



ABORDAGEM FUZZY HÍBRIDA PARA DETECÇÃO DE FRAUDES EM PROGRAMAS DE PARTICIPAÇÃO ATIVA DE USUÁRIOS FINAIS DE ENERGIA

GUILHERME ABREU CARVALHO

outubro de 2024

ABORDAGEM FUZZY HÍBRIDA PARA DETECÇÃO DE FRAUDES EM PROGRAMAS DE PARTICIPAÇÃO ATIVA DE USUÁRIOS FINAIS DE ENERGIA

Guilherme Abreu Carvalho

**Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica - Sistemas Elétricos de Energia**

Orientadora: Zita Maria Almeida do Vale

**Co-orientadores: Luís Filipe de Oliveira Gomes, Ricardo Francisco Marcos Faia e Edson
Bruno Marques Costa**

Júri:

Presidente:

Fernando Maurício Teixeira de Sousa Dias, Professor Adjunto, ISEP

Vogais:

Zita Maria Almeida do Vale, Professora Coordenadora Principal, ISEP

Fernando Lezama Cruzvillasante, Investigador, ISEP

Edson Bruno Marques Costa, Professor Adjunto, IFMA

Ginalber Luiz de Oliveira Serra, Professor Adjunto, IFMA

Resumo

Os avanços nas redes elétricas inteligentes têm desempenhado um papel crucial na descarbonização, facilitando a integração de fontes de energias renováveis e otimizando o equilíbrio entre oferta e demanda de energia. Nesse contexto, um dos principais objetivos das *Smart Grids* é aprimorar a interação entre os usuários finais e o sistema elétrico, por meio da implementação de programas que incentivam a redução do consumo e a adoção de práticas mais sustentáveis. No entanto, apesar das vantagens significativas resultantes da expansão da infraestrutura energética, surgem novos desafios relacionados à segurança e à integridade dos dados coletados. Sem mecanismos robustos de validação, o sistema fica vulnerável a manipulações, o que pode comprometer a eficácia dos mecanismos de distribuição de benefícios. Para resolver esse problema, a presente dissertação propõe uma abordagem *fuzzy* híbrida: um modelo evolutivo orientado a dados (denominado de *Evolving Takagi-Sugeno Plus*) e um sistema *fuzzy* Mamdani baseado em conhecimento. O método evolutivo é utilizado para modelar e prever os padrões de comportamento dos indivíduos em programas de participação ativa de usuários finais de energia. Este é capaz de evoluir dinamicamente, adaptando seus parâmetros e ajustando sua estrutura automaticamente a partir das amostras recebidas. Durante a etapa de concepção do modelo, o método foi comparado com outras técnicas disponíveis na literatura, mostrando resultados competitivos, especialmente em relação ao tempo de execução. Por outro lado, o sistema Mamdani utiliza o resíduo obtido entre a saída do modelo evolutivo e os dados reais de flexibilidade, combinados com informações sobre geração e consumo de energia, para estimar um grau de alerta caso comportamentos anômalos sejam identificados. Os resultados desta fase indicam que o sistema proposto detecta tanto fraudes pontuais quanto aquelas que ocorrem ao longo de períodos extensos. Dessa forma, os métodos combinados demonstram potencial de aplicação em contextos práticos, auxiliando as entidades gestoras na tomada de decisões por meio de uma metodologia robusta e altamente interpretável.

Palavras-chave: Abordagem *Fuzzy* Híbrida, Detecção de Fraudes, Modelos Evolutivos, Programas de Participação Ativa, Redes Elétricas Inteligentes, Sistema *Fuzzy* Mamdani

Abstract

Advances in smart grids have played a crucial role in decarbonization, facilitating the integration of renewable energy sources and optimizing the balance between energy supply and demand. In this context, one of the main objectives of smart grids is to improve the interaction between end users and the electricity system by implementing programs that encourage the reduction of consumption and the adoption of more sustainable practices. However, despite the significant advantages resulting from the expansion of the energy infrastructure, new challenges arise related to the security and integrity of the data collected. Without robust validation mechanisms, the system is vulnerable to manipulation, which can compromise the effectiveness of benefit distribution mechanisms. To solve this problem, this dissertation proposes a hybrid fuzzy approach: a data-driven evolving model (called Evolving Takagi-Sugeno Plus) and a knowledge-based fuzzy Mamdani system. The evolving method is used to model and predict the behavior patterns of individuals in active participation programs for energy end users. It is capable of evolving dynamically, adapting its parameters and adjusting its structure automatically based on the samples received. During the model design stage, the method was compared with other techniques available in the literature, showing competitive results, especially in terms of execution time. On the other hand, the Mamdani system uses the residual obtained between the output of the evolving model and the real flexibility data, combined with information on energy generation and consumption, to estimate a degree of alert if anomalous behavior is identified. The results of this phase indicate that the proposed system detects both one-off frauds and those that occur over long periods. In this way, the combined methods show potential for application in practical contexts, helping management entities to make decisions using a robust and highly interpretable methodology.

Keywords: Hybrid Fuzzy Approach, Fraud Detection, Evolving Models, Active Participation Programs, Smart Grids, Mamdani Fuzzy System

Agradecimentos

Agradeço a Deus por ter me proporcionado saúde e força para superar as dificuldades.

À minha família por estar sempre ao meu lado, compartilhando alegrias e desafios, celebrando conquistas e me fortalecendo nos momentos mais difíceis.

À minha orientadora e aos meus coorientadores, Zita Vale, Luís Gomes, Ricardo Faia e Edson Costa, que apesar das exigências da vida acadêmica, dedicaram parte do seu tempo para esclarecer minhas dúvidas e guiar minha pesquisa na direção certa.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA) e ao Instituto Superior de Engenharia do Porto (ISEP) pelo ambiente propício ao aprendizado e pela parceria na idealização e desenvolvimento do Programa de Dupla Titulação. Essa iniciativa inovadora não apenas enriqueceu minha jornada acadêmica, mas também ampliou horizontes, oportunidades e perspectivas que jamais imaginei serem possíveis. Agradeço também ao IFMA pelo investimento na educação e pelo fornecimento do recurso financeiro que tornou possível a permanência dos seus alunos no exterior.

A todos os amigos que fiz ao longo da minha graduação, com destaque para: Bárbara, Elizabeth, Ellen, Gabriel, Gerliane e Marcos. Vocês tornaram os extensos anos de aprendizado mais leves de enfrentar, seja através da colaboração em sessões de estudo, bem como nos momentos de interação e descontração.

Aos meus amigos e companheiros de intercâmbio: Andressa, Fernanda, Laura, Lucas, Ricardo e Kayon. Por um tempo pensei como eu enfrentaria um curso de mestrado em um país completamente novo e distante de tudo que me era familiar, mas vocês transformaram essa experiência desafiadora em um processo bastante divertido.

Agradeço a todos que, diretamente ou indiretamente, contribuíram para a minha formação acadêmica e conclusão deste trabalho. A jornada que percorri foi enriquecida pela constante presença e apoio de vocês, e não há palavras suficientes para transmitir o quão grato eu sou.

Índice

1	Considerações Iniciais	1
1.1	Contextualização	2
1.2	Enquadramento e Motivações	3
1.3	Objetivos	5
1.4	Organização do Documento	5
2	Estado da Arte	7
2.1	Redes Elétricas Inteligentes	7
2.1.1	Conceitos e Definições	8
2.1.2	Infraestrutura de Medição Avançada	9
2.1.3	Recursos Energéticos Distribuídos	10
2.1.4	Segurança Cibernética	11
2.2	<i>Demand Response</i>	11
2.2.1	Caracterização e Funcionamento	13
2.2.2	Tipos de <i>Demand Response</i> Baseados em Preços	13
2.2.3	Tipos de <i>Demand Response</i> Baseados em Incentivos	16
2.3	<i>Transactive Energy</i> e Negociações <i>Peer to Peer</i>	17
2.3.1	Definição de <i>Transactive Energy</i>	18
2.3.2	Principais Conceitos e Arquitetura do Mercado <i>Peer to Peer</i>	19
2.3.3	Estrutura dos Sistemas de Compartilhamento de Energia <i>Peer to Peer</i>	20
2.3.4	Mecanismos de Mercado	22
3	Fundamentos dos Métodos <i>Fuzzy</i>	25
3.1	Princípios dos Sistemas <i>Fuzzy</i> Clássicos	25
3.1.1	Variáveis Linguísticas e Graus de Pertinência	26
3.1.2	Regras <i>Fuzzy</i> e Operações entre Conjuntos	27
3.1.3	Sistema de Inferência <i>Fuzzy</i> Mamdani	28
3.1.4	Sistema de Inferência <i>Fuzzy</i> Takagi-Sugeno	29
3.1.5	Exemplo de Aplicação de um Sistema <i>Fuzzy</i> Takagi-Sugeno	31
3.2	Sistemas Evolutivos	35
3.2.1	Padronização dos Dados em Tempo Real	36

3.2.2	Agrupamento Evolutivo.....	36
3.2.3	Estimação dos Parâmetros dos Submodelos	38
4	Metodologia	41
4.1	Escolha do Tipo de Abordagem.....	42
4.2	Desenvolvimento do Modelo <i>Fuzzy</i> Evolutivo.....	45
4.2.1	Etapa de Treinamento	45
4.2.2	Etapa de Validação	51
4.3	Etapa de Detecção de Fraudes	52
4.3.1	Definição das Fraudes Introduzidas no Sistema	53
4.3.2	Construção do Detector de Fraudes <i>Fuzzy</i> Mamdani	54
4.4	Métricas para Avaliação do Desempenho	62
5	Casos de Estudo e Resultados	65
5.1	Detalhamento do Problema	65
5.2	Descrição dos Conjuntos de Dados	67
5.3	Caso 1: Modelagem dos Padrões de Consumo em Agregados Familiares e Supermercados .	69
5.3.1	Cenário 1: Agregado Familiar de Três Pessoas.....	69
5.3.2	Cenário 2: Supermercados com Área Inferior a 400 m ²	73
5.3.3	Análise dos Resultados e Comparação entre Cenários.....	75
5.4	Caso 2: Detecção de Fraudes em <i>Demand Response</i>	76
5.4.1	Simulação de Eventos por Deslocamento de Cargas.....	77
5.4.2	Concepção do Modelo de Participação Ativa do Prosumidor	79
5.4.3	Cenário 1: Caracterização do Sistema em Operação Normal	82
5.4.4	Cenário 2: Detecção de Manipulação em Dados de Flexibilidade	84
5.4.5	Análise dos Resultados e Comparação entre Cenários.....	86
6	Considerações Finais.....	89
6.1	Conclusões.....	89
6.2	Propostas de Trabalhos Futuros	91

Lista de Figuras

Figura 1 – Configuração e funcionalidades da medição inteligente	10
Figura 2 – Estratégias utilizadas na gestão do lado da demanda	12
Figura 3 – Conceito de <i>Transactive Energy</i>	18
Figura 4 – Modelo de comercialização de energia P2P	20
Figura 5 – Tipos de mecanismos de mercado P2P	23
Figura 6 – Funções de pertinência para a variável temperatura	26
Figura 7 – Sistema <i>fuzzy</i> com fuzzificador e defuzzificador	28
Figura 8 – Funções de pertinência gaussianas dos conjuntos <i>fuzzy</i> de entrada	33
Figura 9 – Saídas locais e pontos de linearização do sistema <i>fuzzy</i> TS	34
Figura 10 – Aproximação da função $y = x^3$ por meio de sistema <i>fuzzy</i> TS	34
Figura 11 – Exemplo de agrupamento <i>fuzzy</i> e pertinências de três amostras	37
Figura 12 – Diagrama de blocos da metodologia proposta	41
Figura 13 – Conjunto <i>fuzzy</i> “Geração” e funções de pertinência	56
Figura 14 – Conjunto <i>fuzzy</i> “Consumo” e funções de pertinência	56
Figura 15 – Conjunto <i>fuzzy</i> “Resíduo” e funções de pertinência	57
Figura 16 – Conjunto <i>fuzzy</i> “Grau de Alerta” e funções de pertinência	58
Figura 17 – Exemplo de defuzzificação por centroide no conjunto <i>fuzzy</i> “Grau de Alerta”	61
Figura 18 – Exemplo de injeção de dados falsos	67
Figura 19 – Treinamento do modelo (Caso 1, Cenário 1)	70
Figura 20 – Evolução das regras <i>fuzzy</i> (Caso 1, Cenário 1)	70
Figura 21 – Parâmetro σ e suporte de um <i>cluster</i> selecionado (Caso 1, Cenário 1)	71
Figura 22 – Validação do modelo (Caso 1, Cenário 1)	72
Figura 23 – Treinamento do modelo (Caso 1, Cenário 2)	73
Figura 24 – Evolução das regras <i>fuzzy</i> (Caso 1, Cenário 2)	74
Figura 25 – Validação do modelo (Caso 1, Cenário 2)	74
Figura 26 – Consumo desagregado por aparelhos, antes do evento de DR (Caso 2)	77
Figura 27 – Consumo total do participante e dos aparelhos, antes do evento de DR (Caso 2). 78	
Figura 28 – Consumo desagregado por aparelhos, após o evento de DR (Caso 2)	78
Figura 29 – Consumo total do participante e dos aparelhos, após o evento de DR (Caso 2) ...	79
Figura 30 – Dados de geração e consumo utilizados como entrada do algoritmo (Caso 2)	80
Figura 31 – Dados de flexibilidade utilizados como saída do algoritmo (Caso 2)	80
Figura 32 – Modelo de participação ativa gerado pelo eTS+ (Caso 2)	81
Figura 33 – Evolução das regras <i>fuzzy</i> (Caso 2)	81
Figura 34 – Dados não manipulados de geração e consumo (Caso 2)	82
Figura 35 – Validação do modelo utilizando novos dados de um dia (Caso 2)	83
Figura 36 – Grau de alerta obtido durante operação normal (Caso 2)	83
Figura 37 – Fraude pontual aplicada na flexibilidade e validação do modelo (Caso 2)	84
Figura 38 – Grau de alerta para detecção de fraude pontual (Caso 2)	85
Figura 39 – Fraude de menor intensidade e validação do modelo (Caso 2)	85
Figura 40 – Grau de alerta para detecção de fraude de menor intensidade (Caso 2)	86

Lista de Tabelas

Tabela 1 – Parâmetros dos conjuntos <i>fuzzy</i> de entrada.....	32
Tabela 2 – Saídas locais do sistema <i>fuzzy</i> TS do tipo 0	32
Tabela 3 – Base de regras do sistema <i>fuzzy</i> TS do tipo 0	32
Tabela 4 – Base de regras do sistema <i>fuzzy</i> TS do tipo 1	33
Tabela 5 – Parâmetros dos conjuntos <i>fuzzy</i> do sistema Mamdani	59
Tabela 6 – Base de regras <i>fuzzy</i> do sistema Mamdani	60
Tabela 7 – Conjuntos de dados utilizados nos casos de estudo	68
Tabela 8 – Comparação do eTS+ com outros métodos da literatura (Caso 1, Cenário 1).....	72
Tabela 9 – Comparação do eTS+ com outros métodos da literatura (Caso 1, Cenário 2).....	75
Tabela 10 – Preço da energia com base em tarifa bi-horária diária.....	77

Acrônimos e Símbolos

Lista de Acrônimos

AMI	<i>Advanced Measurement Infrastructure</i>
CPP	<i>Critical Peak Price</i>
DBB	<i>Demand Bidding and Buyback</i>
DR	<i>Demand Response</i>
DSM	<i>Demand Side Management</i>
DLC	<i>Direct Load Control</i>
DERs	<i>Distributed Energy Resources</i>
eTS+	<i>Evolving Takagi Sugeno Plus</i>
FDIA	<i>False Data Injection Attack</i>
HVAC	<i>Heating, Ventilation and Air Conditioning</i>
ICT	<i>Information and Communication Technologies</i>
IL	<i>Interruptible Load</i>
LfwRLS	<i>Local Fuzzy Weighted Recursive Least Squares</i>
MAE	<i>Mean Absolute Error</i>
MIMO	<i>Multiple Input / Multiple Output</i>
MISO	<i>Multiple Input / Single Output</i>
MSE	<i>Mean Squared Error</i>
P2P	<i>Peer to Peer</i>
RMSE	<i>Root Mean Square Error</i>
RTP	<i>Real Time Price</i>

SG	<i>Smart Grids</i>
ToU	<i>Time of Use Pricing</i>
TE	<i>Transactive Energy</i>
TES	<i>Transactive Energy System</i>

Lista de Símbolos

\mathbf{C}_k^i	Covariância da i -ésima regra <i>fuzzy</i> no instante k
\mathbf{z}_k	Dados de entrada e saída no instante k
$\bar{\mathbf{z}}_k$	Dados de entrada e saída padronizados no instante k
δ_k	Desvio padrão, no instante k , dos dados de entrada e saída (\mathbf{z}_k)
μ_j^i	Função de pertinência gaussiana no eixo j e para o cluster i
\mathbf{G}_k^i	Ganho da i -ésima regra <i>fuzzy</i> no instante k , por meio do método LfwRLS
λ_k^i	Grau de ativação normalizado da i -ésima regra <i>fuzzy</i> no instante k
i	Índice para identificação das regras <i>fuzzy</i> ou <i>clusters</i>
Δ_k^i	Matriz das proposições consequentes da i -ésima regra <i>fuzzy</i> no instante k
ζ_k	Média, no instante k , dos dados de entrada e saída (\mathbf{z}_k)
R	Quantidade de <i>clusters</i> ou regras <i>fuzzy</i>
$\tilde{\mathbf{y}}$	Saída global estimada pelo modelo (convertida para a escala original)
$\hat{\mathbf{y}}$	Saída global estimada pelo modelo (na forma padronizada)

1 Considerações Iniciais

O presente capítulo introduz os aspectos teóricos do trabalho desenvolvido. Em primeiro lugar, é feita uma contextualização com a realidade da União Europeia para cumprimento de acordos e metas de energia e clima. O tema está alinhado com a perspectiva atual dos sistemas de energia elétrica, os quais são constantemente monitorados e controlados por toda uma infraestrutura de tecnologia da informação e comunicação. Desse modo, são expostos três mecanismos recentes e intrinsecamente baseados no funcionamento das redes elétricas inteligentes. Estes visam o balanceamento entre a geração e o consumo de energia, fator que influencia diretamente na perspectiva global da transição energética. Entretanto, a ausência da validação das informações recebidas pode torná-los vulneráveis à manipulação dos dados de distribuição de benefícios. Nesse intuito, destaca-se no presente trabalho, a utilização de um método *fuzzy*¹ evolutivo para concepção de um modelo capaz de prever² dados de envolvimento dos indivíduos em programas de participação ativa de usuários finais. Além disso, em conjunto com dados de geração e consumo de energia, um sistema *fuzzy* Mamdani utiliza o resíduo obtido do modelo evolutivo para gerar estimativas de comportamentos anômalos. Esse conhecimento auxilia na detecção e prevenção de fraudes, contribuindo assim para a integridade e eficácia desses programas. Além da contextualização inicial, este capítulo apresenta as motivações que fundamentaram a escolha do tema, os objetivos formulados e a organização deste trabalho de dissertação.

¹O termo “fuzzy” pode ser traduzido como “nebuloso”, “vago” ou “impreciso”.

²Nesta dissertação, a palavra “previsão” possui o mesmo sentido de “predição, estimação ou identificação”, ou seja, trata-se da tarefa de reproduzir o comportamento dos dados observados.

1.1 Contextualização

A crescente preocupação ambiental e o aumento da conscientização pública nos últimos anos levaram muitos países a adotarem medidas para reduzir os impactos negativos ao meio ambiente. Nesse contexto, destaca-se a União Europeia (UE), por possuir um dos mais altos padrões de política ambiental do mundo, resultado de um conjunto de políticas e estratégias que visam uma transição ecológica, com o objetivo de alcançar a neutralidade climática até 2050. Com base no Plano de Metas Climáticas para 2030, a UE deve reduzir as emissões de gases de efeito estufa em pelo menos 55% abaixo dos níveis de 1990 até 2030 (Weitzel et al. 2023, Siitonen et al. 2023, Cifuentes-Faura 2022).

Nesse intuito, também foram apresentadas uma sequência de metas relacionadas às questões energéticas, baseadas em um plano de desenvolvimento denominado de REPowerEU. Este surgiu em resposta à perturbação do mercado global de energia pelo conflito Rússia/Ucrânia e representa uma alternativa para redução da dependência da Europa dos combustíveis fósseis russos, além de possuir foco em três principais fatores: produção de energia limpa, economia de energia e diversificação das fontes de produção (Kuzemko et al. 2022, Frilingou et al. 2023).

A produção de energia limpa inclui o investimento significativo em tecnologias renováveis, como energia solar e eólica. Conforme Faia et al. (2024), a quota de energia renovável instalada nos utilizadores finais de eletricidade aumentou significativamente nos últimos anos. Segundo o Roteiro Energético 2050 da Comissão Europeia (CE), 75% do consumo total de energia final deverá ser suprido por fontes renováveis até 2050. A expansão dessas fontes não apenas reduz a dependência de combustíveis fósseis, mas também contribui para a diversificação das fontes de produção e a criação de uma infraestrutura energética mais sustentável (Khojasteh et al. 2024).

Ademais, dentre os tópicos citados anteriormente, a CE define a economia de energia como a maneira mais rápida e barata de enfrentar a atual crise energética e reduzir os custos de produção (Kuzemko et al. 2022). A economia de energia envolve a implementação de medidas de eficiência energética, que incluem desde melhorias em infraestrutura, como a modernização de edifícios e indústrias, até a promoção de melhores práticas de consumo. Além disso, incentiva-se o desenvolvimento de tecnologias inovadoras dentro do contexto das redes elétricas inteligentes, que otimizam o uso e a distribuição da eletricidade. Essas medidas, aliadas à diversificação das fontes de energia e ao aumento da participação das energias renováveis, são essenciais para a descarbonização do setor energético (Falzon et al. 2024).

1.2 Enquadramento e Motivações

Ultimamente, estudos recentes vêm sendo publicados com foco em mecanismos de gerenciamento do lado da demanda, os quais podem ser categorizados principalmente em eficiência energética e *Demand Response*). Segundo Abedrabboh & Al-Fagih (2023), a eficiência energética consiste na melhoria da eficiência da procura, como também na alteração do comportamento do consumo para um mais eficiente. No caso da *Demand Response*, esta corresponde à modificação do consumo de eletricidade em resposta a sinais de preços, condições da rede elétrica ou outras necessidades operacionais (Zia et al. 2020).

Resumidamente, a *Demand Response* pode ser dividida em duas classes: baseada em incentivos (os consumidores são motivados a reduzir seu consumo durante períodos de alta demanda por meio de estímulos financeiros) e baseada em preços (são utilizadas variações nos preços da eletricidade ao longo do dia para incentivar os consumidores a ajustarem seu consumo de energia de acordo com a demanda). Algumas vantagens desse mecanismo são: melhoria da estabilidade do sistema elétrico; redução de custos operacionais; maior autonomia e participação ativa do usuário final (Stanelyte et al. 2022).

Além disso, com a integração de diferentes prosumidores³ na economia de energia, surge a necessidade de se estabelecer um mecanismo de comercialização de eletricidade. Dessa forma, surge o conceito de *Transactive Energy* (TE). Esta pode ser entendida como uma estrutura composta por participantes que usam ferramentas de automação para comunicar e trocar energia com base em restrições de valor e confiabilidade da rede. São usadas transações econômicas baseadas no mercado para negociação e compartilhamento de energia entre os prosumidores, produtores de energia renovável e convencional, sistemas de armazenamento e consumidores ativos dentro de um sistema de energia (Zia et al. 2020, Huang et al. 2021).

Um exemplo prático da implementação dos princípios de *Transactive Energy* são as comunidades energéticas baseadas em *Peer to Peer* (P2P). Nesse modelo, os participantes podem gerar, armazenar e compartilhar energia diretamente entre si. De certo modo, essa abordagem existe a partir de três tipos principais de mecanismos de mercado: descentralizado, centralizado e distribuído. A diferença fundamental entre eles reside na presença ou ausência de um coordenador. No modelo centralizado, há um coordenador responsável por intermediar as transações.

³Prosumidor é um termo que combina as palavras “produtor” e “consumidor” para descrever um indivíduo ou entidade que não apenas consome bens ou serviços, mas também os produz. No contexto dos sistemas de energia, um prosumidor é alguém que gera sua própria energia e também consome da rede elétrica.

No descentralizado, os pares negociam energia diretamente, sem a necessidade de terceiros. O modelo distribuído combina elementos de ambos, permitindo que os pares negociem energia diretamente entre si ou por meio de um coordenador (Suthar et al. 2023).

De forma geral, os programas de participação ativa viabilizam a troca de energia e a cooperação entre pequenos e médios consumidores, com foco no balanceamento entre consumo e geração. Entretanto, eles carecem de ferramentas para validação das informações obtidas, tornando o sistema vulnerável à manipulação dos benefícios. Neste contexto, a injeção de dados falsos surge como uma das principais ameaças nesses programas, pois permite que usuários mal-intencionados manipulem dados para obter vantagens indevidas. Isso pode resultar em distorções no balanceamento de carga, prejudicando a confiabilidade do sistema e comprometendo a equidade entre os participantes. Sem mecanismos eficazes de verificação e validação, a injeção de dados falsos pode gerar tanto impactos financeiros quanto técnicos, enfraquecendo a confiança no programa e inviabilizando sua expansão (Boopathy et al. 2024).

Dessa forma, uma solução eficaz para esse desafio consiste no desenvolvimento de modelos que capturem os padrões de participação dos prosumidores, garantindo transparência e prevenindo fraudes. Embora existam algumas abordagens promissoras, como o uso de algoritmos de aprendizado de máquina, a maioria dessas soluções ainda está em fase experimental ou apresenta limitações em termos de adaptabilidade e robustez. Em virtude da variedade, velocidade e volume crescente dos dados presentes em sistemas de energia, o desenvolvimento de modelos de previsão exige a adoção de um método que seja capaz de lidar com a complexidade e a dinâmica desses dados. Nesse contexto, os sistemas *fuzzy* evolutivos surgem como uma abordagem promissora, uma vez que o termo “*fuzzy*” refere-se à habilidade de lidar com incertezas e imprecisões inerentes aos dados, enquanto “evolutivo” indica a capacidade do sistema de alterar sua estrutura dinamicamente com base no conhecimento adquirido de amostras recebidas em tempo real.

Entretanto, a concepção de modelos de participação por si só não fornece informações suficientes para a detecção eficaz de fraudes, uma vez que estas dependem de uma variedade de fatores, incluindo a variabilidade dos comportamentos dos prosumidores, as diferenças nas técnicas de manipulação de dados e as particularidades de cada programa de participação. Portanto, o método de detecção de fraudes deve ser adaptável a cada cenário e capaz de incorporar o conhecimento dos operadores responsáveis, permitindo ajustes contínuos e refinamentos com base em novas evidências e padrões emergentes.

1.3. Objetivos

Desse modo, a solução proposta no presente trabalho consiste na aplicação de um método *fuzzy* evolutivo conhecido como *Evolving Takagi-Sugeno Plus* (eTS+), na modelagem dos padrões de participação dos indivíduos, na forma de dados de consumo e flexibilidade. Ademais, um sistema *fuzzy* Mamdani é utilizado com o objetivo de gerar indicativos de fraudes a partir de comportamentos anômalos nos dados observados. A integração entre esses dois métodos *fuzzy* proporciona robustez e interpretabilidade à metodologia desenvolvida, resultando em uma ferramenta abrangente para previsão e monitoramento das informações obtidas dos prosumidores.

1.3 Objetivos

O presente trabalho visa garantir a segurança, eficiência e transparência dos programas de participação ativa de usuários finais de energia. A metodologia desenvolvida visa fornecer suporte às entidades responsáveis pela gestão desses programas, auxiliando-os a garantir a integridade dos dados coletados. Para alcançar esse objetivo, o trabalho foi organizado em uma sequência de tarefas, as quais estão expostas a seguir.

- Levantamento da base bibliográfica e revisão sistemática do estado da arte;
- Desenvolvimento e implementação de modelos de previsão de participação a partir de dados comuns, como geração e consumo de energia;
- Planejamento e implementação de um modelo de detecção de fraudes, levando em consideração fatores como a interpretabilidade do método escolhido, com o intuito de facilitar a validação das informações fornecidas pelos usuários finais.
- Aplicação da metodologia desenvolvida em casos de estudos reais, análise dos resultados e comparação com outras estratégias disponíveis na literatura.

1.4 Organização do Documento

O documento está organizado em seis capítulos principais, nos quais são abordados os aspectos mais importantes do trabalho realizado.

Após a exposição da introdução no capítulo 1, o capítulo 2 apresenta o estado da arte, considerando a área de sistemas de energia. Nesse tópico, são descritos em detalhes: a importância das *Smart Grids* para o contexto atual dos sistemas de energia elétrica; o funcionamento das

estratégias de *Demand Response* (tanto baseada em preços, como baseada em incentivos); o conceito inovador de *Transactive Energy* e sua relação com a participação ativa dos usuários finais; e os sistemas de compartilhamento de energia baseados em *Peer to Peer*, sua arquitetura e mecanismos de mercado.

No capítulo 3, são expostos os fundamentos de Sistemas *Fuzzy*, incluindo a apresentação dos principais sistemas *fuzzy* clássicos, que constituem a base deste trabalho; e os Sistemas Evolutivos, explorando a padronização dos dados em tempo real, a formação de agrupamentos por aprendizagem evolutiva e a estimação dos parâmetros dos submodelos *fuzzy*.

No capítulo 4, a metodologia é descrita em uma sequência de etapas: primeiramente, são discutidos os principais tipos de abordagens utilizadas nas metodologias do estado da arte. Posteriormente, é explicado o processo de implementação e validação do método *fuzzy* evolutivo selecionado para modelagem dos padrões de participação dos indivíduos. Segue-se a etapa de detecção de fraudes, onde é demonstrado como comportamentos fraudulentos serão simulados e onde são detalhadas as fases de desenvolvimento do sistema *fuzzy* Mamdani para detecção de fraudes. Ao final do capítulo, são apresentadas as métricas utilizadas para avaliação do desempenho dos modelos desenvolvidos.

O capítulo 5 apresenta os casos de estudo formulados e os resultados obtidos com a aplicação da metodologia desenvolvida. Em primeiro lugar, detalha-se o problema de injeção de dados falsos em programas de participação ativa de usuários finais de energia. Na sequência, demonstra-se a eficácia do método *fuzzy* evolutivo na modelagem dos padrões de participação dos indivíduos. Além disso, no segundo caso de estudo, o modelo treinado é utilizado para estimar a flexibilidade para o dia corrente. No entanto, o foco principal deste segundo caso é a simulação de um cenário de fraude em um programa de *Demand Response*, utilizando o sistema *fuzzy* Mamdani proposto para identificação de potenciais pontos de manipulação.

Por fim, no capítulo 6, são apresentadas as conclusões desta dissertação, juntamente com propostas de trabalhos futuros.

2 Estado da Arte

Este capítulo consiste em uma revisão abrangente de três áreas-chave pertinentes ao trabalho proposto. Primeiramente, destaca-se a importância das redes elétricas inteligentes no atual cenário dos sistemas de energia elétrica. Em seguida, uma análise detalhada sobre *Demand Response* é apresentada, enfatizando seu papel crucial como um mecanismo que permite a participação ativa dos consumidores finais de energia, visando o equilíbrio entre oferta e demanda de energia. Por fim, é discutido o conceito de *Transactive Energy*, além da sua relação com as negociações *peer-to-peer*.

2.1 Redes Elétricas Inteligentes

Os sistemas de energia convencionais foram concebidos com base em uma cadeia de valor para a energia elétrica que consiste em instalações de geração de energia centralizadas e ativamente controladas, com o objetivo de atender a demanda de um número relativamente grande de cargas passivas (de Lima et al. 2024). Além disso, a energia elétrica deve fluir de forma unidirecional: dos grandes centros de produção para os usuários finais. Desse modo, as redes elétricas são formadas basicamente por três estruturas principais:

- **Redes de transmissão:** Diretamente conectadas às grandes usinas centralizadas e têm a função de transmitir energia por distâncias muito longas. Nesse nível, a complexa estrutura malhada da rede melhora a robustez e permite a troca de energia com os países vizinhos.
- **Rede de subtransmissão:** Garante o fornecimento de energia aos grandes consumidores. Também despacha energia para subestações que abastecem a rede de distribuição.

- Rede de distribuição: Nesse estágio, são previstas estações de transformação abaixadoras que ajustam os níveis de tensão para valores compatíveis com as cargas regionais. Normalmente são compostas por uma estrutura radial de linhas de baixa tensão com ramificações relativamente pequenas, uma vez que o custo de construção e manutenção das estruturas malhadas é muito alto.

Desse modo, conforme Qays et al. (2023), um desperdício substancial de energia é suportado nas redes elétricas convencionais, as quais apresentam alguns desafios, como o aumento contínuo na demanda de carga e no nível de penetração de fontes de energia renováveis. Esses fatores têm levado vários órgãos governamentais a implementar medidas para maximizar a eficiência do uso da eletricidade, como a redução do consumo de energia auxiliar, a troca inteligente de cargas na rede de distribuição e o monitoramento das perdas nos sistemas de transmissão e distribuição (Dewangan et al. 2023).

De acordo com Lezama et al. (2020), a natureza simplista da rede convencional torna o sistema limitado. A falta de flexibilidade atrapalha a reação a falhas intermitentes, além de dificultar o redirecionamento do excesso de energia em um setor para locais com mais necessidade. Segundo Faia et al. (2024), a transformação do sistema de energia impõe novos desafios na operação e gestão que devem ser enfrentados para explorar todo o potencial nos diferentes níveis de abastecimento. Com o intuito de reduzir os problemas associados à geração convencional e promover uma transformação na infraestrutura da rede elétrica, pesquisas vêm sendo direcionadas ao contexto das Redes Elétricas Inteligentes (*Smart Grids* - SG) (Abdulsalam et al. 2023).

2.1.1 Conceitos e Definições

O conceito de rede inteligente foi introduzido como uma nova visão da rede elétrica convencional: um sistema digital avançado de fluxo bidirecional, capaz de realizar autocorreção, adaptável, resiliente e sustentável, além de oferecer previsão de carga com diferentes níveis de incerteza. Mudanças revolucionárias nos sistemas de comunicação apresentam maior possibilidade de controle e monitoramento em todo o sistema de energia, e conseqüentemente se tornam a opção mais barata, flexível e eficaz. Desse modo, as *Smart Grids* são uma chance de usar as novas tecnologias de comunicação e informação para transformar o sistema convencional de energia (Dileep 2020). Algumas vantagens da popularização e desenvolvimento das SG incluem: o aumento da segurança e resiliência da rede de distribuição; recursos avançados de monitoramento de geren-

2.1. Redes Elétricas Inteligentes

ciamento de carga; produção de eletricidade mais limpa e descentralizada; fluxo bidirecional de eletricidade e a redução de custos nas operações da rede devido ao balanceamento dinâmico entre produção e demanda.

De forma geral, as redes elétricas inteligentes envolvem uma série de elementos interligados que trabalham em conjunto para viabilizar uma rede elétrica adaptável às demandas contemporâneas. Entre esses elementos, destacam-se as Infraestruturas de Medição Avançada (AMI), as quais possibilitam uma coleta mais precisa e em tempo real de dados de consumo, os Recursos Energéticos Distribuídos (DERs), que promovem uma diversificação e descentralização da geração de energia ao integrar fontes renováveis e tecnologias de armazenamento, e o contínuo foco em Segurança Cibernética para proteger contra potenciais ameaças digitais que podem comprometer a integridade e operação das redes. Em virtude da relevância desses temas para o contexto das *Smart Grids*, todos serão detalhadamente discutidos a seguir.

2.1.2 Infraestrutura de Medição Avançada

A infraestrutura de medição avançada é uma das partes críticas de uma rede elétrica inteligente. É considerado um dos primeiros passos para a digitalização dos sistemas de controle da rede elétrica. Geralmente, a AMI consiste nos medidores inteligentes concentradores e no sistema de gerenciamento de dados de medição. Este é considerado um componente essencial na AMI e serve basicamente como um banco de dados de longo prazo e gerenciamento de eventos. Os medidores inteligentes possuem a função de registrar o consumo de energia do utilizador final e reportar isso ao centro de utilidades. Os recursos avançados suportados pelos medidores inteligentes são comunicação bidirecional, geração distribuída, automonitoramento, autocorreção, autoadaptação e controle abrangente (Singh & Mahajan 2021).

Além disso, os medidores inteligentes consistem basicamente na placa de comunicação e na placa do medidor que são conectados por meio de uma porta serial. A placa de comunicação usa um mecanismo baseado em interrupção para obter dados ou outras informações necessárias da placa do medidor. Após esse processo, os dados são enviados para a concessionária pela placa de comunicação (Mohapatra & Rath 2021). Devido à digitalização, os medidores de energia inteligentes têm mais pontos de ataque em comparação com os medidores de energia tradicionais (Ajiboye et al. 2024). Conforme pode ser visto na Figura 1, a estrutura de medição permite que o medidor inteligente tenha funções de registro e armazenamento de dados (comumente apre-

sentados na forma de tensão e corrente). A estrutura de comunicação permite a comunicação bidirecional entre o consumidor e o utilitário através da conexão de linha de energia ou conexão sem fio. Além disso, esse módulo permite que os medidores inteligentes se conectem aos centros remotos para fins de controle e gerenciamento (Chen et al. 2023).




Figura 1 – Configuração e funcionalidades da medição inteligente (adaptado de Chen et al. (2023))

2.1.3 Recursos Energéticos Distribuídos

Ultimamente, os recursos energéticos distribuídos ganharam atenção especial devido à sua rápida implantação na instalação de capacidade de energia (González & Rendon 2022). Estes referem-se basicamente a fontes de energia descentralizadas de pequena escala que geram eletricidade localmente, como painéis solares e turbinas eólicas. Além disso, de acordo com Jaramillo et al. (2021), outras cargas inteligentes e tecnologias de baixo carbono, como aquecimento elétrico, ar condicionado e cogeração também podem ser vistos com DERs.

A importância dos DERs está na sua capacidade de promover a redução de gases de efeito estufa, a redução da participação da energia convencional, a criação de novos modelos de negócios para todo o setor de energia e o surgimento em massa de prosumidores e tecnologias de participação ativa por parte do usuário final. Os impactos positivos dos DERs são a redução das perdas, a melhoria dos perfis de tensão e o aumento da resiliência da rede elétrica. Entretanto, as desvantagens dessa tecnologia são a instabilidade da tensão e frequência e a desconexão da geração distribuída (González & Rendon 2022).

2.1.4 Segurança Cibernética

Conforme Inayat et al. (2022), a segurança cibernética nas redes inteligentes tem o objetivo de defender a confidencialidade, disponibilidade e integridade de dispositivos eletrônicos e redes de computadores. Envolve a proteção dos sistemas e redes digitais que controlam a geração, transmissão e distribuição de eletricidade contra acesso não autorizado, manipulação ou interrupção. Os ataques cibernéticos em redes inteligentes podem causar quedas de energia generalizadas, danos a equipamentos e até mesmo danos físicos às pessoas e ao meio ambiente. Com o objetivo de lidar com esses riscos, a implementação de redes inteligentes deve ter como foco a:

- **Proteção contra ataques cibernéticos:** as redes inteligentes enfrentam uma variedade de ameaças cibernéticas. Com a proliferação de dispositivos inteligentes conectados à rede, os problemas causados por ataques cibernéticos a esses tipos de infraestrutura devem receber mais atenção. Um exemplo de proteção contra esses ataques é a criptografia, a qual deve ser usada para proteger todos os dados confidenciais, incluindo dados de autenticação do usuário, dados de configuração e comandos de controle (Singh et al. 2021).
- **Segurança de dados:** Conforme pode ser visto no tópico anterior, as redes inteligentes dependem da coleta e análise de grandes quantidades de dados, que podem ser sensíveis e confidenciais. Garantir a segurança desses dados é crucial para manter a integridade da rede elétrica. Uma forma de realizar essa tarefa é a partir de algoritmos baseados em Inteligência Artificial (IA), como exposto em Haq et al. (2023), onde é feita uma implementação de uma rede neural convolucional para detecção de roubo de eletricidade a partir de dados de consumo de medidores inteligentes.
- **Confiabilidade do sistema:** Segundo Abrahamsen et al. (2021), ataques em *Smart Grids* podem ocorrer em todos os níveis, desde a geração e distribuição até redes domésticas. Os ataques bem-sucedidos podem levar à instabilidade da rede ou, no pior dos casos, falhas e apagões. Dessa forma, as medidas de segurança cibernética devem ser projetadas para garantir a confiabilidade e resiliência de todo o sistema.

2.2 Demand Response

Com o intuito de realizar mudanças positivas no sentido da Transição Energética, investimentos foram aplicados para criação e implementação de métodos de gerenciamento eficiente de ener-

gia. Alguns desses métodos são conhecidos como mecanismos de participação ativa de consumidores finais de energia e consistem em iniciativas e abordagens que incentivam os consumidores a se envolverem ativamente no processo de compra, venda e consumo de energia elétrica. Essa atividade está intimamente relacionada com a busca pela otimização da demanda de energia elétrica por parte dos consumidores, a fim de obter equilíbrio, melhorar a eficiência energética e reduzir a necessidade de investimentos em infraestrutura adicional. Desse modo, grandes exemplos disso estão presentes em técnicas de gerenciamento do lado da demanda (DSM).

De acordo com Guelpa & Verda (2021), o DSM é provavelmente o termo mais difundido para descrição da mudança de comportamento de consumo do usuário, com o objetivo de atender requisitos ou objetivos específicos. Consiste em um arranjo de ações que vão desde o aumento da eficiência energética até o gerenciamento contínuo dos recursos de energia alocados. O padrão de carga deve ser alterado para uma operação ideal do sistema, a qual pode ser obtida por meio de DSM. Este tem como foco principal a integração de técnicas de economia de energia, preços unitários variáveis ou dinâmicos para reduzir a carga de pico em vez de atender à demanda, confiando em novas fontes de geração.

A integração do DSM à infraestrutura da *Smart Grid* pode ser alcançada por meio da utilização de sistemas de comunicação, dispositivos de controle baseados em sensores e dispositivos de medição automatizados. Nesse contexto, os mais recentes dispositivos de tecnologia da informação e comunicação (ICT) podem fornecer maior eficiência na operação da rede (Mohanty et al. 2022). De acordo com Panda et al. (2022), as modificações que podem ser feitas no perfil de consumo podem ser classificadas em quatro tipos: Eficiência Energética; *Time of Use*; Reserva giratória e *Demand Response* (Figura 2). Entretanto, uma das formas mais utilizadas é a *Demand Response*, a qual será detalhadamente descrita a seguir.




Figura 2 – Estratégias utilizadas na gestão do lado da demanda (adaptado de Panda et al. (2022))

A *Demand Response* consiste em uma metodologia relevante de gerenciamento do lado da demanda, uma vez que permite equilibrar a oferta e demanda de energia elétrica, gerenciar picos de demanda, integrar fontes renováveis intermitentes, promover a eficiência energética e in-

centivar a participação ativa dos consumidores. Entretanto, estes programas estão sujeitos à manipulação de informações, as quais ocorrem com o intuito de influenciar resultados em um determinado contexto, gerando vantagens financeiras sobre os outros participantes e afetando a operação do sistema elétrico. Desse modo, a fim de fundamentar essa área de estudo, abaixo estão descritas as definições da *Demand Response* e as diferentes formas em que a gestão de energia pode ser realizada.

2.2.1 Caracterização e Funcionamento

De acordo com a Comissão Federal Reguladora de Energia (FERC), a *Demand Response* é definida como um programa desenvolvido com o intuito de motivar mudanças no consumo de energia dos usuários finais, com base nas variações do preço da eletricidade ao longo do tempo ou através da aplicação de incentivos financeiros aos participantes, destinados a reduzir o consumo em momentos de pico ou quando a confiabilidade da rede é comprometida (Patnam & Pindoriya 2021). Outra definição mais recente foi publicada na Diretiva Europeia 2019/944, a qual afirma que este programa consiste na “alteração, por parte dos clientes finais, dos seus padrões de consumo normais ou correntes, em resposta aos sinais do mercado” (Silva et al. 2022).

Desse modo, considerando o cenário atual, os programas de *Demand Response* modernos proporcionam um envolvimento mais ativo dos clientes de todos os setores, bem como os mecanismos pelos quais a flexibilidade do lado da demanda é fornecida. Com o crescente aumento da flexibilidade da demanda dos consumidores, surge também a necessidade de preços mais dinâmicos, além de mecanismos baseados em mercado (D’Ettorre et al. 2022). Em resumo, a *Demand Response* pode ser dividida em dois tipos principais que se baseiam na forma como a mudança do consumo é incentivada, os quais são os programas baseados em preços e os baseados em incentivos. Os programas baseados em preços são subdivididos em: *Time of Use Pricing* (ToU), Preço de Pico Crítico (CPP) e Preços em Tempo Real (RTP). No caso dos baseados em incentivos, estes podem ser de Controle de Carga Direta (DLC), de Carga Interrompível (IL) e de Licitação de Demanda e Recompra (DBB). Todos os tipos serão discutidos com mais detalhes a seguir.

2.2.2 Tipos de *Demand Response* Baseados em Preços

Nos programas baseados em preços, os consumidores são expostos diretamente a preços e/ou tarifas variáveis no tempo. Isso leva a uma maior aleatoriedade no comportamento do consumi-

dor quando comparada a programas baseados em incentivos, para os quais as regras contratuais determinam comportamentos esperados. No entanto, essa metodologia aumenta a conscientização do consumidor sobre o impacto do uso da eletricidade nos custos gerais do sistema e incentiva a redução de gastos de energia, por meio do direcionamento da maior parcela do consumo para horários de baixa tarifa (D’Ettorre et al. 2022).

Desse modo, esse tipo é usado para nivelar a curva de demanda e para evitar o reforço da rede no longo prazo, mas não fornece flexibilidade em tempo real ao sistema, uma vez que não há compromisso do ponto de vista do consumidor, o qual pode decidir livremente se irá reagir aos sinais de preço ou não (Freire-Barceló et al. 2022, Silva et al. 2022). Como exemplo, no trabalho de Mota et al. (2024), um algoritmo genético é proposto para minimização dos custos de energia com base em preços dinâmicos, geração distribuída e compartilhamento de energia da comunidade doméstica. A eficácia do algoritmo é comprovada por meio de dois estudos de caso baseados em dados reais de consumo domiciliar: o primeiro estudo aborda a otimização dos custos de energia para uma residência individual, enquanto o segundo explora a gestão dos custos em uma comunidade de vinte casas que compartilham energia fotovoltaica.

2.2.2.1 *Time of Use Pricing*

Esse tipo de esquema de *Demand Response* é baseado em tempo e fornece preços fixos para diferentes períodos cíclicos considerados, como um dia ou uma semana. Usualmente, um dia é dividido em três intervalos, denominados de intervalo de pico, intervalo de meio-pico e intervalo fora do pico. Dessa forma, os consumidores são cobrados de forma severa ao consumirem energia nos horários de pico. Isso estimula a redução do consumo nesses horários e a movimentação das cargas removíveis para os horários fora de pico (Ranaboldo et al. 2024).

Ademais, geralmente é fornecido um preço pré-determinado com base na carga do sistema, como uma taxa de pico durante as horas de demanda de carga de pico. Durante esse período, o custo da eletricidade será cobrado ao preço da tarifa de ponta. Do mesmo modo, em momentos de baixa carga, a eletricidade será cobrada com base na menor tarifa possível (Kiptoo et al. 2020). De acordo com Parrish et al. (2020), existem ainda duas outras terminologias, as quais são o TOU-CPP e o dTOU. O TOU-CPP é o preço de pico crítico sobreposto ao ToU. Desse modo, este possui duas componentes de preço: o preço diário ToU e o preço de pico crítico ocasional aplicado durante eventos críticos do sistema. O dTOU significa preço dinâmico de uso e nele os preços variam entre os níveis de preços fixos, mas o tempo de preços diferentes não é fixo.

2.2. Demand Response

2.2.2.2 Preço de Pico Crítico

Segundo Ranaboldo et al. (2024) e Amin et al. (2020), o preço de pico crítico é semelhante ao ToU, exceto em momentos em que a confiabilidade do sistema é comprometida, fazendo com que o preço normal de pico seja substituído por um preço muito mais alto. O CPP responde de maneira adequada com base nas condições atuais, ao invés de se basear em dados históricos. Comparando com o ToU, o CPP possui preços muito mais elevados e uma maior eficácia na redução da carga de pico. Além disso, esse esquema se aplica durante um período estritamente definido e é normalmente utilizado durante um número limitado de dias por ano (Parrish et al. 2020).

2.2.2.3 Preços em Tempo Real

No caso desse tipo de tarifação, também chamada de "preço dinâmico", as tarifas de eletricidade variam tipicamente de hora em hora, refletindo as flutuações do preço do mercado grossista. Dessa forma, os consumidores são normalmente comunicados com cerca de um dia ou uma hora de antecedência. Quando os preços não são divulgados com base no dia seguinte, é necessário um módulo de previsão de preços para a gestão energética dos consumidores (Ranaboldo et al. 2024). De acordo com Silva et al. (2020), esse programa é considerado um dos mais eficientes e econômicos, uma vez que permite que os varejistas participem das tarefas de distribuição de energia com menos riscos.

Além desses fatores, a *Demand Response* baseada em RTP incentiva os consumidores a ajustarem suas rotinas de consumo para obter mais benefícios monetários. Conforme Nawaz et al. (2022), a eficácia dos programas RTP depende da troca eficiente de informações entre o fornecedor e o consumidor. Isso significa que qualquer atraso ou imprecisão nas informações de preços pode afetar diretamente o comportamento dos consumidores, diminuindo a eficácia do programa. Desse modo, para a implementação de um esquema RTP, são exigidas capacidades de comunicação em tempo real nas instalações dos consumidores, além de um alto requisito de largura de banda. Como forma de resolver esse problema, o *Day-Ahead* RTP (DA-RTP) é frequentemente utilizado, onde os consumidores recebem a informação dos preços previstos em tempo real para o dia seguinte e são cobrados pelo consumo do dia anterior. No trabalho de Rodrigues et al. (2022), é visto que atualmente existem duas modalidades principais de precificação em tempo real sendo praticadas, sendo uma delas o DA-RTP e outra que fornece o preço com uma hora de antecedência, conhecida como RT-RTP.

2.2.3 Tipos de *Demand Response* Baseados em Incentivos

Nos programas baseados em incentivos, os consumidores optam por participar dos mercados de energia e recebem pagamentos em troca da variação de carga oferecida e aceita no mercado. Caso não haja resposta ou não ocorra o cumprimento das demandas contratuais, o participante é penalizado (Nawaz et al. 2022, Davarzani et al. 2021, Iqbal et al. 2021). Ao contrário de mecanismos baseados em preços, neste a flexibilidade do lado da demanda é considerada um recurso despachável, que pode ser negociado em mercados de energia e balanceamento. Isto é realizado oferecendo aos consumidores incentivos financeiros para reduzir suas próprias cargas ou dando-lhes o direito de desligar suas cargas em determinados momentos ou por um determinado período (D’Ettorre et al. 2022, Kanakadhurga & Prabakaran 2022).

Percebe-se, atualmente, o crescimento da disponibilidade de produtos de mercados baseados em incentivos para pequenos clientes residenciais. Como exemplo disso, na Finlândia, a empresa Helen Ltd fornece a implementação de ações de controle de carga direta aos usuários finais de pequena e grande escala, com o intuito de explorar a flexibilidade destes em troca de benefícios econômicos (D’Ettorre et al. 2022). Além disso, é válido ressaltar a importância dos dispositivos de medição inteligente para o correto funcionamento de programas baseados em incentivos. Isso se justifica na necessidade de registro dos dados de consumo de forma efetiva, além de permitir a comunicação em tempo real nas redes elétricas inteligentes. A não disponibilidade destes torna o sistema vulnerável à manipulação dos mecanismos de participação e distribuição de benefícios, uma vez que aplicar os procedimentos de medição e verificação seria uma tarefa árdua (Ahmadzadeh et al. 2021, Elma et al. 2022, D’Ettorre et al. 2022).

2.2.3.1 Controle de Carga Direta

Conforme Ranaboldo et al. (2024), o controle de carga direta é um programa de *Demand Response* patrocinado pela concessionária que permite que sejam ligados ou desligados dispositivos específicos durante os períodos de pico de demanda. O DLC fornece uma capacidade de regulação de frequência muito rápida, pois permite que a concessionária desligue remotamente os aparelhos elétricos dos participantes em um prazo muito curto. Os principais participantes do DLC são residenciais e pequenas cargas comerciais; as cargas participantes, como condicionadores de ar e aquecedores de água, podem suportar as interrupções de curto prazo e não degradar sua qualidade de serviço (Wu & Tang 2019, Waseem et al. 2020). Nesse contexto, de acordo com Yuan et al. (2021), Azuatalam et al. (2020) e Tomat et al. (2022), grande parte das aplicações de

DLC são vistas no controle de sistemas de aquecimento, ventilação e ar-condicionado (HVAC) em edifícios, com o objetivo de proporcionar o melhor conforto térmico para os ocupantes. Além disso, isso ocorre porque os sistemas HVAC desempenham um papel significativo na resposta da demanda, os quais são comumente utilizados para otimizar o gerenciamento de energia por meio de termostatos inteligentes controlados a partir de DLC.

2.2.3.2 Carga Interrompível

Esse tipo de programa consiste em operadores que solicitam aos clientes uma redução de carga pré-definida, onde os que não respondem ao chamado são penalizados. Uma vez que as cargas residenciais são normalmente consideradas como agregadas, isso facilita a comunicação e o gerenciamento do operador (Davarzani et al. 2021). A carga interrompível é a parte interrompível da carga do usuário durante os períodos de pico de carga ou emergência, permitindo uma resposta rápida e melhorando a resiliência do lado da demanda (Wang et al. 2020).

2.2.3.3 Licitação de Demanda e Recompra

Nos programas de licitação de demanda e recompra, um protocolo automatizado de negociação é estabelecido entre os fornecedores e os consumidores de energia. Ambos os participantes concordam com o preço – considerando todas as situações de forma isolada e de acordo com as flutuações do mercado – para uma quantidade predeterminada de cortes voluntários da demanda de ponta disponibilizados pelo consumidor ao fornecedor. Atualmente, grande parte das aplicações desses programas são vistas com sucesso em grandes consumidores, como indústrias e grandes edifícios comerciais, uma vez que para clientes residenciais é normalmente impraticável (Rodrigues et al. 2022).

2.3 *Transactive Energy* e Negociações *Peer to Peer*

A presente subseção explora dois conceitos essenciais para o correto funcionamento dos mecanismos de participação ativa dos consumidores finais de energia. Primeiramente, são apresentados os princípios básicos de *Transactive Energy*, destacando suas características e como essa abordagem pode contribuir para uma rede elétrica mais flexível. Em seguida, são expostos os fundamentos de *Transactive Energy* e os detalhes das negociações *Peer to Peer*, incluindo a arquitetura, os sistemas de compartilhamento de energia, os mecanismos de mercado e as oportunidades econômicas que essas práticas podem gerar para os consumidores e o setor elétrico.

2.3.1 Definição de *Transactive Energy*

Este é um conceito revolucionário que está transformando o setor energético em todo o mundo. Tradicionalmente, os consumidores de energia elétrica eram apenas receptores passivos, limitados a pagar suas contas e consumir a eletricidade fornecida pelas concessionárias. No entanto, o paradigma de *Transactive Energy* está mudando essa dinâmica, permitindo que os consumidores se tornem participantes ativos e engajados no mercado de energia. De acordo com a *GridWise Architecture Council*, *Transactive Energy* consiste em “um sistema de mecanismos econômicos e de controle que permite o equilíbrio dinâmico entre oferta e demanda em toda a infraestrutura elétrica, usando o valor como parâmetro operacional chave” (Figura 3). Na definição, o termo “sistema” refere-se a uma rede composta por múltiplos participantes, cada um com seus próprios objetivos individuais e/ou sociais, que seguem um conjunto de regras comuns. O equilíbrio dinâmico entre oferta e demanda é essencial, uma vez que tanto a oferta quanto a demanda estão em constante mudança, exigindo um equilíbrio contínuo para evitar instabilidades e garantir a segurança da infraestrutura elétrica (Zia et al. 2020).

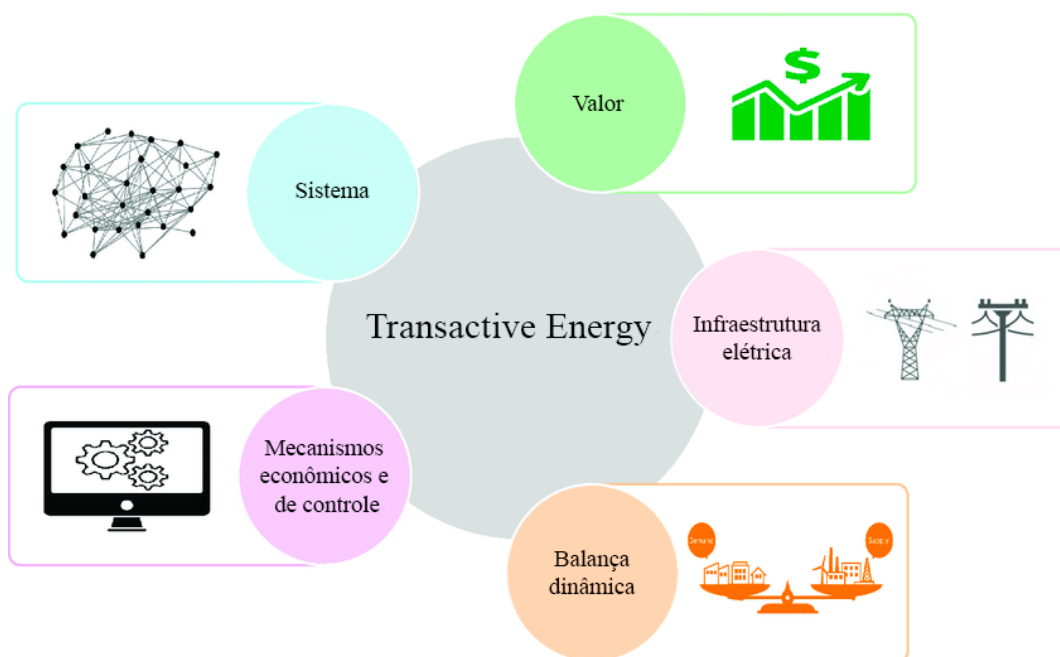


Figura 3 – Conceito de *Transactive Energy* (adaptado de Zia et al. (2020))

O valor no contexto do sistema está relacionado ao Preço Marginal de Custo (MCP) pelo qual os participantes do mercado comercializam e consomem energia, buscando um resultado benéfico para todos. Esse valor busca criar uma situação de ganha-ganha, onde todos os participantes recebem incentivos justos. O MCP é fundamental para a operação do mercado e a realização de

2.3. *Transactive Energy* e Negociações *Peer to Peer*

um Sistema Transativo de Energia (TES). Ele é definido como o preço marginal de curto prazo por unidade de transação de energia em um local específico, devendo ser transparente para todos os participantes. Além disso, todas as decisões de transação de energia dentro de um TES são baseadas nesses sinais de preço (Li et al. 2020, Zia et al. 2020).

Um sistema baseado em *Transactive Energy* aproveita as flexibilidades dos prosumidores para aprimorar o equilíbrio entre oferta e demanda da rede elétrica, ao mesmo tempo em que lida com os desafios das redes locais. Por exemplo, por meio do sinal de preço, é possível equalizar as curvas de demanda dos consumidores, deslocando o consumo de eletricidade de períodos de pico para horários de menor demanda. Uma abordagem alternativa é permitir que a demanda siga a geração, aumentando assim o fator de carga das instalações de geração existentes (Nizami et al. 2022). Além disso, um exemplo muito comum da implementação de conceitos de *Transactive Energy* é o compartilhamento de energia entre participantes por meio de transações *Peer to Peer*. Em virtude da importância dessas negociações para o objetivo dos mecanismos de participação ativa de usuários finais, estas serão detalhadas a seguir.

2.3.2 Principais Conceitos e Arquitetura do Mercado *Peer to Peer*

O *Peer to Peer* consiste em uma técnica de gerenciamento de energia de última geração que tem como objetivo beneficiar economicamente os consumidores proativos que transacionam sua energia como bens e serviços. Além disso, o comércio de energia P2P dá mais flexibilidade aos usuários finais, gerando oportunidades de consumir energia limpa e contribui para a transição energética (Soto et al. 2021, Tushar et al. 2020). De acordo com Xia et al. (2022), o comércio de energia P2P pode ser visto como uma "economia compartilhada". Isso porque permite que os clientes compartilhem seu excedente de geração no local ou a flexibilidade de sua demanda de energia com outros necessitados. Refere-se a um conceito de troca direta de eletricidade, sem a necessidade de um intermediário, como acontece nos programas de *Demand Response*. Algumas vantagens do P2P são: melhoria da confiabilidade do sistema elétrico; fortalecimento do vínculo social; equilíbrio entre oferta e demanda; corte da demanda de pico; diminuição da necessidade de geração e a redução das contas de eletricidade (Azim et al. 2022).

A Figura 4 ilustra a arquitetura do modelo de comércio P2P. Existem quatro atores principais: consumidores, prosumidores, a concessionária de energia elétrica e o coordenador de compartilhamento de energia. A diferença entre prosumidores e consumidores é que os consumidores

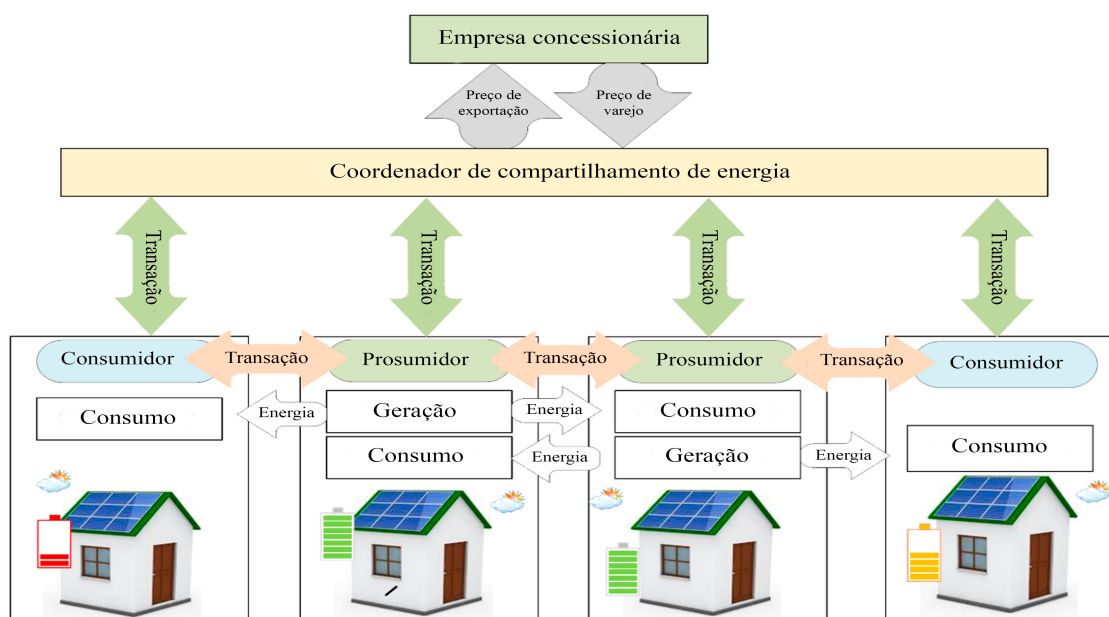


Figura 4 – Modelo de comercialização de energia P2P (adaptado de Bukar et al. (2023))

apenas consomem a eletricidade disponível, enquanto os prosumidores produzem e consomem. Entre estes dois atores, há trocas de energia e dinheiro que são representadas respectivamente pelas setas de energia e setas de negociação. O processo de negociação é intermediado por uma plataforma supervisionada pelo coordenador, permitindo que um participante negocie a venda de eletricidade com consumidores e prosumidores.

No modelo de comercialização de eletricidade P2P, o custo de exportação da eletricidade é estabelecido abaixo do preço de varejo, com o intuito de incentivar os prosumidores a equilibrar a geração distribuída. Inicialmente, prosumidores e consumidores compartilham sua geração e consumo em um mercado local, a um preço doméstico, e em seguida negociam com um varejista. Geralmente, o preço doméstico é determinado entre o preço de exportação e o preço de varejo. Essa abordagem permite que consumidores e prosumidores se beneficiem da troca de eletricidade por meio do comércio P2P (Soto et al. 2021).

2.3.3 Estrutura dos Sistemas de Compartilhamento de Energia *Peer to Peer*

O compartilhamento de energia P2P considera as exigências dos consumidores ao mesmo tempo que garante que o sistema esteja operando com segurança e eficiência. Os recursos compartilhados entre os participantes podem ser acessados por outros pares diretamente, sem a necessidade de intervenção de outras entidades. Além disso, qualquer entidade pode ser adicionada ou removida da rede P2P, sem ocasionar perdas de serviço. Desse modo, para facilitar o gerenci-

amento de energia com as camadas conectadas, o sistema de compartilhamento é dividido em duas camadas: a camada física e a camada virtual (Bukar et al. 2023, Tushar et al. 2021).

A camada física representa basicamente uma rede que facilita a transferência de eletricidade entre os vendedores e os compradores, uma vez que os acordos entre ambas as partes são feitos na camada virtual. Pode consistir tanto na rede de distribuição tradicional mantida pelo operador do sistema, como em uma rede de distribuição de uma microrrede independente, em conjunto com a rede tradicional (Suthar et al. 2023). É geralmente dividida em alguns elementos principais:

- **Conexão à rede:** Tanto nos sistemas P2P baseados em microrredes conectadas à rede quanto nas ilhas, é importante definir os pontos de conexão com a rede principal. O objetivo disso é a avaliação do sistema de compartilhamento a partir da inclusão de medidores inteligentes nos pontos de conexão (Tushar et al. 2020).
- **Medição inteligente:** Os prosumidores devem ter infraestrutura de medição avançada para participar do comércio P2P. Eles devem estar equipados com um medidor inteligente que recebe informações de demanda, geração e condições de mercado, e que deve decidir se o prosumidor compartilhará sua energia com outros pares dentro da comunidade, além de se comunicar por meio de protocolos de comunicação apropriados (Tushar et al. 2021).
- **Infraestrutura de comunicação:** Basicamente, as infraestruturas de comunicação são necessárias dentro dos comércios P2P por permitirem a descoberta de novos prosumidores e facilitar a troca de informação entre eles. A infraestrutura adotada precisa atender requisitos de latência, taxa de transferência, confiabilidade e segurança (Tushar et al. 2021).

A camada virtual fornece uma conexão segura para os participantes decidirem sobre a comercialização de energia. Todos têm acesso à plataforma virtual, onde ocorre a transferência de informações, criação e igualação das ordens de compra e venda por meio de um mecanismo de mercado adequado, e realização das transações financeiras. Assim como a camada física, a camada virtual é composta por alguns elementos principais, descritos a seguir (Bukar et al. 2023).

- **Sistema de informação:** Consiste em um sistema seguro de alto desempenho que ajuda os prosumidores a decidir sobre os parâmetros de energia. Este deve ser capaz de: permitir que todos os participantes se comuniquem entre si; integrar os participantes em uma plataforma de mercado adequada; monitorar o funcionamento do mercado e estabelecer restrições nas decisões dos participantes para garantir a segurança da rede (Tushar et al. 2020).

- **Operação do mercado:** Permite que os prosumidores participem de um processo eficiente de compartilhamento de energia, combinando as ordens de venda e compra quase em tempo real. Os participantes compartilham seus recursos com membros da comunidade em diferentes intervalos de tempo, com base em um preço compatível com o status de oferta e demanda de energia dentro da comunidade (Tushar et al. 2021).
- **Mecanismo de precificação:** Equilibra a demanda e o fornecimento de energia dentro da comunidade. Difere dos mercados tradicionais de eletricidade, uma vez que as energias renováveis normalmente têm custos marginais muito baixos, gerando mais lucros a partir da venda de energia a preços adequados (Tushar et al. 2020).
- **Sistema de gestão de energia:** É responsável por licitar o mercado em nome do prosumidor e garante a segurança do fornecimento de energia. A decisão de compartilhar energia depende de informações de oferta e demanda em tempo real e pelas regras definidas pelo prosumidor em vários parâmetros de mercado, como preço e fonte de energia (Tushar et al. 2021).

2.3.4 Mecanismos de Mercado

Segundo Azim et al. (2022) e Suthar et al. (2023), os mecanismos de mercado também desempenham um papel crucial na definição da natureza e do tipo de comércio P2P. Diferentemente do mercado atual de eletricidade, o comércio P2P requer uma abordagem de baixo para cima para incorporar prosumidores ao mercado. Dependendo da forma como os prosumidores são coordenados para a troca de energia, um mercado P2P pode ser dividido em três tipos: centralizado (baseado na comunidade), descentralizado (completo) e híbrido. Desse modo, na Figura 5 são sintetizadas as diferenças entre esses três mecanismos de mercado.

No esquema de mercado descentralizado, os pares negociam energia entre si sem o envolvimento de terceiros (Figura 5 (a)). Desse modo, os prosumidores têm sua privacidade protegida e controle total sobre seus próprios dispositivos, uma vez que não há envolvimento de coordenadores centralizados. Esse modelo é o mais adequado para casos em que os produtores e consumidores estão localizados próximos uns dos outros. Entretanto, como não há um operador do sistema nesse mecanismo, torna-se difícil para a concessionária programar seus recursos, resultando na redução da eficiência operacional do sistema de distribuição. Além disso, como os interesses individuais são priorizados em detrimento dos interesses coletivos, esse mecanismo também leva à redução do bem-estar social da comunidade P2P (Bukar et al. 2023).

2.3. Transactive Energy e Negociações Peer to Peer

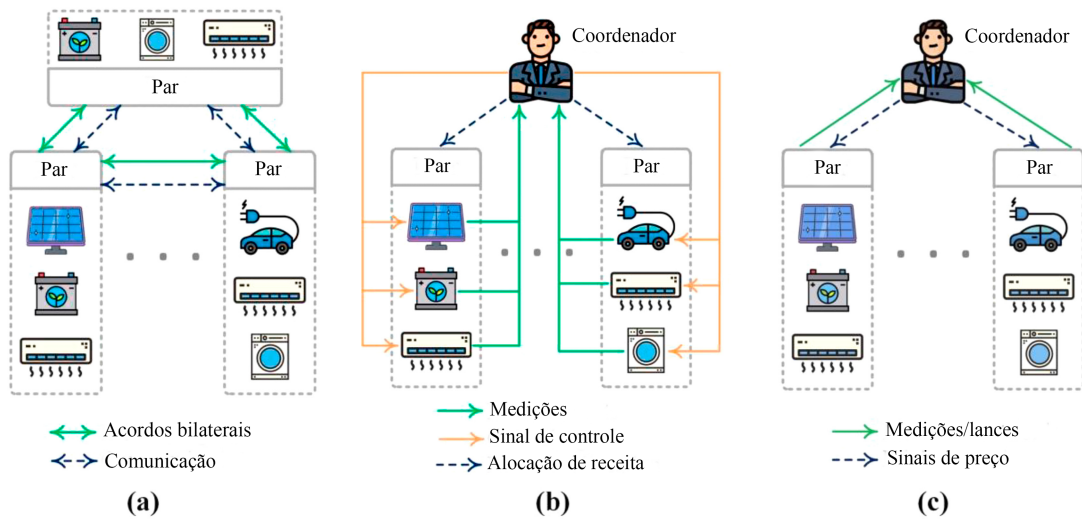


Figura 5 – Tipos de mecanismos de mercado P2P: (a) descentralizado, (b) centralizado e (c) distribuído (adaptado de Suthar et al. (2023))

No caso de um mecanismo de mercado centralizado, os prosumidores podem compartilhar interesses comuns por meio de um coordenador (Figura 5 (b)). Essa entidade central decide a quantidade de transferência de energia, os preços de compra e venda e distribui a receita entre os participantes. A disponibilidade de informações no ponto central resulta no bem-estar social máximo da comunidade, em comparação com os mecanismos centralizado e híbrido. Porém, existem duas grandes desvantagens desse esquema de mercado: a infraestrutura de comunicação pode ficar sobrecarregada, uma vez que toda e qualquer informação deve passar por uma única entidade; e a privacidade dos participantes é comprometida, visto que todos compartilham seus dados com o operador do sistema (Suthar et al. 2023).

Por fim, o modelo híbrido combina características das duas abordagens anteriores (Figura 5 (c)). Os participantes têm a opção de realizar transações diretas entre si quando estão em proximidade física e podem se conectar diretamente. Nesse caso, um produtor de energia pode vender seu excedente diretamente para um consumidor interessado, sem a necessidade de intermediários ou a utilização da rede elétrica convencional. Entretanto, quando um produtor de energia tem um excedente que não pode ser consumido diretamente por um participante próximo, a energia é enviada para a rede elétrica. O produtor recebe créditos correspondentes à quantidade de energia injetada na rede. Esses créditos podem ser usados posteriormente para compensar o consumo do produtor ou serem transferidos para outros participantes que desejem adquiri-los. De forma resumida, o modelo P2P híbrido possibilita aos consumidores uma programação independente (Bukar et al. 2023, Suthar et al. 2023).

3 Fundamentos dos Métodos *Fuzzy*

O presente capítulo apresenta uma revisão detalhada dos métodos *fuzzy* utilizados neste trabalho. Inicialmente, são explorados os princípios dos sistemas *fuzzy* clássicos, focando na explicação dos sistemas de inferência Mamdani e Takagi-Sugeno. O sistema Mamdani é utilizado durante a etapa de detecção de fraudes, enquanto o sistema Takagi-Sugeno, combinado com o paradigma dos sistemas evolutivos, forma a base do algoritmo *Evolving Takagi-Sugeno Plus* utilizado na etapa de modelagem dos padrões de participação dos indivíduos.

3.1 Princípios dos Sistemas *Fuzzy* Clássicos

Segundo Klir & Yuan (1995), a lógica consiste no estudo dos métodos e princípios de raciocínio em todas as formas possíveis. Na lógica clássica, também conhecida como lógica booleana ou lógica *crisp*, as proposições podem assumir somente dois valores, sendo um a negação do outro. Para afirmações verdadeiras, se atribui o nível lógico 1 e para afirmações falsas, se atribui o nível lógico 0. Desse modo, fica evidente que a lógica clássica é capaz de representar somente problemas que envolvam duas características distintas, como ligado/desligado, aberto/fechado, entre outros.

Diante desse problema, o matemático estadunidense Lotfi Asker Zadeh introduziu, por meio de seu trabalho intitulado de “*Fuzzy Sets*” e publicado no ano de 1965, os termos “Lógica *Fuzzy*” e “conjuntos *fuzzy*” (Zadeh 1965). A Lógica *Fuzzy* consiste em um tipo de raciocínio para processamento de informações vagas e imprecisas extraídas do conhecimento humano. Isso ocorre por meio da representação do problema na forma de variáveis linguísticas, de forma a considerar cada uma destas como um conjunto *fuzzy* de uma variável de entrada ou saída (Wang 1997).

3.1.1 Variáveis Linguísticas e Graus de Pertinência

De acordo com Babuška (2012) e Wang (1997), uma variável linguística L pode ser definida matematicamente por meio de uma quintupla $L = (x, A, U, g, m)$, onde: x é a variável base; $A = \{A_1, A_2, \dots, A_N\}$ é o conjunto de termos linguísticos de x ; U é o domínio ou universo de discurso da variável x ; g é a regra sintática que gera os valores de x como um arranjo dos termos linguísticos (A) com conectivos lógicos e modificadores; m é a regra semântica que atribui a cada termo linguístico seu conjunto *fuzzy* em X .

Uma variável base é descrita por seu próprio sentido clássico (como temperatura e força) e representada a partir de termos linguísticos (como baixa, média, alta). Cada termo linguístico é descrito por um conjunto *fuzzy* e atribuído um grau de pertinência no intervalo $[0, 1]$. O grau de pertinência é uma função que estabelece o quanto a variável x pertence a um determinado conjunto *fuzzy* (Wang 1997). Essa formulação pode ser vista na Equação 1, onde $\mu_{A_f}(x)$ é o grau de pertinência do conjunto *fuzzy* A_f e U é o intervalo de valores que a pertinência pode assumir.

$$\mu_{A_f}(x) : U \mapsto [0, 1] \tag{1}$$

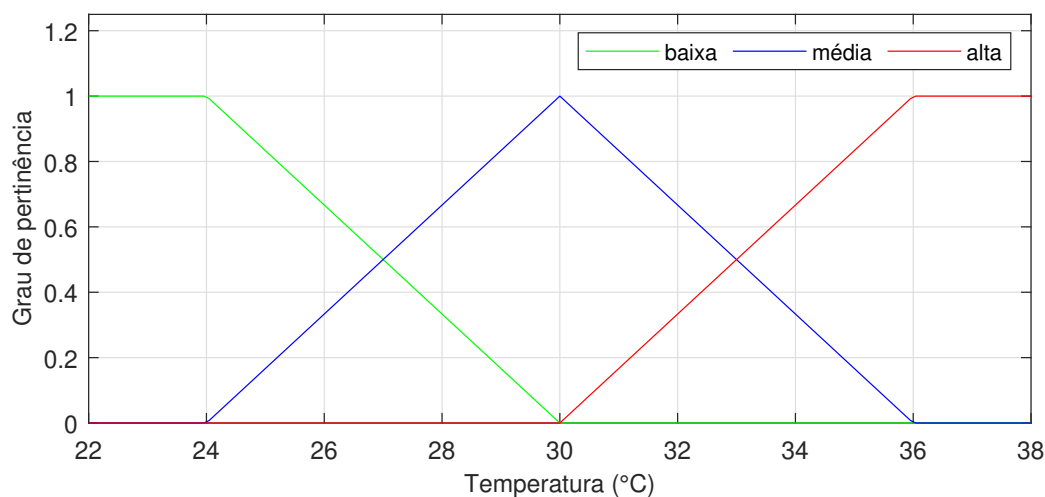


Figura 6 – Funções de pertinência para a variável temperatura

Os graus de pertinência podem ser formulados pelo conhecimento prévio do especialista ou de forma automática a partir dos dados de entrada e saída. Os tipos mais comuns e constantemente utilizados em aplicações de engenharia são as funções triangular, trapezoidal e gaussiana. Considerando o exemplo do controle de temperatura de uma sala, na Figura 6 é possível visualizar o universo de discurso da variável temperatura $U = \{22, 38\}$, uma função de pertinência tri-

angular que representa a temperatura média e duas funções trapezoidais que representam as temperaturas baixa e alta. Para o caso de uma temperatura de 27 °C, percebe-se que a pertinência global é composta pelos conjuntos baixa e média, ambos com 0,5 de pertinência.

3.1.2 Regras *Fuzzy* e Operações entre Conjuntos

Juntamente com as funções de pertinência, as regras do tipo **SE-ENTÃO** constituem a base de conhecimento dos sistemas *fuzzy*. Basicamente, elas possuem a seguinte estrutura:

$$\mathbf{SE} < \text{proposição antecedente} > \mathbf{ENTÃO} < \text{proposição consequente} > \quad (2)$$

De acordo com Wang (1997), existem dois tipos de proposição, tanto antecedente como consequente: as proposições atômicas e as compostas. Uma proposição atômica consiste em uma declaração única do tipo “ x é A ”, sendo x uma variável linguística e A um valor linguístico (conjunto *fuzzy*) de x . As proposições compostas são uma combinação de proposições atômicas a partir dos conectivos **E**, **OU** e **NÃO**, os quais representam respectivamente as operações de norma-t, norma-s e complemento. Considerando que x e y são variáveis linguísticas nos universos de discurso U e V , e A e B são conjuntos *fuzzy* nesses domínios, as regras de utilização de cada conectivo são expostas a seguir:

- Conectivo **E**: Relação de intersecção entre os conjuntos *fuzzy* e valor mínimo das funções de pertinência (representado pelo operador \wedge).

$$x \text{ é } A \mathbf{E} y \text{ é } B \Rightarrow \mu_{A \cap B}(x, y) = \min [\mu_A(x), \mu_B(y)] \quad (3)$$

- Conectivo **OU**: Relação de união entre os conjuntos *fuzzy* e valor máximo das funções de pertinência (representado pelo operador \vee).

$$x \text{ é } A \mathbf{OU} y \text{ é } B \Rightarrow \mu_{A \cup B}(x, y) = \max [\mu_A(x), \mu_B(y)] \quad (4)$$

- Conectivo **NOT**: Relação de complemento entre as funções de pertinência (representado pelo operador \neg).

$$x \mathbf{NÃO} \text{ é } A \Rightarrow \mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (5)$$

Desse modo, as regras **SE-ENTÃO** podem ser constituídas tanto de proposições atômicas, como de proposições compostas por meio de conectivos lógicos. Essa flexibilidade possibilita aos siste-

mas *fuzzy* a construção de regras que contemplem com maior exatidão todo o espaço de dados utilizado. Entretanto, em grande parte das aplicações reais, os dados estão em sua forma numérica, sendo necessária a representação dos mesmos na forma de conjuntos *fuzzy*. Esse processo é realizado por uma interface chamada de fuzzificador, por meio do mapeamento das entradas e suas respectivas funções de pertinência. Do mesmo modo, o resultado da inferência *fuzzy* é defuzzificado, ou seja, obtido em sua forma numérica novamente para que seja interpretável por especialistas (Wang 1997, Babuška 2012). A Figura 7 ilustra um sistema *fuzzy* genérico, o qual é composto pelo fuzzificador, a base de regras, a máquina de inferência e o defuzzificador.

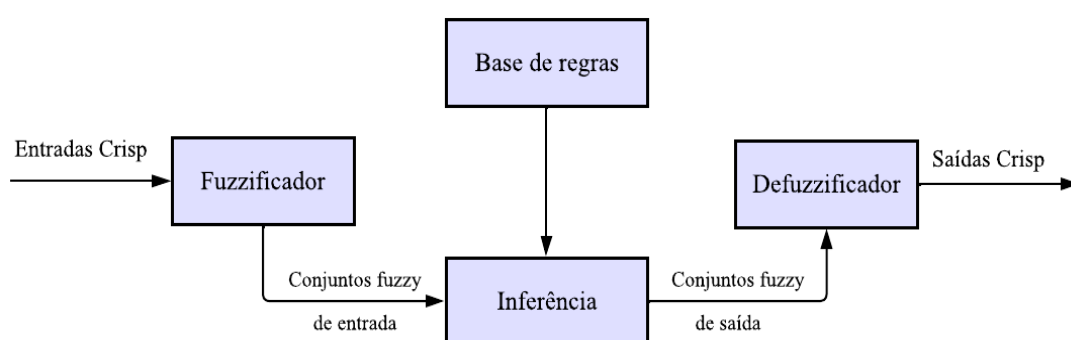


Figura 7 – Sistema *fuzzy* com fuzzificador e defuzzificador

Uma metodologia baseada nesse sistema foi inicialmente proposta por Ebrahim Mamdani em 1974 para o controle de um motor a vapor e uma caldeira, resultando no desenvolvimento do sistema de inferência *fuzzy* de mesmo nome (Mamdani 1974). Outro método amplamente utilizado atualmente foi introduzido por Takagi e Sugeno. A principal distinção em relação ao método de Mamdani é a substituição dos conjuntos *fuzzy* de saída por equações matemáticas (Takagi & Sugeno 1985), eliminando a necessidade de defuzzificação. Ambos são de extrema importância para a área de Sistemas *Fuzzy* e serão detalhadamente discutidos a seguir.

3.1.3 Sistema de Inferência *Fuzzy* Mamdani

Também conhecido como modelo linguístico, o sistema *fuzzy* Mamdani foi proposto por Ebrahim Mamdani na década de 1970, em seu trabalho intitulado de “*Application of Fuzzy Algorithms for Control of Simple Dynamic Plant*” (Mamdani 1974). Neste tipo de sistema, tanto o antecedente como o conseqüente são proposições *fuzzy*. Conforme visto anteriormente, a etapa de fuzzificação é o ponto inicial de um sistema *fuzzy*, a qual consiste na representação das entradas na forma de conjuntos *fuzzy*. A relação entre cada variável linguística do antecedente e determinado conjunto *fuzzy* $A_j^i(x_j)$ é dada pela função de pertinência (Rodrigues Júnior 2021):

$$\mu_{A_j^i(x_j)} : \mathbb{R} \rightarrow [0, 1] \quad (6)$$

Após a fuzzificação, regras do tipo **SE-ENTÃO** são aplicadas. Cada regra especifica as condições do antecedente que ativam a consequência. Desse modo, o formato geral de regra dentro de um sistema Mamdani é (Costa 2016):

$$\text{Regra}^i : \text{SE } (x_1 \text{ é } A_1^i) \text{ E } \cdots \text{ E } (x_n \text{ é } A_n^i) \text{ ENTÃO } y = B_i \quad (7)$$

onde, $i = [1, R]$, $j = [1, n]$, R é o número máximo de regras, A_j^i e B^i são os termos linguísticos (conjuntos *fuzzy* de entrada e saída, respectivamente), x_j (ou $\mathbf{x} = [x_1, \dots, x_n]$ na forma vetorial) são as variáveis linguísticas do antecedente (entrada do sistema) e y é a variável do consequente (saída do sistema). A próxima etapa é a de agregação, onde os conjuntos *fuzzy* de saída são combinados usando operações de intersecção ou união, para formar um conjunto *fuzzy* agregado que representa a contribuição de todas as regras ativadas. Considerando que a regra exposta na Equação 7 utiliza o operador lógico **E**, o grau de ativação é (Wang 1997):

$$B_i = \mu_{A_1^i(x_1)} \wedge \cdots \wedge \mu_{A_n^i(x_n)} = \min(\mu_{A_1^i(x_1)}, \dots, \mu_{A_n^i(x_n)}) \quad (8)$$

Por fim, na etapa de defuzzificação, o conjunto *fuzzy* agregado é convertido em uma saída real. Existem vários métodos de defuzzificação, que geralmente se dividem em duas categorias principais: os métodos baseados em máximos e os métodos baseados em centróides. Os métodos baseados em máximos incluem abordagens como o método do Máximo Valor de Pertinência, onde a saída é determinada pelo valor mais alto de pertinência entre todos os conjuntos *fuzzy* ativados. Por outro lado, dentre os métodos baseados em centróides, o Centro de Gravidade é o mais comum. Neste método, a saída real é calculada como o centro de gravidade do conjunto *fuzzy* agregado, levando em consideração os graus de pertinência de cada conjunto *fuzzy* ativado. Este método é amplamente utilizado devido à sua simplicidade e à capacidade de produzir resultados nítidos satisfatórios.

3.1.4 Sistema de Inferência *Fuzzy* Takagi-Sugeno

O sistema de inferência *fuzzy* Takagi-Sugeno (TS), proposto inicialmente por Takagi & Sugeno (1985) no trabalho intitulado de "*Fuzzy Identification of Systems and Its Applications to Modeling*

and Control”, consiste em uma ferramenta matemática para construir um modelo de um sistema onde as implicações *fuzzy* e o raciocínio são usados. Dentre os diferentes tipos de modelos *fuzzy*, a estrutura TS é uma das mais utilizadas para aproximar uma ampla classe de sistemas complexos e não lineares. Nos modelos TS, o antecedente é composto por proposições *fuzzy*, enquanto o consequente consiste em uma função matemática das variáveis do antecedente (Wang 1997).

De acordo com Rodrigues Júnior (2021), a grande aplicabilidade dos modelos TS se deve ao fato de que estes lidam com entradas e saídas na forma de valores reais, se adequando com a maioria dos problemas práticos de engenharia. Entretanto, devido à natureza matemática dos consequentes das regras, o sistema *fuzzy* perde um pouco de sua versatilidade e interpretabilidade, uma vez que não representa o conhecimento humano de maneira linguística, como ocorre nos sistemas *fuzzy* Mamdani. Nos sistemas TS, a *i*-ésima regra tem o seguinte formato (Costa 2016):

$$\text{Regra}^i : \mathbf{SE} (x_1 \text{ é } A_1^i) \mathbf{E} \cdots \mathbf{E} (x_n \text{ é } A_n^i) \mathbf{ENTÃO} y_i = f_i(x_1, \cdots, x_n) \quad (9)$$

sendo que $i = [1, R]$, $j = [1, n]$, R é o número máximo de regras, x_j (ou $\mathbf{x} = [x_1, \cdots, x_n]$ na forma vetorial) são as variáveis linguísticas do antecedente (entrada do sistema), y_i é a variável do consequente (saída do sistema) e A^i são os termos linguísticos (conjuntos *fuzzy* dos antecedentes). Antes de realizar o cálculo da saída do modelo TS, o grau de ativação de cada regra precisa ser conhecido. Ele é calculado por meio da combinação das funções de pertinência para cada entrada individual, a partir dos conectivos utilizados nas regras (**E, OU, NÃO**) (Babuška 2012). Considerando a regra com conectivos **E** vista na Equação 9, o grau de ativação pode ser calculado da seguinte forma (Costa 2016):

$$\tau_i(\mathbf{x}) = \mu_{A_1^i(x_1)} \wedge \cdots \wedge \mu_{A_n^i(x_n)} \quad (10)$$

Segundo Wang (1997), existem diferentes formas de realizar a operação de norma-t. Entretanto, conforme afirmado por Babuška (2012), os modelos *fuzzy* TS utilizam o produto algébrico para obtenção do grau de ativação da regra *i*:

$$\tau_i(\mathbf{x}) = \prod_{j=1}^n \mu_j^i(x_j) \quad (11)$$

O grau de ativação normalizado para a *i*-ésima regra é dado por (Wang 1997):

$$\lambda_i(\mathbf{x}) = \frac{\tau_i}{\sum_{i=1}^R \tau_i} \quad (12)$$

Embora as funções do consequente possam assumir diferentes tipos de funções matemáticas, elas podem ser representadas da seguinte forma (Rodrigues Júnior 2021):

$$y_i = \mathbf{a}_i^T \mathbf{x} + b_i \quad (13)$$

onde, \mathbf{a}_i^T é um vetor de parâmetros relacionado com a i -ésima regra e b_i é um escalar. Caso $\mathbf{a}_i^T \mathbf{x}$ seja igual a 0, a equação do consequente é composta apenas pelo escalar b_i , resultando no que é chamado de um sistema *fuzzy* TS do tipo 0. De forma semelhante, caso b_i seja igual a 0, o modelo é dito homogêneo. Por fim, a saída global consiste em uma combinação linear da saída de cada modelo local i com seu grau de ativação normalizado (λ_i) (Rodrigues Júnior 2021):

$$\mathbf{y} = \left(\sum_{i=1}^R \lambda_i \mathbf{a}_i^T \right) \mathbf{x} + \sum_{i=1}^R \lambda_i b_i \quad (14)$$

3.1.5 Exemplo de Aplicação de um Sistema *Fuzzy* Takagi-Sugeno

A exatidão de um modelo *fuzzy* TS depende de características como o número de conjuntos *fuzzy*, a complexidade das funções do consequente e o formato das funções de pertinência. Comparando com o sistema Mamdani, os sistemas de inferência *fuzzy* TS possuem mais flexibilidade para incorporar equações matemáticas complexas (Vanegas-Ayala et al. 2024). Além disso, de acordo com Castro (1995), os sistemas *fuzzy* são considerados aproximadores universais de funções. Para demonstrar essa característica e entender todas as etapas da implementação de um sistema *fuzzy* TS básico, abaixo é exposta a aplicação de um sistema TS tipo 0 e um do tipo 1 para aproximação da função matemática $y = x^3$.

Nesse caso, pode-se verificar rapidamente que os valores de x são a entrada do sistema e y é a saída. Para x , foi definido um total de 7 conjuntos *fuzzy* representados por funções de pertinência gaussianas, cujos valores de centro e desvio padrão são apresentados na Tabela 1. O universo de discurso do sistema foi escolhido como sendo de $x = -3$ até $x = 3$ ($U = \{-3, 3\}$). Os centros das gaussianas foram estabelecidos como cada um dos valores inteiros nesse intervalo ($\mathbf{c} = [-3, -2, -1, 0, 1, 2, 3]$). No caso do desvio padrão, foram selecionados valores arbitrários conforme os testes realizados, chegando ao valor de 0,3 por ter obtido melhor desempenho.

Tabela 1 – Parâmetros dos conjuntos *fuzzy* de entrada

Conjunto <i>fuzzy</i>	A ₁	A ₂	A ₃	A ₄	A ₅	A ₆	A ₇
Centro	-3	-2	-1	0	1	2	3
Desvio padrão	0,3	0,3	0,3	0,3	0,3	0,3	0,3

Considerando um sistema *fuzzy* TS do tipo 0, a saída de cada submodelo local será um escalar e o conhecimento do especialista é responsável por identificar qual saída constante é necessária para cada entrada. Isso pode ser obtido rapidamente através da aplicação de cada ponto analisado (centros das gaussianas) na função $y = x^3$ (Tabela 2). Desse modo, a montagem da base de regras também se torna mais simples, entretanto, menos representativa. Na Tabela 3 é apresentada a base de regras construída para esse caso e as funções de pertinência de cada um dos conjuntos *fuzzy* são expostas na Figura 8.

Tabela 2 – Saídas locais do sistema *fuzzy* TS do tipo 0

Conjunto <i>fuzzy</i>	A ₁	A ₂	A ₃	A ₄	A ₅	A ₆	A ₇
Saída local	-27	-8	-1	0	1	8	27

Tabela 3 – Base de regras do sistema *fuzzy* TS do tipo 0

Número	Definição da regra
R1	SE x é A ₁ ENTÃO $y = -27$
R2	SE x é A ₂ ENTÃO $y = -8$
R3	SE x é A ₃ ENTÃO $y = -1$
R4	SE x é A ₄ ENTÃO $y = 0$
R5	SE x é A ₅ ENTÃO $y = 1$
R6	SE x é A ₆ ENTÃO $y = 8$
R7	SE x é A ₇ ENTÃO $y = 27$

No caso do sistema de inferência *fuzzy* Takagi-Sugeno de ordem 1, os consequentes das regras *fuzzy* são equações matemáticas de primeiro grau. Desse modo, a aproximação desse tipo de sistema é mais precisa em relação ao de ordem 0, uma vez que uma reta pode representar uma região maior em torno de um ponto. Os conjuntos *fuzzy* de entrada foram os mesmos utilizados para o caso de ordem 0 e podem ser vistos na Figura 8. Para obtenção das saídas locais, foi utilizada a expansão em série de Taylor de primeira ordem, onde $f(x)$ é a função linear, $f(x_0)$ é a função aplicada no ponto de linearização e $f'(x)$ é a derivada (Equação 15).

3.1. Princípios dos Sistemas *Fuzzy* Clássicos

$$f(x) = f(x_0) + f'(x_0)(x - x_0) \quad (15)$$

No caso do exemplo estudado, a função resultante para cada saída local é:

$$f(x) = (x_0)^3 + 3(x_0)^2(x - x_0) \quad (16)$$




Figura 8 – Funções de pertinência gaussianas dos conjuntos *fuzzy* de entrada

Desse modo, a base de regras foi construída a partir do mapeamento entre cada conjunto *fuzzy* de entrada e cada saída local nos diferentes pontos de linearização (Tabela 4). É correto pensar que o formato da saída influencia diretamente no resultado obtido. Conforme visto anteriormente, ambos os sistemas possuíam os mesmos 7 conjuntos *fuzzy* de entrada e cada saída está relacionada com um conjunto por meio de uma função de pertinência gaussiana. Essas saídas são locais, sendo que o somatório da contribuição de cada uma delas gera a saída global.

Tabela 4 – Base de regras do sistema *fuzzy* TS do tipo 1

Número	Definição da regra
R1	SE x é A_1 ENTÃO $y = 27x + 54$
R2	SE x é A_2 ENTÃO $y = 12x + 16$
R3	SE x é A_3 ENTÃO $y = 3x + 2$
R4	SE x é A_4 ENTÃO $y = 0$
R5	SE x é A_5 ENTÃO $y = 3x - 2$
R6	SE x é A_6 ENTÃO $y = 12x - 16$
R7	SE x é A_7 ENTÃO $y = 27x - 54$

Como resultado, a Figura 9 apresenta as saídas locais (em vermelho) em torno dos pontos de linearização (em azul) para os dois exemplos estudados. Após esse estágio, foi calculada a saída global do sistema com base na Equação 14. Como o primeiro caso possui apenas constantes no consequente das regras, o resultado da Figura 10 (a) não é tão satisfatório. No caso da aproximação pelo sistema *fuzzy* TS do tipo 1, observa-se uma melhoria significativa no desempenho (Figura 10 (b)). Avaliando o resultado por meio da métrica de erro RMSE, o erro obtido no sistema do tipo 0 foi de 1,9182, comparado com 0,7184 para o sistema do tipo 1.




Figura 9 – Saídas locais e pontos de linearização do sistema *fuzzy* TS do tipo 0 (a) e do tipo 1 (b)




Figura 10 – Aproximação da função $y = x^3$ por meio de sistema *fuzzy* TS do tipo 0 (a) e do tipo 1 (b)

3.2 Sistemas Evolutivos

De acordo com o *Oxford English Dictionary*, o termo “evoluir” significa “desdobrar, revelar, desenvolver, mudar”. Um sistema pode ser dito evolutivo se tiver capacidade de aprender, adaptar e desenvolver sua estrutura gradualmente para melhorar o desempenho. Os sistemas difusos em evolução surgiram no século XXI e foram construídos a partir de modelos *fuzzy* baseados em regras ou *neuro-fuzzy* com aprimoramento dos parâmetros e também da estrutura da rede. As primeiras abordagens para o projeto da base de regras *fuzzy* dependiam do conhecimento de um especialista humano para representação das regras na forma **SE-ENTÃO**.

Entretanto, dependendo da aplicação, a tarefa de aquisição de conhecimento poderia ser difícil e demorada (Baruah & Angelov 2011). Nesse sentido, pesquisas recentes tornaram o processo de construção da base de regras mais efetivo, o qual dependia somente dos dados de entrada e saída do sistema. Inicialmente, todo o aprendizado era realizado de maneira *offline* e a partir de um conjunto de dados fixo, gerando uma quantidade fixa de regras. Entretanto, como a base de regras era estática, o sistema desenvolvido não conseguia lidar com desvios nos dados de entrada, o que era possível somente a partir da reconstrução do sistema com os dados desviados incluídos.

Por outro lado, nos últimos anos, com o crescente desenvolvimento no campo de tecnologias de informação e comunicação, surgiu também a necessidade por sistemas rápidos e recursivos (não iterativos), incrementais (dados aprendidos um de cada vez), com memória eficiente (dispensam o armazenamento de treinamentos anteriores) e evolutivos (mudança da estrutura e parâmetros do modelo levando em consideração variações no padrão dos dados recebidos) (Baruah & Angelov 2011). As pesquisas recentes no âmbito dos sistemas *fuzzy* evolutivos contribuem com diferentes métodos para suprir essa necessidade.

No caso desta dissertação, foi escolhido o algoritmo *Evolving Takagi-Sugeno Plus*, proposto por Plamen Angelov no trabalho intitulado de “*Evolving Intelligent Systems: Methodology and Applications*” (Angelov et al. 2010). Essa escolha se baseou na necessidade de uma metodologia robusta para previsão de flexibilidade energética em programas de participação ativa de consumidores finais de energia. Além de apresentar todas as características citadas anteriormente, o eTS+ possui a vantagem de trabalhar com fluxos de dados reais e modelar o sistema continuamente. Desse modo, as subseções seguintes descrevem algumas etapas características do eTS+, com o intuito de fundamentar a metodologia proposta.

3.2.1 Padronização dos Dados em Tempo Real

A padronização tem como objetivo transformar os dados para que todos tenham uma escala comum, facilitando a interpretação e comparação de diferentes variáveis. No caso de algoritmos *offline*, existem dados históricos disponíveis e a padronização é realizada em batelada (média e desvio padrão são calculados e posteriormente aplicados para padronizar todo o conjunto de dados de uma só vez). No entanto, em sistemas evolutivos, os dados fluem continuamente ao longo do tempo, fato que exige a implementação de técnicas de padronização em tempo real (Lughofer 2011, Rodrigues Júnior 2021).

Sabendo que os dados que chegam a cada instante possuem média e variância que se modificam ao longo do tempo, a atualização recursiva da média é definida por (Rodrigues Júnior 2021):

$$\zeta_k = \frac{k-1}{k}\zeta_{k-1} + \frac{1}{k}\mathbf{z}_k, \zeta_1 = \mathbf{z}_1, \quad (17)$$

onde, $\mathbf{z}_k = [\mathbf{x}^T \mathbf{y}^T]$ é o par entrada-saída no instante k , $\mathbf{x}^T = [x_1, x_2, \dots, x_n]$, $\mathbf{y}^T = [y_1, y_2, \dots, y_m]$, n é o número de entradas e m é o número de saídas. O desvio padrão é atualizado da seguinte forma (Angelov et al. 2010):

$$\delta_k^2 = \frac{k-1}{k}\delta_{k-1}^2 + \frac{1}{k}|\mathbf{z}_k - \zeta_k|^2, \delta_1^2 = 1. \quad (18)$$

A padronização da amostra k consiste na subtração pela média e divisão pelo desvio padrão, como se segue (Angelov et al. 2010):

$$\bar{\mathbf{z}}_k = \frac{\mathbf{z}_k - \zeta_k}{\delta_k} \quad (19)$$

onde, $\bar{\mathbf{z}}_k$ é a amostra padronizada. Para retornar à escala original (representada por $\tilde{\mathbf{z}}_k$), o seguinte procedimento é necessário (Rodrigues Júnior 2021):

$$\tilde{\mathbf{z}}_k = \bar{\mathbf{z}}_k \delta_k + \zeta_k \quad (20)$$

3.2.2 Agrupamento Evolutivo

Uma alternativa para identificar a estrutura de sistemas reais consiste na criação de grupos a partir de pontos de dados, sem a necessidade de rótulos ou categorias predefinidas. Essa tarefa é denominada de *Clustering* e tem como objetivo descobrir padrões subjacentes e carac-

terísticas semelhantes, de modo que as amostras pertencentes ao mesmo grupo estejam mais intimamente relacionadas entre si do que com amostras de outros grupos. Além disso, o procedimento de *Clustering* pode ser entendido como uma melhoria das técnicas tradicionais de particionamento do espaço de dados em regiões locais, uma vez que estas são inacessíveis em sistemas de muitas entradas e valores linguísticos. No contexto dos sistemas *fuzzy*, as técnicas de agrupamento diferem em alguns aspectos dos métodos tradicionais. Isso acontece porque, tradicionalmente, os *clusters* formados devem ser exclusivos, ou seja, não pode ocorrer sobreposição (Angelov 2013).

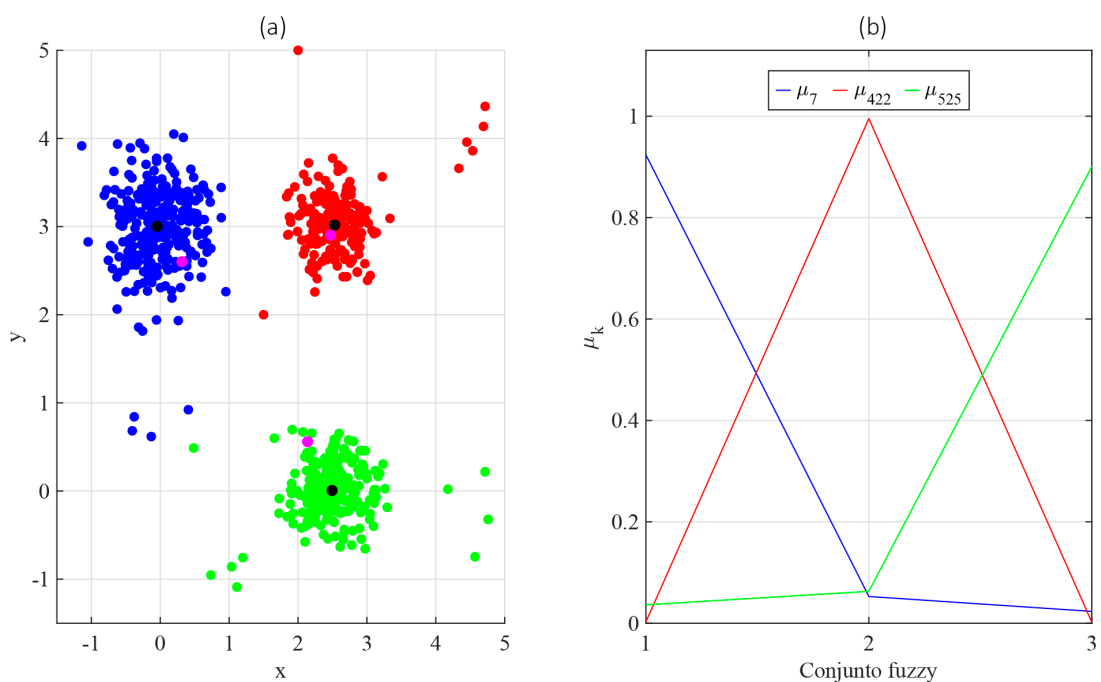


Figura 11 – Exemplo de agrupamento *fuzzy* e pertinências de três amostras

No caso *fuzzy*, um agrupamento é formado a partir de amostras com padrões semelhantes e para cada amostra é atribuído um grau de pertinência. Desse modo, uma amostra pode pertencer a mais de um grupo, sendo que o valor máximo da pertinência é igual a 1. Com o objetivo de explicar rapidamente essa característica, na Figura 11 (a) é possível verificar três *clusters* formados a partir de um algoritmo *Fuzzy C-means*. Na cor preta, estão os centros (ou pontos focais dos *clusters*). Além disso, percebe-se também uma amostra de cor rosa em cada um dos agrupamentos. Estas foram selecionadas para efeito de análise de suas funções de pertinência triangulares (Figura 11 (b)). A amostra pertencente ao *cluster* azul tem índice 7 e possui 0,92389 de pertinência nesse *cluster*, e respectivamente 0,0628 e 0,0020 nos demais. Desse modo, conclui-se também que a amostra de índice 422 e a amostra de índice 525 fazem parte, respectivamente, dos *clusters* 2 e 3, por possuírem maior grau de pertinência nestes. Resumidamente, as funções

de pertinência triangulares expostas na figura, informam o quanto cada amostra pertence a um determinado agrupamento (Rodrigues Júnior 2021).

O algoritmo *Fuzzy C-means* aplicado anteriormente, juntamente com outros disponíveis na literatura (como *Fuzzy K-means* e Gustafson-Kessel), são exemplos de técnicas que necessitam que o número de *clusters* a serem criados seja informado antecipadamente. Entretanto, essa exigência não é interessante para o caso de um sistema evolutivo, visto que o mesmo deve ser capaz de extrair características relevantes a partir dos dados que chegam a cada instante e consequentemente ser o mais independente possível do conhecimento do especialista.

3.2.3 Estimação dos Parâmetros dos Submodelos

De acordo com Rodrigues Júnior (2021), o formato das funções matemáticas dos modelos locais pode variar conforme a aplicação, como por exemplo funções polinomiais, gaussianas, trapezoidais, entre outras. De todo modo, considerando que os submodelos são do tipo linear, a saída global estimada pelas Equações 31 e 32, em um instante k , é:

$$\mathbf{y}_k = \Phi_k^T \mathbf{\gamma}_k \quad (21)$$

onde, $\mathbf{y}_k = [y_k^1, y_k^2, \dots, y_k^m]^T$, $\Phi_k = [\lambda_1 \mathbf{x}_k^T, \lambda_2 \mathbf{x}_k^T, \dots, \lambda_R \mathbf{x}_k^T]^T$ são as ponderações do vetor de entradas $\mathbf{x}_k = [1, x_k^1, x_k^2, \dots, x_k^n]^T$, $\mathbf{\gamma}_k = [(\gamma_k^1)^T, (\gamma_k^2)^T, \dots, (\gamma_k^R)^T]^T$ é o vetor de parâmetros da base de regras e γ_{ki} denota a matriz de parâmetros dos R submodelos lineares. Essa matriz pode ser vista na equação seguinte (Angelov et al. 2010):

$$\gamma_i = \begin{bmatrix} a_i^{01} & \dots & a_i^{0m} \\ \dots & \dots & \dots \\ a_i^{n1} & \dots & a_i^{nm} \end{bmatrix} \quad (22)$$

Dado que os sistemas evolutivos não possuem estrutura fixa, novos submodelos podem ser gerados durante o processo de aprendizagem, assim como também podem ser removidos (caso não sejam relevantes o suficiente). Para modelos *offline*, métodos clássicos de estimação de parâmetros são facilmente aplicáveis (como por exemplo, o Método dos Mínimos Quadrados). A utilização desse método para o caso evolutivo necessita de algumas adaptações, com o intuito de permitir a mudança de estrutura (adição ou remoção de *clusters/regras fuzzy*) (Angelov 2004b). Em vista disso, é utilizado o Método dos Mínimos Quadrados Ponderados *Fuzzy*, que atualiza os

3.2. Sistemas Evolutivos

parâmetros da parte consequente de duas formas: global (GfwRLS) ou local (LfwRLS). A otimização global garante um melhor desempenho da aproximação do sistema como um todo. Entretanto, a otimização local é normalmente mais adequada porque leva em conta a aproximação de cada submodelo definido por um *cluster*, além de ser menos influenciada pelo processo de evolução, visto que as matrizes de covariância não mudam, apenas os graus de ativação normalizados (Angelov et al. 2010). De forma geral, considerando um índice genérico $q = [1, 2, \dots, k]$ e pares de vetores de entrada e saída $(\mathbf{x}_q^T, \mathbf{y}_q^T)$, a função de custo local que deve ser minimizada é (Rodrigues Júnior 2021):

$$E_L^i = \sum_{q=1}^k \lambda_q^i (\mathbf{x}_q) (\mathbf{y}_q - \mathbf{x}_q^T \gamma_q^i)^2 \quad (23)$$

Como o critério local é calculado para cada uma das regras (R), para obter a função custo global, tem-se (Rodrigues Júnior 2021):

$$E_L = \sum_{i=1}^R E_L^i \quad (24)$$

Na forma matricial, o critério local da Equação 23 é (Angelov et al. 2010):

$$E_L^i = (\mathbf{Y} - \mathbf{X}^T \mathbf{\Gamma}^i)^T \Lambda^i (\mathbf{Y} - \mathbf{X}^T \mathbf{\Gamma}^i) \quad (25)$$

sendo que $i = [1, R]$, Λ^i é uma matriz diagonal com os graus de ativação normalizados dos submodelos (λ^i), \mathbf{X}^T contém as entradas e $\mathbf{\Gamma}^i$ é uma matriz composta com valores instantâneos de \mathbf{x} e γ^i (Rodrigues Júnior 2021).

4 Metodologia

A metodologia proposta na presente dissertação pode ser explicada a partir do diagrama de blocos presente na Figura 12. Inicialmente, um método *fuzzy* evolutivo denominado *Evolving Takagi-Sugeno Plus* é utilizado para capturar os padrões de envolvimento dos indivíduos em programas de participação ativa de usuários finais, tanto em termos de dados de consumo quanto de flexibilidade. Desse modo, no primeiro bloco, o algoritmo observa a saída fornecida (Y) e estabelece relações com o vetor de entradas (X), realizando o ajuste contínuo da base de regras *fuzzy* com base nas dinâmicas observadas. Isso garante que o sistema permaneça relevante e preciso à medida que novos dados são introduzidos.

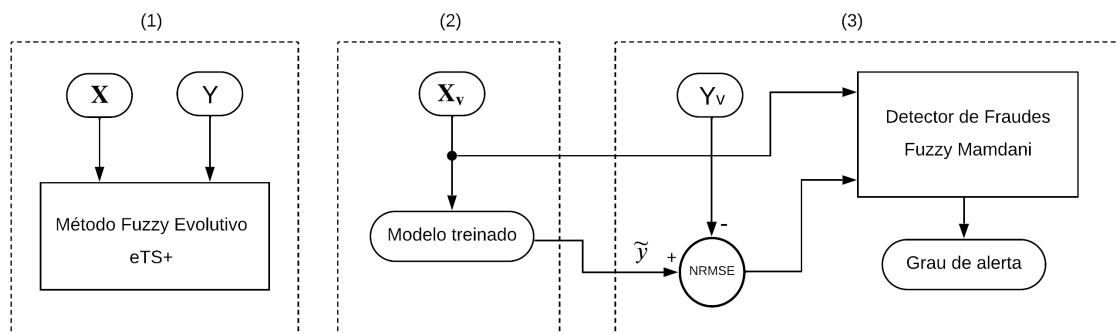


Figura 12 – Diagrama de blocos da metodologia proposta

Na sequência, o modelo resultante é validado por meio da aplicação de amostras desconhecidas (X_v). Na validação, as capacidades de evolução do método não são consideradas, uma vez que a base de regras é mantida fixa e os novos dados são incluídos nos *clusters* já existentes, com base no cálculo da proximidade espacial das novas amostras em relação ao centro de cada *cluster*. Isso significa que a estimativa gerada pelo eTS+ na validação será satisfatória se a dinâmica dos novos dados for semelhante à aprendida durante o treinamento.

Com base nisso, foi proposto um sistema detector de fraudes *fuzzy* Mamdani que utiliza os dados reais de validação (X_v) e o resíduo obtido entre a saída real (Y_v) e a estimativa gerada pelo eTS+ (\hat{y}). Nessa implementação, o resíduo considerado foi o índice de erro RMSE, o qual foi normalizado para se adequar facilmente a todos os cenários. A partir da avaliação das entradas recebidas, o detector de fraudes calcula a saída e gera um grau de alerta de manipulação para cada uma das amostras observadas. Percebe-se, portanto, que a integração de um método *fuzzy* evolutivo com um sistema *fuzzy* clássico baseado em conhecimento proporciona robustez e interpretabilidade à metodologia desenvolvida. As seções seguintes são dedicadas a detalhar cada uma das etapas mencionadas anteriormente, além de explicar a escolha do tipo de abordagem e demonstrar algumas métricas de erro para avaliação do desempenho.

4.1 Escolha do Tipo de Abordagem

Um modelo pode ser construído de várias maneiras, dependendo do contexto e dos objetivos específicos. Essas abordagens incluem a utilização de métodos baseados nas leis físicas do processo, baseados em dados experimentais de entrada e saída ou uma combinação de ambos. Uma abordagem baseada nas leis físicas do processo também pode ser descrita como uma “caixa branca”, visto que as equações e fenômenos físicos que regem a dinâmica do sistema são conhecidos. Considerando uma perspectiva de previsão do desempenho energético de um edifício, Sun et al. (2020) destaca que os modelos físicos podem prever o comportamento térmico por meio de equações matemáticas, levando em conta as propriedades detalhadas dos materiais de construção. Entretanto, as principais desvantagens desses modelos são: (1) exigência do conhecimento das características físicas; (2) dificuldade em fazer suposições adequadas; (3) procedimento muito demorado; (4) incapacidade de adaptação a variações externas (Shahcheraghian et al. 2024).

Por outro lado, um modelo “caixa preta” é uma abordagem que baseia-se apenas nas relações entre as entradas e saídas de um sistema, sem considerar como o sistema processa essas informações internamente. Embora essa característica possa inicialmente parecer uma desvantagem, essa estrutura permite maior aplicabilidade em sistemas de comportamento não linear, variantes com o tempo, com grande número de variáveis de controle e que necessitam de ajuste automático dos parâmetros conforme o fluxo de dados de entrada (Hassija et al. 2024). Isso também os torna aplicáveis em diversos cenários de detecção de fraudes, pois, em vez de exigir a modelagem

4.1. Escolha do Tipo de Abordagem

específica da fraude, eles apenas necessitam da resposta que ela provoca nos dados de entrada e/ou saída. Algumas vantagens desses modelos são: menor necessidade de conhecimento do domínio e maior adaptabilidade. Do mesmo modo, algumas desvantagens são: demanda por dados representativos e maior custo computacional. Por fim, a modelagem “caixa cinza” combina elementos das duas anteriores. Esses modelos são capazes de capturar tanto os aspectos determinísticos quanto estocásticos de um sistema, oferecendo uma visão mais equilibrada e completa do fenômeno em estudo. Além disso, são normalmente mais interpretáveis que os modelos de caixa preta e mais eficientes computacionalmente que os modelos de caixa branca (Li et al. 2021).

O presente trabalho opta por uma abordagem “caixa preta”, em virtude da crescente disponibilidade de dados provenientes de redes de sensores e comunicação em tempo real, bem como a complexidade envolvida na criação de modelos físicos que representem adequadamente os mecanismos de participação ativa dos usuários finais de energia. Entre os modelos de caixa preta, destacam-se os métodos clássicos, como ARX e ARIMA, amplamente utilizados na engenharia e na previsão de séries temporais. No entanto, esses métodos apresentam limitações notáveis, como: forte dependência de linearidade entre as variáveis de entrada e saída, exigência de dados estacionários, baixa capacidade de generalização para dados complexos, dificuldade na definição da estrutura do modelo e grandes desafios para utilização em sistemas multivariáveis (Tuncar et al. 2024, Chodakowska et al. 2024).

Para superar essas limitações, métodos de Inteligência Artificial, como redes neurais artificiais, e de Inteligência Computacional, como sistemas *fuzzy* evolutivos, são apropriados, pois aprendem diretamente dos dados, sem depender de suposições rígidas sobre o comportamento do sistema. Apesar das redes neurais artificiais serem altamente aplicáveis em sistemas de energia, elas enfrentam barreiras como alto custo computacional, necessidade de grandes volumes de dados, complexidade de ajuste e configuração, além da dependência de manutenção contínua (Shahcheraghian et al. 2024). Em contraste, os sistemas *fuzzy* evolutivos surgem como uma alternativa promissora, superando grandes limitações dos métodos clássicos e de IA. Tais sistemas combinam a flexibilidade da lógica *fuzzy*, que permite lidar com incertezas e dados aproximados, com a capacidade de ajuste e otimização dos algoritmos evolutivos (Gu et al. 2023, Vanegas-Ayala et al. 2024). Dentre esses métodos, destaca-se o *Evolving Takagi-Sugeno Plus (eTS+)*, escolhido por suas diversas vantagens, que o tornam ideal para sistemas com elevado nível de complexidade, incluindo:

- Não linearidade: Os sistemas *fuzzy* TS, por sua própria natureza, são considerados aproximadores universais de funções. Baseado na estratégia de “dividir para conquistar”, uma função não-linear complexa pode ser subdividida em submodelos lineares locais que contribuem de forma proporcional para a saída global do sistema. Além disso, as funções de pertinência são frequentemente funções não lineares das variáveis do antecedente, adicionando uma camada adicional de flexibilidade ao sistema. Desse modo, um modelo *fuzzy* TS é essencialmente um modelo não-linear global, composto por um conjunto de modelos lineares locais interligados por funções de pertinência, que atuam como transições suaves entre as diferentes regiões do espaço de entrada (Costa 2016, Rodrigues Júnior 2021).
- Parâmetros variantes com o tempo: A capacidade de aprendizado contínuo e evolução em tempo real faz com que o eTS+ seja especialmente eficaz em lidar com esse problema. Ao contrário dos métodos adaptativos, que apenas ajustam os parâmetros do sistema, os métodos evolutivos têm a capacidade de atualizar não apenas os parâmetros, mas também de modificar a estrutura do sistema de forma autônoma e em resposta a mudanças externas. Ademais, os parâmetros da saída global do modelo *fuzzy* são compostos por combinações dos submodelos locais e dependem do grau de ativação normalizado de cada regra *fuzzy*. Estes últimos são recalculados a partir da estimação recursiva dos parâmetros do consequente, demonstrando que a própria estrutura do eTS+ já integra parâmetros variantes com o tempo, facilitando sua aplicação em sistemas com essa complexidade (Costa 2016, Angelov et al. 2010).
- Múltiplas entradas e múltiplas saídas: As regras *fuzzy* no eTS+ são projetadas para se adequar as exigências de sistemas reais, apresentando uma estrutura flexível que suporta múltiplas entradas e múltiplas saídas. Isso permite que o eTS+ capture dependências entre as variáveis, resultando em um modelo mais preciso e representativo do comportamento real de sistemas complexos. A abordagem também facilita a integração de dados variados e a adaptação a diferentes cenários, aumentando a robustez e a aplicabilidade do modelo (Angelov et al. 2010, Rodrigues Júnior 2021).
- Incertezas: Em qualquer sistema *fuzzy*, as incertezas estão relacionadas com as funções de pertinência do antecedente da base de regras *fuzzy*. No caso do eTS+, as incertezas não são tratadas como termos linguísticos representativos do conhecimento humano, mas sim como funções de pertinência gaussianas associadas a agrupamentos formados por aprendizagem evolutiva (Costa 2016, Angelov et al. 2010).

4.2 Desenvolvimento do Modelo *Fuzzy* Evolutivo

Esta seção visa expor os procedimentos para a criação e validação de um modelo de sistema capaz de capturar os padrões de envolvimento dos indivíduos em programas de participação ativa de usuários finais de energia. Para atingir esse objetivo, foi escolhido o método *Evolving Takagi-Sugeno Plus* (eTS+), uma técnica avançada de modelagem baseada em sistemas *fuzzy*, projetada para lidar com cenários dinâmicos e não estacionários. Este permite o ajuste contínuo e online das suas regras e parâmetros à medida que novos dados são introduzidos, garantindo que o modelo se mantenha relevante mesmo diante de mudanças nas condições do sistema.

O modelo evolutivo eTS+ se baseia no sistema *fuzzy* Takagi-Sugeno tradicional, mas possui a capacidade de evoluir ao longo do tempo sem intervenção humana. Seu mecanismo de aprendizado é incremental, permitindo que o modelo aprenda continuamente a partir das amostras que chegam a cada instante, eliminando a necessidade de re-treinamento completo e reduzindo drasticamente o custo computacional. Além disso, a habilidade do eTS+ de lidar com incerteza e múltiplas variáveis de entrada e saída torna-o uma ferramenta extremamente eficaz para a modelagem de sistemas complexos. A característica evolutiva do modelo não apenas o torna aplicável a diferentes cenários, mas também permite a captura de interações dinâmicas que abordagens tradicionais podem negligenciar. A implementação deste método foi realizada na linguagem *MATLAB*, seguindo as definições apresentadas nos livros de referência e nas etapas detalhadas a seguir, garantindo um processo rigoroso para a construção do modelo.

4.2.1 Etapa de Treinamento

Dado que esta etapa envolve essencialmente dois procedimentos distintos, o treinamento do eTS+ foi dividido em dois algoritmos: o primeiro abrange uma visão geral da implementação, enquanto o segundo foca especificamente no processo de evolução da estrutura do sistema.

4.2.1.1 Aspectos Gerais e Determinação do Consequente

De forma geral, uma das etapas do aprendizado em sistemas *fuzzy* é a determinação do consequente (ou saída do sistema). É relevante destacar que, embora essa etapa seja tipicamente abordada como uma das últimas fases na implementação de um sistema *fuzzy*, ela está sendo descrita inicialmente aqui com o intuito de tornar mais simples o entendimento do trabalho desenvolvido. Desse modo, o pseudocódigo abaixo demonstra as etapas de implementação do

eTS+, sendo que k é o instante atual e TD é a quantidade de amostras (pode não ser fixa, caso o sistema esteja trabalhando em modo *online* indefinidamente).

- 1: **para** $k \leftarrow 1$ até TD **faça**
 - 2: Receber o par entrada-saída ($\mathbf{z}_k = (\bar{\mathbf{x}}_k, \bar{\mathbf{y}}_k)$)
 - 3: $\bar{\mathbf{z}}_k =$ padronizar \mathbf{z}_k (Eq. 19)
 - 4: $\mathbf{x}^* = eClustering+(\bar{\mathbf{z}}_k)$ (Alg. 2)
 - 5: **se** ($k = 1$) **então**
 - 6: Inicializar: $\mathbf{G}_k^i = 0$; $\mathbf{C}_1^i = \Omega \mathbf{I}$; $\Delta_k^i = 0$; $\hat{\mathbf{y}}_1 = \bar{\mathbf{y}}_1$;
 - 7: **se não**
 - 8: Calcular os graus de ativação (τ_i) e normalizá-los (λ^i) (Eqs. 28 e 29)
 - 9: Atualizar \mathbf{G}_k^i , \mathbf{C}_k^i e Δ_k^i recursivamente pelo método LfwRLS (Eq. 30)
 - 10: Obter as saídas locais ($\hat{\mathbf{y}}_k^i$) (Eq. 31)
 - 11: Estimar a saída global ($\hat{\mathbf{y}}_k$) (Eq. 32)
 - 12: $\tilde{\mathbf{y}}_k =$ converter $\hat{\mathbf{y}}_k$ para a escala original (Eq. 20)
 - 13: **fim se**
 - 14: **fim para**
-

Algoritmo 1 – Etapa de determinação do consequente no algoritmo *Evolving Takagi-Sugeno Plus*

O procedimento é inicializado com o recebimento do primeiro ponto de dados normalizado ($\bar{\mathbf{z}}_1$) (de acordo com a Equação 19). Ademais, na fase de inicialização, o retorno do eTS+ é a componente y deste ponto. Percebe-se, no Algoritmo 1, que a cada acréscimo em k , é feito o cálculo da saída global para aquele instante (y_k), a partir da contribuição de cada saída local associada a um *cluster/regra fuzzy*. A variável \mathbf{G}_k^i é a matriz de ganho, Δ_k^i contém as proposições do consequente e \mathbf{C}_k^i é a covariância, as quais são consideradas para cada regra *fuzzy* no instante k e são atualizadas recursivamente de acordo com a Equação 30. A covariância é inicializada como $\mathbf{C}_1^i = \Omega \mathbf{I}$, sendo que Ω é normalmente usado com valor padrão de 1000 e \mathbf{I} é a matriz identidade de dimensões $(n + 1) \times (n + 1)$. Considerando que o objetivo dessa seção é compreender o cálculo da saída do sistema, é importante analisar a estrutura da base de regras. Desse modo, na subseção 3.1.4, foi descrita a estrutura de um sistema *fuzzy* Takagi-Sugeno (TS) clássico, a partir da exposição do formato das regras *fuzzy*, operações entre conjuntos por meio de conectivos lógicos e o mecanismo de inferência. Entretanto, o caso explicado se baseia apenas em sistemas *fuzzy* de múltiplas entradas e uma saída (MISO). Todavia, conforme Angelov et al. (2004a), os sistemas *fuzzy* evolutivos TS podem possuir múltiplas entradas e múltiplas saídas (MIMO), sendo

que a i -ésima regra *fuzzy* é definida por:

$$\begin{aligned} & \mathbf{R}^i : \mathbf{SE} \ x_1 \text{ é } A_1^i \ \mathbf{E} \cdots \mathbf{E} \ (x_n \text{ é } A_n^i) \\ \mathbf{ENTÃO} \ & \left(y_1^i = a_{01}^i + \sum_{j=1}^n a_{j1}^i x_j \right) \ \mathbf{E} \cdots \mathbf{E} \ \left(y_m^i = a_{0m}^i + \sum_{j=1}^n a_{jm}^i x_j \right) \end{aligned} \quad (26)$$

Onde, $i = [1, 2, \dots, L]$; L é o número de regras; x_j são as variáveis linguísticas do antecedente (entradas do sistema); $j = [1, 2, \dots, n]$; y_v^i são as variáveis do consequente (saídas do sistema); $v = [1, 2, \dots, m]$; A_j^i são os termos linguísticos (conjuntos *fuzzy*) de entrada; a_{0v}^i é o termo constante da equação matemática do consequente e a_{jv}^i são os coeficientes que ponderam as entradas x_j . A relação entre cada variável linguística do antecedente com determinado conjunto *fuzzy* A_j^i é descrita por funções de pertinência gaussianas, conforme visto na Equação 27. Nesta equação, k representa a amostra atual, N é o número de amostras, $\mu_j^i(x_k)$ é o grau de pertinência da entrada x_k ao j -ésimo conjunto *fuzzy* da i -ésima regra *fuzzy*; e σ_j^i é a projeção da zona de influência do i -ésimo *cluster* no eixo da j -ésima variável de entrada (x_j) (Angelov et al. 2010).

$$\mu_j^i(x_k) = e^{-\frac{(x_j^* - x_{kj})^2}{2(\sigma_j^i)^2}}, \quad k = [1, 2, \dots, N] \quad (27)$$

Para a obtenção da saída global, é necessário calcular o grau de ativação de cada regra *fuzzy* (τ^i). Dado que há diversas classes de operadores de norma-t disponíveis, o modelo *fuzzy* TS utiliza o produto algébrico para calcular o grau de ativação da i -ésima regra (Equação 28).

$$\tau^i(x_k) = \prod_{j=1}^n \mu_j^i(x_k) = \prod_{j=1}^n \mu_j^i(x_k) = \mu_1^i(x_k) \times \cdots \times \mu_n^i(x_k) \quad (28)$$

Cada regra aproxima a saída em uma região local com centro no ponto focal do *cluster* correspondente e o grau de ativação dessa aproximação depende da distância entre x_k e o ponto focal (representada pela função de pertinência da Equação 27). Como a soma dos graus de ativação deve ser igual a 1, ele é normalizado de acordo com a Equação 29 (Costa 2016).

$$\lambda^i(x_k) = \frac{\tau^i(x_k)}{\sum_{l=1}^R \tau^l(x_k)}; \quad (29)$$

Para a identificação do consequente, o eTS+ utiliza a técnica de Mínimos Quadrados Recursivos *Fuzzy* Local (LfWRLS). No trabalho de Rodrigues Júnior (2021), esse método é explicado e implementado de maneira mais didática, a partir do cálculo recursivo das matrizes de ganho (\mathbf{G}_k^i),

covariância (\mathbf{C}_k^i) e de proposições do consequente (Δ_k^i):

$$\begin{aligned}\mathbf{G}_k^i &= \frac{\mathbf{C}_{k-1}^i \mathbf{x}^T}{1 + \mathbf{x} \lambda_k^i \mathbf{C}_{k-1}^i \mathbf{x}^T} \\ \mathbf{C}_k^i &= \mathbf{C}_{k-1}^i - \lambda_k^i \mathbf{G}_k^i \mathbf{x}^T \mathbf{C}_{k-1}^i \\ \Delta_i^T(k) &= \Delta_i^T(k-1) + \lambda_k^i \mathbf{G}_k^i (\mathbf{y}_k^T - \mathbf{x} \Delta_i^T(k-1))\end{aligned}\tag{30}$$

Desse modo, a saída local para cada instante é obtida pela Equação 31 (Rodrigues Júnior 2021):

$$\mathbf{y}_k^i = \Delta_i^T(k) \mathbf{x}^T\tag{31}$$

Por fim, a saída global pode ser obtida através do método de defuzzificação por média ponderada (Equação 32). Esse processo envolve somar as saídas de cada submodelo local, correspondentes a um *cluster*/regra *fuzzy* (\mathbf{y}_k^i), ponderadas pelo grau de ativação normalizado (λ_k^i) (Takagi & Sugeno 1985).

$$\mathbf{y}_k = \sum_{i=1}^R \lambda_k^i \mathbf{y}_k^i\tag{32}$$

4.2.1.2 Processo de Evolução da Estrutura

Os sistemas evolutivos são caracterizados pela capacidade de modificar sua estrutura interna ao longo do tempo, à medida que novas informações são recebidas. Diferentemente de sistemas adaptativos, que apenas ajustam seus parâmetros dentro de uma estrutura fixa, sistemas evolutivos podem criar, modificar ou excluir componentes, como regras ou *clusters*, de maneira dinâmica. O método *Evolving Takagi-Sugeno Plus* utiliza o algoritmo *eClustering+*, conforme proposto por Angelov et al. (2010), para segmentar o espaço de dados em *clusters* que podem se sobrepor uns aos outros, onde cada *cluster* está associado a uma regra *fuzzy* e a um submodelo que contribui para a saída global do sistema. Essa característica é a justificativa do *eClustering+* ser mostrado no Algoritmo 1 como uma função que retorna um ponto focal de um *cluster*. Além disso, a vantagem deste em relação a outros métodos é a independência da definição de limites específicos do problema. Essa flexibilidade permite uma melhor adaptação às variações dos dados ao longo do tempo, tornando o sistema capaz de se ajustar de maneira dinâmica e sem a necessidade de intervenção humana. Para compreender a aprendizagem não supervisionada dos antecedentes pelo *eClustering+*, abaixo é apresentado o pseudocódigo do algoritmo e uma descrição detalhada de cada uma das suas etapas.

4.2. Desenvolvimento do Modelo *Fuzzy* Evolutivo

```

1: para k ← 1 até TD faça
2:   Receber o par entrada-saída padronizado ( $\bar{\mathbf{z}}_k = (\bar{\mathbf{x}}_k, \bar{\mathbf{y}}_k)$ )
3:   se ( $k = 1$ ) então
4:     Inicialização:  $R = 1$ ;  $x^{1*} = \bar{x}_1$ ;  $D_1(\bar{\mathbf{z}}_1) = 1$ ;  $\sigma_1^j = 0,5$ 
5:   se não
6:     Coletar uma nova amostra ( $\bar{\mathbf{z}}_k$ ) e calcular a densidade ( $D_k(\bar{\mathbf{z}}_k)$ ) (Eq. 33)
7:     Atualizar a densidade dos centros dos clusters ( $D_k(\bar{\mathbf{z}}^{i*})$ ) (Eq. 34)
8:     se (Condição A2) então
9:       Executar:  $R = R + 1$ ;  $\bar{\mathbf{z}}^{i*} = \bar{\mathbf{z}}_k$ ;  $D_k(\bar{\mathbf{z}}^{i*}) = 1$ 
10:    fim se
11:    se (Condição B) então
12:      Executar: Remoção do cluster atual;  $R = R - 1$ 
13:    fim se
14:    Atribuir  $\bar{\mathbf{z}}_k$  ao cluster mais próximo
15:  fim se
16: fim para

```

Algoritmo 2 – Etapa de agrupamento evolutivo (*eClustering+*) do algoritmo *Evolving Takagi-Sugeno Plus*

Após o recebimento da primeira amostra dos dados normalizados ($\bar{\mathbf{z}}_1$), o *eClustering+* é inicializado conforme descrito na quarta linha do pseudocódigo, cujo significado de cada expressão é: $x^{1*} = x_1$: o primeiro *cluster* é formado com ponto focal igual ao primeiro ponto de dados; $D_1(\bar{\mathbf{z}}_1) = 1$: visto que o x_1 é o ponto focal, a densidade desse ponto será igual a 1; $R = 1$: a quantidade de regras é igual a 1; $\sigma_i^j = 0,5$: valor padrão de 0,5 para o raio do primeiro *cluster*, conforme visto em Angelov et al. (2010). Desse modo, a partir do momento que uma nova amostra é recebida, o *eClustering+* calcula a densidade ($D_k(\bar{\mathbf{z}}_k)$) recursivamente a partir da Equação 33 e a informação correspondente à distribuição espacial de todos os dados é acumulada nas variáveis b_k e c_{kj} , sendo que $j = [1, n + m]$, n é o número de entradas e m é o número de saídas.

$$D_k(\bar{\mathbf{z}}_k) = \frac{k-1}{(k-1) \left(\sum_{j=1}^{n+m} (\bar{\mathbf{z}}_{kj})^2 + 1 \right) + b_k - 2 \sum_{j=1}^{n+m} \bar{\mathbf{z}}_{kj} c_{kj}}, \quad k = [2, \dots] \quad (33)$$

onde, $b_k = b_{k-1} + \sum_{j=1}^{n+m} (\bar{\mathbf{z}}_{(k-1)j})^2$; $b_1 = 0$; $c_{kj} = c_{(k-1)j} + \bar{\mathbf{z}}_{(k-1)j}$; e $c_{1j} = 0$.

Desse modo, supondo que no instante k , um novo ponto de dados é selecionado para ser um

ponto focal de um *cluster*. Sua densidade calculada de acordo com Equação 33 deve ser mantida na memória e atualizada nas iterações seguintes. A atualização é necessária em virtude da natureza *online* do algoritmo e devido ao fato de que cada nova amostra influenciará a densidade dos dados. Além disso, a densidade em torno dos pontos focais dos *clusters* também deve ser atualizada recursivamente a partir da Equação 34, onde i^* representa os pontos focais da i -ésima regra difusa e $D_1(\bar{\mathbf{z}}^{i^*}) = 1$ (Angelov 2004b).

$$D_k(\bar{\mathbf{z}}^{i^*}) = \frac{k-1}{k-1 + (k-2) \left(\frac{1}{D_{k-1}(\bar{\mathbf{z}}^{i^*})} - 1 \right) + \sum_{j=1}^{n+m} (\bar{\mathbf{z}}_{kj} - \bar{\mathbf{z}}_{(k-1)j})}, \quad k = [2, \dots] \quad (34)$$

Conforme afirmado no início dessa subseção, o particionamento do espaço de dados para criação de uma base de regras *fuzzy* resulta em *clusters* que se sobrepõem e não são estritamente exclusivos. Nesse caso, o particionamento deve atender aos seguintes itens (Angelov et al. 2010):

1. Os *clusters* possuem alta capacidade de generalização.
2. As funções de pertinência dos conjuntos *fuzzy* formados em torno dos centros dos *clusters* abrangem todo o espaço de dados.
3. A estrutura pode ser simplificada ao remover *clusters* menos representativos.

O cumprimento de todos esses requisitos garante que o *eClustering+* seja realizado da maneira correta. A primeira tarefa é rapidamente alcançada formando *clusters* em torno de pontos focais de alta densidade (Angelov et al. 2010). Com esse intuito, Angelov et al. (2004a) propôs uma condição de avaliação denominada de A_2 (Equação 35).

$$\text{Condição } A_2: D_k(\bar{\mathbf{z}}_k) > \max_{i=1}^R D_k(\bar{\mathbf{z}}_k^{i^*}) \quad \text{OU} \quad D_k(\bar{\mathbf{z}}_k) < \min_{i=1}^R D_k(\bar{\mathbf{z}}_k^{i^*}) \quad (35)$$

Basicamente, dois critérios são testados: se a densidade do ponto de dados atual é maior que o valor máximo da densidade dos *clusters* existentes; ou, se a densidade do ponto de dados atual é menor que o valor mínimo da densidade dos *clusters* existentes. Caso um desses critérios seja verdadeiro, o ponto de dados do instante k representa regiões inexploradas no espaço de dados. Desse modo, um novo *cluster* será formado e os elementos de $\bar{\mathbf{z}}_k$ farão parte do centro (ponto focal) desse *cluster*. Entretanto, caso a condição não seja satisfeita, os elementos de $\bar{\mathbf{z}}_k$ serão admitidos no *cluster* mais próximo (Angelov et al. 2010, Rodrigues Júnior 2021).

Após a criação de novos *clusters* pela condição A_2 , é importante verificar a redundância da base

4.2. Desenvolvimento do Modelo *Fuzzy* Evolutivo

de regras, para assim evitar *clusters* sobrepostos. Para isso, no trabalho de Angelov & Zhou (2006), foi introduzida a condição B (Equação 36), sendo que μ_i^j consiste no grau de pertinência (mais detalhadamente descrito na Equação 27), $i = [1, R]$ e $j = [1, n]$. Como não é necessário ter vários *clusters* que descrevem a mesma região, todos os que satisfazem essa condição são substituídos pelo *cluster* gerado anteriormente na condição A_2 (Rodrigues Júnior 2021).

$$\text{Condição B: SE } \mu_i^j(\bar{z}_{kj}) > e^{-1} \text{ ENTÃO } (R \leftarrow R - 1) \quad (36)$$

4.2.2 Etapa de Validação

Em resumo, um sistema evolutivo é capaz de evoluir dinamicamente, ajustando sua estrutura e adaptando seus parâmetros com base em novas amostras recebidas a cada instante. Esse tipo de sistema não apenas reage às mudanças nos dados, mas também aprende continuamente a partir dessas mudanças, melhorando sua performance e precisão ao longo do tempo. Como forma de verificar se o modelo treinado atende aos requisitos de desempenho exigidos, o pseudocódigo abaixo apresenta o procedimento de validação do algoritmo *Evolving Takagi-Sugeno Plus* utilizado neste trabalho, cujas etapas serão minuciosamente detalhadas a seguir.

-
- 1: **para** $k \leftarrow 1$ até TDv **faça**
 - 2: Receber o par entrada-saída dos dados desconhecidos ($z_k = (\bar{x}_k, \bar{y}_k)$)
 - 3: \bar{z}_k = aplicar padronização em batelada de z_k
 - 4: Computar o grau de pertinência de \bar{z}_k aos *clusters* existentes (Eq. 27)
 - 5: Calcular os graus de ativação normalizados (λ^i) (Eq. 29)
 - 6: Obter as saídas locais (\hat{y}_k^i) (Eq. 31)
 - 7: Estimar a saída global (\hat{y}_k) (Eq. 32)
 - 8: \tilde{y}_k = converter \hat{y}_k para a escala original
 - 9: **fim para**

Algoritmo 3 – Etapa de validação do algoritmo *Evolving Takagi-Sugeno Plus*

Assim como na etapa de treinamento, o algoritmo é executado em um ciclo iterativo, onde k representa a amostra atual dos dados desconhecidos pelo sistema treinado e TDv é o número total de amostras. Durante esta fase, os dados podem ser padronizados em lote utilizando a média e o desvio padrão calculados recursivamente durante o treinamento. Uma vez que os *clusters* já estão formados, a etapa seguinte consiste em verificar a pertinência de cada nova

amostra recebida em relação aos *clusters* existentes. Desse modo, fica evidente a importância de formar agrupamentos altamente representativos, com grande capacidade de generalização, além de eliminar àqueles que apresentem sobreposição.

Em seguida, os graus de ativação são calculados com base na Equação 28 e normalizados a partir da Equação 29. Além de utilizar os *clusters* formados durante o treinamento, na etapa de validação, a matriz de proposições do consequente (Δ_k^i) precisa ser conhecida, o que permite calcular a contribuição de cada submodelo *fuzzy* linear (y_k^i) de acordo com a Equação 31. Na sequência, a saída global do sistema *fuzzy Evolving Takagi-Sugeno Plus* pode ser obtida por meio do somatório da saída de cada submodelo local pelo respectivo grau de ativação normalizado (λ_k^i) (Equação 32). Para finalizar, a estimativa resultante é convertida para a escala original por meio da operação inversa da padronização em batelada.

4.3 Etapa de Detecção de Fraudes

A etapa de detecção de fraudes tem como objetivo identificar comportamentos anômalos em programas de participação ativa de usuários finais de energia, garantindo a integridade do sistema e a correta distribuição de benefícios. A abordagem *fuzzy* híbrida proposta utiliza dois métodos principais: o modelo *Evolving Takagi-Sugeno Plus* (eTS+), utilizado para previsão dos padrões de participação dos indivíduos, e um sistema *fuzzy* Mamdani, responsável por emitir um grau de alerta caso comportamentos anômalos sejam identificados. Para garantir uma detecção eficaz de fraudes, uma sequência estruturada de etapas deve ser seguida: Inicialmente, é fundamental que o padrão de comportamento dos indivíduos seja modelado com precisão. O método evolutivo utiliza dados históricos de geração, consumo e flexibilidade para conceber um modelo capaz de inferir o comportamento esperado quando novas amostras de entrada são recebidas. Quando são identificadas discrepâncias entre os dados reais e os padrões aprendidos pelo modelo, resulta-se em índices de erro, conhecidos como resíduo. Desse modo, o sistema *fuzzy* Mamdani interpreta cada uma das entradas e a saída (geração, consumo, resíduo e grau de alerta) como conjuntos *fuzzy*, os quais utilizam termos linguísticos para representar as variáveis de forma mais próxima à linguagem humana. Em seguida, o processo de inferência é realizado, por meio da associação dos conjuntos *fuzzy* com regras *fuzzy* construídas a partir de conhecimento especializado. A saída obtida do mecanismo de inferência é posteriormente defuzzificada, ou seja, convertida em um valor numérico para que seja utilizável em contextos práticos.

4.3. Etapa de Detecção de Fraudes

Com base nisso, observa-se que o método de detecção de fraudes desenvolvido neste trabalho é altamente interpretável por especialistas e fácil de adaptar a novas aplicações. Para ilustrar os testes realizados com este método, primeiramente é necessário definir como as fraudes são simuladas. Dessa forma, a subseção 4.3.1 detalha as diferenças entre fraudes aditivas e multiplicativas e apresenta as equações matemáticas relevantes, considerando o intervalo de atuação das manipulações. Por outro lado, a subseção 4.3.2 descreve minuciosamente todo o processo de concepção do detector de fraudes *fuzzy* Mamdani, incluindo a definição dos conjuntos *fuzzy*, funções de pertinência, base de regras, agregação do conjunto *fuzzy* de saída e defuzzificação.

4.3.1 Definição das Fraudes Introduzidas no Sistema

De acordo com Dasgupta et al. (2021), os ataques aos programas de participação ativa de usuários finais podem ocorrer de diversas maneiras. Considerando que os participantes são remunerados com base no consumo reduzido ou flexibilidade ofertada em resposta às solicitações da entidade agregadora, as motivações das fraudes tornam-se evidentes. No presente trabalho, essas fraudes são caracterizadas pela injeção de dados falsos que substituem a informação verdadeira, sendo subdivididas nas formas aditiva e multiplicativa. A equação matemática que descreve uma fraude aditiva pode ser vista na Equação 37.

$$y_F(k) = y(k) + \alpha(k) \quad (37)$$

Onde, k é a amostra atual, y_F é a informação fraudulenta, y é a informação verdadeira e α é uma função matemática que caracteriza a manipulação. Em aplicações comuns, o consumo normalmente é reduzido e a flexibilidade é acrescida, ou seja, o valor de α deve ser negativo para o primeiro caso e positivo para o segundo. Considerando que as informações variam significativamente ao longo do dia, é apropriado que o valor de α varie de forma proporcional aos dados verdadeiros. Em virtude da dificuldade de simular um valor adequado para cada instante em fraudes aditivas, o presente trabalho se utiliza apenas de fraudes multiplicativas, cuja definição está exposta a seguir (Equação 38).

$$\begin{cases} y_F(k) = y(k) \cdot \beta(k), & \text{se } k \in [A, B] \\ y_F(k) = y(k), & \text{se } k \notin [A, B] \end{cases} \quad (38)$$

Onde, β consiste em uma função matemática dependente da amostra considerada (k). No pre-

sente trabalho, são utilizados somente valores fixos de β , resultando em uma fraude aplicada de maneira proporcional aos dados verdadeiros. Além disso, é importante definir os limites de ocorrência da fraude. Caso a amostra k faça parte do intervalo $[A, B]$, a função retornará o valor manipulado correspondente àquela amostra. Por outro lado, caso k esteja fora do intervalo, $\beta(k)$ será igual a zero, ou seja, a função resultante y_R será igual a y , preservando os dados originais.

Percebe-se, portanto, que a implementação da equação anterior gera um vetor de dados falsos que irá substituir as informações verdadeiras em um determinado intervalo de amostras. Essa técnica permite simular diferentes ocorrências de fraude nos cenários estudados neste trabalho e utilizar a metodologia desenvolvida para identificar os comportamentos anômalos gerados.

4.3.2 Construção do Detector de Fraudes *Fuzzy Mamdani*

A proposta desta subseção consiste no desenvolvimento de um sistema de detecção de fraudes utilizando o modelo *fuzzy Mamdani*. Este destaca-se por sua capacidade de inferir informações a partir de variáveis linguísticas, tornando-o altamente eficaz em cenários onde os dados são imprecisos e ruidosos, como frequentemente ocorre em sistemas de energia. O sistema proposto utiliza como entrada os dados de geração e consumo de energia, bem como o resíduo obtido pela diferença entre as previsões geradas pelo modelo *fuzzy evolutivo* e os dados reais. A saída representa uma medida de grau de alerta, que pode ser utilizada para identificar potenciais fraudes ou anomalias no sistema monitorado. Dentre os sistemas *fuzzy* baseados em conhecimento, o sistema Mamdani destaca-se como um dos mais utilizados por sua simplicidade e habilidade em modelar sistemas complexos de forma intuitiva. Desenvolvido por Ebrahim Mamdani na década de 1970, este sistema utiliza regras **SE-ENTÃO** para traduzir o conhecimento humano em um formato que pode ser processado computacionalmente.

Uma das principais vantagens é a sua elevada interpretabilidade, uma vez que as regras são formuladas com base em uma estrutura utilizada no raciocínio humano, permitindo que os especialistas possam configurar e ajustar o sistema com facilidade. Além disso, o sistema Mamdani destaca-se pela sua flexibilidade, ao permitir a inclusão de novas regras ou a modificação das regras existentes de forma simplificada, tornando o sistema adaptável a novos padrões de comportamento. A capacidade de lidar com múltiplas entradas e saídas também é um ponto forte, possibilitando o processamento simultâneo de variáveis independentes. Outros aspectos técnicos relevantes são sua capacidade de generalização e a eficiência no processo de defuzzifica-

4.3. Etapa de Detecção de Fraudes

ção, uma vez que o sistema é capaz de converter as saídas *fuzzy* em valores numéricos precisos, mesmo diante de dados de entrada incompletos, imprecisos ou ruidosos. Com o objetivo de facilitar o entendimento, o sistema *fuzzy* Mamdani desenvolvido neste trabalho será descrito com base nessa sequência de etapas: seleção das variáveis de entrada e saída do problema; definição das funções de pertinência e fuzzificação; criação da base de regras e agregação; defuzzificação da saída obtida. Este modelo será detalhadamente explicado nesta seção e posteriormente utilizado em cenários de detecção de fraudes no capítulo de Casos de Estudo e Resultados.

4.3.2.1 Escolha das Variáveis de Entrada e Saída

As variáveis de entrada influenciam o comportamento do sistema, enquanto uma variável de saída representa o resultado desejado ou a ação a ser executada. Devido à escassez de dados específicos sobre fraudes, a tarefa de treinar modelos de Inteligência Artificial torna-se desafiadora. Por esse motivo, o sistema Mamdani proposto no presente trabalho utiliza como entrada dados de geração e consumo de energia dos indivíduos durante sua participação no programa, além do resíduo obtido a partir da aplicação de novas amostras no modelo *fuzzy* evolutivo treinado na subseção 4.2.1. O resíduo é interpretado como um desvio do comportamento do indivíduo, pois se baseia em uma representação fiel dos padrões de participação ao longo do tempo. Quanto aos dados de geração, estes são utilizados como informação adicional para estabelecer possíveis correlações com os comportamentos observados no consumo de energia. Por fim, para a saída do sistema proposto, foi idealizado um grau de alerta que indica a probabilidade de ter ocorrido uma fraude em um determinado momento. Esta abordagem permite uma análise mais abrangente dos padrões de comportamento dos participantes, facilitando a detecção de anomalias que possam indicar potenciais fraudes ou irregularidades.

4.3.2.2 Definição das Funções de Pertinência e Fuzzificação

As variáveis *crisp* (não *fuzzy*) de geração, consumo, resíduo e grau de alerta definidas na etapa anterior agora são vistas como conjuntos *fuzzy* de entrada e saída. Esses conjuntos requerem uma maneira de representar o conhecimento linguístico do especialista, fato que é alcançado por meio das funções de pertinência. Estas têm o objetivo de converter os valores numéricos das variáveis em graus de pertinência associados a um conjunto *fuzzy* específico, representado por um termo linguístico. Isso pode ser visto nas Figuras 13 a 16, as quais representam respectivamente os conjuntos *fuzzy* de entrada “Geração”, “Consumo” e “Resíduo” e o conjunto *fuzzy* de saída “Grau de Alerta”. Na Figura 13, o universo de discurso foi escolhido como o intervalo [0;

2,5], uma vez que a energia gerada nos casos de estudos analisados se concentra nessa faixa. O comportamento da geração foi investigado e dividido em três funções de pertinência: duas trapezoidais e uma triangular. As funções trapezoidais indicam que a energia gerada de 0 a 0,5 kWh é considerada baixa, enquanto uma geração de 2 a 2,5 kWh é considerada alta. A função triangular “média” representa os valores intermediários de geração de energia, fazendo intersecções suaves com as outras duas funções.

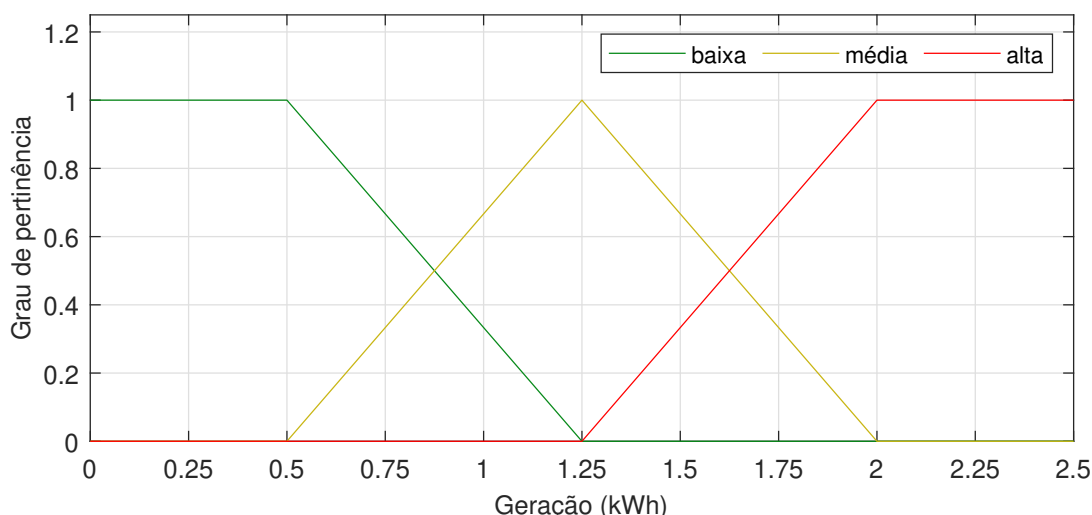


Figura 13 – Conjunto fuzzy “Geração” e funções de pertinência

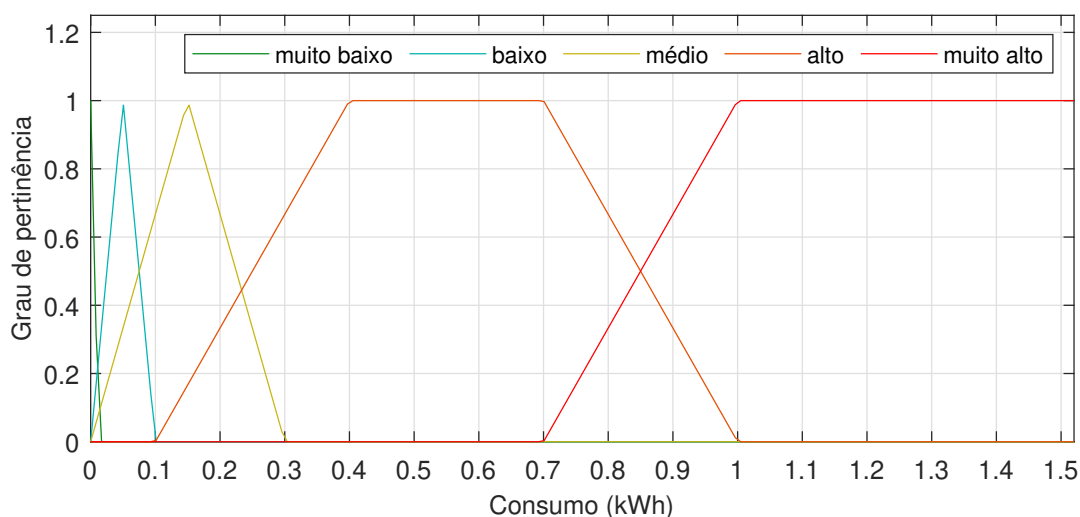


Figura 14 – Conjunto fuzzy “Consumo” e funções de pertinência

Para o conjunto fuzzy Consumo, fez-se necessário um refinamento maior, uma vez que essa variável é considerada uma das mais importante em programas de participação ativa de usuários finais. Desse modo, a Figura 14 apresenta três funções trapezoidais e duas triangulares, definidas em um universo de discurso de [0; 1,52], refletindo o comportamento real do consumo. Observa-se que a função do termo linguístico “muito baixo” ocupa uma pequena parcela do con-

4.3. Etapa de Detecção de Fraudes

sumo total, assim como os termos “baixo” e “médio”. Isso foi projetado dessa maneira devido à configuração padrão dos dados de consumo reais e com o intuito de tornar o sistema Mamdani sensível a pequenas variações no comportamento observado. Além disso, os termos “alto” e “muito alto” são definidos desta forma com o intuito de representar os picos característicos dos dados analisados.

O modelo *fuzzy* evolutivo empregue na primeira fase da metodologia é capaz de gerar estimativas da participação dos indivíduos a partir da aplicação de novos dados de entrada. Desse modo, fica evidente que, caso o erro obtido seja pequeno, os novos dados inseridos são semelhantes aos dados utilizados durante o treinamento do modelo, indicando que o prosumidor manteve um padrão de consumo e geração. Por outro lado, um erro elevado sugere uma mudança significativa no comportamento do prosumidor, o que pode significar alterações reais nas suas rotinas de consumo e geração, ou a realização de práticas fraudulentas. A possibilidade de tratar informações vagas e imprecisas como esta é uma das características que distinguem os métodos *fuzzy* das tecnologias tradicionais de Inteligência Artificial.

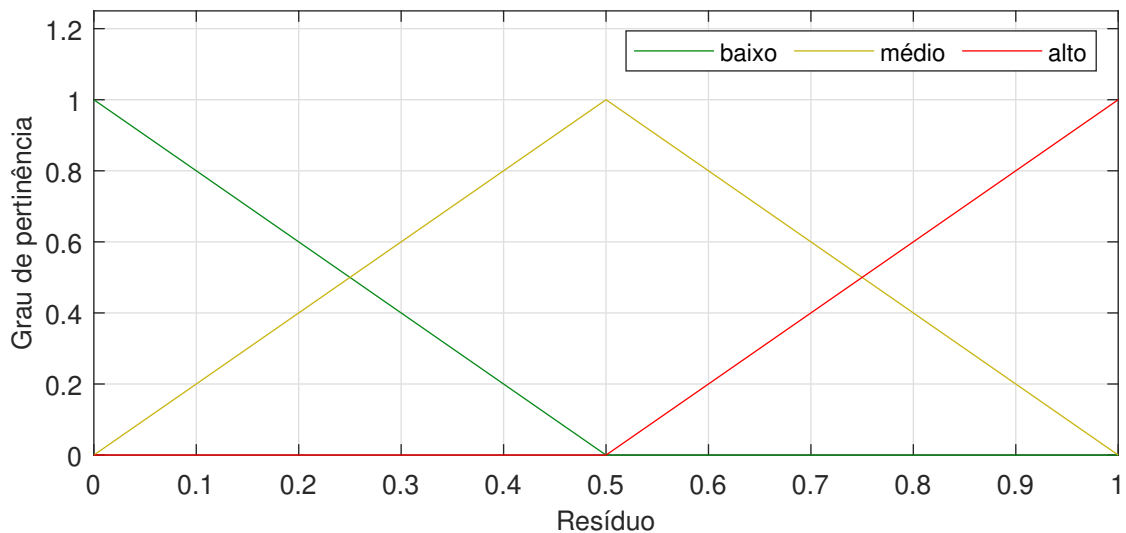


Figura 15 – Conjunto *fuzzy* “Resíduo” e funções de pertinência

Com base na ideia de avaliação do comportamento do prosumidor, foi idealizado um conjunto *fuzzy* para a variável “Resíduo”, cujas pertinências podem ser vistas na Figura 15. A métrica de erro utilizada é o erro RMSE, cuja definição matemática está explicada na subseção 4.4. Ademais, nos sistemas *fuzzy* clássicos, os conjuntos *fuzzy* necessitam de um universo de discurso bem definido e, em geral, os índices de erro não possuem valores máximo e mínimo. Desse modo, antes de ser aplicada no sistema Mamdani, essa métrica é normalizada, para permanecer sempre dentro do intervalo [0, 1].

Considerando que as manipulações em sistemas de energia são influenciadas por múltiplos fatores, torna-se mais eficaz o desenvolvimento de um sistema que não se limite a apenas relatar a ocorrência de uma fraude, mas que seja baseado em diferentes níveis de alerta, os quais combinados indicam a chance de ter ocorrido uma fraude em momentos específicos. Com base nisso, o conjunto *fuzzy* de saída “Grau de Alerta” foi projetado, cujos níveis consistem nos termos linguísticos representados pelas funções de pertinência da Figura 16. O universo de discurso foi definido em uma escala de porcentagem de fraude, variando de 0% a 100%, com funções de pertinência triangulares divididas de maneira simétrica para representar cada termo linguístico.

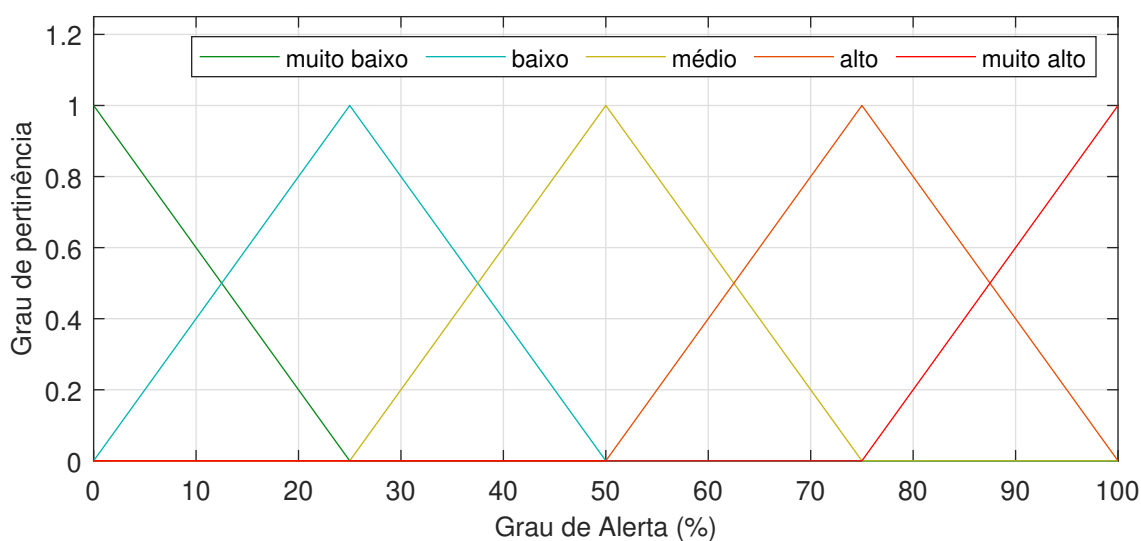


Figura 16 – Conjunto *fuzzy* “Grau de Alerta” e funções de pertinência

Ao final desta etapa, obtém-se a saída fuzzificada, que representa os graus de pertinência dos valores reais de entrada e saída em relação aos diferentes conjuntos *fuzzy*. Como informação complementar, a Tabela 5 apresenta os parâmetros utilizados para construção das funções de pertinência vistas anteriormente. Para as funções trapezoidais, os parâmetros são: a (início da pertinência zero), b (início da pertinência máxima), c (fim da pertinência máxima) e d (fim da pertinência zero). Nas funções triangulares, os parâmetros incluem: i (início da subida da pertinência), m (onde a pertinência atinge seu máximo) e f (ponto final da descida da pertinência).

4.3.2.3 Criação da Base de Regras *Fuzzy* e Agregação

Uma base de regras *fuzzy* consiste em um conjunto organizado de proposições que definem como os conjuntos *fuzzy* de entrada são combinados para determinar a saída. Para o sistema Mamdani proposto neste trabalho, apenas 6 regras foram necessárias para gerar o comportamento esperado pelo sistema. As regras foram criadas a partir da observação dos padrões verificados

4.3. Etapa de Detecção de Fraudes

Tabela 5 – Parâmetros dos conjuntos *fuzzy* do sistema Mamdani

Conjunto <i>fuzzy</i>	Termo linguístico	Tipo de função	Parâmetros
Geração	baixa	Trapezoidal	$a = 0; b = 0; c = 0,5; d = 1,25$
	média	Triangular	$i = 0,5; m = 1,25; f = 2$
	alta	Trapezoidal	$a = 1,25; b = 2; c = 2,5; d = 2,5$
Consumo	muito baixo	Trapezoidal	$a = 0; b = 0; c = 0,005; d = 0,01$
	baixo	Triangular	$i = 0; m = 0,05; f = 0,1$
	médio	Triangular	$i = 0; m = 0,15; f = 0,3$
	alto	Trapezoidal	$a = 0,1; b = 0,4; c = 0,7; d = 1$
	muito alto	Trapezoidal	$a = 0,7; b = 1; c = 1,52; d = 1,52$
Resíduo	baixo	Triangular	$i = 0; m = 0; f = 0,5$
	médio	Triangular	$i = 0; m = 0,5; f = 1$
	alto	Triangular	$i = 0,5; m = 1; f = 1$
Grau de Alerta	muito baixo	Triangular	$i = 0; m = 0; f = 25$
	baixo	Triangular	$i = 0; m = 25; f = 50$
	médio	Triangular	$i = 25; m = 50; f = 75$
	alto	Triangular	$i = 50; m = 75; f = 100$
	muito alto	Triangular	$i = 75; m = 100; f = 100$

nos dados de consumo e geração de energia, além da análise do resíduo obtido entre a variável alvo e a estimativa gerada pelo eTS+. Por exemplo, a primeira regra da Tabela 6 foi criada com o objetivo de desprezar as incertezas obtidas durante a concepção do modelo de participação. Do mesmo modo, as regras 2 e 3 atribuem pesos maiores para a saída à medida que os erros calculados aumentam. Além disso, a quarta regra serve para caracterizar os picos de consumo observados nos dados reais. Por fim, as últimas duas regras também indicam comportamentos esperados: a regra 5 é comumente ativada durante o período da noite e madrugada, enquanto a regra 6 se aplica ao restante do dia.

Percebe-se que as regras expostas na Tabela 6 foram desenvolvidas para identificar potenciais fraudes por meio da análise do resíduo e dos desvios de comportamento detectados nos dados de consumo e geração de energia. A interpretabilidade das regras foi cuidadosamente considerada, permitindo que os operadores compreendam facilmente a resposta fornecida pelo sistema de detecção de fraudes *fuzzy* Mamdani. O sistema desenvolvido neste trabalho foi concebido a

partir da análise dos casos e cenários presentes nos Casos de Estudo. Para aplicações reais, é possível incorporar conhecimento de outros especialistas, ajustando as funções de pertinência e a base de regras *fuzzy*, o que permite uma adaptação constante e a personalização do sistema conforme as necessidades específicas de diferentes ambientes operacionais.

Tabela 6 – Base de regras *fuzzy* do sistema Mamdani

Nº	Descrição da regra
1	SE Resíduo é baixo ENTÃO Grau de Alerta é muito baixo
2	SE Resíduo é médio ENTÃO Grau de Alerta é médio
3	SE Resíduo é alto ENTÃO Grau de Alerta é muito alto
4	SE Consumo é muito alto ENTÃO Grau de Alerta é muito baixo
5	SE Geração é baixa E Consumo é muito baixo ENTÃO Grau de Alerta é muito baixo
6	SE Geração é alta E Consumo é baixo ENTÃO Grau de Alerta é muito baixo

Em linhas gerais, uma regra *fuzzy* é considerada ativada quando a pertinência total do seu antecedente (também chamada de grau de ativação) é diferente de zero e menor ou igual a 1. Em outras palavras, a ativação de uma regra significa que a condição especificada no antecedente é verdadeira para o valor atual da variável de entrada. Entretanto, cada regra gera uma contribuição individual para o cálculo do conjunto *fuzzy* de saída que atende aos requisitos das entradas. Em um sistema Mamdani típico, é comum que mais de uma regra seja ativada simultaneamente. Portanto, é crucial combinar as contribuições de todas as regras ativadas, através de um método conhecido como agregação.

A agregação pode ser realizada de diferentes formas. Neste trabalho, foi utilizado o método de Máximo, em virtude de sua simplicidade e capacidade de gerar resultados satisfatórios. Para fins didáticos, uma situação hipotética pode ser descrita da seguinte forma: considera-se que em determinado momento, a geração de um participante é de 1,5 kWh, o consumo é de 0,05 kWh e o resíduo obtido é igual a 0. Percebe-se, nas Figuras 13 e 14, que a geração é classificada pelos termos linguísticos “média” e “alta” (com pertinências aproximadas de 0,65 e 0,35, respectivamente) e o consumo totalmente como “baixo” (pertinência máxima). Desse modo, considerando que o uso do operador lógico **E** resulta no valor mínimo das funções de pertinência, o grau de ativação da regra 6 é: $\min(0,35; 1) = 0,35$. A contribuição dessa regra para a saída do sistema resulta de uma implicação, ou seja, um corte horizontal igual a 0,35 na função de pertinência do termo “muito baixo” no conjunto *fuzzy* Grau de Alerta. Uma vez que o resíduo é igual a 0, este

4.3. Etapa de Detecção de Fraudes

pode ser classificado totalmente como “baixo” (pertinência máxima). Dessa forma, a primeira regra é completamente ativada, gerando uma contribuição igual à área delimitada pela função de pertinência triangular do termo linguístico “muito baixo”, no conjunto *fuzzy* de saída. Com base nisso, percebe-se que duas regras foram ativadas simultaneamente, tornando necessária a utilização de um método de agregação. O método de Máximo visa selecionar o conjunto *fuzzy* de saída obtido a partir da regra mais representativa, ou seja, que possui maior grau de ativação. Dessa forma, a contribuição da regra 6 será ignorada, uma vez que a primeira regra possui grau de ativação igual a 1.

4.3.2.4 Obtenção da Saída Numérica por Defuzzificação

De forma semelhante à etapa de agregação, a defuzzificação pode ser realizada de diversas formas. No entanto, o método escolhido para o presente trabalho foi o Centro de Gravidade. Este foi selecionado devido a sua ampla utilização e à capacidade de produzir um resultado que representa a média ponderada de todas as saídas possíveis. Isso é alcançado por meio da divisão do conjunto *fuzzy* final em duas parcelas de mesma área, encontrando o ponto de equilíbrio ou centro de massa do conjunto. A Figura 17 utiliza o conjunto *fuzzy* agregado do exemplo anterior para demonstrar esse comportamento, onde uma linha vertical representa o valor do centroide (x^*), dividindo a forma geométrica obtida em duas áreas de mesmo tamanho.

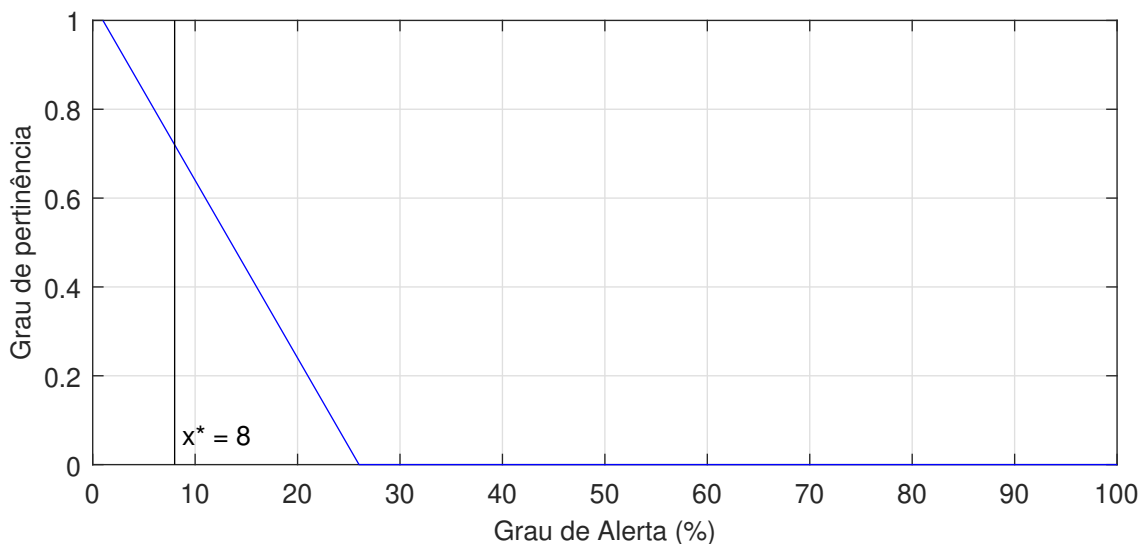


Figura 17 – Exemplo de defuzzificação por centroide no conjunto *fuzzy* “Grau de Alerta”

Percebe-se, portanto, que a defuzzificação pelo método do Centro da Gravidade se baseia em cálculos de área. De forma geral, as funções de pertinência no conjunto *fuzzy* agregado podem ser contínuas ou discretas. A Equação 39 apresenta as metodologias de cálculo para esses dois

tipos de funções, sendo que x_i é uma amostra no instante i , $\mu(x_i)$ é o grau de pertinência e n representa a quantidade total de amostras.

$$x^* = \frac{\int x \cdot \mu(x)(dx)}{\int \mu(x)(dx)} \text{ (caso contínuo), } x^* = \frac{\sum_{i=1}^n x_i \cdot \mu(x_i)}{\sum_{i=1}^n \mu(x_i)} \text{ (caso discreto)} \quad (39)$$

4.4 Métricas para Avaliação do Desempenho

O desempenho de um modelo pode ser medido a partir da precisão dos valores estimados. Diferentes métricas podem ser aplicadas, dependendo do tipo de problema ou das características dos dados utilizados (Das et al. 2021). Um dos objetivos do presente trabalho consiste em modelar os padrões de participação dos indivíduos em programas de gerenciamento do lado da demanda. Desse modo, este pode ser caracterizado como um problema de regressão e as métricas escolhidas para avaliação do modelo desenvolvido são formuladas e descritas abaixo, sendo que N é a quantidade de amostras, y é o vetor de dados reais e \tilde{y} de dados estimados.

- **Erro Quadrático Médio (MSE)**

$$MSE = \frac{1}{N} \sum_{k=1}^N (y_k - \tilde{y}_k)^2 \quad (40)$$

Em virtude da formulação do MSE, a presença de dados discrepantes gera um resíduo que contribui de forma quadrática para o erro total. Desse modo, caso o modelo faça previsões que diferem consideravelmente dos valores reais correspondentes, geralmente o índice de erro MSE será significativamente maior do que o calculado por outras métricas (Kulkarni & Satapathy 2020).

- **Erro Absoluto Médio (MAE)**

$$MAE = \frac{1}{N} \sum_{k=1}^N |y_k - \tilde{y}_k| \quad (41)$$

A formulação matemática do MAE é bem semelhante à do MSE. Contudo, a principal diferença está no fato de que o MAE não atribui pesos adicionais para erros maiores. A simplicidade é uma grande vantagem dessa métrica, uma vez que se baseia apenas no valor absoluto entre os dados e as previsões do modelo. Conforme Kulkarni & Satapathy (2020), caso o MAE seja igual a 0, o

4.4. Métricas para Avaliação do Desempenho

dado estimado é perfeitamente igual ao dado observado. Por outro lado, um erro MAE grande sugere que o modelo pode ter problemas em determinadas áreas.

- **Raiz do Erro Quadrático Médio (RMSE)**

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \tilde{y}_k)^2} \quad (42)$$

Por ser uma derivação do MSE, o erro RMSE possui as mesmas vantagens e a raiz quadrada é calculada para fornecer um resultado na mesma escala dos dados originais. Em virtude disso, é considerada a métrica de erro mais interpretável e conseqüentemente bastante utilizada em problemas de regressão (Piotrowski et al. 2022). Diante do exposto, fica evidente que a escolha das métricas de desempenho depende da aplicação e da necessidade de atribuir (ou não) pesos adicionais para erros maiores. Em virtude de suas vantagens, as três métricas citadas anteriormente serão utilizadas para avaliar as etapas de treinamento e validação do modelo *fuzzy* evolutivo utilizado neste trabalho.

5 Casos de Estudo e Resultados

No presente capítulo, é apresentado o problema motivador do trabalho em questão, os casos de estudos formulados e os resultados dos testes da metodologia desenvolvida no capítulo anterior. De forma geral, existem diversas abordagens para solucionar o problema de injeção de dados falsos em programas de participação ativa de usuários finais de energia. Essas abordagens incluem tanto o uso do conhecimento sobre os padrões de consumo e geração de energia dos clientes quanto o desenvolvimento de métodos inteligentes para detecção de fraudes. Dessa forma, o primeiro caso de estudo foca no desenvolvimento de um modelo de participação utilizando dados de consumo de agregados familiares e supermercados. No primeiro cenário, são analisados agregados familiares compostos por três pessoas, enquanto o segundo cenário aborda supermercados com área inferior a 400 m². Por outro lado, o segundo caso de estudo simula um consumidor participando de um programa de *Demand Response*. No primeiro cenário, considera-se uma situação de operação normal, onde todos os dados fornecidos são verídicos. Já no segundo cenário, uma fraude é aplicada para manipular os dados de flexibilidade. Em ambos os casos, aplica-se o sistema de detecção de fraudes *fuzzy* Mamdani, desenvolvido neste trabalho, demonstrando sua eficácia na identificação de informações fraudulentas.

5.1 Detalhamento do Problema

Os programas de participação ativa de usuários finais desempenham um papel significativo na gestão eficiente da demanda de energia elétrica. Entretanto, com a crescente complexidade das redes elétricas e a digitalização dos sistemas de medição e controle de energia, surgem oportu-

tunidades para práticas fraudulentas. As fraudes abrangem a manipulação deliberada de informações com o intuito de obter vantagens financeiras no programa, prejudicando os resultados e burlando as regras estabelecidas. É importante ressaltar que essas manipulações podem ocorrer em diversos níveis dos sistemas de energia transacional e ter implicações significativas para a eficácia, integridade e confiança entre os participantes. Entretanto, o presente trabalho não se concentra na origem da manipulação, visando apenas o desenvolvimento de uma estratégia eficaz de detecção e prevenção de fraudes, por meio da modelagem dos padrões de participação dos indivíduos e do envio de alertas baseado em comportamentos anômalos.

Em um contexto mais amplo, os TES envolvem vários componentes, como o controle de mecanismo de mercado hierárquico e centralizado, o controlador doméstico (HC), a infraestrutura de comunicação e os participantes de geração/consumo de energia. O HC instalado no domicílio do usuário desempenha uma função crucial, reagindo aos sinais de preços provenientes do mercado transacional. Em resposta, ele fornece informações como preços de aquisição, de forma automatizada. A troca de informações entre os prosumidores e os agentes do mercado requer um sistema de comunicação que seja seguro, confiável e altamente resiliente, visto que qualquer interrupção pode comprometer a eficiência do TES (Tooki & Popoola 2024).

Conforme Tatipatri & Arun (2024), a perda da integridade de um sistema de energia transacional é muitas vezes causada por ataques de injeção de dados falsos (FDIAs). Tipicamente, um FDIA pode ser descrito como um processo que envolve a inserção de informações distorcidas como entrada ou a manipulação dos dados existentes em um sistema. Qualquer sistema de distribuição de energia que integra medidores inteligentes e uma infraestrutura de comunicação está suscetível a ataques cibernéticos. Um agente mal-intencionado tem a capacidade de manipular os preços da eletricidade transmitidos através da infraestrutura cibernética ou comprometer um grupo específico de medidores inteligentes, alterando as leituras registradas. Por exemplo, quando ocorre uma interferência no sinal de tarifação, o preço da eletricidade que os consumidores recebem pode se tornar incorreto, influenciando diretamente nos seus padrões de consumo.

Os invasores também podem explorar a vulnerabilidade e projetar diferentes ataques visando elementos menos seguros no sistema, como medidores e eletrodomésticos inteligentes, sistemas de aquecimento, ventilação e ar-condicionado e DERs integrados à infraestrutura de comunicação. Um ataque direcionado aos medidores inteligentes pode levar a estimativas inadequadas da demanda total, resultando em cálculos equivocados dos preços da eletricidade. Tais ataques cibernéticos podem repercutir nos valores cobrados pela eletricidade, nos hábitos de consumo

5.2. Descrição dos Conjuntos de Dados

dos consumidores ativos e na estabilidade da rede de distribuição. É importante notar que o impacto desses ataques não se limita a um único período, podendo se estender ao longo de vários períodos subsequentes. Devido à intrínseca relação entre os preços da eletricidade e a demanda, um ataque cibernético às informações dos preços afeta a demanda total e, inversamente, qualquer manipulação na demanda também impacta os preços da eletricidade (Mohammadi et al. 2021, Dasgupta et al. 2021).

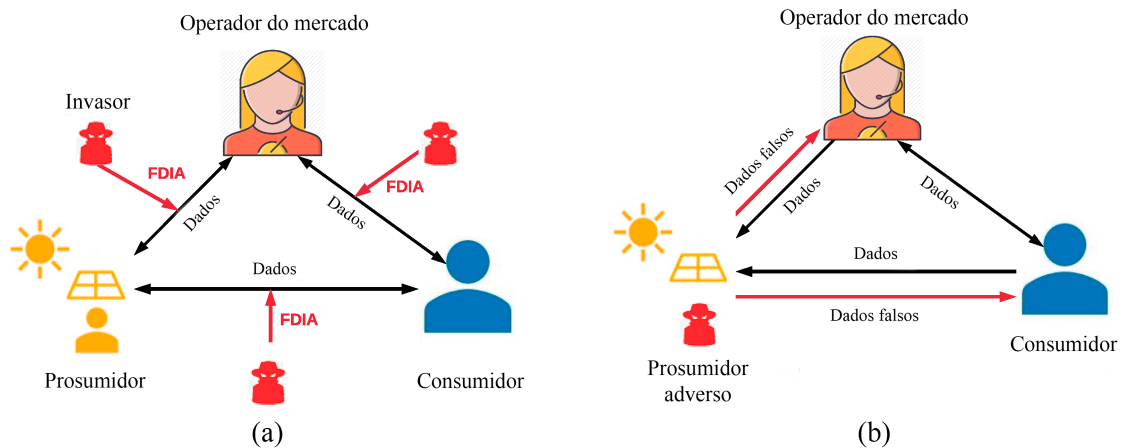


Figura 18 – Exemplo de injeção de dados falsos: (a) nos canais de comunicação, (b) por parte de um prosumidor participante do programa (adaptado de Dasgupta et al. (2021))

Com o objetivo de simplificar o entendimento, a Figura 18 ilustra duas diferentes ocorrências de FDIAs: Na Figura 18 (a), um invasor emprega FDIAs para manipular as ofertas de compra ou os sinais de preço que circulam entre prosumidores, consumidores e operadores de mercado. O objetivo é provocar perdas financeiras para todos os participantes ou perturbar a operação regular do mercado. Por outro lado, na Figura 18 (b), um prosumidor com intenções adversas age como um invasor, introduzindo dados falsos ao operador do mercado ou aos seus pares, com o objetivo de aumentar os próprios ganhos financeiros (Dasgupta et al. 2021).

5.2 Descrição dos Conjuntos de Dados

Uma das etapas fundamentais no desenvolvimento de um modelo é a aquisição de conjuntos de dados confiáveis para treinamento e validação. Atualmente existem diversos repositórios gratuitos que disponibilizam dados de diferentes aplicações, além de permitirem a autores de trabalhos científicos compartilharem os *datasets* utilizados no desenvolvimento de sua pesquisa. Desse modo, no presente trabalho, os dados obtidos são resultados de pesquisas finalizadas e publicadas no *site* Zenodo. Com o propósito de tornar mais simples o mapeamento de cada um

dos conjuntos de dados utilizados, a Tabela 7 apresenta uma descrição das principais informações extraídas e o período de amostragem de cada *dataset*.

Tabela 7 – Conjuntos de dados utilizados nos casos de estudo

Nº	Nome	Informações	Amostragem
1	<i>Regional flexibility in households and super-markets</i>	Cinco perfis de consumo anuais (kWh)	1 hora
2	<i>Dataset of an Energy Community's Consumption and Generation with Appliance Allocation for One Year</i>	Perfis de consumo de 51 edifícios, desagregados em aparelhos individuais (kWh)	15 minutos
3	<i>Dataset of 30 energy customers with flexibility data, and distributed generation, considering residential, small commerce, large commerce, and industrial customers</i>	Geração (kWh); Consumo (kWh) e Flexibilidade (kWh)	15 minutos

O primeiro *dataset* consiste em uma iniciativa alemã para determinação do potencial de flexibilidade em comunidades regionais. O projeto é denominado de “WindNODE - A vitrine da energia inteligente do nordeste da Alemanha” e é mantido pelo Instituto de Pesquisa em Economia Ecológica. Basicamente, são fornecidos cinco perfis de consumo (em kWh) durante o ano de 2017, sendo que o primeiro consiste no consumo padrão e os próximos quatro são variações deste a partir da redução em aparelhos específicos (como ar-condicionado e sistemas HVAC). Essa estratégia foi aplicada no âmbito de agregados residenciais (levando em conta a quantidade de pessoas) e supermercados (com base na área ocupada). As amostras foram coletadas durante intervalos de 1 hora, totalizando uma quantia de 8760 (Gähns et al. 2020).

O segundo *dataset* descreve uma comunidade de energia que contém perfis de produção fotovoltaica e perfis de consumo do usuário final, desagregados por aparelhos individuais utilizados. O conjunto de dados final apresenta 35136 amostras, consistindo em dados de produção fotovoltaica e consumo agregado e desagregado de 50 domicílios residenciais e um prédio público (biblioteca municipal). De forma geral, os perfis foram obtidos de leituras domiciliares em diferentes locais (como Londres e França), enquanto o perfil do edifício público foi baseado nos perfis de consumo e produção fotovoltaica do edifício de pesquisa do GECAD (*Research Group on Intelligent Engineering and Computing for Advanced Innovation and Development*). Todos os perfis passaram pelo processo de normalização e novos foram gerados para completar o número de usuários finais necessários (Goncalves et al. 2022).

5.3. Caso 1: Modelagem dos Padrões de Consumo em Agregados Familiares e Supermercados

O último conjunto de dados representa informações de geração fotovoltaica, consumo e flexibilidade (em kWh) de 30 clientes durante o período de uma semana. Os perfis residenciais analisados baseiam-se nos dados disponíveis pelo Grupo de Trabalho de Mineração e Análise Inteligente de Dados (IDMA). Do total apresentado, 10 são residenciais, 10 são pequenos comércios, 5 são grandes comércios e os 5 restantes são industriais. Essa diversidade é importante porque possibilita a análise de diferentes cenários e aglomerados em programas de participação ativa de usuários finais. Por fim, neste *dataset*, a leitura é feita a cada 15 minutos, gerando um total de 672 amostras (Pereira et al. 2022).

5.3 Caso 1: Modelagem dos Padrões de Consumo em Agregados Familiares e Supermercados

O primeiro caso de estudo visa demonstrar a aplicabilidade do método evolutivo na modelagem dos padrões de consumo dos indivíduos. Por esse motivo, são fornecidos detalhes sobre o processo de treinamento e validação, a estrutura do modelo e as características dos *clusters* formados. De forma geral, a energia consumida está diretamente ligada à flexibilidade, uma vez que o participante é flexível à medida que promove uma mudança do consumo para horários fora de pico da rede elétrica, reduz o uso de aparelhos menos eficientes, entre outras alternativas. Além disso, é importante comentar sobre as variáveis utilizadas nos cenários seguintes. De forma geral, o algoritmo necessita de pelo menos uma entrada e uma saída para aprender com base em uma correlação entre essas duas informações. Para isso, dados de consumo padrão foram utilizados como entrada, enquanto na saída foram aplicados dados de consumo modificado pelo desligamento de aparelhos específicos, como ar-condicionado e sistemas HVAC. Essa abordagem permite que os padrões de consumo modificados sejam modelados, refletindo o comportamento do cliente durante solicitações de desligamento desses aparelhos.

5.3.1 Cenário 1: Agregado Familiar de Três Pessoas

No primeiro cenário, foram utilizados dados de um agregado familiar composto por três pessoas, abrangendo um período de um mês com intervalos de uma hora. Dessa forma, a quantidade total de amostras foi de 720, das quais 70% foram designadas para treinamento e 30% para teste. A Figura 19 apresenta a previsão gerada pelo eTS+ na fase de treinamento. Durante esse estágio, o algoritmo processa cada amostra em tempo real e calcula a estimativa com base nos dados de

entrada e saída. Percebe-se visualmente que os *clusters* formados pelo eTS+ detectaram padrões de consumo mais baixos e ajustaram seu aprendizado a partir desses padrões. Essa afirmação é confirmada logo na Figura 20, onde um novo *cluster* é adicionado à base de regras no momento em que ocorre o primeiro pico de consumo, fato que demonstra a característica evolutiva da metodologia proposta. Além disso, o método utilizado neste trabalho também é escalável para aplicação em diferentes contextos, reduz a sobrecarga computacional devido ao ajuste incremental de regras e possui capacidade de implementação em tempo real, o que o torna ideal em situações que exigem respostas rápidas.




Figura 19 – Treinamento do modelo (Caso 1, Cenário 1)




Figura 20 – Evolução das regras fuzzy (Caso 1, Cenário 1)

Ademais, considerando que este estudo de caso tem o propósito de destacar características importantes da concepção do modelo *fuzzy* evolutivo, é essencial examinar algumas variáveis dos

5.3. Caso 1: Modelagem dos Padrões de Consumo em Agregados Familiares e Supermercados

agrupamentos formados pelo eTS+. Com esse objetivo, um *cluster* foi selecionado como referência e foram extraídos os dados de suporte e o parâmetro sigma. O suporte representa o número de amostras associadas a um *cluster*, indicando sua capacidade de generalização, enquanto o parâmetro sigma corresponde ao raio dos *clusters*, determinando a zona de influência de cada um deles. Na Figura 21, é possível visualizar ambas as variáveis do *cluster* selecionado. O raio dos clusters é ajustado automaticamente com base nas amostras recebidas a cada instante, destacando a capacidade de otimização interna oferecida pelo eTS+ (Figura 21 (a)). No presente trabalho, o raio dos *clusters* é mantido dentro do intervalo [0,3; 0,5], uma escolha padronizada que tem mostrado resultados satisfatórios em grande parte dos conjuntos de dados utilizados. No que diz respeito ao suporte, observa-se um aumento significativo das amostras associadas ao longo do tempo (Figura 21 (b)). Agrupamentos com alto suporte são considerados fortes candidatos para permanecer na base de regras, enquanto aqueles com baixo suporte provavelmente serão removidos.

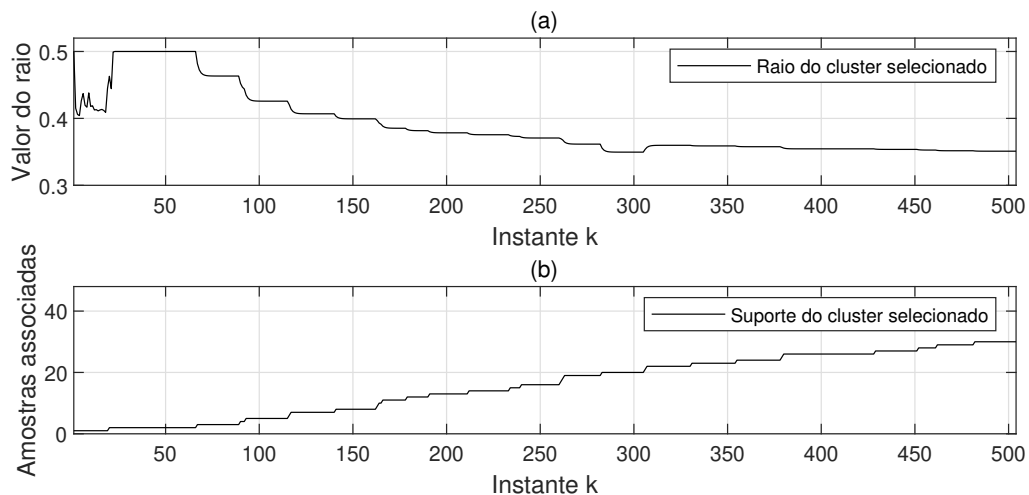


Figura 21 – Parâmetro *sigma* e suporte de um *cluster* selecionado (Caso 1, Cenário 1)

O processo de treinamento do método evolutivo consiste no ajuste automático da quantidade de *clusters* / regras *fuzzy* a partir da identificação de padrões nos dados observados. A fase de validação, por sua vez, envolve a aplicação de amostras desconhecidas ao sistema para verificar a eficácia do treinamento realizado. Esse passo é crucial, pois avalia a capacidade do modelo de generalizar o conhecimento adquirido durante o treinamento. Fica evidente, na Figura 22, que o modelo aprendeu satisfatoriamente a dinâmica dos dados observados, uma vez que os erros obtidos se concentram basicamente durante os períodos de pico.

A escolha deste método também pode ser justificada pela Tabela 8, onde é exposta a comparação do desempenho do eTS+ com outras estratégias disponíveis na literatura. Essa comparação é




Figura 22 – Validação do modelo (Caso 1, Cenário 1)

realizada com base nas métricas de erro descritas na subseção 4.4 e o melhores resultados são apresentados em negrito. Os algoritmos escolhidos foram métodos evolutivos *fuzzy* cujas regras são do tipo Takagi-Sugeno, com o intuito de demonstrar a quantidade final de regras geradas, assim como o custo computacional (representado pelo tempo de execução, em segundos). Os tempos foram obtidos por meio de uma média aritmética de 15 execuções para cada experimento, em um computador com as seguintes especificações: CPU: AMD Ryzen 5 5600GT; Memória RAM: 16 GB; GPU: AMD Radeon Graphics Vega 7; Disco: SSD PCIe 3.0. Dado que todas as técnicas produzem resultados idênticos para o mesmo conjunto de dados, os erros apresentados foram extraídos da primeira execução de cada experimento.

Tabela 8 – Comparação do eTS+ com outros métodos da literatura (Caso 1, Cenário 1)

Métodos	MAE		MSE		RMSE		Tempo (s)	Regras
	T	V	T	V	T	V		
eTS	0,0313	0,0353	0,0029	0,0036	0,0545	0,0604	1,1632	5
Simpl_eTS	0,0317	0,0366	0,0029	0,0038	0,0547	0,0620	0,7213	2
exTS	0,0304	0,0341	0,0030	0,0036	0,0550	0,0603	0,9267	3
eTS+	0,0252	0,0292	0,0024	0,0048	0,0487	0,0690	0,0175	2

Analisando o erro absoluto médio, o eTS+ apresenta uma vantagem considerável em comparação com os demais métodos, tanto nas etapas de treinamento, como de validação. No caso dos erros MSE e RMSE, os algoritmos eTS e exTS obtiveram um melhor desempenho quando amostras desconhecidas foram aplicadas. Entretanto, essa pequena melhoria está associada a tempos de execução significativamente maiores do que o método adotado neste trabalho. Para simplificar,

5.3. Caso 1: Modelagem dos Padrões de Consumo em Agregados Familiares e Supermercados

o eTS, o Simpl_eTS e o exTS foram respectivamente 66, 40 e 52 vezes mais lentos que o eTS+. Isso demonstra a aplicabilidade do eTS+ em aplicações que exigem processamento em tempo real, onde a velocidade da resposta é crucial para uma tomada de decisão rápida e eficiente. Além disso, a quantidade de regras geradas está diretamente associada à capacidade de aprendizado do sistema. Verifica-se que, assim como o Simpl_eTS, o eTS+ necessitou de apenas duas regras para gerar resultados satisfatórios neste cenário.

5.3.2 Cenário 2: Supermercados com Área Inferior a 400 m²

O segundo cenário é baseado nos dados de perfis de consumo de supermercados, considerando a área ocupada. Assim como no cenário anterior, foram utilizadas 720 amostras, com 70% destinadas ao treinamento e os 30% restantes à fase de teste. Na Figura 23, são apresentados os resultados do treinamento realizado pelo eTS+. Visualmente, é possível perceber uma variação considerável apenas ao final do treinamento, após a amostra 450. Analisando a evolução das regras apresentada na Figura 24, verifica-se que o algoritmo identificou a necessidade de gerar um novo *cluster* por volta desse período. Esse comportamento demonstra a capacidade do eTS+ de identificar até mesmo pequenas variações nos dados observados, adaptando sua estrutura para corresponder a essas mudanças de forma eficaz.

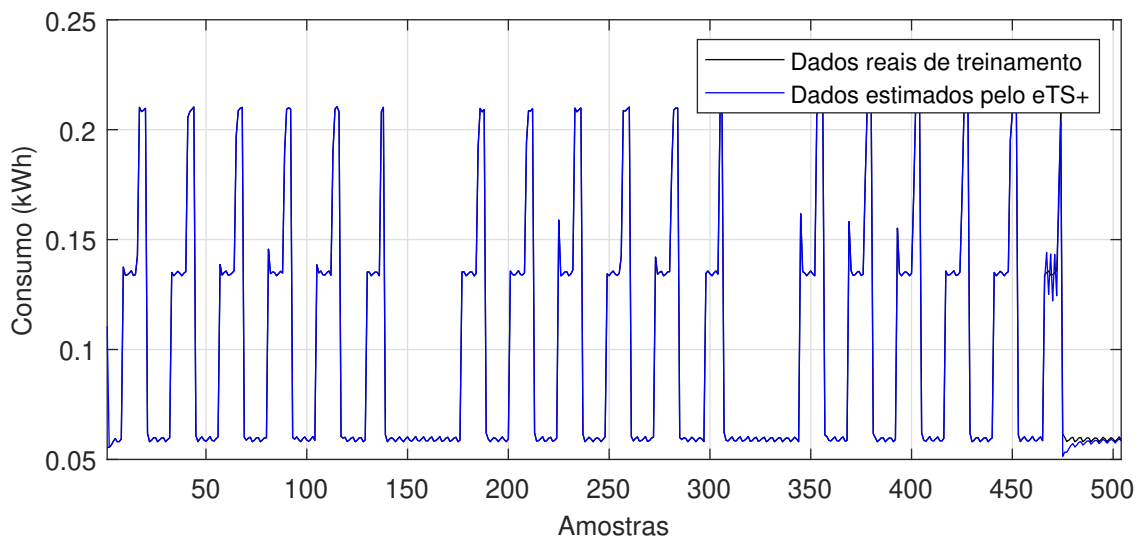


Figura 23 – Treinamento do modelo (Caso 1, Cenário 2)

Essa eficácia pode ser comprovada na Figura 25, onde é apresentada a validação do cenário em estudo. Percebe-se, na Figura 25, que no caso desse cenário, uma única regra *fuzzy* foi capaz de gerar bons resultados também na validação. Isso significa que o *cluster* formado possui grande capacidade de generalização, abrangendo grande parte das novas amostras que chegam a cada

instante. Além disso, de forma semelhante ao primeiro cenário, os resultados de treinamento e validação obtidos pelo eTS+ foram comparados com outras estratégias *fuzzy* evolutivas da literatura. O método utilizado neste trabalho apresentou erros menores em relação ao eTS, o Simpl_eTS e o exTS, perdendo apenas no caso do erro MSE dos dados de validação (Tabela 9).




Figura 24 – Evolução das regras *fuzzy* (Caso 1, Cenário 2)

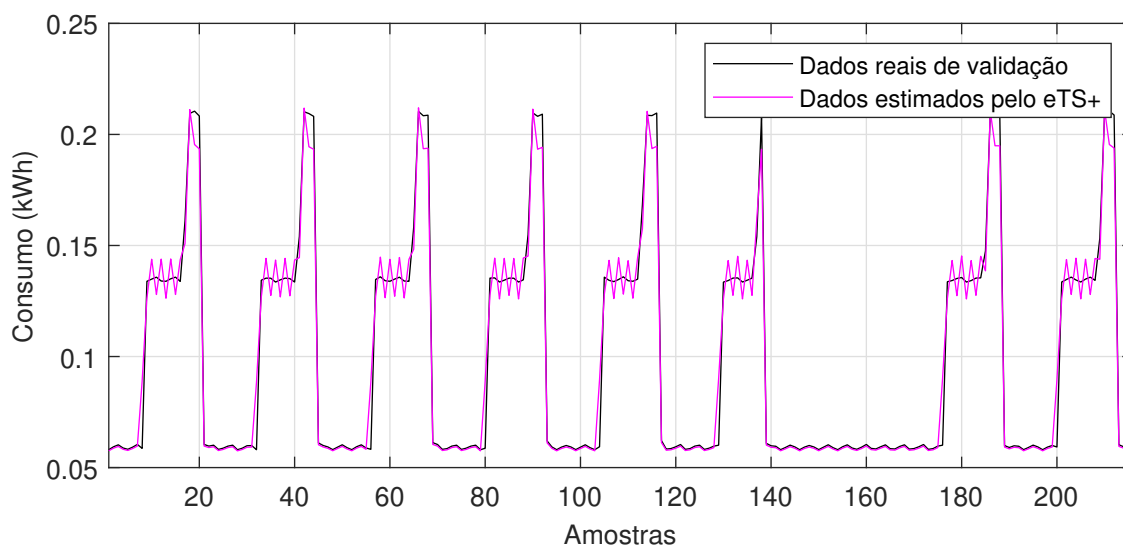


Figura 25 – Validação do modelo (Caso 1, Cenário 2)

Conforme visto anteriormente, um dos principais diferenciais do eTS+ é seu tempo de execução, que novamente foi drasticamente menor que o dos outros métodos (0,0163 segundos), tornando-o mais adequado para aplicações em tempo real. Além disso, apenas uma regra foi gerada, diferentemente das quatro regras dos outros algoritmos, o que indica maior simplicidade do modelo sem comprometer a precisão. Essa combinação de velocidade, simplicidade e boa performance torna o eTS+ uma solução promissora, especialmente em cenários que exigem

5.3. Caso 1: Modelagem dos Padrões de Consumo em Agregados Familiares e Supermercados

respostas rápidas e eficiência computacional.

Tabela 9 – Comparação do eTS+ com outros métodos da literatura (Caso 1, Cenário 2)

Métodos	MAE		MSE		RMSE		Tempo (s)	Regras
	T	V	T	V	T	V		
eTS	0,0052	0,0055	5,8472	6,5981	0,0076	0,0083	0,7875	4
Simpl_eTS	0,0054	0,0057	6,2533	6,9456	0,0079	0,0085	0,8558	4
exTS	0,0054	0,0057	6,1744	6,9060	0,0078	0,0083	1,0157	4
eTS+	0,0026	0,0052	3,4806	7,2141	0,0059	0,0081	0,0163	1

5.3.3 Análise dos Resultados e Comparação entre Cenários

Os resultados obtidos no primeiro caso de estudo demonstram a eficácia do método *Evolving Takagi-Sugeno Plus* na modelagem dos padrões de participação dos indivíduos. No primeiro cenário, referente a um agregado familiar de três pessoas, o eTS+ apresentou uma precisão significativa ao capturar padrões de consumo e ajustar sua estrutura para acomodar variações horárias. A criação automática de *clusters* permitiu a modelagem eficiente dos picos de consumo, como também pode ser observado nas amostras de validação (Figura 22). A metodologia mostrou-se robusta para aplicação em cenários de ajuste de cargas variáveis, resultando em baixos índices de erro, conforme demonstrado na Tabela 8.

No segundo cenário, ao modelar o consumo de supermercados, o método foi igualmente eficaz, embora tenha ocorrido uma ligeira variação na estimativa a partir da amostra 450, conforme indicado na Figura 23. A quantidade de regras *fuzzy* mudou com base nessas variações, a partir da criação de um novo *cluster* e posterior remoção, quando este se tornou desnecessário. Assim como no primeiro cenário, a comparação com outros métodos demonstrou que o eTS+ obteve desempenho superior em termos de velocidade de processamento e menor número de regras, tornando-o uma escolha ideal para aplicações que exigem processamento em tempo real.

A comparação entre os cenários revela que o eTS+ possui alta adaptabilidade, independentemente do tipo de perfil de consumo. Enquanto o agregado familiar apresentou um padrão mais estável de consumo, os supermercados, por sua vez, exibiram maiores picos. Apesar disso, o sistema foi capaz de modelar ambos os cenários de maneira eficiente, ajustando as regras e os *clusters* de forma automática a partir das amostras recebidas a cada instante. As diferenças nos erros de previsão entre os dois cenários são mínimas, o que demonstra a capacidade do método

de lidar com diferentes perfis de consumo sem necessidade de intervenção manual.

Além de índices de erro extremamente baixos em ambos os cenários, o eTS+ se destacou como uma solução mais eficiente em termos de desempenho computacional, sendo 66 vezes mais rápido que o Simpl_eTS e 52 vezes mais rápido que o exTS no primeiro cenário. No segundo cenário, o eTS+ manteve bons resultados com apenas uma regra, demonstrando sua capacidade de generalização a partir de poucas informações disponíveis, mesmo diante de algoritmos criados com foco na simplicidade, como é o caso do Simpl_eTS. Esse desempenho atrelado a baixo custo computacional é particularmente relevante para aplicações que exigem respostas em tempo real, onde a demanda pode flutuar rapidamente. Essas características diferem o método utilizado neste trabalho das demais abordagens presentes na literatura, as quais normalmente não se baseiam em aprendizado incremental, possuem alto custo computacional e necessitam do conhecimento prévio sobre a dinâmica do sistema.

5.4 Caso 2: Detecção de Fraudes em *Demand Response*

Devido à complexidade técnica e à natureza sempre mutável das fraudes, a tarefa de prever futuras manipulações torna-se extremamente desafiadora. Desse modo, o presente trabalho se concentra na detecção de fraudes ocorridas em tempo real, com o intuito de entender os comportamentos associados a essas atividades fraudulentas. Para isso, foi proposto um sistema de inferência *fuzzy* Mamdani que avalia as entradas recebidas e gera estimativas de comportamentos anômalos a partir de uma base de regras *fuzzy*. As entradas deste método são respectivamente os dados de geração e consumo atuais de participação do indivíduo, além do resíduo obtido entre os dados reais de flexibilidade e a estimação gerada pelo modelo *fuzzy* evolutivo. Para demonstrar essa implementação, o presente estudo de caso se utiliza dos *datasets* 2 e 3 da Tabela 7 para criar cenários realistas e demonstrar a aplicabilidade da metodologia desenvolvida.

Dessa forma, neste caso de estudo, é considerado um domicílio residencial localizado em Porto (Portugal), com potência instalada de 6,9 kVA, utilizando energia produzida por painéis fotovoltaicos (autoconsumo) e consumindo da rede elétrica. Mediante um contrato estabelecido com uma entidade coordenadora de *Demand Response*, o cliente concorda em deslocar o uso de cargas elétricas dos períodos de pico para outros horários do mesmo dia ou para a madrugada do dia seguinte. Essa prática resulta na redução do valor final da fatura de eletricidade e contribui para diminuir a demanda de energia nos períodos de maior esforço da rede.

5.4.1 Simulação de Eventos por Deslocamento de Cargas

Inicialmente, é importante definir a tarifa que será paga pelo cliente. Para simplificar o exemplo em questão e torná-lo mais didático, optou-se por uma tarifa bi-horária, pela facilidade em destacar de maneira direta os benefícios de consumir energia em períodos fora dos horários de pico. Nesse contexto, considerando que a empresa Energias de Portugal (EDP) é a responsável pela venda de energia elétrica em Portugal Continental, foram consultados os preços de oferta atualizados no *site* oficial, os quais estão expostos na Tabela 10.

Tabela 10 – Preço da energia com base em tarifa bi-horária diária

Período do dia	Preço (€/kWh)
Fora de vazio (08h00 a 21h45)	0,2431
Vazio (22h00 a 07h45)	0,1480

O deslocamento de cargas proposto neste programa de *Demand Response* se baseia nos aparelhos presentes na residência do participante. Neste exemplo, os eletrodomésticos considerados são: máquina de lavar louça, máquina de lavar roupa, máquina de secar roupa, micro-ondas e chaleira elétrica. A Figura 26 apresenta o consumo desagregado de cada um desses equipamentos ao longo de um dia, onde a amostra 1 representa a hora 00h00 e a amostra 96 corresponde à hora 23h45. Nota-se que grande parte do consumo está concentrada em um intervalo específico: das 12h15 (amostra 50) até aproximadamente 15h30 (amostra 63). A Figura 27 apresenta o consumo total do participante e a proporção que é atribuída aos aparelhos em questão, antes da ocorrência do deslocamento de cargas.




Figura 26 – Consumo desagregado por aparelhos, antes do evento de DR (Caso 2)

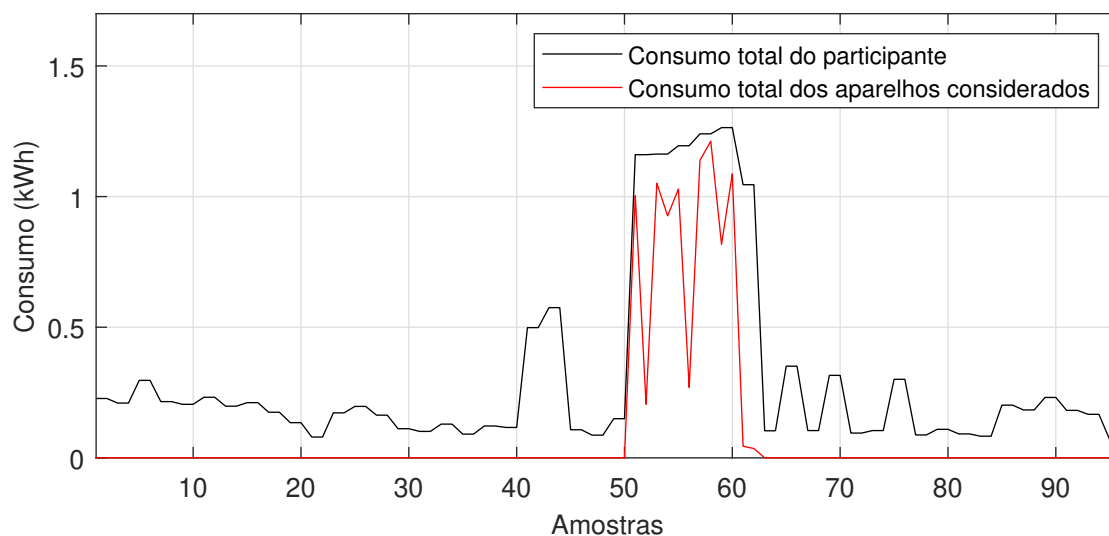


Figura 27 – Consumo total do participante e dos aparelhos, antes do evento de DR (Caso 2)

Com base nas Figuras 26 e 27, fica evidente que o participante está consumindo majoritariamente durante o período de alta tarifa, o que resulta em um custo maior de energia. Com base nisso, procedeu-se ao deslocamento das cargas para horários de baixa tarifa (Figura 28). Para o dia seguinte, foi considerado que o cliente passa a utilizar a máquina de lavar roupa durante o período noturno, após as 22h00. Após a conclusão da lavagem, à meia-noite, as roupas são postas para secar. Além disso, a máquina de lavar louça passa a ser utilizada logo no início da manhã, às 05h30. Enquanto as louças estão sendo lavadas pela máquina, o cliente utiliza o micro-ondas para preparar sua refeição. Percebe-se que essas mudanças não interferem significativamente na rotina do participante e proporcionam benefícios econômicos devido a redução do consumo em horários de pico.

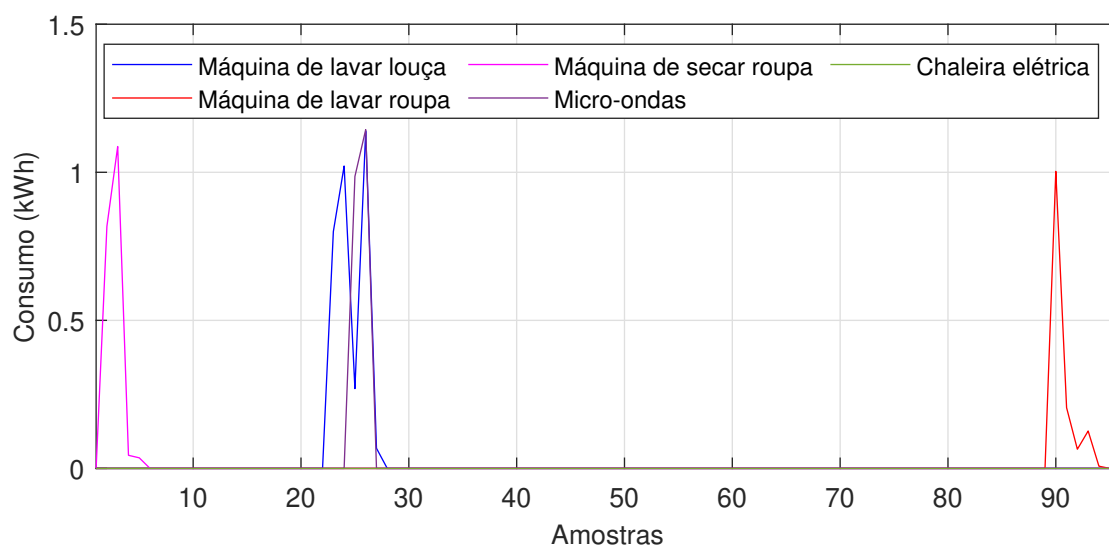


Figura 28 – Consumo desagregado por aparelhos, após o evento de DR (Caso 2)

5.4. Caso 2: Detecção de Fraudes em *Demand Response*

Desse modo, a Figura 29 apresenta o consumo total do participante e o consumo dos aparelhos após o evento *Demand Response*. Nota-se uma redução significativa durante os horários de pico, com um aumento apenas nos períodos fora de pico (antes da amostra 33 e após a amostra 89). Além disso, a redução do custo na fatura de energia foi de 13,02%, sendo que o custo inicial era de 6,44 € e o custo final foi de 5,60 €. Considerando as vantagens desse tipo de abordagem, assume-se que o prosumidor deseja continuar participando do programa de *Demand Response* proposto pela entidade. Portanto, torna-se necessário desenvolver um modelo de participação, o que permitirá uma compreensão mais aprofundada dos hábitos energéticos do indivíduo.

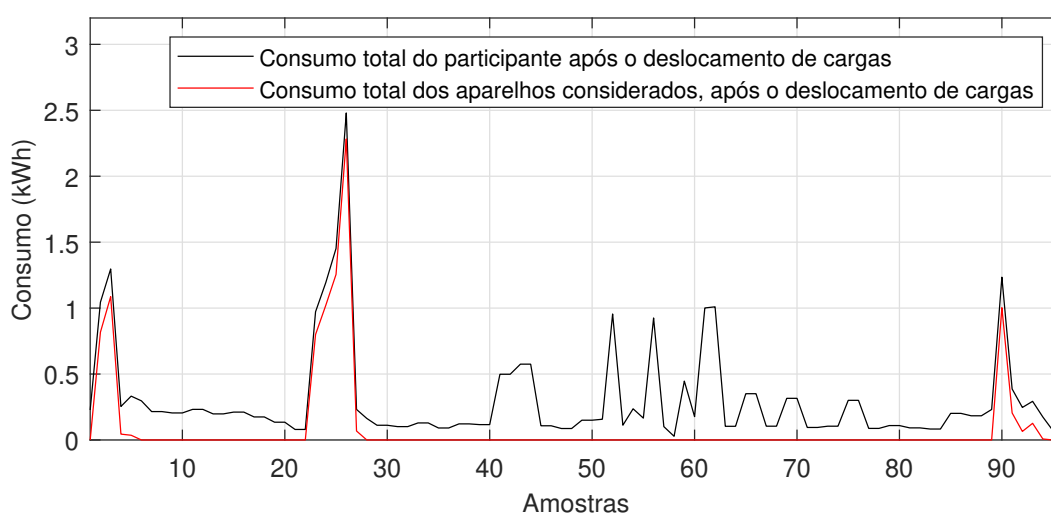


Figura 29 – Consumo total do participante e dos aparelhos, após o evento de DR (Caso 2)

5.4.2 Concepção do Modelo de Participação Ativa do Prosumidor

O objetivo de um modelo de participação ativa é retratar os padrões de envolvimento de um cliente em um programa de gestão energética. Esse engajamento pode ser avaliado com base na flexibilidade fornecida ao sistema durante as solicitações da entidade agregadora, bem como nos dados de consumo durante esses períodos. Quando os dados de flexibilidade estão disponíveis, é mais vantajoso modelar a partir dessa variável, pois ela consiste em uma informação direta e específica sobre a capacidade do cliente de ajustar seu consumo em resposta às demandas do sistema. Desse modo, para criar um modelo eficaz, é crucial analisar quais dados influenciam no comportamento da variável alvo (ou saída do sistema). É evidente que a energia gerada em autoconsumo aumenta o potencial de flexibilidade e os dados históricos de energia consumida permitem identificar horários de pico, sazonalidades e outras tendências características dos dados utilizados, proporcionando um conhecimento aprofundado sobre os padrões esperados.

Dessa forma, nos gráficos (a) e (b) da Figura 30, é possível verificar as entradas aplicadas no eTS+, as quais consistem respectivamente nos dados históricos de geração e consumo do cliente enquanto participa do programa de *Demand Response* proposto na etapa anterior. Do mesmo modo, a Figura 31 apresenta os dados de flexibilidade fornecida ao sistema, caracterizando a saída observada pelo algoritmo evolutivo. As amostras de treinamento correspondem a dados reais extraídos do *dataset* mencionado na terceira linha da Tabela 7, cujo período considerado foi de seis dias, com registros realizados a cada 15 minutos, totalizando 576 pontos.

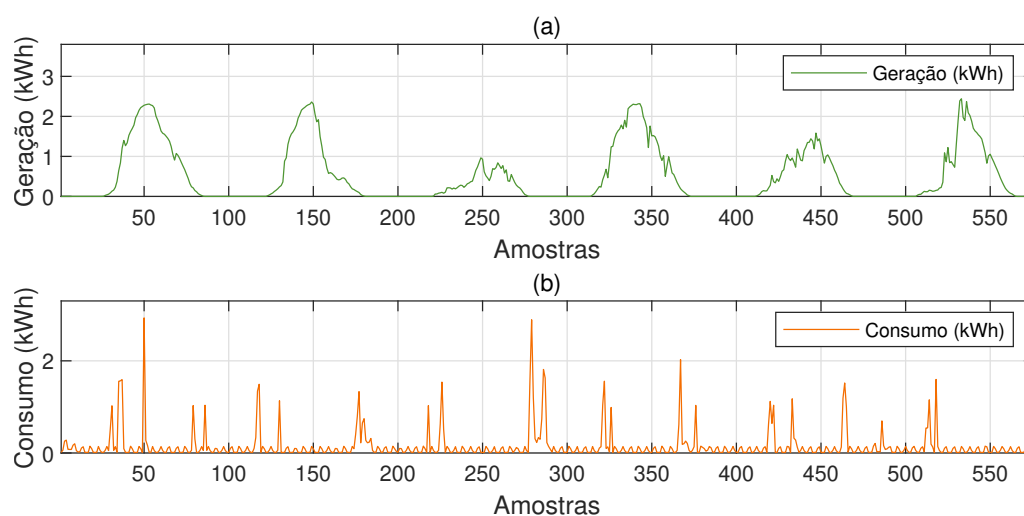


Figura 30 – Dados de geração e consumo utilizados como entrada do algoritmo (Caso 2)




Figura 31 – Dados de flexibilidade utilizados como saída do algoritmo (Caso 2)

Vale ressaltar que o modelo foi treinado com um número reduzido de amostras devido à dificuldade de encontrar dados reais e confiáveis de flexibilidade em períodos mais longos. Apesar da limitação no número de amostras, a eficácia do algoritmo não é comprometida. Uma única amostra é suficiente para iniciar o treinamento do modelo, enquanto as amostras subsequen-

5.4. Caso 2: Detecção de Fraudes em *Demand Response*

tes são utilizadas para ajustar e refinar a base de regras, adaptando-se às dinâmicas dos novos dados conforme necessário. Este processo de ajuste contínuo permite que o modelo mantenha sua precisão e relevância, mesmo com um conjunto de dados limitado.

Diante disso, a Figura 32 apresenta a comparação entre os dados reais de flexibilidade do cliente e os dados estimados pelo eTS+ durante a fase de treinamento. Verifica-se que o resultado obtido possui um desempenho geral satisfatório, apresentando dificuldades apenas durante picos nos dados observados. A característica evolutiva da metodologia em estudo pode ser comprovada pela Figura 33, onde é apresentada a quantidade de regras *fuzzy* em cada instante. Considerando que o eTS+ inicia com apenas uma regra, é perceptível um aumento localizado no início do treinamento; além disso, uma exclusão ocorreu na amostra 56 devido à sobreposição de *clusters*.

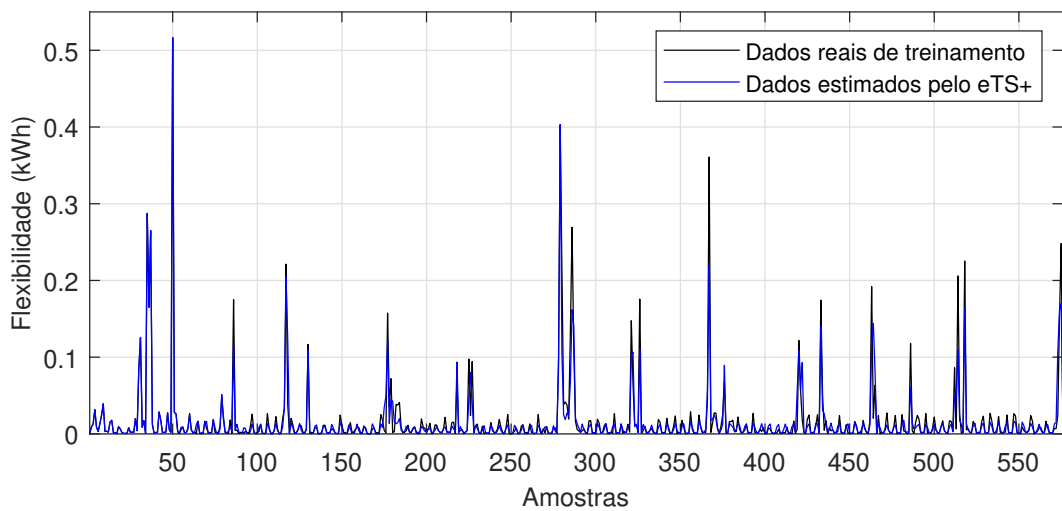


Figura 32 – Modelo de participação ativa gerado pelo eTS+ (Caso 2)




Figura 33 – Evolução das regras *fuzzy* (Caso 2)

Uma vez que o modelo de participação ativa foi construído, as subseções seguintes são dedicadas

a apresentar sua utilização em conjunto com o sistema *fuzzy* Mamdani proposto para detecção de fraudes. Inicialmente, será demonstrado um cenário ideal onde não há manipulação dos dados, permitindo observar o comportamento normal do sistema e validar a precisão das estimativas fornecidas pelo modelo. Posteriormente, será explorado um cenário onde ocorrem manipulações intencionais nos dados de flexibilidade, simulando tentativas de fraude. Esses cenários visam realizar comparações e testar a robustez e interpretabilidade do sistema *fuzzy* Mamdani na identificação de discrepâncias significativas entre os padrões esperados e os dados fornecidos.

5.4.3 Cenário 1: Caracterização do Sistema em Operação Normal

De forma geral, um modelo de participação ativa deve ser capaz de inferir os padrões de participação do indivíduo a partir da inserção de entradas desconhecidas. No presente trabalho, essa inferência pode ser realizada pela validação do algoritmo *fuzzy* evolutivo proposto na metodologia, com base nos dados históricos de geração e consumo. Sabendo que o modelo foi construído a partir de dados de seis dias anteriores, considera-se que a entidade deseja conhecer a flexibilidade desse participante para o dia corrente. Dado que o objetivo deste cenário é demonstrar o comportamento normal do sistema, a Figura 34 (a) apresenta os dados verdadeiros de geração, enquanto a Figura 34 (b) exibe os dados verdadeiros de consumo. Ambos os dados, não manipulados, foram aplicados no eTS+ para gerar a estimativa de flexibilidade.




Figura 34 – Dados não manipulados de geração e consumo (Caso 2)

Na Figura 35, é possível verificar a comparação entre os valores reais de flexibilidade do indivíduo (em preto) e a estimativa gerada pelo eTS+ (em rosa). Observa-se que o modelo conseguiu capturar a dinâmica dos dados históricos utilizados durante o treinamento, oferecendo uma esti-

5.4. Caso 2: Detecção de Fraudes em *Demand Response*

mativa satisfatória da flexibilidade a partir da aplicação dos dados atuais de geração e consumo. A inserção de entradas desconhecidas pode gerar indicativos de fraudes, pois se os novos dados forem significativamente diferentes dos dados de treinamento (ou seja, se o padrão de consumo e geração do cliente variar muito), o resultado obtido terá grandes índices de erro. Nesta dissertação, este índice pode ser avaliado por meio de uma métrica de erro RMSE, o qual foi normalizado para se adequar à entrada exigida no sistema Mamdani.




Figura 35 – Validação do modelo utilizando novos dados de um dia (Caso 2)




Figura 36 – Grau de alerta obtido durante operação normal (Caso 2)

A resposta gerada pelo detector de fraudes *fuzzy* Mamdani no cenário de operação normal pode ser vista na Figura 36. Observa-se que nos locais onde o resíduo calculado é baixo, o indicativo de fraude varia em torno de 10% a 35%. Isso ocorre devido ao impacto das regras associadas ao conjunto “Resíduo” na obtenção da saída do sistema. Além disso, na amostra 49 da Figura 36, o grau de alerta é de 50%. Isso foi resultado de um resíduo consideravelmente maior que o

esperado na Figura 35, derivado de incertezas durante a modelagem. Entretanto, por meio da análise do comportamento apresentado pelo sistema Mamdani em diversos testes, foi definido um limiar de fraude, com o intuito de evitar alertas falsos positivos. Desse modo, determinou-se que a entidade responsável deve ser avisada somente para graus de alerta acima de 50%, garantindo que o sistema desenvolvido mantenha o equilíbrio entre sensibilidade e precisão.

5.4.4 Cenário 2: Detecção de Manipulação em Dados de Flexibilidade

O presente cenário visa demonstrar a aplicabilidade do método desenvolvido a partir da simulação de fraudes nos dados reais de flexibilidade. A escolha dessa variável se deve à sua relevância nos programas de participação ativa de usuários finais, onde a integridade das informações obtidas dos prosumidores é crucial para assegurar a operação correta e eficaz do sistema. Desse modo, a Figura 37 apresenta uma fraude pontual realizada pelo participante, caracterizada pela substituição dos dados verdadeiros (em preto) pelos dados falsos (em vermelho). Os dados fraudulentos foram obtidos a partir da Equação 38, sendo que a constante β foi definida como 20, com o intuito de reproduzir os picos de flexibilidade observados nos dados reais.




Figura 37 – Fraude pontual aplicada na flexibilidade e validação do modelo (Caso 2)

Além disso, a Figura 37 apresenta uma comparação entre os dados reais de flexibilidade e a estimativa gerada pelo eTS+. É importante destacar que, assim como no cenário anterior, os dados de geração e consumo não foram manipulados pelo participante, consistindo nos mesmos observados na Figura 34. Dessa forma, ao serem utilizados como entrada do modelo evolutivo treinado, este gera uma estimativa da flexibilidade real esperada para cada par de amostras de geração e consumo. Percebe-se visualmente, na Figura 37, que a utilização dessa técnica auxilia

5.4. Caso 2: Detecção de Fraudes em *Demand Response*

na detecção de fraudes em dados de flexibilidade, uma vez que o modelo foi treinado com base em dados históricos do participante e é capaz de gerar uma estimativa que corresponde à flexibilidade obtida em um cenário sem manipulações. Entretanto, isso não ocorre, gerando uma discrepância considerável entre a estimativa resultante e os dados manipulados.




Figura 38 – Grau de alerta para detecção de fraude pontual (Caso 2)

Esse resíduo é inserido diretamente no detector de fraudes *fuzzy* Mamdani, assim como os dados de geração e consumo. Em seguida, o sistema avalia cada conjunto de entradas e gera uma estimativa do grau de alerta para cada instante (Figura 38). Percebe-se que o resultado obtido foi satisfatório, uma vez que a fraude pode ser facilmente identificada pela intensidade do grau de alerta. O valor resultante foi de 92%, superando significativamente o limiar definido e demonstrando a necessidade de envio das informações para a entidade responsável, com o intuito de garantir a integridade contínua do sistema de participação ativa.




Figura 39 – Fraude de menor intensidade e validação do modelo (Caso 2)

O sistema desenvolvido também é capaz de indicar a existência de fraudes de menor intensidade e que se prolongam por um grande período de tempo. Ao realizar manipulações menores de forma frequente, o agente fraudador se aproveita do fato de que pequenas discrepâncias são menos suspeitas e mais fáceis de justificar. Com base nisso, a Figura 39 apresenta a fraude realizada pelo participante, a qual foi obtida por meio da Equação 38, sendo que β é igual a 4. Assim como no estudo anterior, percebe-se que o método evolutivo gera uma resposta de flexibilidade equivalente aos dados não fraudulentos de geração e consumo aplicados na entrada.




Figura 40 – Grau de alerta para detecção de fraude de menor intensidade (Caso 2)

Consequentemente, a diferença entre a estimação produzida (em rosa) e os dados fraudulentos de flexibilidade geram um índice de erro RMSE, que é normalizado antes de ser utilizado no sistema Mamdani. Além dessa entrada, os dados de geração e consumo também são aplicados, ocasionando na estimativa do grau de alerta da Figura 40. Verifica-se que o limiar definido foi ultrapassado no início do dia (característica que se prolonga nas amostras posteriores), indicando a necessidade de envio das informações para a entidade. Ademais, em virtude da característica mutável das fraudes, uma vez que o sistema Mamdani gera um pico de alerta (como o exposto na amostra 10), é importante analisar o comportamento do prosumidor ao redor desse indicativo.

5.4.5 Análise dos Resultados e Comparação entre Cenários

O segundo caso de estudo teve como objetivo demonstrar a aplicação do sistema *fuzzy* Mamdani para detecção de fraudes em um programa de *Demand Response*. No primeiro cenário, o sistema operou em condições normais, sem fraudes, e obteve uma resposta de grau de alerta em níveis baixos, indicando um comportamento adequado e sem anomalias. Isso foi importante

5.4. Caso 2: Detecção de Fraudes em *Demand Response*

para definir o limiar de fraude, visando minimizar o risco de identificar erroneamente situações normais como fraudulentas. No segundo cenário, onde houve a simulação de fraudes nos dados de flexibilidade, o sistema *fuzzy* Mamdani foi capaz de identificar discrepâncias significativas entre os dados reais e os manipulados. A substituição dos dados verdadeiros pelos falsos resultou em um grau de alerta de 92%, bem acima do limiar de 50% estabelecido para disparar um alarme.

A comparação entre os cenários revela que o sistema é capaz de detectar tanto fraudes pontuais, quanto fraudes de menor intensidade que se prolongam durante grandes períodos de tempo. Essas manipulações sutis, realizadas repetidamente, podem passar despercebidas por sistemas tradicionais, mas o método proposto conseguiu identificá-las com base nos dados históricos e na evolução dos padrões de flexibilidade. A validação contínua do modelo garante que o sistema seja capaz de se adaptar a fraudes que evoluem gradualmente, aumentando a eficácia na detecção de atividades anômalas.

Em termos de aplicabilidade, o sistema *fuzzy* Mamdani desenvolvido, em conjunto com o modelo evolutivo eTS+, demonstrou-se eficaz na detecção de fraudes no programa de *Demand Response*. De forma geral, a metodologia proposta destaca-se por sua versatilidade, podendo ser adaptada a diversos programas de participação ativa, incluindo aqueles baseados em *Transactive Energy* e *Peer to Peer*, os quais foram cuidadosamente fundamentados neste trabalho. Conforme discutido anteriormente, o sistema Mamdani é personalizável, dado que pode ser configurado de acordo com as características específicas de cada programa, enquanto o modelo evolutivo é capaz de alterar sua estrutura dinamicamente em resposta à interação de cada participante. Além disso, a robustez do modelo o torna apto para operação em tempo real, viabilizando seu uso em cenários onde uma resposta ágil é crucial. Em resumo, a implementação da metodologia *fuzzy* híbrida proposta assegura a detecção precisa de fraudes, tanto pontuais quanto persistentes, mesmo em cenários onde as manipulações ocorrem de forma gradual e são difíceis de identificar por métodos tradicionais. Dessa forma, o presente trabalho apresenta uma solução inovadora para o problema de injeção de dados falsos em programas de participação ativa de usuários finais de energia, auxiliando as entidades gestoras na manutenção da estabilidade, segurança e confiança entre os participantes.

6 Considerações Finais

Este capítulo é destinado a apresentar as conclusões do trabalho desenvolvido, explicando os principais objetivos alcançados e algumas perspectivas de trabalhos futuros.

6.1 Conclusões

Nesta dissertação, uma metodologia *fuzzy* híbrida foi proposta para modelagem dos padrões de envolvimento dos indivíduos e detecção de fraudes em programas de participação ativa de usuários finais de energia. A combinação de um método evolutivo baseado em dados e um sistema *fuzzy* Mamdani resulta em uma técnica robusta e altamente interpretável. Essa abordagem permite não apenas capturar a complexidade dos padrões de comportamento dos usuários, mas também oferece uma forma eficaz de identificar anomalias que podem indicar fraudes.

O método *Evolving Takagi-Sugeno Plus* é capaz de aprender e ajustar sua estrutura continuamente com base nas amostras recebidas, resultando em uma redução significativa dos erros de previsão e eliminando a necessidade de intervenção manual por parte de especialistas. A eficácia do eTS+ pode ser comprovada pelos resultados competitivos apresentados neste trabalho, que foram comparados com outras técnicas amplamente utilizadas na literatura. Além das métricas de erro, também foram analisados os tempos de execução e a quantidade final de regras, com o objetivo de realizar uma análise detalhada do custo computacional. Em todos os testes realizados, o eTS+ demonstrou tempos de execução excessivamente mais baixos do que os demais métodos, com valores em torno de um centésimo de segundo.

Além disso, o sistema *fuzzy* Mamdani foi aplicado na detecção de comportamentos anômalos

em dados de flexibilidade, resultando em um grau indicativo de manipulação. Inicialmente, o método foi aplicado em um cenário livre de manipulações, revelando baixos índices de alerta para esse caso. Ademais, por meio do aumento da flexibilidade ofertada pelo prosumidor, foram simulados dois tipos de fraudes, com o intuito de avaliar a resposta produzida pelo sistema Mamdani em diferentes situações. Os resultados obtidos demonstraram a eficácia da inferência realizada, por meio da indicação de picos de alerta nas amostras manipuladas. Dessa forma, conclui-se que o objetivo geral desta dissertação está alinhado com os objetivos das organizações gestoras dos programas de participação ativa de usuários finais de energia, visando garantir segurança, eficiência e transparência, por meio da implementação de um mecanismo robusto e eficaz de detecção de fraudes. Para cumprimento dessas metas, definiu-se uma sequência de objetivos específicos, os quais foram rigorosamente cumpridos, conforme exposto a seguir.

O primeiro objetivo específico consistiu no levantamento da base bibliográfica e na revisão sistemática do estado da arte. Essa etapa, descrita nos capítulos 2 e 3, foi crucial para identificar as principais abordagens e metodologias já existentes, abrangendo estudos sobre *Smart Grids*, programas de *Demand Response*, *Transactive Energy*, *Peer to Peer* e os fundamentos de Sistemas *Fuzzy* e Métodos Evolutivos. Essa revisão permitiu compreender as lacunas e limitações das soluções atuais, justificando a escolha pela abordagem *fuzzy* híbrida proposta neste trabalho, que combina a robustez de um modelo evolutivo com a interpretabilidade de um sistema *fuzzy* Mamdani baseado em conhecimento.

O segundo objetivo foi o desenvolvimento e implementação de modelos de previsão de participação a partir de dados comuns, como geração e consumo de energia. Para isso, foi utilizado o algoritmo eTS+, uma abordagem evolutiva que se ajusta continuamente com base nas amostras recebidas, sem necessidade de intervenção manual. Esse modelo foi capaz de prever de forma precisa os padrões de participação, adaptando-se dinamicamente às variações dos dados de entrada e resultando em uma redução significativa dos erros de treinamento. A implementação foi realizada em linguagem *MATLAB*, seguindo uma revisão sistemática das referências oficiais. Todo o procedimento de implementação e as especificidades do modelo estão detalhados na subseção 4.2.

O terceiro objetivo foi o planejamento e implementação de um método de detecção de fraudes, com foco na facilidade de validação por especialistas. O sistema foi desenvolvido com o auxílio da *Toolbox* de Lógica *Fuzzy* do *MATLAB* e todo o procedimento está descrito na subseção 4.3.2. Este foi utilizado para detectar fraudes com base em dados de geração e consumo e nos resíduos

gerados entre os dados reais e as previsões do modelo evolutivo. O sistema demonstrou sua capacidade de diferenciar casos em que não ocorreram manipulações, gerando grandes indicativos apenas quando uma fraude foi aplicada.

Por fim, a realização do último objetivo específico pode ser vista no capítulo 5, o qual consistiu na aplicação da metodologia em casos de estudo reais, na análise dos resultados e na comparação com outras estratégias da literatura. Foram conduzidos dois estudos de caso: no primeiro, modelos de participação ativa foram concebidos a partir do eTS+, utilizando-se de dados de consumo de agregados familiares e supermercados. No segundo caso, o sistema Mamdani proposto foi utilizado para detectar fraudes em um cenário com fraude em dados de flexibilidade. Além disso, o sistema também foi aplicado em um cenário de operação normal, demonstrando que a sensibilidade do método foi corretamente ajustada, evitando assim a ocorrência de falsos positivos. Em ambos os casos, a metodologia *fuzzy* híbrida desenvolvida demonstrou uma performance superior aos métodos tradicionais, apresentando ótimos resultados de métricas de erro, custo computacional e interpretabilidade em situações de fraude.

6.2 Propostas de Trabalhos Futuros

Os resultados obtidos durante o desenvolvimento desta dissertação proporcionam uma base sólida para novas investigações e trabalhos futuros. Dentre as principais propostas, destacam-se:

- Aprimorar o modelo de previsão a partir da análise aprofundada das séries temporais de geração e consumo. Por exemplo, o estudo da sazonalidade permite capturar variações periódicas que ocorrem em intervalos regulares, como mudanças na produção de energia solar ao longo das estações do ano ou picos de consumo durante períodos de clima extremo.
- Implementar o algoritmo *fuzzy* evolutivo e o detector de fraudes *fuzzy* Mamdani em linguagem *Python*, para execução em tempo real em um sistema embarcado (como *Raspberry Pi*), permitindo a análise contínua dos dados coletados diretamente de medidores inteligentes.
- Utilizar métodos de otimização global (como algoritmos genéticos e enxame de partículas) para ajuste automático dos parâmetros antecedentes e consequentes do sistema Mamdani, com base em dados históricos de entrada e saída.
- Analisar a viabilidade de aplicar métodos *fuzzy* ou *neuro-fuzzy* mais recentes na fase de modelagem e previsão.

Referências Bibliográficas

- Abdulsalam, K. A., Adebisi, J., Emezirinwune, M. & Babatunde, O. (2023), 'An overview and multi-criteria analysis of communication technologies for smart grid applications', *e-Prime-Advances in Electrical Engineering, Electronics and Energy* **3**, 100121.
- Abedrabboh, K. & Al-Fagih, L. (2023), 'Applications of mechanism design in market-based demand-side management: A review', *Renewable and Sustainable Energy Reviews* **171**, 113016.
- Abrahamsen, F. E., Ai, Y. & Cheffena, M. (2021), 'Communication technologies for smart grid: A comprehensive survey', *Sensors* **21**(23), 8087.
- Ahmadzadeh, S., Parr, G. & Zhao, W. (2021), 'A review on communication aspects of demand response management for future 5g iot-based smart grids', *IEEE Access* **9**, 77555–77571.
- Ajiboye, P. O., Agyekum, K. O.-B. O. & Frimpong, E. A. (2024), 'Privacy and security of advanced metering infrastructure (ami) data and network: a comprehensive review', *Journal of Engineering and Applied Science* **71**(1), 91.
- Amin, A., Tareen, W. U. K., Usman, M., Ali, H., Bari, I., Horan, B., Mekhilef, S., Asif, M., Ahmed, S. & Mahmood, A. (2020), 'A review of optimal charging strategy for electric vehicles under dynamic pricing schemes in the distribution charging network', *Sustainability* **12**(23), 10160.
- Angelov, P. (2004b), 'An approach for fuzzy rule-base adaptation using on-line clustering', *International Journal of Approximate Reasoning* **35**(3), 275–289.
- Angelov, P. (2013), *Autonomous learning systems: from data streams to knowledge in real-time*, John Wiley & Sons.
- Angelov, P., Filev, D. P. & Kasabov, N. (2010), *Evolving intelligent systems: methodology and applications*, John Wiley & Sons.
- Angelov, P., Victor, J., Dourado, A. & Filev, D. (2004a), 'On-line evolution of takagi-sugeno fuzzy models', *IFAC Proceedings Volumes* **37**(16), 67–72.
- Angelov, P. & Zhou, X. (2006), Evolving fuzzy systems from data streams in real-time, in '2006 International symposium on evolving fuzzy systems', IEEE, pp. 29–35.
- Azim, M. I., Tushar, W., Saha, T. K., Yuen, C. & Smith, D. (2022), 'Peer-to-peer kilowatt and negawatt trading: A review of challenges and recent advances in distribution networks', *Renewable and Sustainable Energy Reviews* **169**, 112908.
- Azuatalam, D., Lee, W.-L., de Nijs, F. & Liebman, A. (2020), 'Reinforcement learning for whole-building hvac control and demand response', *Energy and AI* **2**, 100020.
- Babuška, R. (2012), *Fuzzy modeling for control*, Vol. 12, Springer Science & Business Media.
- Baruah, R. D. & Angelov, P. (2011), 'Evolving fuzzy systems for data streams: a survey', *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* **1**(6), 461–476.

- Boopathy, P., Liyanage, M., Deepa, N., Velavali, M., Reddy, S., Maddikunta, P. K. R., Khare, N., Gadekallu, T. R., Hwang, W.-J. & Pham, Q.-V. (2024), 'Deep learning for intelligent demand response and smart grids: A comprehensive survey', *Computer Science Review* **51**, 100617.
- Bukar, A. L., Hamza, M. F., Ayup, S., Abobaker, A. K., Modu, B., Mohseni, S., Brent, A. C., Ogbonaya, C., Mustapha, K. & Idakwo, H. O. (2023), 'Peer-to-peer electricity trading: A systematic review on currents development and perspectives', *Renewable Energy Focus* .
- Castro, J. L. (1995), 'Fuzzy logic controllers are universal approximators', *IEEE transactions on systems, man, and cybernetics* **25**(4), 629–635.
- Chen, Z., Amani, A. M., Yu, X. & Jalili, M. (2023), 'Control and optimisation of power grids using smart meter data: A review', *Sensors* **23**(4), 2118.
- Chodakowska, E., Nazarko, J., Nazarko, Ł. & Rabayah, H. S. (2024), 'Solar radiation forecasting: A systematic meta-review of current methods and emerging trends', *Energies* **17**(13), 3156.
- Cifuentes-Faura, J. (2022), 'European union policies and their role in combating climate change over the years', *Air Quality, Atmosphere & Health* **15**(8), 1333–1340.
- Costa, E. B. M. (2016), Controle PID fuzzy adaptativo com estabilidade robusta por enxame de partículas multiobjetivo, Dissertação de mestrado, Universidade Federal do Maranhão, <http://tedebc.ufma.br:8080/jspui/handle/tede/303>.
- Das, S. K., Das, S. P., Dey, N. & Hassaniien, A. E. (2021), *Machine learning algorithms for industrial applications*, Springer.
- Dasgupta, R., Sakzad, A. & Rudolph, C. (2021), 'Cyber attacks in transactive energy market-based microgrid systems', *Energies* **14**(4), 1137.
- Davarzani, S., Pisica, I., Taylor, G. A. & Munisami, K. J. (2021), 'Residential demand response strategies and applications in active distribution network management', *Renewable and Sustainable Energy Reviews* **138**, 110567.
- de Lima, T. D., Lezama, F., Soares, J., Franco, J. F. & Vale, Z. (2024), 'Modern distribution system expansion planning considering new market designs: Review and future directions', *Renewable and Sustainable Energy Reviews* **202**, 114709.
- Dewangan, F., Abdelaziz, A. Y. & Biswal, M. (2023), 'Load forecasting models in smart grid using smart meter information: A review', *Energies* **16**(3), 1404.
- Dileep, G. (2020), 'A survey on smart grid technologies and applications', *Renewable energy* **146**, 2589–2625.
- D'Ettoire, F., Banaei, M., Ebrahimi, R., Pourmousavi, S. A., Blomgren, E., Kowalski, J., Bohdanowicz, Z., Łopaciuk-Gonczaryk, B., Biele, C. & Madsen, H. (2022), 'Exploiting demand-side flexibility: State-of-the-art, open issues and social perspective', *Renewable and Sustainable Energy Reviews* **165**, 112605.
- Elma, O., Kuzlu, M. & Pipattanasomporn, M. (2022), 'A smart direct load control approach using dynamic voltage control for demand response programs', *Electric Power Components and Systems* pp. 1–13.
- Faia, R., Lezama, F., Soares, J., Pinto, T. & Vale, Z. (2024), 'Local electricity markets: A review on

- benefits, barriers, current trends and future perspectives', *Renewable and Sustainable Energy Reviews* **190**, 114006.
- Falzon, J., Gonzi, R. D., Grima, S. & Vella, E. (2024), 'Energy performance of buildings for incentivisation in energy-efficient structures: an analysis of secondary data in malta', *Processes* **12**(5), 874.
- Freire-Barceló, T., Martín-Martínez, F. & Sánchez-Miralles, Á. (2022), 'A literature review of explicit demand flexibility providing energy services', *Electric Power Systems Research* **209**, 107953.
- Frilingou, N., Xexakis, G., Koasidis, K., Nikas, A., Campagnolo, L., Delpiazzo, E., Chiodi, A., Gargiulo, M., McWilliams, B., Koutsellis, T. et al. (2023), 'Navigating through an energy crisis: Challenges and progress towards electricity decarbonisation, reliability, and affordability in italy', *Energy Research & Social Science* **96**, 102934.
- Goncalves, C., Barreto, R., Faria, P., Gomes, L. & Vale, Z. (2022), 'Dataset of an energy community's generation and consumption with appliance allocation', *Data in Brief* **45**, 108590.
- González, D. M. L. & Rendon, J. G. (2022), 'Opportunities and challenges of mainstreaming distributed energy resources towards the transition to more efficient and resilient energy markets', *Renewable and Sustainable Energy Reviews* **157**, 112018.
- Gu, X., Han, J., Shen, Q. & Angelov, P. P. (2023), 'Autonomous learning for fuzzy systems: a review', *Artificial Intelligence Review* **56**(8), 7549–7595.
- Guelpa, E. & Verda, V. (2021), 'Demand response and other demand side management techniques for district heating: A review', *Energy* **219**, 119440.
- Gährs, S., Deisböck, A., Cremer, N. & Cremerius, P. (2020), 'Regional flexibility in households and supermarkets'.
URL: <https://doi.org/10.5281/zenodo.4568663>
- Haq, E. U., Pei, C., Zhang, R., Jianjun, H. & Ahmad, F. (2023), 'Electricity-theft detection for smart grid security using smart meter data: A deep-cnn based approach', *Energy Reports* **9**, 634–643.
- Hassija, V., Chamola, V., Mahapatra, A., Singal, A., Goel, D., Huang, K., Scardapane, S., Spinelli, I., Mahmud, M. & Hussain, A. (2024), 'Interpreting black-box models: a review on explainable artificial intelligence', *Cognitive Computation* **16**(1), 45–74.
- Huang, Q., Amin, W., Umer, K., Gooi, H. B., Eddy, F. Y. S., Afzal, M., Shahzadi, M., Khan, A. A. & Ahmad, S. A. (2021), 'A review of transactive energy systems: Concept and implementation', *Energy Reports* **7**, 7804–7824.
- Inayat, U., Zia, M. F., Mahmood, S., Berghout, T. & Benbouzid, M. (2022), 'Cybersecurity enhancement of smart grid: Attacks, methods, and prospects', *Electronics* **11**(23), 3854.
- Iqbal, S., Sarfraz, M., Ayyub, M., Tariq, M., Chakraborty, R. K., Ryan, M. J. & Alamri, B. (2021), 'A comprehensive review on residential demand side management strategies in smart grid environment', *Sustainability* **13**(13), 7170.
- Jaramillo, A. F. M., Laverty, D. M., Morrow, D. J., del Rincon, J. M. & Foley, A. M. (2021), 'Load modelling and non-intrusive load monitoring to integrate distributed energy resources in low and medium voltage networks', *Renewable Energy* **179**, 445–466.

- Kanakadhurga, D. & Prabakaran, N. (2022), 'Demand side management in microgrid: A critical review of key issues and recent trends', *Renewable and Sustainable Energy Reviews* **156**, 111915.
- Khojasteh, M., Faria, P., Gomes, L. & Vale, Z. (2024), 'Energy trading strategy of community shared energy storage', *Electrical Engineering* **106**(3), 3415–3426.
- Kiptoo, M. K., Lotfy, M. E., Adewuyi, O. B., Conteh, A., Howlader, A. M. & Senjyu, T. (2020), 'Integrated approach for optimal techno-economic planning for high renewable energy-based isolated microgrid considering cost of energy storage and demand response strategies', *Energy Conversion and Management* **215**, 112917.
- Klir, G. & Yuan, B. (1995), *Fuzzy sets and fuzzy logic*, Vol. 4, Prentice hall New Jersey.
- Kulkarni, A. J. & Satapathy, S. C. (2020), *Optimization in machine learning and applications*, Springer.
- Kuzemko, C., Blondeel, M., Dupont, C. & Brisbois, M. C. (2022), 'Russia's war on ukraine, european energy policy responses & implications for sustainable transformations', *Energy Research & Social Science* **93**, 102842.
- Lezama, F., Soares, J., Canizes, B. & Vale, Z. (2020), 'Flexibility management model of home appliances to support dso requests in smart grids', *Sustainable Cities and Society* **55**, 102048.
- Li, S., Lian, J., Conejo, A. J. & Zhang, W. (2020), 'Transactive energy systems: The market-based coordination of distributed energy resources', *IEEE Control Systems Magazine* **40**(4), 26–52.
- Li, Y., O'Neill, Z., Zhang, L., Chen, J., Im, P. & DeGraw, J. (2021), 'Grey-box modeling and application for building energy simulations-a critical review', *Renewable and Sustainable Energy Reviews* **146**, 111174.
- Lughofer, E. (2011), *Evolving fuzzy systems-methodologies, advanced concepts and applications*, Vol. 53, Springer.
- Mamdani, E. H. (1974), 'Application of fuzzy algorithms for control of simple dynamic plant', **121**(12), 1585–1588.
- Mohammadi, S., Eliassen, F., Zhang, Y. & Jacobsen, H.-A. (2021), 'Detecting false data injection attacks in peer to peer energy trading using machine learning', *IEEE Transactions on Dependable and Secure Computing* **19**(5), 3417–3431.
- Mohanty, S., Panda, S., Parida, S. M., Rout, P. K., Sahu, B. K., Bajaj, M., Zawbaa, H. M., Kumar, N. M. & Kamel, S. (2022), 'Demand side management of electric vehicles in smart grids: A survey on strategies, challenges, modelling, modeling, and optimization', *Energy Reports* **8**, 12466–12490.
- Mohapatra, H. & Rath, A. K. (2021), 'A fault tolerant routing scheme for advanced metering infrastructure: an approach towards smart grid', *Cluster computing* **24**(3), 2193–2211.
- Mota, B., Faria, P. & Vale, Z. (2024), 'Energy cost optimization through load shifting in a photovoltaic energy-sharing household community', *Renewable Energy* **221**, 119812.
- Nawaz, A., Zhou, M., Wu, J. & Long, C. (2022), 'A comprehensive review on energy management, demand response, and coordination schemes utilization in multi-microgrids network', *Applied Energy* **323**, 119596.

- Nizami, S., Tushar, W., Hossain, M., Yuen, C., Saha, T. & Poor, H. V. (2022), 'Transactive energy for low voltage residential networks: A review', *Applied Energy* **323**, 119556.
- Panda, S., Mohanty, S., Rout, P. K., Sahu, B. K., Bajaj, M., Zawbaa, H. M. & Kamel, S. (2022), 'Residential demand side management model, optimization and future perspective: A review', *Energy Reports* **8**, 3727–3766.
- Parrish, B., Heptonstall, P., Gross, R. & Sovacool, B. K. (2020), 'A systematic review of motivations, enablers and barriers for consumer engagement with residential demand response', *Energy Policy* **138**, 111221.
- Patnam, B. S. K. & Pindoriya, N. M. (2021), 'Demand response in consumer-centric electricity market: Mathematical models and optimization problems', *Electric Power Systems Research* **193**, 106923.
- Pereira, H., Gomes, L., Morais, H. & Vale, Z. (2022), 'Dataset of 30 energy customers with flexibility data, and distributed generation, considering residential, small commerce, large commerce, and industrial customers'.
URL: <https://doi.org/10.5281/zenodo.6783289>
- Piotrowski, P., Rutyna, I., Baczyński, D. & Kopyt, M. (2022), 'Evaluation metrics for wind power forecasts: A comprehensive review and statistical analysis of errors', *Energies* **15**(24), 9657.
- Qays, M. O., Ahmad, I., Abu-Siada, A., Hossain, M. L. & Yasmin, F. (2023), 'Key communication technologies, applications, protocols and future guides for iot-assisted smart grid systems: A review', *Energy Reports* **9**, 2440–2452.
- Ranaboldo, M., Aragüés-Peñalba, M., Arica, E., Bade, A., Bullich-Massagué, E., Burgio, A., Caccamo, C., Caprara, A., Cimmino, D., Domenech, B. et al. (2024), 'A comprehensive overview of industrial demand response status in europe', *Renewable and Sustainable Energy Reviews* **203**, 114797.
- Rodrigues Júnior, S. E. (2021), Metodologia de modelagem computacional inteligente para previsão de séries temporais baseada em sistemas evolutivos e análise espectral singular recursiva, Tese de doutorado, Universidade Federal do Maranhão, <https://tedebc.ufma.br/jspui/handle/tede/3620>.
- Rodrigues, L. S., Marques, D. L., Ferreira, J. A., Costa, V. A. F., Martins, N. D. & Neto Da Silva, F. J. (2022), 'The load shifting potential of domestic refrigerators in smart grids: A comprehensive review', *Energies* **15**(20), 7666.
- Shahcheraghian, A., Madani, H. & Ilinca, A. (2024), 'From white to black-box models: A review of simulation tools for building energy management and their application in consulting practices', *Energies* **17**(2), 376.
- Siitonen, P., Honkapuro, S., Annala, S. & Wolff, A. (2023), 'Customer perspectives on demand response in Europe: a systematic review and thematic synthesis', *Sustainability: Science, Practice and Policy* **19**(1), 14–32.
- Silva, B. N., Khan, M. & Han, K. (2020), 'Futuristic sustainable energy management in smart environments: A review of peak load shaving and demand response strategies, challenges, and opportunities', *Sustainability* **12**(14), 5561.
- Silva, C., Faria, P., Vale, Z. & Corchado, J. (2022), 'Demand response performance and uncertainty:

- A systematic literature review', *Energy Strategy Reviews* **41**, 100857.
- Singh, N. K. & Mahajan, V. (2021), 'End-user privacy protection scheme from cyber intrusion in smart grid advanced metering infrastructure', *International Journal of Critical Infrastructure Protection* **34**, 100410.
- Singh, P., Masud, M., Hossain, M. S. & Kaur, A. (2021), 'Blockchain and homomorphic encryption-based privacy-preserving data aggregation model in smart grid', *Computers & Electrical Engineering* **93**, 107209.
- Soto, E. A., Bosman, L. B., Wollega, E. & Leon-Salas, W. D. (2021), 'Peer-to-peer energy trading: A review of the literature', *Applied Energy* **283**, 116268.
- Stanelyte, D., Radziukyniene, N. & Radziukynas, V. (2022), 'Overview of demand-response services: A review', *Energies* **15**(5), 1659.
- Sun, Y., Haghghat, F. & Fung, B. C. (2020), 'A review of the-state-of-the-art in data-driven approaches for building energy prediction', *Energy and Buildings* **221**, 110022.
- Suthar, S., Cherukuri, S. H. C. & Pindoriya, N. M. (2023), 'Peer-to-peer energy trading in smart grid: Frameworks, implementation methodologies, and demonstration projects', *Electric Power Systems Research* **214**, 108907.
- Takagi, T. & Sugeno, M. (1985), 'Fuzzy identification of systems and its applications to modeling and control', *IEEE transactions on systems, man, and cybernetics* pp. 116–132.
- Tatipatri, N. & Arun, S. (2024), 'A comprehensive review on cyber-attacks in power systems: Impact analysis, detection and cyber security', *IEEE Access* .
- Tomat, V., Vellei, M., Ramallo-González, A. P., González-Vidal, A., Le Dréau, J. & Skarmeta-Gómez, A. (2022), 'Understanding patterns of thermostat overrides after demand response events', *Energy and Buildings* **271**, 112312.
- Tooki, O. O. & Popoola, O. M. (2024), 'A comprehensive review on recent advances in transactive energy system: Concepts, models, metrics, technologies, challenges, policies and future', *Renewable Energy Focus* p. 100596.
- Tuncar, E. A., Sağlam, Ş. & Oral, B. (2024), 'A review of short-term wind power generation forecasting methods in recent technological trends', *Energy Reports* **12**, 197–209.
- Tushar, W., Saha, T. K., Yuen, C., Smith, D. & Poor, H. V. (2020), 'Peer-to-peer trading in electricity networks: An overview', *IEEE Transactions on Smart Grid* **11**(4), 3185–3200.
- Tushar, W., Yuen, C., Saha, T. K., Morstyn, T., Chapman, A. C., Alam, M. J. E., Hanif, S. & Poor, H. V. (2021), 'Peer-to-peer energy systems for connected communities: A review of recent advances and emerging challenges', *Applied Energy* **282**, 116131.
- Vanegas-Ayala, S.-C., Barón-Velandia, J. & Romero-Riaño, E. (2024), 'Systematic review of forecasting models using evolving fuzzy systems', *Computation* **12**(8), 159.
- Wang, B., Li, Y., Ming, W. & Wang, S. (2020), 'Deep reinforcement learning method for demand response management of interruptible load', *IEEE Transactions on Smart Grid* **11**(4), 3146–3155.
- Wang, L. X. (1997), *A Course in Fuzzy Systems and Control*, Prentice-Hall, Inc.

- Waseem, M., Lin, Z., Ding, Y., Wen, F., Liu, S. & Palu, I. (2020), 'Technologies and practical implementations of air-conditioner based demand response', *Journal of Modern Power Systems and Clean Energy* **9**(6), 1395–1413.
- Weitzel, M., Vandyck, T., Los Santos, L. R., Tamba, M., Temursho, U. & Wojtowicz, K. (2023), 'A comprehensive socio-economic assessment of eu climate policy pathways', *Ecological Economics* **204**, 107660.
- Wu, Y.-K. & Tang, K.-T. (2019), 'Frequency support by demand response—review and analysis', *Energy Procedia* **156**, 327–331.
- Xia, Y., Xu, Q., Li, S., Tang, R. & Du, P. (2022), 'Reviewing the peer-to-peer transactive energy market: Trading environment, optimization methodology, and relevant resources', *Journal of Cleaner Production* p. 135441.
- Yuan, J., Xiao, Z., Chen, X., Lu, Z., Li, J. & Gang, W. (2021), 'A temperature & humidity setback demand response strategy for hvac systems', *Sustainable Cities and Society* **75**, 103393.
- Zadeh, L. A. (1965), 'Information and control', *Fuzzy sets* **8**(3), 338–353.
- Zia, M. F., Benbouzid, M., Elbouchikhi, E., Muyeen, S., Techato, K. & Guerrero, J. M. (2020), 'Microgrid transactive energy: Review, architectures, distributed ledger technologies, and market analysis', *Ieee Access* **8**, 19410–19432.

DECLARAÇÃO DE INTEGRIDADE

Guilherme Abreu Carvalho

DECLARAÇÃO DE INTEGRIDADE

Declaro ter conduzido este trabalho académico com integridade. Não plagiei ou apliquei qualquer forma de uso indevido de informações ou falsificação de resultados ao longo do processo que levou à sua elaboração.

Declaro que o trabalho apresentado neste documento é original e de minha autoria, não tendo sido utilizado anteriormente para nenhum outro fim.

Declaro ainda que tenho pleno conhecimento do Código de Conduta Ética do P.PORTO.

ISEP, Porto, 21 de outubro de 2024