

# EMS Baseado em Lógica Fuzzy para Aumento da Vida Útil de Baterias Considerando GD Residencial e Tarifas Dinâmicas

David Alejandro Molina Somoza  
Universidade Federal da Integração Latino-Americana  
Foz do Iguaçu – PR, Brasil  
dam.somoza.2021@aluno.unila.edu.br

João Manoel Lenz Vianna da Silva  
Universidade Federal da Integração Latino-Americana  
Foz do Iguaçu – PR, Brasil  
joao.lenz@unila.edu.br

**Resumo** — A crescente inserção de fontes renováveis intermitentes, combinado com a adoção de sistemas de armazenamento e a implementação de tarifas dinâmicas de energia, torna essencial o desenvolvimento de estratégias inteligentes de gerenciamento energético que conciliem eficiência econômica e preservação dos componentes do sistema. Nesse contexto, este trabalho desenvolve e avalia um sistema de gerenciamento de energia baseado em lógica fuzzy aplicado a uma geração distribuída residencial conectada à rede elétrica, composta por geração fotovoltaica, carga residencial, sistema de armazenamento em baterias e considerando tarifas dinâmicas de compra e venda de eletricidade. O estudo considera Londres, Reino Unido, como estudo de caso, utilizando dados de geração fotovoltaica, perfil de carga e tarifas variáveis. Os objetivos do sistema proposto são atender a carga local e o gerenciamento de energia da geração distribuída. Em segundo plano, o sistema busca preservar a vida útil da bateria, reduzindo sua degradação por ciclagem por meio de um Fuzzy Supervisor, ao mesmo tempo em que busca aproveitar momentos tarifários favoráveis, realizando a compra de energia em períodos de baixo custo e a venda em períodos de maior valor. Para auxiliar a tomada de decisão, foram utilizadas previsões de uma hora na frente obtidas por redes neurais artificiais, incluindo previsão da geração fotovoltaica e das tarifas de energia. O desempenho do controlador fuzzy foi comparado com um método heurístico determinístico baseado em regras fixas, em três cenários de operação: dados nominais, variação da tarifa de compra e aumento da carga residencial. Os resultados mostraram que o método fuzzy aumentou a vida útil da bateria em todos os cenários, apresentando um ganho médio de aproximadamente 0,97 ano, equivalente a 9,7% em relação ao método heurístico. Além disso, o controlador demonstrou capacidade de aproveitar tarifas atrativas, comprando energia em períodos de baixo custo, vendendo em momentos favoráveis e utilizando a bateria em picos de tarifa de compra. Em termos econômicos, ambos os métodos apresentaram resultados próximos, evidenciando que a estratégia fuzzy adotada priorizou a preservação da bateria, enquanto o aproveitamento tarifário atuou como objetivo secundário.

**Palavras-chave** — geração distribuída, sistema de gerenciamento de energia, lógica fuzzy, degradação por ciclagem.

## I. INTRODUÇÃO

Nos últimos anos, o setor elétrico mundial tem passado por mudanças significativas, impulsionadas pelo aumento da eletrificação e pela necessidade de reduzir as emissões associadas à geração de energia. Segundo a Agência Internacional de Energia, do inglês *International Energy Agency* (IEA), a demanda global por eletricidade cresceu 4,3% em 2024 em relação ao ano anterior, valor superior ao

crescimento médio observado nos anos anteriores, reforçando o papel cada vez mais importante da eletricidade na matriz energética mundial [1].

No Reino Unido, a transição energética tem avançado de forma significativa. O país foi um dos primeiros a estabelecer uma meta legal de emissões líquidas zero até 2050, além de ter reduzido suas emissões em aproximadamente 50% desde 1990 [2]. No setor elétrico, esse processo é observado pela redução da participação de fontes fósseis e pelo aumento da geração renovável. Em 2025, a geração renovável representou aproximadamente 52,5% da eletricidade produzida na região, sendo a energia eólica responsável por cerca de 87,1 TWh, enquanto a geração solar atingiu aproximadamente 20,0 TWh, correspondendo a 6,9% da geração total [3]. No mesmo ano, a demanda total de eletricidade no Reino Unido foi de 320,2 TWh, enquanto o consumo final pelos usuários atingiu 273,8 TWh, distribuídos entre diferentes perfis de consumidores, incluindo o setor residencial, comercial e industrial, sendo o setor residencial responsável por 93,5 TWh desse total [3].

Em um sistema tradicional, a produção de energia elétrica é realizada de forma centralizada, por meio de grandes usinas conectadas aos sistemas de transmissão e, em geral, distantes dos centros de consumo. Entretanto, tecnologias como a solar fotovoltaica ou eólica permitem que parte da geração seja instalada próxima à carga, especialmente em residências, comércios e pequenos empreendimentos [4]. Esse conceito caracteriza a geração distribuída (GD) que, de acordo com Ackermann *et al.* [5], pode ser definida como unidades de geração de pequena escala conectadas diretamente ao sistema de distribuição ou próximas ao ponto de consumo, desempenhando um papel importante na modernização e flexibilização dos sistemas elétricos.

No Reino Unido, a GD fotovoltaica tem apresentado crescimento relevante. Dados oficiais do governo britânico indicam que, ao final de fevereiro de 2026, o país possuía aproximadamente 22,0 GW de capacidade solar fotovoltaica instalada, distribuída em cerca de 2 milhões de instalações [6]. Além disso, mecanismos regulatórios como o *Smart Export Guarantee* permitem que pequenos geradores de baixo carbono recebam pagamento pela energia excedente exportada para a rede elétrica [7].

Apesar das vantagens da GD fotovoltaica, sua operação apresenta desafios devido à variabilidade da produção solar e à diferença temporal entre geração e consumo. Em sistemas residenciais, a maior produção fotovoltaica normalmente ocorre durante o dia, enquanto parte importante da demanda

pode ocorrer em outros horários. Dessa forma, surge a necessidade de coordenação entre geração fotovoltaica, carga residencial, rede elétrica e sistemas de armazenamento de energia [5].

A partir desse cenário, os Sistemas de Gerenciamento de Energia, do inglês *Energy Management Systems* (EMS), tornam-se fundamentais para coordenar a operação dos recursos energéticos distribuídos. Em sistemas compostos por geração fotovoltaica, carga residencial, rede elétrica e sistemas de armazenamento de energia por baterias (SAEB), o EMS é responsável por definir o fluxo de potência entre os diferentes elementos do sistema, buscando atender à demanda, reduzir custos operacionais, aumentar o aproveitamento da geração renovável e manter o sistema de armazenamento dentro de limites seguros de operação [8].

Entre as estratégias mais simples de EMS, e que funcionam como métodos de referência para avaliar o desempenho de novos algoritmos, destacam-se os métodos heurísticos baseados em regras fixas [9], [10]. Nesse tipo de abordagem, a tomada de decisão ocorre a partir de condições previamente definidas. A principal vantagem desse tipo de método está na simplicidade de implementação, na facilidade de interpretação e no baixo custo computacional. No entanto, como suas regras permanecem constantes durante a operação, esses métodos apresentam menor capacidade de adaptação frente à variabilidade das condições operacionais do sistema [11].

Para superar as limitações das estratégias baseadas em regras fixas, diferentes técnicas inteligentes vêm sendo aplicadas ao gerenciamento de energia em microrredes e sistemas residenciais, incluindo otimização matemática, controle preditivo, redes neurais artificiais, aprendizado por reforço e lógica fuzzy [8]. Entre essas abordagens, a lógica fuzzy apresenta a possibilidade de representar o conhecimento do sistema por meio de regras linguísticas interpretáveis, como “tarifa alta”, “excedente elevado” ou “déficit reduzido”. Com isso, o controlador consegue combinar variáveis técnicas e econômicas sem exigir um modelo matemático exato de todos os componentes do sistema [12].

A aplicação de controladores fuzzy em sistemas com geração renovável e armazenamento tem sido amplamente estudada. Arcos-Avilés *et al.* [12] propuseram um controlador fuzzy de baixa complexidade para uma microrrede residencial conectada à rede, composta por fontes renováveis e armazenamento, com o objetivo de reduzir flutuações na potência trocada com a rede e manter o estado de carga da bateria dentro de limites seguros. De forma semelhante, Castillo-Calzadilla *et al.* [13] aplicaram lógica fuzzy em um sistema residencial com armazenamento, considerando produção local, carga e tarifa elétrica. Mais recentemente, Cavus *et al.* [14] apresentaram uma estrutura de gerenciamento que combina previsão com lógica fuzzy para microrredes conectadas à rede, buscando reduzir a dependência da rede e preservar a saúde da bateria. Esses estudos indicam que o fuzzy é uma alternativa adequada quando o sistema apresenta incertezas, variáveis com comportamento não linear e múltiplos critérios de decisão.

Diante desse contexto, este trabalho desenvolve um sistema de gerenciamento de energia baseado em lógica fuzzy para uma GD residencial conectada à rede elétrica, tomando Londres, no Reino Unido, como local de estudo, devido à disponibilidade de dados públicos, à variabilidade sazonal da

geração fotovoltaica e à existência de tarifas residenciais dinâmicas de compra e venda de energia, o que permite avaliar tanto o custo da energia importada da rede quanto a possibilidade de retorno econômico pela exportação do excedente energético [7]. A modelagem da GD residencial é composta por geração fotovoltaica, carga residencial, rede elétrica e um SAEB implementando um modelo de degradação cíclica. O objetivo é gerenciar a energia da GD para atender a demanda e aproveitar a geração solar. Além disso, se busca preservar a vida útil da bateria, reduzindo sua degradação por meio de um fuzzy supervisor, que ajusta dinamicamente a atuação do SAEB conforme aumenta a degradação. Além de priorizar o uso adequado do armazenamento, o sistema busca aproveitar condições tarifárias favoráveis, incentivando a compra de energia em períodos de baixo custo e a venda em períodos de maior valor. O controlador proposto utiliza informações atuais do sistema e previsões de uma hora na frente obtidas por redes neurais artificiais para definir a operação da bateria considerando o balanço energético, as tarifas dinâmicas de compra e venda e a degradação do SAEB. Para avaliar seu desempenho, os resultados são comparados com um método heurístico determinístico baseado em regras fixas, em três cenários de operação: condição nominal, variação da tarifa de compra e aumento da carga residencial.

## II. METODOLOGIA

A metodologia adotada neste trabalho foi estruturada conforme sintetizado na Fig. 1.




Fig. 1. Fluxograma da metodologia adotada.

Neste trabalho, a metodologia foi organizada em três seções principais: descrição da arquitetura e do

dimensionamento da GD, treinamento das redes neurais artificiais de previsão e implementação dos métodos de gerenciamento de energia.

#### A. Arquitetura, Dimensionamento e Critérios de Projeto do Sistema de Geração Distribuída

A arquitetura do sistema tomou como referência o modelo proposto por [15], composto por geração fotovoltaica, SAEB, carga residencial e interface com a rede. A operação do sistema é supervisionada pelo EMS, responsável por definir a atuação da bateria de acordo com as condições energéticas e tarifárias da GD. A Fig. 2 apresenta a representação esquemática do sistema simulado.




Fig. 2. Arquitetura do sistema de geração distribuída residencial conectado à rede elétrica simulado no trabalho.

Conforme as características do sistema elétrico de baixa tensão do Reino Unido, a frequência adotada para a simulação foi de 50 Hz e uma tensão de linha de 400 V<sub>CA</sub> [16]. Essa definição foi mantida em todos os componentes do sistema, de modo a garantir coerência com as condições reais de operação do sistema analisado.

Do ponto de vista energético, a análise do sistema foi descrita a partir do balanço de potência entre geração, carga, armazenamento e rede. Assim, para cada instante  $k$ , o balanço de potência pode ser expresso como mostrado em (1),

$$P_{PV}(k) + P_{Rede}(k) + P_{BAT}(k) + P_{carga}(k) = 0 \quad (1)$$

em que  $P_{PV}(k)$  representa a potência gerada pelo sistema fotovoltaico,  $P_{carga}(k)$  a potência demandada pela carga,  $P_{BAT}(k)$  a potência associada à bateria e  $P_{Rede}(k)$  a potência trocada com a rede elétrica.

A convenção de sinais adotada considera  $P_{PV}(k)$  positiva quando se está gerando energia fotovoltaica, enquanto  $P_{carga}(k)$  se considera negativa quando a carga demanda energia. Para a bateria,  $P_{BAT}(k) > 0$  indica descarga, enquanto  $P_{BAT}(k) < 0$  indica carregamento. Para a rede elétrica,  $P_{Rede}(k) > 0$  representa importação de potência da rede, enquanto  $P_{Rede}(k) < 0$  representa exportação de potência para a rede.

Dessa forma, quando a geração fotovoltaica excede a demanda da carga, o excedente pode ser direcionado ao carregamento da bateria ou exportado para a rede elétrica. Por outro lado, em situações de déficit de geração, a carga pode ser suprida pela bateria, pela rede, ou por ambas, conforme a estratégia de gerenciamento adotada.

#### 1) Método do Sistema de Resolução

A modelagem do sistema foi desenvolvida no ambiente MATLAB/Simulink, por permitir a integração de modelos elétricos, sistemas de controle e algoritmos de gerenciamento de energia em uma mesma plataforma.

Antes da execução das simulações, foi definida a configuração numérica do modelo. No bloco *powergui*, adotou-se a solução fasorial, uma vez que o objetivo principal do trabalho é avaliar o fluxo de potência e o comportamento energético do sistema de GD ao longo do tempo a uma frequência constante. Dessa forma, a abordagem fasorial torna-se adequada para estudos no nível superior de controle, reduzindo o esforço computacional e mantendo uma representação suficiente para a operação do sistema [11].

O solver foi configurado com passo variável (*Variable-Step*), permitindo que o passo de integração seja ajustado automaticamente de acordo com a dinâmica do modelo [17]. Como método de solução, utilizou-se o *ode23tb*, recomendado para problemas complexos e adequado para equilibrar uma precisão aceitável com o menor tempo de simulação possível [18].

O passo de tempo adotado na simulação foi de uma hora, de modo que cada unidade temporal no Simulink representa 1 h de operação do sistema. Essa configuração foi escolhida para manter compatibilidade com a resolução dos dados de entrada utilizados pelo EMS, incluindo carga, geração fotovoltaica e tarifas de energia, todos tratados em intervalos horários.

#### 2) Modelagem da Carga

A carga do sistema foi representada por um perfil empírico de consumo residencial, tomando como referência dados da cidade de Heyfield, localizada no estado de Victoria, Austrália [19]. Embora proveniente de outra região, o perfil apresenta um comportamento horário característico de cargas residenciais, sendo considerado adequado para a avaliação da estratégia de gerenciamento energético desenvolvida neste trabalho.

Para a composição da demanda, selecionou-se o perfil diário de primavera correspondente a uma residência com maior nível de eletrificação, incluindo sistema de climatização e aquecimento de água por resistência elétrica padrão em tarifa diurna. Esse perfil foi escolhido por representar uma condição de consumo residencial mais exigente e por permitir a utilização de uma curva diária padronizada. Esse perfil diário foi repetido ao longo de todo o período de simulação. Com essa repetição, o consumo anual equivalente da carga resultou em 6132 kWh/ano.

Essa escolha representa uma simplificação metodológica, pois elimina a variação sazonal da demanda. No entanto, permite avaliar o desempenho do EMS sob uma condição de carga constante em termos de padrão diário, facilitando a análise dos efeitos da variação tarifária e da intermitência da geração fotovoltaica sobre as decisões de saída do controlador.

No MATLAB/Simulink, a carga foi implementada por meio do bloco *Three-Phase Dynamic Load*, conforme a abordagem utilizada em [15]. O uso do bloco e a modelagem estão representados na Fig. 3. Os parâmetros nominais do bloco foram ajustados de acordo com o sistema elétrico de baixa tensão do Reino Unido. O perfil horário de carga foi aplicado como entrada da potência ativa da carga, enquanto a potência reativa foi considerada nula. Essa simplificação foi

adotada, tanto no modelo da carga quanto dos demais componentes, porque o foco do trabalho está no gerenciamento dos fluxos de potência ativa dos componentes da GD residencial, não sendo objetivo da pesquisa a análise detalhada de variações de tensão ou de potência reativa [20].




Fig. 3. Modelo Simulink de uma carga variável [15].

### 3) Modelagem e Dimensionamento do Sistema Fotovoltaico

O sistema fotovoltaico foi modelado por meio do bloco *Simple Solar Inverter*, disponível na biblioteca utilizada em [15], conforme mostrado na Fig. 4. Esse bloco representa de forma simplificada a interface entre a geração fotovoltaica e o sistema trifásico, permitindo inserir diretamente o perfil de potência ativa. Com isso, evita-se a modelagem detalhada dos conversores eletrônicos de potência e garante-se que a potência injetada no sistema corresponda ao perfil de geração desejado.




Fig. 4. Modelo Simulink do sistema Fotovoltaico simplificado [15].

Como o bloco utiliza a convenção de potência absorvida pela rede, o sinal da potência fotovoltaica foi invertido antes de ser aplicado à entrada do inversor, de modo que a geração fosse representada como potência injetada no sistema elétrico, e não como uma carga. As demais configurações do bloco foram mantidas padrões ao colocado por [15], exceto os parâmetros do sistema elétrico.

Os dados de geração fotovoltaica foram obtidos para o ano 2019 por meio do PVGIS (*Photovoltaic Geographical Information System*), uma aplicação web desenvolvida pelo *Joint Research Centre* da Comissão Europeia para estimar dados de radiação solar e produção de sistemas fotovoltaicos [21]. Para a simulação, foram adoptadas as configurações padrões do aplicativo, considerado um sistema fotovoltaico conectado à rede, com plano fixo, tecnologia de silício cristalino, base de dados PVGIS-SARAH3 e perdas totais do sistema de 14%.

A potência de pico fotovoltaico ( $P_{FV,pico}$ ) configurada no aplicativo foi dimensionada por meio de

$$P_{FV,pico} = \frac{C_{carga}}{Y_{esp} \cdot (1 - P_{totais})} \quad (2)$$

sendo que o cálculo baseia-se no consumo anual da residência ( $C_{carga}$ ), nas perdas totais do sistema ( $P_{totais}$ ) e no rendimento específico médio estabelecido para Londres ( $Y_{esp}$ ), fixado em 1000 kWh/kWp [22]. No final, foi obtido um valor de 7,13 kWhp.

### 4) Modelagem e Dimensionamento do Sistema de Armazenamento de Energia

O SAEB utilizado neste trabalho foi desenvolvido a partir da estrutura apresentada em [15]. O modelo original considerava a possibilidade de operação ilhada; entretanto, essa funcionalidade foi retirada, uma vez que o sistema analisado corresponde a uma GD residencial conectada à rede elétrica. Além disso, foi incorporado ao modelo um cálculo de degradação por ciclagem, permitindo considerar a perda progressiva da capacidade nominal da bateria ao longo da simulação.

A estrutura final do SAEB é apresentada na Fig. 5. O modelo recebe como entrada a potência ativa de referência, definida pelo sistema de gerenciamento de energia. Dessa forma, a operação da bateria foi realizada apenas em função da potência ativa, responsável pelas ações de carga e descarga. Como saída, o modelo fornece a potência trocada pela bateria com o sistema trifásico principal e o estado de carga da bateria (EDC).




Fig. 5. Modelo do SAEB implementado no Simulink.

Na entrada do SAEB, o bloco de saturação limita a potência de referência de acordo com a potência nominal de carga e descarga da bateria. Em seguida, o bloco de limite de carga verifica o EDC e impede que a bateria opere fora dos limites estabelecidos. Por fim, o bloco de cálculo do estado de carga atualiza o EDC da bateria a partir da potência efetivamente processada.

A potência ativa de referência do SAEB é fornecida pelo EMS, podendo ser proveniente do método heurístico ou do controlador fuzzy, conforme mostra a Fig. 6. Nessa estrutura, os métodos de gerenciamento recebem como entradas as principais variáveis da GD, como potência demandada pela carga, potência fotovoltaica, EDC e tarifas de compra e venda de energia.




Fig. 6. Integração entre o sistema de armazenamento e os métodos de gerenciamento de energia.

#### a) Estado de Carga (SoC, State of Charge)

O cálculo do EDC baseou-se na metodologia proposta por [15]. O EDC instantâneo é calculado por

$$EDC(t) = EDC(0) - \left[ \frac{\int P_{corr}(t) dt}{C_{nom} * SOH(t)} \right] * 100 \quad (3)$$

$$P_{corr}(t) = \begin{cases} \eta * P_{in}(t), & \text{se } P_{in}(t) \leq 0 \\ \frac{P_{in}(t)}{\eta}, & \text{se } P_{in}(t) > 0 \end{cases} \quad (4)$$

onde  $EDC(0)$  é o estado de carga inicial da bateria,  $P_{corr}(t)$  a potência corrigida pela eficiência,  $C_{nom}$  a capacidade nominal da bateria,  $SOH$  o estado de saúde da bateria, em inglês *State of Health*,  $P_{in}$  a potência de entrada no bloco da bateria e  $\eta$  a eficiência da bateria.

A bateria utilizada como referência foi a Pylontech US5000, baseada na tecnologia de íon-lítio do tipo LiFePO. Essa escolha foi feita por se tratar de uma bateria aplicada em sistemas estacionários de armazenamento e por apresentar informações técnicas que permitem relacionar a vida útil com a profundidade de descarga, do inglês *Depth of Discharge* (DoD) [23]. As principais configurações da bateria e os parâmetros adotados no modelo são apresentados na Tabela I.

TABELA I. CONFIGURAÇÕES E PARÂMETROS IMPLEMENTADOS NA MODELAGEM DO SISTEMA DE ARMAZENAMENTO

| Parâmetros                           | Valor                |
|--------------------------------------|----------------------|
| Capacidade nominal por bateria [kWh] | 3,552 <sup>a</sup>   |
| Potência nominal por bateria [kW]    | 1,78 <sup>a</sup>    |
| Preço por bateria [R\$]              | 5036,56 <sup>a</sup> |
| EDC máximo [%]                       | 80                   |
| EDC mínimo [%]                       | 20                   |
| EDC inicial [%]                      | 50                   |

a. Obtidos de [23]

Como a operação foi limitada ao intervalo entre 20% e 80% de EDC, com o objetivo de evitar descargas profundas, apenas 60% da capacidade nominal foi considerada útil para carga e descarga. Considerando o perfil residencial utilizado neste trabalho, cuja carga média é de aproximadamente 0,7 kWh por hora, foram adotadas três baterias para permitir o suprimento da residência por cerca de 9 horas em condição média de consumo. Durante as simulações assumiu-se uma distribuição de potência igual entre as baterias.

#### b) Degradação por ciclagem da bateria

A degradação por ciclagem foi calculada com base no método apresentado por Manwell *et al.* [24], no qual o dano acumulado da bateria é obtido pela relação entre o número de ciclos realizados e o número de ciclos até a falha para uma determinada profundidade de descarga. O dano total pode ser expresso por (5), onde  $D$  é o dano total causado à bateria,  $i$  o número de ciclos,  $N_i$  o ciclo “i” e  $C_{F,i}$  o número de ciclos até a falha para o ciclo “i” e DoD de valor “F”.

$$D = \sum_{i=1}^{N_{DoD}} N_i \frac{1}{C_{F,i}} \quad (5)$$

Para a identificação dos ciclos e semiciclos ao longo da operação, foi utilizado o método de contagem de ciclos *Rainflow* na forma *on-line* [25]. Diferentemente do método *Rainflow* tradicional, que realiza a contagem de ciclos a partir de todo o histórico de dados previamente conhecido, a abordagem *on-line* permite a identificação incremental dos ciclos à medida que os dados são gerados, sendo mais adequada para simulações dinâmicas e aplicações em tempo real, como no presente estudo.

A relação entre a DoD e o número de ciclos até a falha foi obtida a partir da curva de vida útil obtida pelo vendedor web da bateria [26]. Para isso, os pontos da curva foram extraídos utilizando a ferramenta *WebPlotDigitizer* e, posteriormente, foram importados para o MATLAB, onde foi realizada uma regressão não linear por mínimos quadrados.

Para representar o comportamento não linear da degradação da bateria, foi adotado um modelo de função exponencial dupla [24], conforme mostrado em (6), onde  $C_F$  são os ciclos até a falha,  $a_i$  são as constantes de *Fitting* e DoD a profundidade de descarga. Esse modelo foi definido no MATLAB por meio da função *fittype*, permitindo estimar os coeficientes da equação a partir dos dados coletados da curva da bateria. O processo de ajuste foi realizado com o algoritmo *Trust-Region*, que é adequado para problemas não lineares com restrições, sendo impostos limites aos coeficientes para garantir coerência física do modelo, especialmente para os termos exponenciais, que foram restringidos a valores negativos [27]. O MATLAB então ajusta iterativamente os parâmetros da equação de forma a minimizar o erro entre os valores medidos e os valores estimados pelo modelo.

$$C_F = a_1 + a_2 \cdot a_3^{DoD} + a_4 \cdot a_5^{DoD} \quad (6)$$

Após a implementação do método de ajuste de curva, os coeficientes obtidos foram:  $a_1 = 5189$ ,  $a_2 = 8000$ ,  $a_3 = -5$ ,  $a_4 = 20.831,67$  e  $a_5 = -0,0356$ .

Neste trabalho, a bateria foi considerada operacional até atingir um SOH de 60%, valor considerada como limite inferior para aplicações de segunda vida em sistemas estacionários [28]. Na simulação, isso foi implementado através do bloco *Stop Simulation* o qual foi configurado para terminar a simulação quando  $SOH \leq 60\%$ . Embora esse valor tenha sido adotado como limite de operação para a aplicação principal, a bateria ainda pode apresentar valor residual para aplicações estacionárias menos exigentes. De acordo com Bach *et al.* [29], baterias de LiFePO podem ser vendidas entre 13-59% do custo de uma bateria nova. Neste estudo, se considerou uma porcentagem de venda de 23%, impactando na análise econômica.

### 5) Ponto de conexão de alimentação principal

A conexão da GD com a rede elétrica principal foi modelada por meio do bloco *Three-Phase Source*, proveniente da biblioteca utilizada no modelo de referência [15]. Esse bloco representa o ponto de alimentação da rede no qual o sistema residencial está conectado, permitindo a importação ou exportação de energia conforme o balanço de potência da GD.

Para representar as condições do local de estudo, a fonte trifásica foi configurada com tensão fase-fase de 11 kV<sub>CA</sub> e frequência de 50 Hz [30]. Esse nível de tensão corresponde ao lado de média tensão da rede, sendo posteriormente adequado ao nível de baixa tensão por meio de um transformador trifásico de dois enrolamentos.

O transformador utilizado foi configurado com potência nominal de 250 kVA e frequência nominal de 50 Hz [30]. Seus enrolamentos foram definidos com tensão fase-fase de 11 kV<sub>CA</sub> no lado primário e 400 V<sub>CA</sub> no lado secundário, permitindo a conexão do sistema residencial ao barramento principal da GD. As demais configurações da fonte e do transformador foram mantidas conforme o modelo de referência adotado.

### B. Modelo Autorregressivo não Linear para Predições das Variáveis

Diferentemente do método heurístico, que toma decisões apenas com base nas condições instantâneas do sistema, os controladores fuzzy desenvolvidos neste trabalho utilizam também previsões com horizonte de um passo à frente, correspondente a uma hora. A escolha da utilização de previsões de curto prazo foi fundamentada conforme na metodologia proposta em [11]. Essas previsões foram aplicadas às principais variáveis da GD, incluindo a geração fotovoltaica, a demanda da carga e as tarifas de compra e venda de energia.

Essas variáveis apresentam comportamento temporal com variações significativas ao longo do dia, influenciadas por fatores como disponibilidade solar, perfil de consumo residencial e dinâmica tarifária. Por esse motivo, a representação dessas séries por modelos lineares pode não ser suficiente para capturar adequadamente suas variações. Nesse contexto, foram utilizadas redes neurais artificiais com estrutura autorregressiva não linear, capazes de identificar relações temporais a partir dos dados históricos e estimar o valor futuro das variáveis analisadas [11].

O treinamento das redes neurais tomou como base a metodologia apresentada em [11], na qual são utilizados modelos disponíveis no ambiente MATLAB para previsão de séries temporais. Entretanto, diferentemente da referência adotada, neste trabalho foram avaliadas diferentes configurações das redes, variando parâmetros de treinamento [31]. A escolha do modelo final foi realizada avaliando o menor erro quadrático médio (MSE) de validação (7) [32], enquanto para quantificar a precisão das previsões foram utilizados o erro médio absoluto (MAE) (8) e o coeficiente de determinação ( $R^2$ ) (9) [33]. Onde  $N$  representa o número de amostras,  $y_i$  o valor real,  $\hat{y}_i$  o valor estimado e  $\bar{y}$  a média dos valores reais.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (9)$$

### 1) Modelo de Predição da Produção Solar

Para a predição da produção fotovoltaica, foi utilizada uma NARXNET (Rede Neural Autorregressiva Não Linear com Entradas Exógenas). Esse tipo de rede é adequado para séries temporais em que o valor futuro depende tanto dos valores passados da própria variável quanto de informações externas relacionadas ao comportamento do sistema [34].

Como a previsão é de curto prazo, não é necessário o uso de variáveis meteorológicas, como irradiação e temperatura, como variáveis exógenas. De acordo com Pedro *et al.* [35], o próprio histórico recente de geração já embute os impactos climáticos imediatos, como a passagem de nuvens. Essa escolha metodológica simplifica o modelo e reduz sua carga computacional. Assim, adotaram-se apenas a hora e o mês como variáveis exógenas para informar à rede neural a trajetória do sol e a sazonalidade, deixando para o histórico de geração o papel de ajustar as oscilações momentâneas.

Para evitar descontinuidades artificiais nas variáveis temporais, a hora e o mês foram codificados de forma cíclica por meio de funções seno e cosseno. Assim, a hora 23 e a hora 0, por exemplo, passam a ser representadas como instantes próximos no ciclo diário, e não como valores numericamente distantes [36]. O mesmo foi aplicado ao mês do ano. As entradas exógenas utilizadas na rede foram, portanto, dadas por (10) e (11), onde  $X$  é o valor da característica cíclica (por exemplo, mês e hora),  $T$  é o período de ciclo (por exemplo, 12 para meses e 23 para horas),  $X_{\sin}$  é o valor transformado pelo seno e  $X_{\cos}$  é o valor transformado pelo cosseno.

$$X_{\sin} = \sin\left(2 \cdot \pi \cdot \frac{X}{T}\right) \quad (10)$$

$$X_{\cos} = \cos\left(2 \cdot \pi \cdot \frac{X}{T}\right) \quad (11)$$

O treinamento foi realizado utilizando dados históricos de produção solar correspondentes ao período de 2011 a 2018, totalizando oito anos de dados horários. A mesma fonte de dados e as mesmas configurações adotadas na modelagem do sistema fotovoltaico foram mantidas nesta etapa, garantindo coerência entre os dados utilizados no dimensionamento e os dados empregados na predição.

A rede foi implementada no MATLAB por meio da função *narxnet*, utilizando treinamento em malha aberta. Foram avaliadas diferentes configurações de atrasos e número de neurônios na camada oculta. Os atrasos testados variaram de 3 a 24 horas, com passo de 3 horas, enquanto o número de neurônios variou de 5 a 20, com passo de 5 neurônios. O algoritmo de treinamento utilizado foi o Levenberg-Marquardt, definido pela função *trainlm*, devido a ser um dos algoritmos de treinamento mais rápidos [37].

Conforme [11], os dados foram divididos em 70% para treinamento, 15% para validação e 15% para teste, respeitando a ordem temporal da série. Essa configuração também foi mantida para o modelo de predição das tarifas. A melhor configuração encontrada apresentou atraso de 3 horas e 20 neurônios na camada oculta, sendo selecionada com base no menor MSE de validação. Ao final do processo, essa rede foi exportada para o Simulink para ser integrada ao sistema de gerenciamento de energia.

### 2) Modelo de Predição das Tarifas de Compra e Venda

Para a predição das tarifas de compra e venda de energia, foi utilizada uma NARNET (Rede Neural Autorregressiva Não Linear) [11]. Diferentemente da rede NARXNET utilizada para a produção fotovoltaica, a NARNET realiza a predição a partir dos valores passados da própria série temporal, sem a inclusão de entradas exógenas [38].

Os dados tarifários foram obtidos a partir da *Octopus Energy*, empresa fornecedora de energia do Reino Unido que disponibiliza tarifas inteligentes e dados públicos por meio de sua plataforma [39]. Para a compra de energia, foi utilizada a tarifa *Agile Octopus*, na versão *August 2022 v1*. Para a venda de energia à rede, foi considerada a tarifa *Agile Outgoing Octopus*, na versão *May 2019*. Ambas apresentam preços dinâmicos definidos em intervalos de 30 minutos. Entretanto, para manter a resolução temporal adotada nas demais variáveis do trabalho, os dados foram reorganizados em valores horários.

O treinamento das redes foi realizado com dados correspondentes aos anos de 2023 e 2024, enquanto os dados de 2025 foram reservados para aplicação nas simulações do sistema de GD. As redes de compra e venda foram treinadas separadamente, mantendo o mesmo procedimento metodológico.

A rede foi implementada no MATLAB por meio da função *narnet*, utilizando treinamento em malha aberta. Foram testadas diferentes configurações de atrasos e número de neurônios na camada oculta. Os atrasos avaliados variaram de 6 a 84 horas, com passo de 6 horas, enquanto o número de neurônios variou entre 10, 15 e 20. Ao igual que a previsão solar, o algoritmo de treinamento utilizado foi o Levenberg-Marquardt.

Para a tarifa de compra, a melhor configuração encontrada foi de 54 atrasos e 10 neurônios na camada oculta, enquanto para a tarifa de venda a melhor configuração foi de 60 atrasos e 10 neurônios. Ao final do treinamento, as redes selecionadas foram exportadas para o Simulink.

### 3) Predição da Carga

Para a carga residencial, não foi realizado o treinamento de uma rede neural artificial, pois a demanda foi representada por um perfil diário típico repetido ao longo da simulação. Assim, para manter a coerência com as demais variáveis previstas utilizadas pelos controladores fuzzy, adotou-se uma variável auxiliar correspondente à carga uma hora à frente, definida simplesmente pelo valor do perfil no instante seguinte.

### C. Sistemas de Gerenciamento de Energia

Neste trabalho, foram avaliadas duas abordagens de gerenciamento: um método heurístico determinístico e controladores baseados em lógica fuzzy. O método heurístico foi utilizado como estratégia de referência, por apresentar uma lógica simples, direta e baseada em regras fixas de operação [11]. Em câmbio, a lógica fuzzy foi adotada por permitir a construção de regras de decisão a partir de variáveis linguísticas, tornando o método adequado para sistemas com comportamento variável, como o presente estudo. Além disso, a lógica fuzzy permite incorporar critérios técnicos e econômicos sem exigir um modelo matemático exato de todo o sistema [11], [40], [41].

Para comparar o desempenho dos métodos de gerenciamento em diferentes condições de operação, foram avaliados três cenários de simulação.

- **Cenário 1:** corresponde à condição nominal do sistema, utilizando os dados originais de geração fotovoltaica, carga residencial e tarifas de energia.
- **Cenário 2:** considera variações na tarifa de compra de energia, implementadas por meio de um código em MATLAB. Nesse caso, para cada mês, os dias foram selecionados de forma proporcional, de modo que aproximadamente um terço apresentasse aumento de 30% na tarifa de compra, um terço apresentasse redução de 30% e o terço restante permanecesse com os valores originais.
- **Cenário 3:** considera variações na carga residencial, no qual aproximadamente um terço dos dias de cada mês teve a demanda aumentada em 30% durante todo o dia.

Essa forma de construção dos cenários foi adotada para avaliar as técnicas de EMS frente às variações inesperadas de perfis, assim como manter a proporcionalidade das alterações ao longo dos meses e permitir uma comparação mais equilibrada entre os métodos de gerenciamento avaliados.

#### 1) Método Heurístico

A lógica de operação é baseada no balanço instantâneo entre a potência fotovoltaica gerada e a potência demandada pela carga, sem utilizar previsões. Quando há excedente de geração fotovoltaica, o método prioriza o carregamento da bateria, respeitando os limites de potência e do EDC; caso a bateria não possa absorver todo o excedente, a energia restante é exportada para a rede. Em situações de déficit de geração, a bateria é utilizada para suprir a carga, desde que o estado de carga permita a descarga; caso contrário, a energia necessária é importada da rede. As regras de funcionamento adotadas para esse método estão apresentadas na Fig. 7.




Fig. 7. Fluxograma do Algoritmo Heurístico [11].

## 2) Método Fuzzy

O sistema de gerenciamento baseado em lógica fuzzy foi construído no MATLAB utilizando a *toolbox Neuro-Fuzzy Designer*, enquanto no Simulink a modelagem foi realizada por meio do bloco *Fuzzy Logic Controller with Rule Viewer*. Foi adotado o método de inferência Mamdani, devido à sua

maior interpretabilidade e facilidade de representação por meio de regras linguísticas [42]. A lógica geral é apresentada na Fig. 8, organizada em quatro etapas: variáveis de entrada e previsão, pré-processamento, tomada de decisão e saída de controle.




Fig. 8. Arquitetura geral do sistema de gerenciamento de energia baseado em previsão e controle fuzzy.

Na primeira etapa da Fig. 8, são utilizadas como entradas as tarifas de compra e venda, a geração fotovoltaica, o EDC, a carga atual e a carga prevista para a próxima hora. As tarifas são processadas por redes NARNET, responsáveis por estimar os preços uma hora à frente, enquanto a geração fotovoltaica é prevista por uma rede NARNXNET.

Em seguida, as variáveis atuais e previstas são organizadas no bloco de pré-processamento. Nessa etapa, são calculadas as variáveis auxiliares utilizadas pelos controladores fuzzy:  $Modo_{BAL}$ ,  $E_N$ ,  $V_T$ ,  $B_{PN}$ ,  $D_N$  e  $C_T$ . O  $Modo_{BAL}$  define a condição atual de operação do sistema a partir da diferença entre geração fotovoltaica e carga, classificando-a como excedente, déficit ou equilíbrio. As variáveis  $E_N$  e  $D_N$  representam, respectivamente, o excedente e o déficit normalizados em relação à potência nominal do SAEB. Já  $B_{PN}$  representa o balanço previsto normalizado, obtido a partir da previsão de geração fotovoltaica e da carga prevista. Por fim,  $V_T$  e  $C_T$  indicam as tendências das tarifas de venda e compra, calculadas a partir da diferença entre os valores previstos e atuais.

A etapa de tomada de decisão é composta por dois controladores fuzzy. O Fuzzy Excedente é utilizado quando há sobra de geração fotovoltaica e avalia se a energia deve ser usada para carregar a bateria, vendida para a rede ou se o sistema deve permanecer em repouso. O Fuzzy Déficit atua quando a geração não atende a carga, avaliando se a demanda deve ser suprida pela bateria, pela rede elétrica ou se o SAEB deve permanecer em repouso.

As saídas desses dois controladores são enviadas ao seletor de modo/decisão final, que escolhe a ação correspondente à condição definida pelo  $Modo_{BAL}$ . Assim, a ação final pode assumir uma das seguintes condições: vender energia, carregar a bateria, manter repouso, descarregar a bateria ou comprar energia da rede. Nos casos em que a decisão é vender ou comprar energia, a ação corresponde à

potência nominal da bateria, enquanto nas demais ações o valor é definido de acordo com os balanços entre a geração fotovoltaica e a carga atuais.

Para priorizar o aumento da vida útil das baterias, também foi desenvolvido um Fuzzy Supervisor associado à degradação da bateria. Esse bloco recebe a informação da degradação da bateria e gera um fator de correção aplicado à ação final. Dessa forma, quando a bateria apresenta maior degradação, a solicitação do SAEB pode ser reduzida, contribuindo para preservar sua vida útil. Por fim, a ação corrigida é enviada ao SAEB como sinal de controle. As funções de pertinência e as regras de cada controlador fuzzy são apresentadas nas subseções seguintes.

### a) Fuzzy Excedente

As entradas desse sistema são o EDC, a tarifa de venda atual ( $T_{V,Atual}$ ), o excedente normalizado ( $E_N$ ), o balanço previsto normalizado ( $B_{PN}$ ) e a tendência da tarifa de venda ( $V_T$ ). A saída é representada por  $Ação_E$ , que indica a ação recomendada para a condição de excedente.

De forma geral, as regras foram construídas para priorizar o carregamento da bateria quando o EDC está baixo ou médio. Por outro lado, a venda de energia passa a ser favorecida quando a bateria apresenta EDC elevado, quando a tarifa de venda é alta ou quando a tendência tarifária indica que o preço pode cair. Em condições nas quais a bateria está carregada e a venda não é vantajosa, o controlador pode indicar repouso, evitando ciclos desnecessários. As funções de pertinência, com seus respectivos universos de discurso, são apresentadas na Fig. 9, enquanto a Tabela 2 apresenta as 17 regras utilizadas para esse sistema fuzzy. É importante ressaltar que as funções de pertinência, as regras e os pesos foram configurados e ajustados de forma empírica com base ao entendimento das variáveis de entrada e dos objetivos do trabalho [12].




Fig. 9. Funções de pertinência do sistema fuzzy para gerenciamento do excesso de potência.

TABELA II. BASE DE REGRAS DO SISTEMA FUZZY PARA GERENCIAMENTO DO EXCESSO DE POTÊNCIA.

| Regra | Variáveis de Entrada |               |       |            |           | Saída             | Peso |
|-------|----------------------|---------------|-------|------------|-----------|-------------------|------|
|       | EDC                  | $T_{V,Atual}$ | $E_N$ | $B_{PN}$   | $V_T$     | Ação <sub>E</sub> |      |
| 1     | Baixo                | -             | -     | -          | -         | Carregar PV       | 1    |
| 2     | Medio                | Baixa         | -     | -          | -         | Carregar PV       | 1    |
| 3     | Medio                | Alta          | -     | Deficit    | -         | Carregar PV       | 1    |
| 4     | Medio                | Alta          | -     | -          | Vai Subir | Carregar PV       | 0.9  |
| 5     | Medio                | Alta          | Alto  | -          | Vai Cair  | Vender            | 0.9  |
| 6     | Medio                | Alta          | Alto  | Excedente  | Vai Cair  | Vender            | 0.9  |
| 7     | Medio                | Alta          | Alto  | Excedente  | Estavel   | Vender            | 0.75 |
| 8     | Medio                | Alta          | Baixo | -          | -         | Carregar PV       | 0.8  |
| 9     | Alto                 | Baixa         | Alto  | Deficit    | -         | Carregar PV       | 0.75 |
| 10    | Alto                 | Baixa         | -     | -          | -         | Repouso           | 0.8  |
| 11    | Alto                 | Alta          | -     | -          | Vai Cair  | Vender            | 1    |
| 12    | Alto                 | Alta          | -     | Excedente  | -         | Vender            | 0.9  |
| 13    | Alto                 | Alta          | Alto  | Equilibrio | Vai Cair  | Vender            | 0.85 |
| 14    | Alto                 | Alta          | -     | Deficit    | Vai Subir | Repouso           | 1    |
| 15    | Alto                 | Alta          | Baixo | Deficit    | -         | Repouso           | 0.9  |
| 16    | Medio                | -             | -     | -          | -         | Carregar PV       | 0.2  |
| 17    | Alto                 | -             | -     | -          | -         | Repouso           | 0.2  |

#### b) Fuzzy Déficit

As entradas desse sistema são o EDC, a tarifa de compra atual ( $T_{CA,Atual}$ ), o déficit normalizado ( $D_N$ ), o balanço previsto normalizado ( $B_{PN}$ ) e a tendência da tarifa de compra ( $C_T$ ). A saída é representada por Ação<sub>D</sub>, que indica a ação recomendada para a condição de déficit.

De forma geral, as regras foram construídas para priorizar a compra de energia da rede quando a tarifa de compra é muito baixa, mesmo em situações de déficit, pois essa

condição pode ser economicamente mais vantajosa. Por outro lado, quando a tarifa de compra é alta e a bateria apresenta EDC suficiente, o controlador tende a priorizar o uso do SAEB para abastecer a carga. Em condições de EDC baixo, déficit reduzido ou quando o balanço previsto indica melhora da condição energética, o sistema pode indicar repouso. As funções de pertinência, com seus respectivos universos de discurso, são apresentadas na Fig. 10, enquanto a Tabela 3 apresenta as 22 regras utilizadas para esse sistema fuzzy.




Fig. 10. Universos de discurso e funções de pertinência do controlador fuzzy de déficit.

TABELA III. REGRAS DE INFERÊNCIA DO CONTROLADOR FUZZY DE DÉFICIT.

| Regra | Variáveis de Entrada |              |       |            |           | Saída             | Peso |
|-------|----------------------|--------------|-------|------------|-----------|-------------------|------|
|       | EDC                  | $T_{Catual}$ | $D_N$ | $B_{PN}$   | $C_T$     | Ação <sub>D</sub> |      |
| 1     | Baixo                | Muito Baixa  | -     | -          | -         | Comprar Rede      | 1    |
| 2     | Baixo                | Baixa        | -     | -          | -         | Repouso           | 1    |
| 3     | Baixo                | Alta         | Baixo | -          | -         | Repouso           | 1    |
| 4     | Baixo                | Alta         | Alto  | Deficit    | Vai Subir | Abastecer Casa    | 0.55 |
| 5     | Baixo                | Alta         | Alto  | Deficit    | Estavel   | Abastecer Casa    | 0.45 |
| 6     | Medio                | Muito Baixa  | -     | Deficit    | -         | Comprar Rede      | 1    |
| 7     | Medio                | Muito Baixa  | -     | -          | Vai Subir | Comprar Rede      | 1    |
| 8     | Medio                | Muito Baixa  | -     | Equilibrio | Estavel   | Comprar Rede      | 0.8  |
| 9     | Medio                | Muito Baixa  | -     | Excedente  | -         | Repouso           | 0.9  |
| 10    | Alto                 | Muito Baixa  | -     | -          | -         | Repouso           | 0.9  |
| 11    | Medio                | Alta         | -     | -          | -         | Abastecer Casa    | 1    |
| 12    | Alto                 | Alta         | -     | -          | -         | Abastecer Casa    | 1    |
| 13    | Medio                | Baixa        | Alto  | Deficit    | -         | Abastecer Casa    | 0.9  |
| 14    | Medio                | Baixa        | Alto  | -          | Vai Subir | Abastecer Casa    | 0.85 |
| 15    | Alto                 | Baixa        | Alto  | -          | -         | Abastecer Casa    | 0.9  |
| 16    | Alto                 | Baixa        | -     | Deficit    | -         | Abastecer Casa    | 0.8  |
| 17    | Alto                 | Baixa        | -     | -          | Vai Subir | Abastecer Casa    | 0.8  |
| 18    | Medio                | Baixa        | Baixo | -          | Vai Cair  | Repouso           | 0.9  |
| 19    | Medio                | Baixa        | -     | Excedente  | -         | Repouso           | 0.9  |
| 20    | Alto                 | Baixa        | Baixo | Excedente  | -         | Repouso           | 0.8  |
| 21    | Medio                | -            | -     | -          | -         | Repouso           | 0.2  |
| 22    | Alto                 | -            | -     | -          | -         | Repouso           | 0.2  |

### c) Fuzzy Supervisor

O Fuzzy Supervisor foi desenvolvido para ajustar a intensidade da ação enviada ao SAEB de acordo com a condição de degradação da bateria. Como mostrado na Fig. 11, esse sistema possui como entrada a variável Degradação, classificada em Normal, Alerta e Crítico, e como saída o Multiplicador, responsável por modificar a ação final do

controlador. Quando a degradação está em condição normal, a ação do SAEB é mantida de forma total; em condição de alerta, a atuação é moderada; e em condição crítica, a ação é restringida, reduzindo solicitações excessivas da bateria. As funções de pertinência, com seus respectivos universos de discurso, são apresentadas na Fig. 11, enquanto a Tabela 4 apresenta as três regras utilizadas nesse sistema fuzzy.




Fig. 11. Universos de discurso e funções de pertinência do controlador fuzzy supervisor.

TABELA IV. REGRAS DE INFERÊNCIA DO CONTROLADOR FUZZY SUPERVISOR.

| Regra | Entrada           | Saída                | Peso |
|-------|-------------------|----------------------|------|
|       | <i>Degradação</i> | <i>Multiplicador</i> |      |
| 1     | Normal            | Total                | 1    |
| 2     | Alerta            | Moderado             | 1    |
| 3     | Crítico           | Restrito             | 1    |

#### D. Declaração do Uso de Ferramentas de Inteligência Artificial

A elaboração deste estudo contou com o apoio de modelos de inteligência artificial, sempre sob revisão e validação do autor. O uso foi nas seguintes áreas: apoio na pesquisa bibliográfica e no estudo de conceitos, *brainstorm* para a estruturação de ideias soltas, revisão e estruturação da escrita do artigo, geração dos *scripts* que produzem as figuras dos resultados e das funções de pertinência dos sistemas fuzzy, apoio nas implementações de códigos dentro do MATLAB (como método *rainflow on-line* e treinamento das redes neurais) e na implementação dos sistemas fuzzy, ajudando na redução das regras, colocações dos pesos e definição das funções de pertinência. A Tabela 5 resume as ferramentas e suas atribuições.

TABELA V. FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL UTILIZADAS E SUAS ATRIBUIÇÕES

| Modelo                       | Ano  | Desenvolvedor | Atribuição dentro do estudo                                                                                                         |
|------------------------------|------|---------------|-------------------------------------------------------------------------------------------------------------------------------------|
| GPT-5.5                      | 2026 | OpenAI        | Apoio bibliográfico, <i>brainstorm</i> , revisão da escrita, figuras dos resultados e metodologia, código do MATLAB e método Fuzzy. |
| Gemini 3.1 Pro               | 2026 | Google        | Apoio bibliográfico, <i>brainstorm</i> , código do MATLAB.                                                                          |
| NotebookLM (Versão Gratuito) | 2026 | Google Labs   | Estudo de conceitos e de referências.                                                                                               |

### III. RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados obtidos a partir da simulação dos métodos de gerenciamento de energia implementados. A análise foi organizada em quatro subseções. Nas três primeiras, são apresentados e discutidos os resultados correspondentes a cada cenário simulado considerando a comparação entre o método heurístico e o método fuzzy. Por fim, a quarta subseção apresenta uma análise comparativa geral entre os três cenários.

Cabe ressaltar que a análise tarifária mostrada nas figuras a seguir, utilizam a moeda Libra Esterlina, utilizada no Reino Unido, em sua subunidade de centavos (p, *pences*). Entretanto, na quarta subseção, serão apresentados e discutidos os resultados na moeda de Real brasileiro (R\$). Foi adotada a conversão do 25 de junho do presente ano, equivalendo 100p a R\$6,88 [43].

#### A. Análise do Cenário 1 – Dados Nominais

Inicialmente, foram avaliados os resultados das redes neurais utilizadas para fornecer as variáveis previstas. A Fig. 12 apresenta um trecho da comparação de 20 dias, escolhido de forma arbitrária, entre os valores reais e previstos para a produção fotovoltaica, tarifa de compra e tarifa de venda.




Fig. 12. Comparação das redes neurais de previsão utilizadas no controlador fuzzy para o cenário nominal, comparando valores reais e previstos de: (a) produção fotovoltaica, (b) tarifa de compra de energia e (c) tarifa de venda de energia.

Como mencionado anteriormente, o coeficiente de determinação foi utilizado para mensurar o quanto a previsão se apegua aos valores reais. De acordo com Amaral *et al.* [44], um  $R^2 < 0,5$  é classificado como tendo baixa capacidade de explicar o fenômeno, redes com  $0,5 < R^2 < 0,7$  seriam classificadas como razoáveis e redes com  $R^2 > 0,7$  seriam tratadas como tendo boa capacidade de explicação.

Na Fig. 12(A), observa-se que a previsão da produção fotovoltaica acompanha a tendência diária da geração, principalmente nos períodos de início e fim de produção solar. Entretanto, por se tratar de uma grandeza com maior variação ao longo do dia e por ter sido treinada para aprender o comportamento médio por hora, alguns picos de geração não são reproduzidos com a mesma intensidade. Ainda assim, a rede apresentou MAE de 0,364 kW e  $R^2$  de 0,76, sendo classificada como tendo boa capacidade de representação do comportamento fotovoltaico.

Para as tarifas, os resultados apresentaram maior aderência entre os valores reais e previstos. Na Fig. 12(B), a previsão da tarifa de compra acompanhou adequadamente as variações ao longo do período analisado, incluindo os principais picos e

quedas do sinal tarifário. Essa rede apresentou MAE de 1,64 p/kWh e  $R^2$  de 0,94. De forma semelhante, a Fig. 12(C) mostra que a tarifa de venda também foi bem representada pela rede, com MAE de 0,79 p/kWh e  $R^2$  de 0,89. Esses resultados indicam que as redes tarifárias apresentaram maior capacidade de ajuste em comparação com a rede de previsão fotovoltaica, o que está relacionado ao comportamento mais regular das séries de preço no trecho analisado.

A Fig. 13 apresenta a atuação do fuzzy supervisor ao longo do tempo, mostrando que a ação do fuzzy (ação de referência do SAEB) segue o mesmo perfil. Na Fig. 13(A), observa-se que, nos primeiros anos de operação, a ação do controlador atinge valores próximos aos limites de potência do SAEB, indicando maior liberdade de atuação da bateria. A medida que a degradação da bateria aumenta, verifica-se uma redução progressiva da amplitude da ação fuzzy, evidenciando que o fuzzy supervisor cumpre a sua função ao ajustar a intensidade dos comandos enviados ao SAEB.

A Fig. 13(B) mostra a evolução do multiplicador, que permanece praticamente constante nos primeiros anos e passa a diminuir conforme a degradação avança. Esse perfil segue a configuração adotada nas funções de membresia apresentadas na Fig. 11, refletindo diretamente na redução da ação de controle observada na Fig. 13(A).




Fig. 13. Efeito da degradação da bateria na ação enviada ao SAEB durante o Cenário 1: (a) potência de referência corrigida pelo supervisor fuzzy e (b) multiplicador aplicado em função da degradação da bateria.

Para complementar a análise do Cenário 1, foram selecionados dois intervalos da simulação, nos quais é possível observar com maior detalhe a interação entre geração fotovoltaica, SAEB, rede elétrica, carga e tarifas do método fuzzy comparado com o heurístico.

A Fig. 14 apresenta o trecho simulado entre as horas 4344 e 4368, em que a tarifa de venda apresenta um pico de aumento. Nesse caso, a diferença entre os métodos fica mais evidente. Na Fig. 14(A), o método heurístico utiliza o excedente fotovoltaico para carregar a bateria até o limite superior de EDC e mantém a lógica de descarga associada apenas ao balanço entre geração e carga. Assim, mesmo com variações na tarifa de venda, a operação do SAEB não muda.

Na Fig. 14(B), o método fuzzy aproveita melhor o pico de tarifa de venda. Durante o período de maior geração fotovoltaica, o SAEB é inicialmente carregado, pois o EDC ainda permite armazenamento e o excedente solar está disponível. Porém, quando a tarifa de venda aumenta no instante 4358 h, o Fuzzy Excedente deixa de priorizar apenas o carregamento e passa a favorecer a venda de energia. Isso é observado no comportamento simultâneo da potência do SAEB e da rede, já que na bateria ocorre uma descarga pontual e a exportação para a rede aumenta justamente no intervalo de maior tarifa de venda.

A Fig. 15 apresenta outro intervalo da simulação, entre as horas 7752 e 7800. No método heurístico, mostrado na Fig. 15(A), o comportamento segue o mesmo padrão observado anteriormente, a bateria carrega durante o período de excedente fotovoltaico e, posteriormente, descarrega para atender a carga até atingir o limite inferior de EDC, ficando ali até ter excedente solar de novo.

No método fuzzy, apresentado na Fig. 15(B), o carregamento inicial também ocorre durante o excedente solar, pois o EDC está baixo e o controlador prioriza recuperar a energia armazenada. Posteriormente, a bateria passa a ser descarregada até chegar ao limite inferior do EDC devido à magnitude do déficit, fazendo com que o sistema tenha que começar a comprar a rede para continuar abastecendo a carga.

O trecho posterior à descarga da bateria, a partir do instante 7774 h, evidencia uma limitação importante da metodologia adotada no método fuzzy. Como as previsões utilizadas possuem horizonte de apenas uma hora, o controlador não consegue antecipar eventos tarifários que ocorrem várias horas depois, nem identificar períodos futuros sem excedente fotovoltaico. Isso pode ser observado na Fig. 15, entre os instantes 7774 h e 7800 h, onde o sistema passa a depender integralmente da rede elétrica para atender à carga, mesmo sob tarifas elevadas. Como resultado, há um aumento nos custos operacionais, já que a energia precisa ser adquirida em momentos desfavoráveis, evidenciando a necessidade de um horizonte de previsão mais amplo para uma gestão mais eficiente da energia armazenada.




Fig. 14. Dinâmica dos fluxos de potência, EDC e das tarifas da GD no Cenário 1 durante  $4344 \text{ h} \leq t \leq 4368 \text{ h}$  utilizando dois sistemas de gerenciamento: A) heurístico e B) fuzzy.




Fig. 15. Dinâmica dos fluxos de potência, EDC e das tarifas da GD no Cenário 1 durante  $7752 \text{ h} \leq t \leq 7800 \text{ h}$  utilizando dois sistemas de gerenciamento: A) heurístico e B) fuzzy.

A Fig. 16 apresenta o saldo financeiro ao longo de todo o período de simulação para os métodos heurístico e fuzzy no Cenário 1. Esse saldo é obtido através da diferença monetária entre as vendas acumuladas (exportação) e as compras acumuladas (importação). Observa-se que ambos os métodos apresentam um comportamento cíclico, associado à variação sazonal da geração fotovoltaica, onde no final e início do ano se tem uma menor incidência solar comparado com a metade do ano, fazendo com que nesses períodos se importe mais energia. Nos primeiros anos, a curva por método fuzzy apresenta uma leve vantagem com respeito ao método heurístico. Entretanto, à medida que a degradação da bateria avança, a diferença entre os métodos se torna mais evidente,

isso devido a que o fuzzy supervisor começa a ter mais relevância.

O método heurístico apresentou vida útil de aproximadamente 9,8 anos, momento indicado na Fig. 16 pela linha pontilhada cinza. Essa linha representa o instante em que a bateria atingiu 40% de degradação. A partir desse ponto, o sistema associado ao método heurístico passa a operar sem a contribuição da bateria, o que altera o comportamento do saldo acumulado nos anos finais da simulação.

Ao final do período simulado, o método heurístico apresentou custo acumulado de -24245 p, equivalente a aproximadamente R\$ -1668. Já o método fuzzy apresentou

custo acumulado de -23923 p, equivalente a aproximadamente R\$ -1646, além de uma vida útil estimada de 11 anos.

Esse resultado está relacionado principalmente à atuação do fuzzy supervisor que limita a intensidade da ação para preservar a bateria conforme ela se degrada. Em comparação, o método heurístico utiliza a bateria de forma mais direta sempre que há excedente ou déficit, o que tende a acelerar sua degradação. Assim, embora as curvas de saldo acumulado sejam próximas em grande parte da simulação, a maior vida útil do SAEB no método fuzzy permite manter a contribuição da bateria por mais tempo.




Fig. 16. Evolução do saldo econômico acumulado no Cenário 1 para os métodos heurístico e fuzzy.

#### B. Análise do Cenário 2 – Variações na Tarifa de Compra

Neste cenário é avaliada a variação da tarifa de compra na toma de decisão dos sistemas de gerenciamentos comparados. Antes da análise operacional do sistema, foi verificado o desempenho da rede neural sob as variações implementadas na tarifa de compra no Cenário 2, pois é utilizada como uma das entradas auxiliares do controlador fuzzy.

A Fig. 17 apresenta a comparação entre os valores reais e previstos da tarifa de compra para o mesmo trecho apresentado no Cenário 1. Observa-se que a rede conseguiu acompanhar a tendência geral da série, representando adequadamente os principais períodos de aumento e redução tarifária. Entretanto, em alguns instantes de maior variação, principalmente nos picos mais acentuados, como no instante 5125 h, a previsão apresenta pequenas diferenças em relação ao valor real, o que é esperado devido à maior variabilidade introduzida neste cenário.




Fig. 17. Validação da rede neural de previsão da tarifa de compra no Cenário 2, considerando a série tarifária de compra modificada com variações de 30%, comparando valores reais e previstos.

Para esse caso, a rede apresentou MAE de 2,1 p/kWh e  $R^2$  de 0,91. Em comparação com o Cenário 1, no qual a previsão da tarifa de compra apresentou MAE de 1,64 p/kWh e  $R^2$  de 0,94, observa-se uma redução no desempenho da rede. Mesmo assim, o valor de  $R^2$  permaneceu superior a 0,7, mantendo a classificação de boa capacidade de representação da série.

A Fig. 18 apresenta a simulação entre as horas 5160 e 5208, destacando o efeito da tarifa de compra na operação do sistema. Na Fig. 18(A), o método heurístico opera a bateria apenas com base no balanço entre geração fotovoltaica e carga. Mesmo quando a tarifa assume valores muito baixos ou negativos, o método não altera sua estratégia de operação.

Na Fig. 18(B), o método fuzzy apresenta um comportamento distinto. Observa-se que, nos intervalos entre 5167 h e 5172 h e entre 5179 h e 5195 h, a tarifa de compra atinge valores muito baixos, inclusive sendo negativos. Nesses períodos, o controlador fuzzy eleva o EDC da bateria até o limite superior. Esse comportamento ocorre porque valores reduzidos de tarifa ativam a classe Muito\_Baixa da Tabela 3, e as regras associadas ao Fuzzy Déficit passam a favorecer a compra de energia da rede. Dessa forma, o sistema prioriza o uso da rede elétrica em momentos de baixo custo. Além disso, mesmo após atingir o limite superior de EDC, o controlador fuzzy continua utilizando a rede para abastecer a carga, pois a tarifa negativa indica que há remuneração pelo consumo de energia, tornando essa estratégia economicamente vantajosa.

Esse resultado evidencia uma vantagem do método fuzzy em relação ao heurístico. Enquanto o heurístico reage apenas ao balanço de potência, o fuzzy utiliza a informação tarifária para ajustar sua operação. Assim, quando a energia da rede é barata, o sistema mantém ou eleva o EDC, deixando a bateria disponível para períodos de maior custo. Após o instante 5195 h, com o aumento da tarifa, o EDC elevado proporciona maior flexibilidade operacional.




Fig. 18. Dinâmica dos fluxos de potência, EDC e das tarifas da GD no Cenário 2 durante  $5160 \text{ h} \leq t \leq 5208 \text{ h}$  utilizando dois sistemas de gerenciamento: A) heurístico e B) fuzzy.

A Fig. 19 apresenta o saldo acumulado ao longo de todo o período de simulação para os métodos heurístico e fuzzy no Cenário 2. Observa-se que, diferentemente do Cenário 1, as curvas apresentam maior variação positiva, o que está associado à maior presença de tarifas de compra baixas ou negativas. Nesses momentos, o sistema pode reduzir o custo de operação ou até obter ganho econômico ao consumir energia da rede, dependendo da condição tarifária.

O método heurístico apresentou vida útil de 9,8 anos e custo acumulado final de -10203 p, equivalente a cerca de R\$ -702. Por outro lado, o método fuzzy apresentou vida útil de 10,9 anos e custo acumulado de -8613 p, equivalente a cerca de R\$ -593. Embora seja pequeno, esse melhor desempenho econômico, comparado com o heurístico, está relacionado à capacidade do controlador fuzzy de reconhecer períodos em que a tarifa de compra se encontra muito baixa.

Ao igual que no Cenário 1, a linha pontilhada cinza indicada na Fig. 19 representa o instante em que a bateria do método heurístico atinge o limite de degradação definido para sua operação.




Fig. 19. Evolução do saldo econômico acumulado no Cenário 2 para os métodos heurístico e fuzzy.

### C. Análise do Cenário 3 – Variação na Carga

Nesta subseção é analisado o comportamento do método heurístico e o fuzzy ante a variação incremental da carga. A Fig. 20 apresenta um trecho da simulação entre as horas 5676 e 5724, no qual é possível observar o efeito do aumento de 30% da carga em determinados períodos do cenário. No intervalo entre 5676 h e 5687 h a carga residencial encontra-se acima do perfil nominal, fazendo com que ambos os métodos utilizem o SAEB para atender parte da demanda. No método heurístico, mostrado na Fig. 20(A), a descarga ocorre de forma direta, pois a estratégia responde apenas ao déficit entre geração fotovoltaica e carga, fazendo com que se descarregue até o limite inferior de EDC.

No método fuzzy, mostrado na Fig. 20(B), também ocorre descarga nesse mesmo intervalo, pois a elevação da carga aumenta o déficit normalizado e ativa regras do Fuzzy Déficit associadas ao abastecimento da carga. Mesmo com a lógica mais seletiva do fuzzy, o aumento da demanda torna a utilização da bateria necessária, principalmente quando o EDC ainda se encontra em uma faixa adequada para descarga. Esse comportamento mostra que, em condições de carga elevada, as duas estratégias tendem a aproximar suas respostas, pois a demanda adicional reduz a margem de decisão do controlador.

A principal diferença entre os métodos aparece no intervalo entre as horas 5705 e 5716. Na Fig. 20(A), o método heurístico descarrega a bateria continuamente após a redução da geração fotovoltaica, levando o EDC novamente ao limite mínimo. Já na Fig. 20(B), o método fuzzy realiza uma descarga inicial, mas passa a preservar parte do EDC durante o intervalo 5710 h a 5713 h. Essa resposta está relacionada às funções de pertinência e às regras do Fuzzy Déficit: quando o déficit não é elevado o suficiente e a tarifa de compra se encontra em uma faixa baixa ou em queda, a descarga deixa de ser tão vantajosa, direcionando a operação ao repouso da bateria. Assim, o fuzzy evita descarregar toda a bateria em um período no qual o custo da energia não justifica uma utilização

total do SAEB. Essa mudança faz com que no próximo pico de aumento da tarifa de compra (5713 h até 5716 h) o método fuzzy consiga reduzir a compra de energia da rede.




Fig. 20. Dinâmica dos fluxos de potência, EDC e das tarifas da GD no Cenário 3 durante 5676 h ≤ t ≤ 5724 h utilizando dois sistemas de gerenciamento: A) heurístico e B) fuzzy.

A Fig. 21 apresenta o saldo acumulado ao longo de todo o período de simulação para o Cenário 3. Observa-se que as duas curvas apresentam uma tendência de queda mais acentuada, refletindo o aumento do consumo do sistema. Esse comportamento é esperado, uma vez que a elevação da carga aumenta a energia demandada pela residência e reduz o excedente fotovoltaico disponível para armazenamento ou venda. Como consequência, há maior necessidade de compra de energia da rede, elevando o custo acumulado final.




Fig. 21. Evolução do saldo econômico acumulado no Cenário 3 para os métodos heurístico e fuzzy.

Ao final da simulação, o método heurístico apresentou vida útil da bateria de 10,2 anos e custo acumulado de - 336784 p, equivalente a cerca de R\$ -23171. O método fuzzy apresentou vida útil de 10,8 anos e custo acumulado de - 338283 p, equivalente a cerca de R\$ -23275. Assim, neste

Esse comportamento é importante para entender a diferença entre as estratégias. O método heurístico tende a maximizar o uso imediato da bateria, enquanto o fuzzy tenta equilibrar o uso do armazenamento com o EDC, o nível de déficit, a tarifa de compra e a tendência tarifária.

cenário, o fuzzy manteve maior tempo de operação da bateria, mas apresentou custo acumulado ligeiramente superior ao heurístico. Essa diferença está associada à sua operação mais conservadora em alguns períodos, na qual o controlador preserva o EDC e permite maior participação da rede, mesmo que isso aumente o custo em momentos específicos, tudo isso, com a intenção de diminuir a profundidade dos ciclos e, por ende, a degradação.

Também se observa que a vida útil do método heurístico foi maior neste cenário em comparação ao Cenário 1. Embora o aumento da carga provoque maior demanda de energia, ele também reduz a quantidade de excedente fotovoltaico disponível para ciclos completos de carregamento e descarga. Em alguns períodos, a bateria atinge o limite inferior e permanece sem atuar até que exista excedente suficiente para recarregá-la. Dessa forma, o sistema pode apresentar menor número efetivo de ciclos completos, o que ajuda a explicar o aumento da vida útil estimada, mesmo com maior custo econômico acumulado.

#### D. Análise em Conjunto dos Cenários

Após a análise individual dos cenários, as Figs. 22 e 23 apresentam uma comparação geral entre os métodos avaliados e o sistema sem SAEB, considerando o custo acumulado do sistema e a vida útil estimada da bateria para o fuzzy e o heurístico.

Na Fig. 22, observa-se que o método fuzzy apresentou maior vida útil da bateria em todos os cenários simulados. No Cenário 1, a vida útil passou de 9,8 anos no método heurístico para 11,0 anos no método fuzzy, representando um aumento de aproximadamente 12,2%. No Cenário 2, a vida útil aumentou de 9,8 para 10,9 anos, equivalente a um incremento

de aproximadamente 11,2%. Já no Cenário 3, o aumento foi de 10,2 para 10,8 anos, correspondente a aproximadamente 5,9%. Considerando os três cenários, o método fuzzy apresentou vida útil média de 10,9 anos, enquanto o heurístico apresentou média de 9,93 anos, resultando em um ganho médio de aproximadamente 0,97 ano, ou 9,7%.

Esse comportamento está diretamente relacionado à lógica de operação do controlador fuzzy, sendo o principal fator o uso do Fuzzy Supervisor. Diferentemente do método heurístico, que descarrega a bateria sempre que existe déficit entre geração fotovoltaica e carga, o fuzzy considera simultaneamente o EDC, o nível de déficit, as tarifas de compra e venda e a degradação do SAEB. O Fuzzy Supervisor atua ajustando a intensidade das ações de carga e descarga conforme o nível de degradação da bateria, tornando a operação progressivamente mais conservadora ao longo do tempo. Dessa forma, ele reduz a ocorrência de ciclos mais agressivos e limita descargas desnecessárias, contribuindo para o aumento da vida útil do SAEB.




Fig. 22. Comparação da vida útil estimada da bateria para os métodos heurístico e fuzzy nos três cenários de operação.

Na Fig. 23, observa-se o saldo financeiro obtido para os três cenários, tomando em conta o preço de compra e venda da bateria e do próprio custo acumulado proveniente da compra e venda de energia. É importante destacar que o objetivo deste trabalho não foi maximizar o lucro do sistema, mas sim propor uma estratégia de controle que equilibrasse o desempenho econômico com a preservação da vida útil da bateria. Ainda assim, verifica-se que, na prática, o método fuzzy conseguiu praticamente igualar do saldo financeiro obtido pelo método heurístico nos três cenários.




Fig. 23. Comparação do saldo financeiro para os métodos heurístico, fuzzy e operação sem bateria nos três cenários de operação.

Na mesma Fig. 23, também se observa que a operação do sistema da GD, sem incorporar um SAEB, apresentou menor custo acumulado nos três cenários. Esse resultado está associado ao fato de que a incorporação de SAEB ainda apresenta um custo elevado, fazendo com que, do ponto de

vista estritamente econômico, o sistema sem armazenamento seja mais vantajoso nas condições analisadas. Entretanto, a utilização de SAEB envolve também aspectos que vão além do custo direto. O armazenamento de energia proporciona maior segurança frente às incertezas do sistema elétrico, maior independência em relação à rede e maior controle sobre a própria infraestrutura energética. Além disso, em situações de interrupção no fornecimento de energia, que não formaram parte do escopo do trabalho, a presença da bateria permite que o consumidor mantenha o abastecimento por um determinado período, o que representa um benefício relevante que não é capturado apenas pela análise econômica.

De modo geral, a comparação conjunta mostra que o principal ganho do controlador fuzzy ocorreu na preservação da vida útil da bateria. Em termos econômicos, o fuzzy apresentou desempenho praticamente igual ao método heurístico. Assim, os resultados indicam que o método fuzzy implementado tende a favorecer uma operação mais equilibrada do SAEB, reduzindo a degradação por ciclagem e mantendo a bateria disponível por mais tempo.

#### IV. CONCLUSÕES

Este trabalho desenvolveu e avaliou um sistema de gerenciamento de energia baseado em lógica fuzzy aplicado a uma geração distribuída residencial conectada à rede elétrica, composta por geração fotovoltaica, carga residencial, rede e sistema de armazenamento em baterias, levando em conta tarifas dinâmicas. O EMS desenvolvido foi projetado com os objetivos de gerenciar os fluxos de potência do sistema para abastecer a carga, aproveitar a geração solar e preservar a vida útil da bateria ao mesmo tempo em que o sistema buscou aproveitar condições tarifárias favoráveis de compra e venda de energia. Essa função foi realizada tanto pelas regras mais conservadoras dos controladores fuzzy para situações de excesso e déficit de energia, quanto, principalmente, por meio de um Fuzzy Supervisor.

Os resultados obtidos mostraram que o método fuzzy foi capaz de aumentar a vida útil estimada da bateria em todos os cenários analisados, proporcionando um ganho médio de aproximadamente 0,97 ano, ou 9,7%, em relação ao método heurístico. Além disso, através das discussões dos cenários, conseguiu-se comprovar que o método fuzzy, em comparação com o heurístico, consegue aproveitar tarifas atrativas, importando quando a energia está com um custo muito baixo, exportando quando a tarifa de venda é favorável, e abastecendo a carga em picos de tarifas de compra.

Entretanto, as análises dos fluxos de potência também evidenciaram que a previsão de uma hora na frente é insuficiente para um gerenciamento otimizado, fazendo com que o método fuzzy perca oportunidades de compra em alguns momentos, ou, em outros, não consiga prever um horizonte com aumento tarifário e falta de geração solar. Essa limitante faz com que haja situações em que o fuzzy se comporte similarmente ao heurístico, sem conseguir se antecipar a situações adversas futuras e resultando na importação da rede com tarifas elevadas devido ao déficit solar.

Em relação ao desempenho econômico, ambos os métodos tiveram resultados similares nos três cenários, evidenciando a estrutura mais conservadora do método fuzzy, uma vez que o lucro através da compra e venda de energia virou um objetivo secundário e unicamente ativado em momentos de tarifas muito baixas ou de vendas muito altas.

A partir desses resultados e conclusões, se propõem os seguintes trabalhos futuros:

- Avaliar locais com maior disponibilidade de irradiação solar ao longo de todo o ano e implementar diferentes tarifas de compra e venda.
- Otimizar as funções de pertinência e as regras fuzzy, utilizando diferentes técnicas, buscando melhor equilíbrio entre custo acumulado, vida útil da bateria e aproveitamento tarifário.
- Ampliar o horizonte de previsão do controlador, utilizando janelas superiores a uma hora, como 6 h, 12 h ou 24 h, para permitir que o EMS antecipe períodos de tarifa elevada, baixa geração fotovoltaica ou aumento da carga.
- Comparar o controlador fuzzy com outras estratégias avançadas de gerenciamento, como controle preditivo baseado em modelo, otimização matemática e aprendizado por reforço.
- Avaliar diferentes dimensionamentos do sistema, variando a capacidade da bateria, a potência do sistema fotovoltaico e os limites operacionais de EDC, a fim de identificar configurações mais adequadas técnica e economicamente.

#### AGRADECIMENTOS

A Deus e à Virgem Maria, por terem me guiado e iluminado nos momentos de escuridão e incerteza, e por nunca terem me abandonado.

À minha família, em especial aos meus pais, meus pilares e apoio incondicional, e às minhas irmãs, meus refúgios de compreensão, carinho e acolhimento.

Às amigas construídas ao longo da minha trajetória na UNILA, deixo minha sincera gratidão. Saibam que, sem o apoio e a escuta diária de vocês, nada teria sido o mesmo.

Ao meu orientador, agradeço pela confiança, pelos ensinamentos, pela paciência e pela inspiração ao longo deste processo.

A todas as pessoas que, direta ou indiretamente, fizeram parte da minha trajetória na UNILA e contribuíram para a minha formação, meu muito obrigado.

#### REFERÊNCIAS

- [1] IEA, “Global Energy Review 2025”, mar. 2025. [Online]. Disponível em: [www.iea.org](http://www.iea.org)
- [2] IEA, “United Kingdom”. Acessado: 27 de junho de 2026. [Online]. Disponível em: <https://www.iea.org/countries/united-kingdom>
- [3] DESNZ, “Energy Trends March 2026”, 2026.
- [4] V. C. Teles, “SISTEMA DE GERENCIAMENTO DE ENERGIA PARA MICRORREDES”, Curitiba, 2021.
- [5] T. Ackermann, G. Ran Andersson, e L. Sö Der A, “Distributed generation: a definition”, 2001. [Online]. Disponível em: [www.elsevier.com/locate/epsr](http://www.elsevier.com/locate/epsr)
- [6] DESNZ, “Solar photovoltaics deployment”. Acessado: 27 de junho de 2026. [Online]. Disponível em: <https://www.gov.uk/government/statistics/solar-photovoltaics-deployment>
- [7] Reino Unido, “Smart Export Guarantee (SEG): earn money for exporting the renewable electricity you have generated”. Acessado: 17 de junho de 2026. [Online]. Disponível em: <https://www.gov.uk/government/publications/smart-export-guarantee-seg-earn-money-for-exporting-the-renewable-electricity-you-have-generated>

- [8] S. E. Eyimaya e N. Altin, “Review of Energy Management Systems in Microgrids”, *Applied Sciences (Switzerland)*, vol. 14, n° 3, fev. 2024, doi: 10.3390/app14031249.
- [9] E. Nivolianiti, Y. L. Karnavas, e J. F. Charpentier, “Fuzzy Logic-Based Energy Management Strategy for Hybrid Fuel Cell Electric Ship Power and Propulsion System”, *J. Mar. Sci. Eng.*, vol. 12, n° 10, out. 2024, doi: 10.3390/jmse12101813.
- [10] M. S. M. Pakpahan, L. E. Nugroho, e Widyawan, “Comparative analysis of rule-based heuristic algorithms for microservice chain placement in fog computing”, *Results in Engineering*, vol. 25, mar. 2025, doi: 10.1016/j.rineng.2025.104299.
- [11] G. H. Alves, “Sistema de Gerenciamento de Energia Orientado à Arbitragem Energética e Recomendações para Operação Isolada de Microrredes”, Universidade Federal de Uberlândia, Uberlândia, 2023.
- [12] D. Arcos-Aviles, J. Pascual, L. Marroyo, P. Sanchis, e F. Guinjoan, “Fuzzy logic-based energy management system design for residential grid-connected microgrids”, *IEEE Trans. Smart Grid*, vol. 9, n° 2, p. 530–543, 2018, doi: 10.1109/TSG.2016.2555245.
- [13] T. Castillo-Calzadilla, J. Oroya-Villalta, e C. E. Borges, “Energy Management System for a Residential Positive Energy District Based on Fuzzy Logic Approach (RESTORATIVE)”, *Smart Cities*, vol. 7, n° 4, p. 1802–1835, ago. 2024, doi: 10.3390/smartcities7040070.
- [14] M. Cavus, D. Dissanayake, e M. Bell, “Deep-Fuzzy Logic Control for Optimal Energy Management: A Predictive and Adaptive Framework for Grid-Connected Microgrids”, *Energies (Basel)*, vol. 18, n° 4, fev. 2025, doi: 10.3390/en18040995.
- [15] J. Lesage, “Microgrid Energy Management System (EMS) using Optimization”. Acessado: 17 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/73139-microgrid-energy-management-system-ems-using-optimization>
- [16] Reino Unido, “Network design”. Acessado: 20 de junho de 2026. [Online]. Disponível em: <https://www.ukpowernetworks.co.uk/distribution-network-energy-losses/network-design>
- [17] MathWorks, “Variable Step Solvers in Simulink”. Acessado: 17 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/help/simulink/ug/variable-step-solvers-in-simulink-1.html>
- [18] MathWorks, “Solver - Solver that computes states and outputs for simulation - MATLAB”. Acessado: 17 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/help/simulink/gui/solver.html>
- [19] S. Mohseni, J. Rutovitz, H. Smith, e T. McCoy, “MyTown Microgrid-Residential load profiles for MyTown Microgrid Residential load profiles for Heyfield, Victoria”, 2023.
- [20] L. C. Mendonça, “Modelo Computacional para a Programação Diária de Microgrids e Redes de Distribuição Ativas”, Universidade Federal do Paraná, Curitiba, 2019.
- [21] Comissão Europeia, “JRC Photovoltaic Geographical Information System (PVGIS) - European Commission”. Acessado: 21 de junho de 2026. [Online]. Disponível em: [https://re.jrc.ec.europa.eu/pvg\\_tools/en/](https://re.jrc.ec.europa.eu/pvg_tools/en/)
- [22] HBOWA Nova Energia, “Ângulo e desempenho do painel solar: Por que a inclinação e a direção é importante”. Acessado: 21 de junho de 2026. [Online]. Disponível em: <https://www.pretapower.com/pt/solar-panel-angle-and-performance-why-tilt-and-direction-matter/>
- [23] Paladino Elettriciades, “Módulo de Bateria Pylontech US3000C”. Acessado: 22 de junho de 2026. [Online]. Disponível em: [https://paladinoelettriciades.com/produto/modulo-de-bateria-pylontech-us3000c/?srsltid=AfmBOofAfCPO1PuwecXhqwB3qMusWmRW\\_GYRFWPjb3JA199LhWnW3HD&cn-reloaded=1](https://paladinoelettriciades.com/produto/modulo-de-bateria-pylontech-us3000c/?srsltid=AfmBOofAfCPO1PuwecXhqwB3qMusWmRW_GYRFWPjb3JA199LhWnW3HD&cn-reloaded=1)
- [24] J. F. Manwell, A. Rogers, G. Hayman, C. T. Avelar, e J. G. McGowan, “HYBRID2-A HYBRID SYSTEM SIMULATION MODEL THEORY MANUAL”, 1998.
- [25] M. Musallam e C. M. Johnson, “An efficient implementation of the rainfall counting algorithm for life consumption estimation”, *IEEE Trans. Reliab.*, vol. 61, n° 4, p. 978–986, 2012, doi: 10.1109/TR.2012.2221040.

- [26] Frankensolar Americas, “Pylontech - US3000C”. Acessado: 22 de junho de 2026. [Online]. Disponível em: <https://shop.frankensolar.ca/pylontech-us3000c/>
- [27] Mathworks, “fit - Fit curve or surface to data - MATLAB”. Acessado: 22 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/help/curvefit/fit.html>
- [28] G. Kostenko e A. Zaporozhets, “Transition from Electric Vehicles to Energy Storage: Review on Targeted Lithium-Ion Battery Diagnostics”, *Energies (Basel)*, vol. 17, n° 20, out. 2024, doi: 10.3390/en17205132.
- [29] A. Bach, S. Onori, S. J. Reichelstein, e J. Zhuang, “Fair Market Value of Used Capacity Assets: Forecasts for Repurposed Electric Vehicle Batteries \*”, 2025.
- [30] Electricity North West, “Distribution System Design General Requirements”, 2024.
- [31] L. G. Baca Ruiz, M. P. Cuéllar, M. D. Calvo-Flores, e M. D. C. Pegalajar Jiménez, “An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings”, *Energies (Basel)*, vol. 9, n° 9, set. 2019, doi: 10.3390/en9090684.
- [32] G. Petroli, “Predição do Equilíbrio de Fases entre Biodiesel, Álcoois e CO<sub>2</sub> em Estado Supercrítico por Meio de Redes Neurais Artificiais”, Universidade Tecnológica Federal do Paraná, 2019.
- [33] A. Postal, “Desenvolvimento e validação de modelos de redes neurais para estimativa de evapotranspiração de referência no Paraná”, Universidade Estadual do Oeste do Paraná, Cascavel - PR, 2024.
- [34] Mathworks, “NARXNET”. Acessado: 23 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/help/deeplearning/ref/narxnet.html>
- [35] H. T. C. Pedro e C. F. M. Coimbra, “Assessment of forecasting techniques for solar power production with no exogenous inputs”, *Solar Energy*, vol. 86, n° 7, p. 2017–2028, jul. 2012, doi: 10.1016/j.solener.2012.04.004.
- [36] L. B. Rashid, S. Z. Shuja, e S. Rehman, “Machine Learning Forecasting of Direct Solar Radiation: A Multi-Model Evaluation with Trigonometric Cyclical Encoding”, *Forecasting*, vol. 7, n° 4, dez. 2025, doi: 10.3390/forecast7040058.
- [37] A. Patrik e S. Silva, “Previsão do Preço de Liquidação das Diferenças por Meio de Redes Neurais Artificiais”, Universidade Federal de Ouro Preto, João Monlevade - MG, 2018.
- [38] Mathworks, “NARNET”. Acessado: 23 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/help/deeplearning/ref/narnet.html>
- [39] OctopusEnergy, “Agile Portal”. Acessado: 23 de junho de 2026. [Online]. Disponível em: <https://agile.octopusenergy.com/historical-data>
- [40] S. Hovden, “An Optimal Model Predictive Control-Based Energy Management System for Microgrids”, Trondheim, 2021.
- [41] F. J. Vivas, F. Segura, e J. M. Andújar, “Fuzzy logic-based energy management system for grid-connected residential DC microgrids with multi-stack fuel cell systems: A multi-objective approach”, *Sustainable Energy, Grids and Networks*, vol. 32, dez. 2022, doi: 10.1016/j.segan.2022.100909.
- [42] Mathworks, “Mamdani and Sugeno Fuzzy Inference Systems”. Acessado: 25 de junho de 2026. [Online]. Disponível em: <https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html>
- [43] Google Finance, “Libra esterlina / Real brasileiro”. Acessado: 25 de junho de 2026. [Online]. Disponível em: <https://www.google.com/finance/beta/quote/GBP-BRL?sa=X&sqi=2&ved=2ahUKewJlhc50KWVAXgLLkGHWFQKE0QmY0JegQIDhAu>
- [44] L. Amaral e J. L. Passador, “Redes neurais artificiais na previsão da inflação: aplicação como ferramenta de apoio à análise de decisões financeiras em organizações de pequeno porte”, *Adm. Mackenzie*, vol. 13, São Paulo, p. 68–86, 2012.