

Detecção de Perdas Não Técnicas em Sistemas de Distribuição de Energia Elétrica via Sistema de Inferência *Fuzzy*

Vitor G. Silveira*, Andréia S. Santos**, Lucas Teles Faria*

* *Laboratório de Otimização em Sistemas de Energia Elétrica, Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Faculdade de Engenharia e Ciências (FEC), Av. dos Barrageiros, 1881, Rosana, São Paulo, Brasil (e-mail: vitor.silveira@unesp.br, lucas.teles@unesp.br).*

** *Laboratório de Sistemas Inteligentes (SINTEL), Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Faculdade de Engenharia de Ilha Solteira (FEIS), Av. Professor José Carlos Rossi, 1370, Câmpus 3, Ilha Solteira, São Paulo, Brasil (e-mail: andreia.faria@unesp.br)*

Abstract: Non-technical losses cause financial losses to power utilities and other damages: tax collection reduction, energy quality deterioration, and increase in energy bill. In this sense, the most studies in the specialized literature present methodologies to combat losses with focus on techniques for automatic extraction of knowledge. These techniques do not allow the incorporation of specialist's knowledge in trivial way. Thus, this study presents a methodology for detecting irregular consumer units via fuzzy inference system, where the specialist's knowledge in non-technical losses is intuitively incorporated through fuzzy rules. The methodology is developed in MATLAB® environment and it presents high values for the confusion matrix metrics: success rate ($TS = 95.2\%$), negative reliability ($CN = 78.9\%$), and specificity ($ESP = 71.0\%$). Thus, the methodology has good coverage in identifying irregular consumer units and it is effective in preventing unnecessary visits to regular consumer units.

Resumo: As perdas não técnicas ocasionadas por furtos de energia (ligações clandestinas) e fraudes no medidor de energia ocasionam vultosos prejuízos financeiros às distribuidoras de energia e diversos outros prejuízos à sociedade: redução na arrecadação de impostos, deterioração da qualidade da energia com apagões frequentes, aumento da tarifa de energia entre outros. Nesse sentido, os estudos da literatura especializada, em sua maioria, apresentam metodologias para combate às perdas com foco em técnicas para extração automática de conhecimento. Ocorre que essas técnicas não permitem a incorporação do conhecimento do especialista em perdas de maneira trivial. Assim, este estudo apresenta uma metodologia para detecção de unidades consumidoras irregulares via sistema de inferência *fuzzy*, onde o conhecimento do especialista em perdas é incorporado de forma intuitiva através de um conjunto de regras *fuzzy*. A metodologia proposta é desenvolvida no ambiente MATLAB® e apresenta valores elevados para métricas extraídas da matriz de confusão: taxa de sucesso ($TS = 95,2\%$), confiabilidade negativa ($CN = 78,9\%$) e especificidade ($ESP = 71,0\%$). Assim, a metodologia apresenta boa cobertura na identificação de unidades consumidoras irregulares e é eficaz na prevenção de visitas desnecessárias em unidades consumidoras regulares.

Keywords: Commercial Losses; Energy Theft; Fuzzy Inference Systems; Non-Technical Losses; Power Distribution Systems.

Palavras-chaves: Furto de Energia; Perdas Comerciais; Perdas Não Técnicas (PNTs); Sistema de Distribuição de Energia Elétrica (SDEE); Sistema de Inferência *Fuzzy* (SIF).

1. INTRODUÇÃO

As perdas não técnicas (PNTs) referem-se a toda energia consumida e não faturada em unidades consumidoras (UCs) pertencentes ao sistema de distribuição de energia elétrica (SDEE). As PNTs são definidas como sendo a diferença entre as perdas totais e as perdas técnicas. As perdas técnicas são inerentes ao sistema elétrico e ocorrem devido à dissipação de energia durante o processo de transporte, transformação e medição de energia. Desse modo, essas perdas estão diretamente relacionadas às características de carregamento e topologia da rede elétrica. Por outro lado, as PNTs ocorrem principalmente devido à fatores externos às distribuidoras de energia tais como: furto e fraude nos medidores de energia, erros de leitura, medição e faturamento (Savian *et al.*, 2021).

As PNTs são ocasionadas majoritariamente por furto de energia, onde o furto é caracterizado por ligações clandestinas realizadas diretamente na rede de distribuição ou via desvio direto no medidor de energia (Instituto Acende Brasil, 2017).




Fig. 1 Perdas totais sobre a energia injetada (ANEEL, 2021).




Fig. 2 Perdas totais por regiões do Brasil (ANEEL, 2021).

As PNTs ocasionadas por furto de energia têm prevalecido nas redes de distribuição de países subdesenvolvidos como o Brasil. Essa constatação deve-se a um conjunto de fatores relacionados a questões sociais, visto que uma parcela majoritária das PNTs está associada a aspectos culturais e socioeconômicos (Smith, 2004).

Adicionalmente, se houvesse medidores e redes inteligentes nesses países subdesenvolvidos, certamente algumas modalidades de PNTs seriam extintas; no entanto, o custo proibitivo é um impedimento para implantação em larga escala dessas tecnologias (Firoozi e Mashhadi, 2022).

As perdas financeiras são umas das principais consequências das PNTs para as distribuidoras e para as UCs, pois o consumidor regular arca parcialmente com os custos decorrentes das PNTs (ANEEL, 2021).

Além disso, as ligações clandestinas podem interferir na estabilidade e na qualidade do fornecimento de energia elétrica. Os furtos de eletricidade provocam incertezas relacionadas ao consumo real de energia (Buzau *et al.*, 2020).

As perdas totais, perdas técnicas e PNTs reais estão apresentadas na Fig. 1. Observa-se que desde 2008 até 2021 não houve reduções significativas nas PNTs nas distribuidoras brasileiras. Em 2020, as PNTs atingiram um percentual de 7,3%, sendo o maior valor registrado desde 2008.

A Fig. 2 contém as perdas totais percentuais por regiões do Brasil. A região Norte do país concentra quase metade das perdas totais – 48,74%. Por outro lado, a região Sul é aquela com as menores perdas e cujo valor se aproxima das perdas de países desenvolvidos. Assim, depreende-se que existem fatores locais que favorecem a proliferação das PNTs em algumas regiões do país (Faria, Melo e Padilha-Feltrin, 2016; Ventura *et al.*, 2023).

1.1 Revisão da Literatura

Nesta seção, abordam-se alguns estudos recentes da literatura especializada para prevenção e combate às PNTs.

Em (Sharma e Majumdar, 2021) foi proposto um método *online* para detecção de PNTs. O histórico de consumo mensal (HCM) em kWh foi aplicado para estimar o consumo futuro e; posteriormente, foi realizada uma análise comparativa entre o consumo real e o consumo previsto. A partir dessa análise, foi criada uma lista de UCs com suspeita de irregularidade que possuem uma diferença significativa entre o valor real de consumo e o valor previsto.

Uma metodologia baseada em lógica *fuzzy* foi apresentada por (Rengarajan e Loganathan, 2012) para prevenção de furto de eletricidade. A técnica baseia-se na análise comparativa da carga total fornecida pelo transformador e da carga total consumida por cada UC conectada ao referido transformador.

Medeiros *et al.* (2021) aplicaram dados reais extraídos de medidores inteligentes, onde as medições de tensões, energia dos transformadores e medidores das UCs são conhecidos. O fluxo de carga forneceu as perdas no sistema. A partir da estimativa foi possível determinar a localização da fonte geradora de PNTs.

Um novo método para detecção de PNTs em SDEE de baixa tensão foi apresentado por (Firoozi e Mashhadi, 2022) baseado na estimativa de carga. Foram introduzidos dados de faturamento e informações de saída obtidas medições em tempo real do lado secundário do transformador.

Massaferro *et al.*, (2018) analisaram o impacto da introdução da localização geográfica das UCs no processo de detecção automática de PNTs. A metodologia consiste em duas etapas: (i) a partir dos dados das UCs calculam-se as características; (ii) classificação das UC como suspeita ou como normal via aplicação do algoritmo *Random Forest*.

Neste estudo desenvolve-se uma metodologia para detecção de PNTs conformada por dois módulos: (1) Extração de atributos estatísticos baseado em regimes a partir do HCM das UCs em kWh e (2) sistema de inferência *fuzzy* (SIF) que recebe atributos estatísticos como entrada e fornece como saída um índice de suspeita de irregularidade para cada UC. O resultado dessa metodologia consiste de uma lista de UCs com suspeita de irregularidades; portanto, ela confere maior assertividade para as inspeções em campo.

2. LÓGICA FUZZY

A lógica *fuzzy* introduzida por (Zadeh, 1965) lida com informações vagas ou imprecisas. As técnicas desenvolvidas fornecem uma estrutura eficaz para manipulação de informações aproximadas, permitindo que processos sofisticados sejam controlados por meio de um conjunto de regras *fuzzy* (Sandri e Correa, 1999).




Fig. 3 Exemplos de funções de pertinência. (a) Conjunto *crisp*. (b) Conjunto *fuzzy*. Fonte: Domingos (1998).

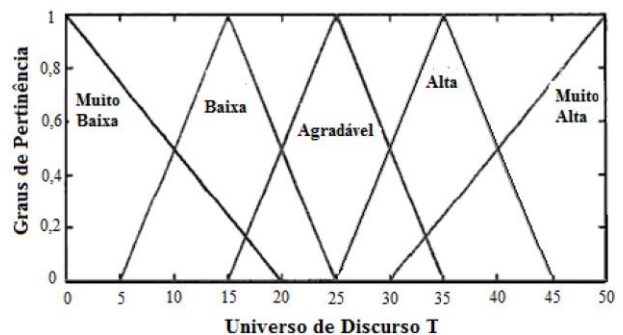


Fig. 4 Conjuntos *fuzzy* com expressões linguísticas para a variável *fuzzy* temperatura (T). Fonte: Rezende (2005).

2.1 Conjuntos Fuzzy

Seja um conjunto *fuzzy* F de universo U modelado por uma função de pertinência $\mu_F: U \rightarrow [0,1]$ que associa cada elemento $x \in U$ a um número real μ_F onde $\mu_F \in [0,1]$. A função de pertinência μ_F representa a pertinência de x em F (Rezende, 2005).

Assim, na lógica *fuzzy*, a pertinência de um determinado elemento em relação a um conjunto refere-se ao pertencimento desse elemento ou não ao respectivo conjunto (Marro *et al.*, 2010). Desse modo, a função de pertinência retrata o grau de compatibilidade de cada elemento x em F para cada $x \in U$.

A Fig. 3 contém um exemplo com funções de pertinência para indivíduos jovens representado por um conjunto *crisp* em (1) – Fig. 3 (a) – e por um conjunto *fuzzy* em (2) – Fig. 3 (b). A transição entre o indivíduo jovem e adulto ocorre de forma suave no conjunto *fuzzy*. Por outro lado, essa mesma transição ocorre de forma abrupta e descontínua no conjunto clássico ou conjunto *crisp*.

$$\mu_c = \begin{cases} 1, & \text{se } Idade \leq 30 \\ 0, & \text{se } Idade > 30 \end{cases} \quad (1)$$

$$\mu_F = \begin{cases} 1, & \text{se } Idade < 20 \\ \frac{35 - Idade}{15}, & \text{se } 20 \leq Idade \leq 35 \\ 0, & \text{se } Idade > 35 \end{cases} \quad (2)$$

$$\text{SE } \langle \text{antecedente} \rangle \text{ ENTÃO } \langle \text{consequente} \rangle \quad (3)$$

2.2 Regras Fuzzy

As regras *fuzzy* fornecem uma descrição qualitativa do sistema em estudo, onde são aplicados termos linguísticos que viabilizam a introdução de dados ou informações imprecisas na forma linguística. Assim, em vez de utilizar dados numéricos, são utilizadas palavras e frases, que podem ser expressas por meio de conjuntos *fuzzy*.

As regras *fuzzy* descrevem o sistema em estudo de forma qualitativa, onde o conhecimento do especialista em PNTs é armazenado em um SIF na forma de regras conforme (3).

Em (3), o termo antecedente contém variáveis *fuzzy* e expressões linguísticas. Se o antecedente for satisfeito, então a parte consequente é executada mesmo que parcialmente via mecanismo de inferência *fuzzy*. O grupo de consequentes de todo o conjunto de regras *fuzzy* satisfeitas são processadas em conjunto para gerar uma resposta determinística para cada variável de saída do SIF.

2.3 Variáveis Linguísticas e Funções de Pertinência

Uma variável linguística é definida como uma representação qualitativa e imprecisa em linguagem cotidiana de uma variável quantitativa em uma aplicação (Rezende, 2005). A cada variável linguística relacionam-se expressões linguísticas ou termos primários.

A Fig. 4 contém um exemplo de uma partição *fuzzy* para a variável linguística temperatura (T) com cinco conjuntos *fuzzy* representados por funções de pertinência triangulares contidas no universo de discurso $T \in [0,50]$. A cada conjunto *fuzzy* associam-se expressão linguísticas que qualificam a variável temperatura de forma imprecisa: “Muito Baixa”, “Baixa”, “Agradável”, “Alta” e “Muito Alta”.

3. METODOLOGIA PARA DETECÇÃO DE UNIDADES CONSUMIDORAS IRREGULARES

Nesta seção é apresentada a metodologia para detecção de UCs irregulares a partir do HCM em kWh via SIF.

3.1 Atributos Estatísticos Baseados em Regimes

A literatura especializada contém inúmeros estudos cujo objetivo é a identificação de UCs irregulares a partir de sistemas classificadores cujas entradas são os dados do HCM em kWh de cada UC.

Esses sistemas classificadores comumente aplicam técnicas de *soft computing* como: mineração de dados e de texto (Nizar, Dong e Wang, 2008), redes neurais artificiais (RNA) (Faria, Padilha-Feltrin e Minussi, 2012), *support vector machine* (Nagi *et al.*, 2010), aplicação de metaheurísticas como *optimum-path forest* (Ramos *et al.*, 2011), aplicação de *deep learning* (Buzau *et al.*, 2020) e outros.

Esses sistemas classificadores não recebem como entrada os dados originais do HCM. Assim, há uma etapa de pré-processamento para extração de atributos a partir do HCM em kWh tais como: coeficientes Wavelets e coeficientes de Fourier, por exemplo.

Neste estudo são extraídos três atributos estatísticos baseados em regimes a partir do HCM. Esses atributos representam o perfil de consumo de cada UC; ademais, têm menor dimensão do que os dados originais.

Atributos baseados em coeficientes Wavelets ou coeficientes de Fourier são mais sensíveis a ruídos, pois captam mínimas variações do HCM. Em contraposição, atributos estatísticos baseados em regimes fornecem uma tendência geral do consumo mensal; portanto, são menos suscetíveis à ruídos que interferem no desempenho dos sistemas classificadores. Além disso, são mais intuitivos e de fácil entendimento por um especialista em PNTs.

A Tabela 1 contém a descrição dos atributos estatísticos baseados em regimes do HCM em kWh (Faria, Padilha-Feltrin e Minussi, 2012; Ferreira, 2008).

A Fig. 5 contém um exemplo para obtenção dos regimes (curva em vermelho) a partir de um HCM hipotético em kWh ao longo de 12 meses (curva azul). O referido HCM contém ao todo três regimes ou patamares. Os primeiros seis meses estão no 1º regime e têm média de 301 kWh. O consumo mensal desses seis meses pertencentes a esse primeiro regime varia, no máximo, 25% em relação à média desse primeiro regime. Esse procedimento é adotado para obtenção dos outros dois regimes.

Tabela 1. Atributos estatísticos baseados em regimes

Parâmetros	Descrições
CV	Coeficiente de variação. Variabilidade da série de consumo mensal em relação à média. $CV = \frac{\text{Desvio Padrão}}{\text{Média}}$.
PMRQ	Percentual de meses em que o consumo em kWh permanece em regimes de queda.
NZ	N.º de zeros. Consumo inferior a 10% da média da série.




Fig. 5 Ilustração de um histórico de consumo mensal anual hipotético (curva azul) com seus respectivos regimes (curva vermelha).




Fig. 6 Diagrama de um modelo de inferência Mamdani. Fonte: Rezende (2005).

3.2 Construção do Histórico de Inspeções

Nesse estudo, não se dispõe do histórico de inspeções; tem-se somente o HCM em kWh. Portanto, o histórico de inspeções é construído via algoritmo para formação de agrupamentos aplicado ao HCM e será conformado por UCs regulares e irregulares. O *cluster* majoritário contém UCs regulares, enquanto o *cluster* minoritário contém UCs irregulares.

A rede neural de Kohonen é aplicada para construção de *clusters* com características semelhantes. Essa rede possui aprendizado não supervisionado, competitivo e identifica padrões em vetores de dados multivariados (Rezende, 2005).

3.3 Sistema de Inferência Fuzzy Mamdani

O SIF Mamdani é uma síntese do conhecimento do especialista que é fundamental para construção da base de regras *fuzzy*. Ademais, o SIF é conformado por conjuntos *fuzzy* associados às expressões linguísticas para cada variável *fuzzy*.

A Fig. 6 contém um diagrama do modelo Mamdani. As variáveis *fuzzy* são convertidas em conjuntos *fuzzy* no módulo de entrada – fuzificação. A máquina de inferência gera um conjunto *fuzzy* de saída a partir dos valores *fuzzy* do módulo de entrada e das regras *fuzzy*. A base de regras possui operações entre conjuntos *fuzzy* nos termos antecedentes e consequentes. As inferências são processadas via regra semântica *Max-Min* ou união e interseção entre conjuntos *fuzzy*.

A defuzificação é feita para conversão da saída do SIF (conjunto *fuzzy*) em um valor numérico. O método do centróide é o mais utilizado no processo de defuzificação e é aplicado neste estudo.

3.4 Métricas para Validação do SIF

A taxa de sucesso (TS) em (4) é usualmente aplicada para avaliação de sistemas classificadores. No entanto, ela é insuficiente em PNTs, pois os grupos de UCs regulares e irregulares são muito díspares – para cada nove UCs regulares, há uma UC irregular (Cometti e Varejão, 2005).

Tabela 2. Matriz de confusão

Matriz de Confusão		Classe Predita	
		N	F
Classe Real	N	Q_{NN}	Q_{NF}
	F	Q_{FN}	Q_{FF}

Assim, avaliam-se outras métricas junto com a TS : confiabilidade negativa (CN) em (5) e a especificidade (ESP) em (6). Essas métricas são obtidas a partir da matriz de confusão adaptada ao problema de PNTs e é representada na Tabela 2. Ela contém UCs regulares ou normais (N) e UCs irregulares ou com fraude (F). Sendo Q_{NN} o número de UCs regulares corretamente classificadas – verdadeiro positivo. Q_{NF} é o número de UCs regulares incorretamente classificadas como irregulares – falso negativo. Q_{FN} é o número de UCs irregulares incorretamente classificadas como regulares – falso positivo e; finalmente, Q_{FF} é o número de UCs irregulares corretamente classificadas – verdadeiro negativo.

A CN em (5) consiste na razão entre o número de UCs irregulares corretamente classificadas e o número de UCs (corretamente e incorretamente) classificadas como irregulares.

A ESP em (6) consiste na razão entre o número de UCs irregulares corretamente classificadas e o número de UCs irregulares contidas na base de dados.

$$TS = \frac{Q_{NN} + Q_{FF}}{Q_{NN} + Q_{FF} + Q_{NF} + Q_{FN}} \quad (4)$$

$$CN = \frac{Q_{FF}}{Q_{FF} + Q_{NF}} \quad (5)$$

$$ESP = \frac{Q_{FF}}{Q_{FF} + Q_{FN}} \quad (6)$$

4. RESULTADOS E DISCUSSÕES

Nesta seção é apresentada a metodologia para detecção de UCs irregulares da classe residencial a partir do HCM real em kWh via SIF Mamdani.

As simulações são realizadas no ambiente de programação MATLAB® instalado em um computador pessoal com processador AMD Ryzen 7 3700X 8-Core; 3,6 GHz e memória RAM com 16 GB.

4.1 Construção de Cenários de Perdas Não Técnicas

O histórico de inspeções com 900 UCs regulares e 100 UCs irregulares foi construído via algoritmo para formação de *clusters* (rede neural de Kohonen) a partir do HCM em kWh referente a 36 meses. A Tabela 3 contém os parâmetros aplicados para treinamento da rede neural de Kohonen.

Tabela 3. Parâmetros para treinamento da RNA Kohonen

Parâmetros	Valores
Taxa de Treinamento	0,5
Constante de Convergência	10^{-2}
Nº Épocas de Treinamento	10^3
Treinamento	Aprendizado Competitivo
Tipo de Treinamento	Aprendizado não supervisionado
Critério de Convergência	Varição magnitude vetores pesos

Tabela 4. Resumo estatístico UCs regulares

Parâmetros	Mín.	Máx.	Média	Desvio Padrão
CV	0	3,4247	0,3246	0,0102
PMRQ	0	0,9722	0,2633	0,0072
NZ	0	27	1,7156	0,1306

Tabela 5. Resumo estatístico UCs irregulares

Parâmetros	Mín.	Máx.	Média	Desvio Padrão
CV	0,603	5,9161	3,0883	0,1831
PMRQ	0,000	0,9722	0,3314	0,0341
NZ	9	35	27,3900	0,7487




Fig. 7 SIF para detecção de PNTs. Fonte: (MATLAB, 2022).

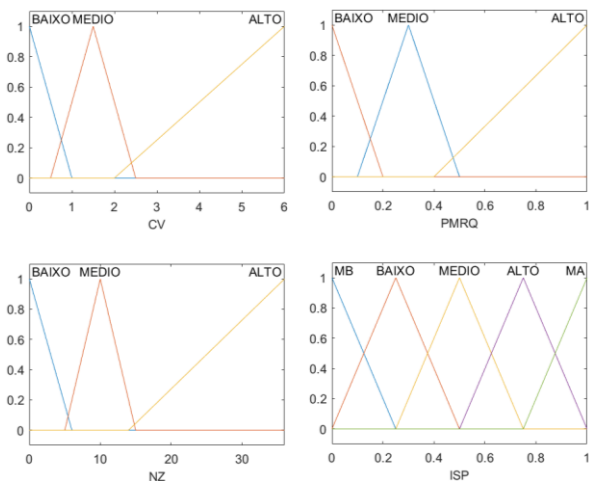


Fig. 8 Funções de pertinência para as variáveis de entrada (CV, PMRQ, NZ) e para a variável de saída ISP. Fonte: (MATLAB, 2022).

As Tabelas 4 e 5 contêm um resumo estatístico dos atributos estatísticos para agrupamento de UCs regulares e irregulares, respectivamente. Os agrupamentos contêm valores distintos para os parâmetros estatísticos; portanto, é possível a construção de um SIF para detecção de PNTs para essa base de dados. Ademais, essa informação é vital para ajuste das funções de pertinência (Fig. 8) e para construção da base de regras *fuzzy* (Tabela 6) do SIF proposto neste estudo.

4.2 Construção do Sistema de Inferência Fuzzy

Neste estudo é desenvolvido um SIF Mamdani para detecção de PNTs. Esse SIF é conformado pelas variáveis *fuzzy* de entrada (atributos estatísticos): CV, PMRQ e NZ (vide Tabela 1) e pela variável de saída índice de suspeita de perdas (ISP). A Fig. 8 contém as funções de pertinência triangulares para as três variáveis de entrada e para a variável de saída. A Tabela 6 contém 27 regras *fuzzy* construídas via operador AND – operador de interseção ou mínimo.

Tabela 6. Conjunto de regras fuzzy com operador AND

Regras Fuzzy	Variáveis de Entrada			Variável de Saída
	CV	PQR	NZ	ISP
1 ^a	B	B	B	MB
2 ^a	B	B	M	B
3 ^a	B	B	A	M
4 ^a	B	M	B	B
5 ^a	B	M	M	M
6 ^a	B	M	A	A
7 ^a	B	A	B	M
8 ^a	B	A	M	A
9 ^a	B	A	A	MA
10 ^a	M	B	B	B
11 ^a	M	B	M	M
12 ^a	M	B	A	A
13 ^a	M	M	B	M
14 ^a	M	M	M	M
15 ^a	M	M	A	A
16 ^a	M	A	B	M
17 ^a	M	A	M	A
18 ^a	M	A	A	MA
19 ^a	A	B	B	M
20 ^a	A	B	M	A
21 ^a	A	B	A	MA
22 ^a	A	M	B	A
23 ^a	A	M	M	A
24 ^a	A	M	A	MA
25 ^a	A	A	B	A
27 ^a	A	A	M	MA
27 ^a	A	A	A	MA

* MB=Muito Baixo; B=Baixo; M=Médio; A=Alto; MA=Muito Alto.

Essas regras representam todas as combinações possíveis entre as três expressões linguísticas “baixo” (B), “médio” (M) e “alto” (A) para as três variáveis de entrada do SIF: CV, PMRQ e NZ. Todas as 27 regras seguem o formato em (7), onde se apresenta a primeira regra da Tabela 6.

$$SE CV=B \text{ AND } PQR=B \text{ AND } NZ=B \text{ ENTÃO } ISP=MB \quad (7)$$

4.3 Detecção de Perdas Não Técnicas

As UCs regulares e irregulares são identificadas a partir do SIF na Fig. 7, onde os três atributos estatísticos da Tabela 1 são as variáveis de entrada e o ISP é a variável de saída.

Como o SIF possui variável de saída $ISP \in [0,1]$, realiza-se uma etapa de pós-processamento em (8).

$$UC = \begin{cases} Irregular, & se \text{ } ISP \geq 0,75 \\ Regular, & se \text{ } ISP < 0,75 \end{cases} \quad (8)$$

A metodologia proposta neste estudo é validada a partir das métricas obtidas via matriz de confusão – Tabela 7. A partir de (4), (5) e (6) obtêm-se os valores percentuais das métricas calculadas a partir dos valores numéricos da matriz de confusão: $TS=95,2\%$, $CN=78,9\%$ e $ESP=71,0\%$.

Tabela 7. Matriz de confusão com dados numéricos

Matriz de Confusão		Classe Predita	
		N	F
Classe Real	N	882	19
	F	29	71

A métrica *ESP* indica a cobertura do classificador, ou seja, o percentual de UCs irregulares que o sistema é capaz de identificar entre todas UCs irregulares existentes na cidade. Por outro lado, a métrica *CN* refere-se à precisão das inspeções, ou seja, o êxito das inspeções em campo na identificação de UCs irregulares.

Portanto, o SIF classificador proposto neste estudo apresenta valores elevados para todas as métricas avaliadas: *TS*, *CN* e *ESP*. Assim, esse sistema apresenta boa cobertura ao identificar uma parcela majoritária das UCs irregulares existentes na cidade em estudo; além disso, minimizam-se visitas ou inspeções desnecessárias das equipes em campo em UCs regulares.

5. CONCLUSÕES

Neste estudo foi apresentada uma metodologia para detecção de unidades consumidoras (UCs) irregulares com perdas não técnicas (PNTs) no sistema de distribuição de energia elétrica (SDEE). A metodologia é conformada por um sistema de inferência *fuzzy* (SIF) Mamdani com três variáveis de entrada (atributos estatísticos baseados em regimes) e uma variável de saída.

A metodologia apresentou elevada taxa de sucesso (*TS* = 95,2%), uma boa cobertura na identificação de uma parte majoritária das UCs irregulares na cidade em estudo (*ESP* = 71%) e; finalmente, evitam-se inspeções desnecessárias em UCs regulares (*CN* = 78,9%).

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela concessão da bolsa de Iniciação Científica (Processo nº: 2021/03103-1) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de uma bolsa de doutorado – Código de financiamento 001.

REFERÊNCIAS

- ANEEL (2021). Perdas de Energia Elétrica na Distribuição. Agência Nacional de Energia Elétrica.
- Buzau, M. M., Tejedor-Aguilera, J., Cruz-Romero, P., Gomez-Exposito, A. (2019). Detection of non-technical losses using smart meter data and supervised learning. *IEEE Transactions on Smart Grid*, v. 10, n. 3, p. 2661–2670.
- Cometti, E. S., Varejão, F. M. (2005). Melhoramentos na identificação de perdas não técnicas através da análise computacional inteligente do perfil de consumo e dos dados cadastrais de consumidores. Relatório técnico final do projeto de pesquisa e desenvolvimento, Vitória, ES.
- Domingos, J. L. (1998). Uma contribuição à modelagem nebulosa. Dissertação (Mestrado em Eng. Elétrica) – Centro de Ciências Exatas e Tecnologia, Depto. de Eng. Elétrica, Univ. Federal de Uberlândia, Uberlândia, MG.
- Instituto Acende Brasil. (2017). Perdas Comerciais e Inadimplência no Setor Elétrico. Disponível em: <<https://acendebrasil.com.br>>.
- Faria, L.T., Padilha-Feltrin, A., Minussi, C.R. (2012). Sistema inteligente híbrido intercomunicativo para detecção de perdas comerciais em sistemas de distribuição de energia elétrica. *In IV Simpósio Brasileiro de Sistemas Elétricos – IV SBSE*, Goiânia, GO.
- Faria, L. T., Melo, J. D., Padilha-Feltrin, A. (2016). Spatial-Temporal Estimation for Nontechnical Losses. *IEEE Transactions on Power Delivery*, v. 31, p. 362–369.
- Ferreira, H.M (2008). Uso de ferramentas de aprendizado de máquina para prospecção de perdas comerciais em distribuição de energia elétrica. 2008. Dissertação de Mestrado. Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas, São Paulo.
- Firoozi, H., Mashhadi, H. R. (2022). Non-technical loss detection in limited-data low-voltage distribution feeders. *Int. J. Elec. Power & Energy Systems*, v. 135, n. 107523.
- Marro, A. A., Souza, A. M. C., Cavalcante, E. R. S., Bezerra, G. S., Nunes, R. O. (2010). Lógica *Fuzzy* - Conceitos e aplicações. *In Natal: Univ. Federal do Rio Grande do Norte (UFRN)*.
- Massaferro, P., Marichal, H., Martino, M. Di, Santomauro, F., Kosut, J. P., Fernandez, A. (2018). Improving electricity non technical losses detection including neighborhood information. *IEEE Power & Energy Society General Meeting (PESGM)*, p. 1–5.
- MATLAB version: 9.13 (R2022b), Natick, Massachusetts: The MathWorks Inc.; 2022.
- Medeiros, M. H., Sanz-Bobi, M. A., Domingo, J. M., Picchi, D. (2021). Network Oriented Approaches Using Smart Metering Data for Non-Technical Losses Detection. *In IEEE Madrid PowerTech, PowerTech*.
- Nagi, J., Yap, K.S., Tiong, S.K., Ahmed, S.K., Mohamad, M. (2010). Nontechnical Loss Detection for Metered Customers in Power Utility Using Support Vector Machines. *IEEE Trans. Power Deliv.*, v. 25, p. 1162–1171.
- Nizar, A. H., Dong, Z. Y., Wang, Y. (2008). Power Utility Nontechnical Loss Analysis with Extreme Learning Machine Method. *IEEE Trans. Power Systems*, v. 23.
- Ramos, C. C. O., Sousa, A. N., Papa, J. P., Falcão, A. X. A. (2011). New Approach for Nontechnical Losses Detection Based on Optimum-Path Forest. *IEEE Trans. Power Systems*, v. 26.
- Rengarajan, S., Loganathan, S. (2012). Power Theft Prevention and Power Quality Improvement using *Fuzzy Logic*. *Int. J. Elect. and Electronics Eng.*, p. 106–110.
- Rezende, S. O. *et al.* (2005). Sistemas inteligentes: fundamentos e aplicações. Barueri: Ed. Manole.
- Sharma, S., Majumdar, A. (2021). Unsupervised detection of non-technical losses via recursive transform learning. *IEEE Trans. on Power Delivery*, v. 36, n. 2, p. 1241–1244.
- Smith, T. B. (2004). Electricity theft: a comparative analysis. *Energy Policy*, v. 32, p. 2067–2076.
- Sandri, S., Correa, C. (1999). Lógica Nebulosa. V Escola de Redes Neurais, Promoção: Conselho Nacional de Redes Neurais, p. 73–90.
- Savian, F. S., Siluk, J. C. M., Garlet, T. B., Nascimento, F. M., Pinheiro, J. R., Vale, Z. (2021). Non-technical losses: A systematic contemporary article review. *In Renewable and Sustainable Energy Reviews*, v. 147.
- Ventura, L., Felix, G. E., Vargas, R., Faria, L. T., Melo, J. D. (2023). Estimation of Non-Technical Loss Rates by Regions. *Electric Power Systems Research*, v. 223, n. 109685, p. 1-9.
- Zadeh, L. A. (1965). *Fuzzy sets*. *Information and Control*, p. 338–353.