. W., LEE, P. K., & LEUNG, M. K. Interfacial electron transfer and bioelectrocatalysis of carbonized plant material as effective anode of the microbial fuel cell. *Electrochimica Acta*, v. 157, p. 314-323, 2015.
- KHAN, M. D.; KHAN, N.; SULTANA, S.; JOSHI, R.; AHMED, S.; YU, E.; SCOTT, K.; AHMAD, A.; KHAN, M. Z. Bioelectrochemical conversion of waste to energy using microbial fuel cell technology. *Process Biochemistry*, v. 57, p. 141-158, 2017.

- KIM, B. H., CHANG, I. S., CHEOL GIL, G., PARK, H. S., & KIM, H. J. Novel BOD (biological oxygen demand) sensor using a mediator-less microbial fuel cell. *Biotechnology letters*, v. 25, p. 541-545, 2003.
- KIM, B. H.; PARK, D. H.; SHIN, P. K.; CHANG, I. S.; KIM, H. J. Mediator-less Biofuel Cell. U.S. Patent n. 5,976,719, 2 nov. 1999.
- KIM, H. J.; PARK, H. S.; HYUN, M. S.; CHANG, I. S.; KIM, M.; KIM, B. H. A mediator-less microbial fuel cell using a metal reducing bacterium, *Shewanella putrefaciens*. *Enzyme and Microbial Technology*, v. 30, n. 2, p. 145-152, 2002.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.
- LEE, D. J., LEE, C. Y. e CHANG, J. S. Treatment and electricity harvesting from sulfate/sulfide containing wastewaters using microbial fuel cell with enriched sulfate-reducing mixed culture. *Journal of Hazardous Materials*, v.243, p.67-72. 2012.
- LEHNEN, D. R. Desenvolvimento de células de combustível microbiana. 2014. 66 f. Dissertação (Mestrado) - Curso de Química, Instituto de Química, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014.
- LI, S.; CHENG, C.; THOMAS, A. Carbon-Based Microbial-Fuel-Cell Electrodes: From Conductive Supports to Active Catalysts. *Advanced Materials*, v. 29, n. 8, p. 1-30, 2017.
- LI, X.; LI, Y.; ZHANG, X.; ZHAO, X.; SUN, Y.; WENG, L.; LI, Y. Long-term effect of biochar amendment on the biodegradation of petroleum hydrocarbons in soil microbial fuel cells. *Science of The Total Environment*, v. 651, p. 796-806, 2019.
- LI, Y., ZHANG, B., CHENG, M., Li, Y., HAO, L. e GUO, H. Spontaneous arsenic (III) oxidation with bioelectricity generation in single-chamber microbial fuel cells. *Journal of Hazardous Materials*, v.306, p.8-12. 2016.
- LIMA, C. M. R. Processos Biológicos na Captação e Transformação de Matéria e Energia. Eixo Biológico, módulo II, unidade 12, 2010. 38 f. Universidade Estadual de Santa Cruz – UESC, Ilhéus, 2010.
- LIN, H.; WU, X.; MILLER, C.; ZHU, J. Improved performance of microbial fuel cells enriched with natural microbial inocula and treated by electrical current. *Biomass and Bioenergy*, v. 54, p. 170-180, 2013.
- LIU, H.; CHENG, S. A.; LOGAN, B. E. Production of electricity from acetate or butyrate using a single-chamber microbial fuel cell. *Environmental Science & Technology*, v. 39, n. 2, p. 658-662, 2005a.

- LIU, H.; RAMNARAYANAN, R.; LOGAN, B. E. Production of electricity during wastewater treatment using a single chamber microbial fuel cell. *Environmental Science & Technology*, [S.I.], v. 38, n. 7, p. 2281-2285, 2004.
- LIU, S. H.; LAI, Y. C.; LIN, C. W. Enhancement of power generation by microbial fuel cells in treating toluene-contaminated groundwater: Developments of composite anodes with various compositions. *Applied Energy*, v. 233, p. 922-929, 2019.
- LOGAN, B. E. Exoelectrogenic bacteria that power microbial fuel cells. *Nature Reviews Microbiology*, v.7, p.375. 2009.
- LOGAN, B. E. *Microbial Fuel Cells*. New Jersey: John Wiley & Sons, 2008. 200 p.
- LOGAN, B. E., HAMELERS, B., ROZENDAL, R., SCHRÖDER, U., KELLER, J., FREGUIA, S., AELTERMAN, P., VERSTRAETE, W. e RABAEY, K. *Microbial Fuel Cells: Methodology and Technology*. *Environmental Science & Technology*, v.40, n.17, p.5181-5192. 2006.
- LOVELY, D. R. Bug juice: harvesting electricity with microorganisms. *Nature Reviews Microbiology*, v. 4, n. 7, p. 497-508, 2006.
- LU, L.; YAZDI, H.; JIN, S.; ZUO, Y.; FALLGREN, P. H.; REN, Z. J. Enhanced bioremediation of hydrocarbon-contaminated soil using pilot-scale bioelectrochemical systems. *Journal of Hazardous Materials*, v. 274, p. 8-15, 2014.
- MALKI, M.; LACEY, A. L.; RODRÍGUEZ, N.; AMILS, R.; FERNANDEZ, V. M. Preferential use of an anode as an electron acceptor by an acidophilic bacterium in the presence of oxygen. *Applied and Environmental Microbiology*, v. 74, n. 14, p. 4472-4476, 2008.
- MANSOOR, M., MARIUN, N., ISMAIL, N., & WAHAB, N. I. A. A guidance chart for most probable solution directions in sustainable energy developments. *Renewable and Sustainable Energy Reviews*, v. 24, p. 306-313, 2013.
- MANTOVANELLI, I. C., RIVERA, E. C., DA COSTA, A. C., & MACIEL FILHO, R. Hybrid neural network model of an industrial ethanol fermentation process considering the effect of temperature. *Applied biochemistry and biotechnology*, v. 137, p. 817-833, 2007.
- MANZANO-AGUGLIARO, F., ALCAYDE, A., MONTOYA, F. G., ZAPATA-SIERRA, A. e GIL, C. Scientific production of renewable energies worldwide: An overview. *Renewable and Sustainable Energy Reviews*, v.18, p.134-143. 2013.
- MARQUES, A. F. Células combustíveis microbianas aplicadas ao tratamento de efluentes. 2014. 83 f. *Mamografia (Conclusão do Curso de Engenharia Ambiental) – Escola de Engenharia de São Carlos, USP, São Carlos, 2014.*
- MATHWORKS. *Neural Networks Toolbox User's Guide*. 4ed. The Machworks, 2002, 901 p.
- MAYEN, M. D. L. A. G.; ARAÚJO, A. C. V.; DO PRADO, P. F.; CARVALHO, C. S.; DUARTE, I. C. S. Geração de eletricidade a partir de soro de queijo utilizando uma célula

- de combustível microbiana. *Revista Brasileira de Energias Renováveis*, v. 7, n. 2, p. 257-265, 2018.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, Springer, v. 5, p. 115–133, 1943.
- MERCER, J. *Microbial Fuel Cells: Generating Power from Waste*. Illumin, v.12, n. 2, 2017
- MIN, B., CHENG, S., & LOGAN, B. E. Electricity generation using membrane and salt bridge microbial fuel cells. *Water research*, v. 39, n. 9, p. 1675-1686, 2005.
- NAGY, Z. K. Model-based control of a yeast fermentation bioreactor using optimally designed artificial neural networks. *Chemical Engineering Journal*, v. 127, n. 1-3, p. 95-109, 2007.
- NATH, A.; MISHRA, A.; PANDE, P. A review of natural polymeric coagulants in wastewater treatment. *Materials Today: Proceedings*, v.46, p.6113-6117, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214785320323324>. Acesso em: 02 de setembro de 2022.
- NEVIN, K. P.; RICHTER, H.; COVALLA, S. F.; JOHNSON, J. P.; WOODARD, T. L.; ORLOFF, A. L.; JIA, H.; ZHANG, M.; LOVLEY, D. R. Power output and coulombic efficiencies from biofilms of *Geobacter sulfurreducens* comparable to mixed community microbial fuel cells. *Environmental Microbiology*, v. 10, n. 10, p. 2505-2514, 2008.
- NUCCI, E. R., SILVA, R. G., SOUZA, V. R., GIORDANO, R. L., GIORDANO, R. C., & CRUZ, A. J. Comparing the performance of multilayer perceptrons networks and neuro-fuzzy systems for on-line inference of *Bacillus megaterium* cellular concentrations. *Bioprocess and biosystems engineering*, v. 30, p. 429-438, 2007.
- OLIVEIRA, V.; SIMÕES, M.; MELO, L. & PINTO, A. M. F. R. Overview on the developments of microbial fuel cells. *Biochemical Engineering Journal* Vol.73, p.53-64, 2013. Página em: <https://www.sciencedirect.com/science/article/abs/pii/S1369703X13000235>. Acesso em: 22 nov 2023.
- PANT D.; BOGAERT G. Van.; DIELS L.; VANBROEKHOVEN K. A review of the substrates used in microbial fuel cells (MFCs) for sustainable energy production. *Bioresource Technology*, v. 101, n. 6, p. 1533-1543, Março 2010.
- PARANYCHIANAKIS, N.V., ANGELAKIS, A.N. Treatment of wastewater with slow rate systems: A review of treatment processes and plant functions. *Critical Reviews in Environmental Science and Technology*. v.36, n. 3, p.72, 2006.
- PARK, H. S.; KIM, B. H.; KIM, H. S.; KIM, H. J.; KIM, G. T.; KIM, M.; CHANG, I. S.; PARK, Y. K.; CHANG, H. I. A novel electrochemically active and Fe (III)-reducing bacterium phylogenetically related to *Clostridium butyricum* isolated from a microbial fuel cell. *Anaerobe*, v. 7, n. 6, p. 297-306, 2001.
- PHAM, C. A.; JUNG, S. J.; PHUNG, N. T.; LEE, J.; CHANG, I. S.; KIM, B. H.; YI, H.; CHUN, J. A novel electrochemically active and Fe (III)-reducing bacterium phylogenetically

related to *Aeromonas hydrophila*, isolated from a microbial fuel cell. *FEMS Microbiology Letters*, v. 223, n. 1, p. 129-134, 2003.

- POTTER, M. C. Electrical effects accompanying the decomposition of organic compounds. *Proceedings of the Royal Society of London. Series B, Containing Papers of a Biological Character*, v. 84, n. 571, p. 260- 276, 1911.
- RABAEY, K., & VERSTRAETE, W. Microbial fuel cells: novel biotechnology for energy generation. *TRENDS in Biotechnology*, v. 23, n. 6, p. 291-298, 2005.
- RABAEY, K.; BOON, N.; HÖFTE, M.; VERSTRAETE, W. Microbial phenazine production enhances electron transfer in biofuel cells. *Environmental Science & Technology*, v. 39, n. 9, p. 3401-3408, 2005.
- RABAEY, K.; BOON, N.; SICILIANO, S. D; VERHAEGE, M.; VERSTRAETE, W. Biofuel cells select for microbial consortia that self-mediate electron transfer. *Applied and Environmental Microbiology*, v. 70, n. 9, p. 5373-5382, 2004.
- RABAEY, K.; VERSTRAETE, W. Microbial fuel cells: novel biotechnology for energy generation. *TRENDS in Biotechnology*, v. 23, n. 6, p. 291-298, 2005.
- RACHINSKI, S. Uso de subprodutos da indústria agropecuária na geração de energia elétrica através de células combustíveis microbianas. *Dissertação (Mestrado em Química) – Universidade Federal do Paraná, Curitiba. 2010.*
- RACHINSKI, S.; CARUBELLI, A.; MANGONI, A. P.; MANGRICH, A. S. Microbial fuel cells used in the production of electricity from organic waste: a perspective of future. *Química Nova*, v. 33, n. 8, p. 1773- 1778, 2010.
- RAHIMNEJAD, M.; ADHAMI, A.; DARVARI, S.; ZIREPOUR, A.; OH, S. Microbial fuel cell as new technology for bioelectricity generation: a review. *Alexandria Engineering Journal*, v. 54, n. 3, p. 745-756, 2015.
- REZAEI, F.; XING, D.; WAGNER, R.; REGAN, J. M.; RICHARD, T. L.; LOGAN, B. E. Simultaneous cellulose degradation and electricity production by *Enterobacter cloacae* in a microbial fuel cell. *Applied and Environmental Microbiology*, v. 75, n. 11, p. 3673-3678, 2009.
- RISSO, C.; SUN, J.; ZHUANG, K.; MAHADEVAN, R.; DEBOY, R.; ISMAIL, W.; SHRIVASTAVA, S.; HUOT, H.; KOTHARI, S.; DAUGHERTY, S.; BUI, O.; SCHILLING, C. H.; LOVLEY, D. R.; METHÉ, B. A. Genome-scale comparison and constraint-based metabolic reconstruction of the facultative anaerobic Fe (III)-reducer *Rhodospirillum rubrum*. *BMC Genomics*, v. 10, n. 447, p. 1-19 2009.
- RODRIGUES, I. C. B. Otimização de parâmetros de construção e operação de células de energia microbiana aplicadas à remoção de sulfato. 2021. 195 f. Tese (Doutorado em Engenharia Ambiental) - Núcleo de Pesquisas e Pós-Graduação em Recursos Hídricos, Universidade Federal de Ouro Preto, Ouro Preto, 2021.

- ROZENDAL, R. A.; HAMELERS, H. V.; RABAEY, K.; KELLER, J.; BUISMAN, C. J. Towards practical implementation of bioelectrochemical wastewater treatment. *Trends in biotechnology*, v. 26, n. 8, p. 450-459, 2008.
- SANTORO, C., ARBIZZANI, C., ERABLE, B. e IEROPOULOS, I. Microbial fuel cells: From fundamentals to applications. A review. *J Power Sources*, v.356, p.225-244. 2017.
- SANTORO, C.; ARBIZZANI, C.; ERABLE, B.; IEROPOULOS, I. Microbial fuel cells: from fundamentals to applications. A review. *Journal of Power Sources*, v. 356, p. 225-244, 2017.
- SANTOS, C. C. D. Modelagem de bacias urbanas com redes neurais artificiais. Diss. Universidade de São Paulo, 2001.
- SHARMA, I.; GHANGREKAR, M. M. Evaluating the suitability of tungsten, titanium, and stainless steel wires as current collectors in microbial fuel cells. *Water Science and Technology*, v. 77, n. 4, p. 999-1006, 2018.
- SHARMA, S.; SHARMA, S.; ATHAIYA, A. Activation functions in neural networks. *Towards Data Sci*, v. 6, n. 12, p. 310–316, 2017.
- SHUKLA, A. K.; SURESH, P.; BERCHMANS, S.; RAJENDRAN, A. Biological fuel cells, and their applications. *Current Science*, v. 87, n. 4, p. 455-468, 2004.
- SILVA, R. G., PINOTTI, L. M., CRUZ, A. J., GIORDANO, R. L., & GIORDANO, R. C. Artificial neural networks to infer biomass and product concentration during the production of penicillin G acylase from *Bacillus megaterium*. *Journal of Chemical Technology & Biotechnology: International Research in Process, Environmental & Clean Technology*, v. 83, n. 5, p. 739-749, 2008.
- TENDER, L. M.; GRAY, S. A.; GROVEMAN, E.; LOWY, D. A.; KAUFFMAN, P.; MELHADO, J.; TYCE, R. C.; FLYNN, D.; PETRECCA, R.; DOBARRO, J. The first demonstration of a microbial fuel cell as a viable power supply: powering a meteorological buoy. *Journal of Power Sources*, v. 179, n. 2, p. 571-575, 2008.
- TRAPERO, J.R.; HORCAJADA, L.; LINARES, J.J. & LOBATO, J. Is microbial fuel cell technology ready? Aneconomicanswertowardsindustrialcommercialization. *Applied Energy* Vol. 185, p. 698-707, 2017. Página em: <https://www.sciencedirect.com/science/article/abs/pii/S0306261916315562>. Acesso em: 14 mar. 2023
- UGGETTI, E.; PUIGAGUT, J. Photosynthetic membrane-less microbial fuel cells to enhance microalgal biomass concentration. *Bioresource Technology*. 218, 1016-1020, 2016.
- VEIT, E. A.; ARAÚJO, I. S. Modelagem computacional aplicada ao ensino de ciências. Moreira, MA, Veit, EA *Ensino superior: bases teóricas e metodológicas*. São Paulo: EPU 225p, 2010.

- VEIT, E. A.; ARAÚJO, I. S. Modelagem computacional aplicada ao ensino de ciências. Moreira, MA, Veit, EA Ensino superior: bases teóricas e metodológicas. São Paulo: EPU 225p, 2010.
- VIRMOND, E. Potencial de cogeração de energia elétrica a partir de resíduos do processamento de sorgo sacarino. *Agroenergia em Revista*, v. 2, p. 37, 2011.
- VON SPERLING, M. Introdução à Qualidade das águas e ao tratamento de esgotos. 4ed. Belo Horizonte: Departamento de Engenharia Sanitária e Ambiental – UFMG, 2014. 470p. (Princípios do Tratamento Biológico de Águas Residuárias, volume 1).
- WANG, H.; DAVIDSON, M.; ZUO, Y.; REN, Z. Recycled tire crumb rubber anodes for sustainable power production in microbial fuel cells. *Journal of Power Sources*, v. 196, n. 14, p. 5863-5866, 2011.
- WANG, Y. F.; MASUDA, M.; TSUJIMURA, S.; KANO, K. Electrochemical regulation of the end-product profile in *Propionibacterium freudenreichii* ET-3 with an endogenous mediator. *Biotechnology and Bioengineering*, v. 101, n. 3, p. 579-586, 2008.
- WANG, Y.; NIU, C. G.; ZENG, G. M.; HU, W. J.; HUANG, D. W.; RUAN, M. Microbial fuel cell using ferrous ion activated persulfate as a cathodic reactant. *International Journal of Hydrogen Energy*, v. 36, n. 23, p. 15344-15351, 2011.
- WIDROW, B. Generalization and Information Storage in Networks of ADALINE Neurons. In: *Self Organization Systems*. Washington: Spartan Books, 1962. p.435-461.
- WIDROW, B. Generalization and Information Storage in Networks of ADALINE Neurons. In: *Self Organization Systems*. Washington: Spartan Books, 1962. p.435-461.
- WILKINSON, S. “Gastrobots”—benefits and challenges of microbial fuel cells in food powered robot applications. *Autonomous Robots*, v. 9, n. 2, p. 99-111, 2000.
- WINFIELD, J.; CHAMBERS, L. D.; ROSSITER, J.; GREENMAN, J.; IEROPOULOS, I. Urine-activated origami microbial fuel cells to signal proof of life. *Journal of Materials Chemistry A*, v. 3, n. 13, p. 7058-7065, 2015.
- WINFIELD, J.; CHAMBERS, L. D.; ROSSITER, J.; GREENMAN, J.; IEROPOULOS, I. Towards disposable microbial fuel cells: natural rubber glove membranes. *International Journal of Hydrogen Energy*, v. 39, n. 36, p. 21803-21810, 2014.
- WINFIELD, J.; CHAMBERS, L. D.; ROSSITER, J.; IEROPOULOS, I. Comparing the short and long term stability of biodegradable, ceramic and cation exchange membranes in microbial fuel cells. *Bioresource Technology*, v. 148, p. 480-486, 2013a.
- WINFIELD, J.; IEROPOULOS, I.; ROSSITER, J.; GREENMAN, J.; PATTON, D. Biodegradation and proton exchange using natural rubber in microbial fuel cells. *Biodegradation*, v. 24, n. 6, p. 733-739, 2013b.

- WRIGHTON, K. C.; AGBO, P.; WARNECKE, F.; WEBER, K. A.; BRODIE, E. L.; DESANTIS, T. Z.; HUGENHOLTZ, P.; ANDERSEN, G. L.; COATES, J. D. A novel ecological role of the Firmicutes identified in thermophilic microbial fuel cells. *The ISME Journal*, v. 2, n. 11, p. 1146-1156, 2008.
- WU, G.; BAO, H.; XIA, Z.; YANG, B.; LEI, L.; LI, Z.; LIU, C. Polypyrrole/sargassum activated carbon modified stainless-steel sponge as high-performance and low-cost bioanode for microbial fuel cells. *Journal of Power Sources*, v. 384, p. 86-92, 2018.
- WU, S.; LI, H.; ZHOU, X.; LIANG, P.; ZHANG, X.; JIANG, Y.; HUANG, X. A novel pilot-scale stacked microbial fuel cell for efficient electricity generation and wastewater treatment. *Water Research*, v. 98, p. 396-403, 2016.
- WU, W.; NIU, H.; YANG, D.; WANG, S.; JIANG, N.; WANG, J.; LIN, J.; HU, C. Polyaniline/Carbon Nanotubes composite modified anode via graft polymerization and self-assembling for microbial fuel cells. *Polymers*, v. 10, n. 7, p. 759-772, 2018.
- XING, D.; ZUO, Y.; CHENG, S.; REGAN, J. M.; LOGAN, B. E. Electricity generation by *Rhodospseudomonas palustris* DX-1. *Environmental Science & Technology*, v. 42, n. 11, p. 4146-4151, 2008.
- XU, S.; LIU, H. New exoelectrogen *Citrobacter* sp. SX-1 isolated from a microbial fuel cell. *Journal of Applied Microbiology*, v. 111, n. 5, p. 1108-1115, 2011.
- YU, J.; PARK, Y.; LEE, T. Effect of separator and inoculum type on electricity generation and microbial community in single-chamber microbial fuel cells. *Bioprocess and biosystems engineering*, v. 37, n. 4, p. 667-675, 2014.
- YUAN, Y.; ZHOU, S.; LIU, Y.; TANG, J. Nanostructured macroporous bioanode based on polyaniline-modified natural loofah sponge for high-performance microbial fuel cells. *Environmental Science & Technology*, v. 47, n. 24, p. 14525-14532, 2013.
- ZENG, L.; ZHAO, S.; HE, M. Macroscale porous carbonized polydopamine-modified cotton textile for application as an electrode in microbial fuel cells. *Journal of Power Sources*, v. 376, p. 33-40, 2018.
- ZHANG, J.; LI, J.; YE, D.; ZHU, X.; LIAO, Q.; ZHANG, B. Tubular bamboo charcoal for anode in microbial fuel cells. *Journal of Power Sources*, v. 272, p. 277-282, 2014.
- ZHANG, L.; FU, G.; ZHANG, Z. Simultaneous nutrient and carbon removal and electricity generation in a self-buffered biocathode microbial fuel cell for high-salinity mustard tuber wastewater treatment. *Bioresource Technology*, v. 272, p. 105-113, 2018.
- ZHANG, L.; ZHOU, S.; ZHUANG, L.; LI, W.; ZHANG, J.; LU, N.; DENG, L. Microbial fuel cell based on *Klebsiella pneumoniae* biofilm. *Electrochemistry Communications*, v. 10, n. 10, p. 1641-1643, 2008.
- ZHANG, X. et al. COD removal characteristics in air-cathode microbial fuel cells. *Bioresource Technology*, v. 176, p. 23-31, 2015.

- ZHANG, X.; CHENG, S.; HUANG, X.; LOGAN, B. E. The use of nylon and glass fiber filter separators with different pore sizes in air-cathode single-chamber microbial fuel cells. *Energy & Environmental Science*, v. 3, n. 5, p. 659-664, 2010.
- ZHANG, X.; CHENG, S.; WANG, X.; HUANG, X.; LOGAN, B. E. Separator characteristics for increasing performance of microbial fuel cells. *Environmental Science & Technology*, v. 43, n. 21, p. 8456-8461, 2009.
- ZHANG, Y.; ANGELIDAKI, I. Counteracting ammonia inhibition during anaerobic digestion by recovery using submersible microbial desalination cell. *Biotechnology and Bioengineering*, v. 112, n. 7, p. 1478-1482, 2015.
- ZHONG, W. H.; CAI, L. C.; WEI, Z. G.; XUE, H. J.; HAN, C.; DENG, H. The effects of closed circuit microbial fuel cells on methane emissions from paddy soil vary with straw amount. *Catena*, v. 154, p. 33-39, 2017.
- ZHOU, M., WANG, H., HASSETT, D. J. e GU, T. Recent advances in microbial fuel cells (MFCs) and microbial electrolysis cells (MECs) for wastewater treatment, bioenergy and bioproducts. *Journal of Chemical Technology & Biotechnology*, v.88, n.4, p.508-518. 2013.
- ZHOU, M.; CHI, M.; LUO, J.; HE, H.; JIN, T. An overview of electrode materials in microbial fuel cells. *Journal of Power Sources*, v. 196, n. 10, p. 4427-4435, 2011.
- ZHOU, S. et al. Nitrogen removal from water of recirculating aquaculture system by a microbial fuel cell. *Aquaculture*, v. 497, p. 74-81, 2018.
- ZHUANG, L.; ZHOU, S.; WANG, Y.; LIU, C.; GENG, S. Membrane-less cloth cathode assembly (CCA) for scalable microbial fuel cells. *Biosensors and Bioelectronics*, v. 24, n. 12, p. 3652-3656, 2009.
- ZUO, Y.; XING, D.; REGAN, J. M.; LOGAN, B. E. Isolation of the exoelectrogenic bacterium *Ochrobactrum anthropi* YZ-1 by using a U-tube microbial fuel cell. *Applied and Environmental Microbiology*, v. 74, n.10, p. 3130-3137, 2008.
- MATHWORKS. Fuzzy Logic Toolbox User's Guide. Natick, 2016, 367 p.
- ZADEH, L. A. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. *IEEE Transactions on Systems, Man and Cybernetics*, v. SMC-3, n. 1, p. 28-44, 1973.
- GOMIDE, F.; GUDWIN, R. Modelagem, Controle, Sistemas e Lógica Fuzzy. *SBA Controle & Automação*, v. 4, n. 3, p. 97-115, 1994.
- HASHMI, A.; KHAN, M. S. Diagnosis Blood Test for Liver Disease using Fuzzy Logic. *International Journal of Sciences: Basic and Applied Research (IJSBAR)*, v. 20, n. 1, p. 151-183, 2015.
- NELLES, O. Nonlinear System Identification. Berlin: Springer, 2001.

- GOMIDE, F.; GUDWIN, R. Modelagem, Controle, Sistemas e Lógica Fuzzy. SBA Controle & Automação, v. 4, n. 3, p. 97–115, 1994.
- SIMÕES, M. G.; SHAW, I. S. Controladores fuzzy baseados em regras. In: Controle de modelagem fuzzy. 2 ed., São Paulo: Blucher, 2007.
- TANSCHKEIT, R. Sistemas Fuzzy. In: Inteligência computacional aplicada a administração, economia e engenharia em matlab. São Paulo, Thomson Learning, 2007. p. 229–264.
- ZHANG, L., ZHU, X., LI, J., LIAO, Q., & YE, D. Biofilm formation and electricity generation of a microbial fuel cell started up under different external resistances. Journal of Power Sources, v. 196, n. 15, p. 6029-6035, 2011.
- SONG, H. J., CHOI, Y. T., WERELEY, N. M., & PUREKAR, A. S. Energy harvesting devices using macro-fiber composite materials. Journal of Intelligent Material Systems and Structures, v. 21, n. 6, p. 647-658, 2010.
- WANG, A., LIU, W., REN, N., CHENG, H., & LEE, D. J. Reduced internal resistance of microbial electrolysis cell (MEC) as factors of configuration and stuffing with granular activated carbon. international journal of hydrogen energy, v. 35, n. 24, p. 13488-13492, 2010.