



Latin American Journal of Energy Research – Lajer (2025) v. 12, n. 3, p. 145–153
<https://doi.org/10.21712/lajer.2025.v12.n3.p145-153>

1º Encontro Interdisciplinar em Energia, Programa de Pós-graduação em Energia, Ufes



Controle de cargas em redes inteligentes: uma revisão de abordagens baseadas em NILM, aprendizado de máquina e reflectometria
Load control in smart grids: a review of NILM-, machine learn-, and reflectometry-based approaches

João José de Sousa Junior^{1,*}, Ana Paula Meneguelo², Daniel José Custódio Coura², Wanderley Cardoso Celeste²

¹ Aluno do Programa de Pós-Graduação em Energia, Universidade Federal do Espírito Santo – Ufes, campus São Mateus, ES, Brasil

² Professor do Programa de Pós-Graduação em Energia, Universidade Federal do Espírito Santo – Ufes, campus São Mateus, ES, Brasil

*Autor para correspondência, E-mail: joaojosedesousajr@gmail.com

Resumo: O controle de cargas é essencial para o gerenciamento eficiente de sistemas de energia, especialmente em redes inteligentes (*smart grid*) com geração distribuída. Esse gerenciamento depende da coleta de dados por meio de sensores, cujas informações são posteriormente processadas por algoritmos de aprendizado de máquina (*machine learning*). Este trabalho tem como objetivo analisar os principais métodos de classificação de cargas, os algoritmos empregados e suas diversas aplicações em contextos reais. A metodologia adotada consiste em uma revisão comparativa de três abordagens: (i) monitoramento não intrusivo de cargas (NILM), (ii) métodos com sensores baseados em reflectometria e (iii) técnicas independentes que utilizam aprendizado de máquina e Internet das Coisas (IoT). Os resultados indicam que, embora o NILM seja amplamente empregado no monitoramento de cargas e os métodos independentes apresentem estratégias variadas para acompanhamento em tempo real, as abordagens com sensores de reflectometria demonstram maior potencial para aumentar a precisão e aprimorar o controle de carga. Além disso, este estudo destaca soluções acessíveis e sustentáveis para o setor elétrico e evidencia o potencial inexplorado da reflectometria em redes inteligentes de energia elétrica, um tema recente e promissor.

Palavras-chave: Aprendizado de máquina; Controle de carga; NILM; Reflectometria; Redes inteligentes.

Abstract: Load control is essential for the efficient management of energy systems, especially in smart grids with distributed generation. This management relies on data collection through sensors, which are later processed by machine learning algorithms. This study aims to analyze the main load classification methods, the algorithms employed, and their various applications in real-world contexts. The adopted methodology consists of a comparative review of three approaches: (i) non-intrusive load monitoring (NILM), (ii) methods using sensors based on reflectometry, and (iii) independent techniques that utilize machine learning and the Internet of Things (IoT). The results indicate that, although NILM is widely used for load monitoring and independent methods offer diverse strategies for real-time tracking, approaches based on reflectometry sensors demonstrate greater potential in improving accuracy and enhancing load control. This study also highlights accessible and sustainable solutions for the energy sector and emphasizes the untapped potential of reflectometry in smart electrical grids, a recent and promising topic.

Keywords: Machine learning; Load control; NILM; Reflectometry; Smart grid.

1 Introdução

Com os avanços das tecnologias, especialmente da inteligência artificial (IA) e da automação, o consumo de energia elétrica tem crescido significativamente, devido ao processamento intenso e contínuo que é exigido pelos *data centers* e chips de alta performance ao treinar os modelos de IA avançados. Este é um dos fatores que pressionam o setor energético a buscar soluções mais eficientes para o seu gerenciamento. De acordo com o Balanço Energético Nacional (2024, p. 6), a oferta interna de energia no Brasil aumentou de 4,8% em relação a 2022, o que representa um acréscimo de 33,2 TWh. Nesse contexto, o uso de abordagens inovadoras torna-se essencial para garantir a estabilidade e a confiabilidade no fornecimento de energia elétrica, considerando este novo perfil de consumo.

Uma alternativa potencial, que melhor lida com esta atualização complexa na demanda, é a geração distribuída (GD), que se apresenta como uma solução promissora para melhoria da segurança e solidez em redes elétricas. Segundo Rosa et al. (2022, p. 3), esse modelo, por sua própria estrutura descentralizada, é capaz de manter o funcionamento do sistema mesmo diante de falhas na rede elétrica convencional. A geração distribuída permite o monitoramento em tempo real tanto da geração quanto do consumo de energia, por meio de medidores inteligentes (*smart meters*), que coletam dados continuamente e possibilitam um gerenciamento mais eficiente. Quando esse gerenciamento é otimizado, há redução de desperdícios, aumento da eficiência energética e maior integração com fontes renováveis, como sistemas fotovoltaicos e turbinas eólicas. Esses elementos compõem o conceito das redes inteligentes, baseadas na comunicação ativa entre os agentes do sistema, oferecendo a versatilidade necessária para lidar melhor com o aumento no uso de energia elétrica.

O Ministério de Minas e Energia (2021, p. 22) destaca que “as primeiras tentativas de se instalar alguma inteligência na rede advieram da medição eletrônica, que foi usada para monitorar o comportamento da carga de grandes consumidores”. Desde então, o monitoramento de cargas passou a desempenhar um papel estratégico no funcionamento de sistemas de geração distribuída, viabilizando a classificação de cargas, a detecção de falhas na rede e o aprimoramento do controle energético. Dentre os métodos disponíveis, destacam-se o monitoramento não-intrusivo de cargas (NILM), reflectometria no domínio do tempo (TDR) e da frequência (FDR).

Devido ao grande volume de dados gerados por esses métodos através dos sensores utilizados, técnicas de aprendizado de máquina têm sido aplicadas para extrair padrões, optimizar decisões e reduzir o tempo de resposta dos sistemas. Esses algoritmos são treinados com conjuntos de dados históricos, permitindo melhora significativa no desempenho das soluções implementadas.

Este trabalho tem por objetivo analisar os principais métodos de monitoramento de carga e os algoritmos de aprendizado de máquina a eles associados, destacando suas aplicações, limitações e vantagens. A partir de uma revisão comparativa, busca-se identificar as abordagens mais promissoras para o monitoramento de cargas em redes inteligentes, reforçando a relevância do tema para a modernização e sustentabilidade do setor elétrico.

2 Metodologia

2.1 Estratégia metodológica

Para a construção de um portfólio bibliográfico com relevância científica, foi adotado o método *Knowledge Development Process – Constructivist* (ProKnow-C), proposto por Ensslin et al. (2010). Esse método sistemático possibilita a seleção, análise e avaliação de produções científicas alinhadas ao tema de interesse.

2.2 Processo de seleção do portfólio bibliográfico

A primeira etapa consistiu na definição das palavras-chave relacionadas ao tema central do estudo. Utilizou-se a seguinte string de busca:

("reflectometry" OR "reflectometry" OR "reflectometry time domain" OR "load classification" OR "electrical load classification" OR "load monitoring") AND ("Machine learn" OR "IA" OR "artificial intelligence" OR "heuristic" OR "metaheuristic*" OR "optimization" OR "optimisation" OR "optimal control" OR "optimal allocation" OR "data analytics" OR "data structures and machine learning" OR "smart cities" OR "smart power grids")*

A pesquisa foi realizada nas bases SCOPUS e *Web of Science*, ambas em inglês, abrangendo o período de 2020 a 2025. A coleta ocorreu em 1º de junho de 2025, apresentando o seguinte resultado:

Scopus: 507 artigos encontrados e *Web of Science*: 343 artigos encontrados.

O total inicial de 850 artigos passou por seis etapas de filtragem, como representado na Figura 1 abaixo.

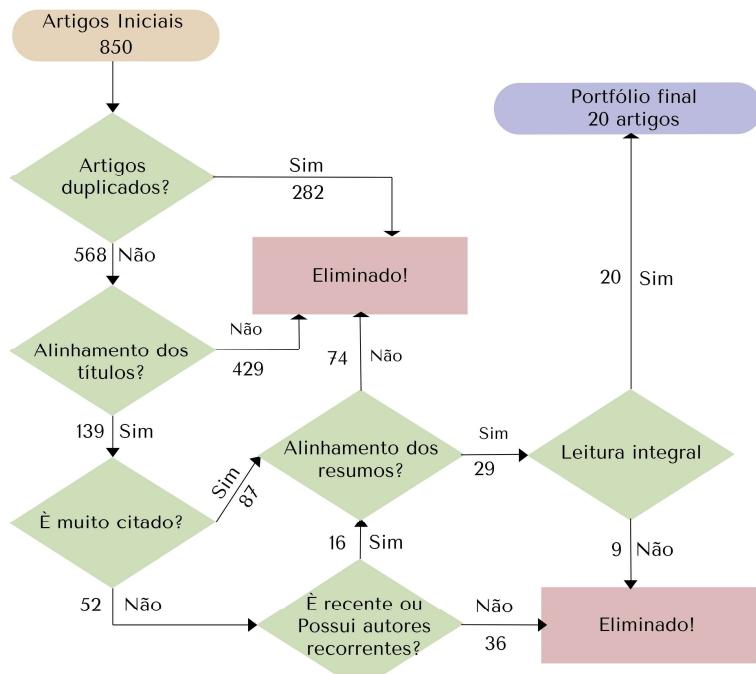


Figura 1. Representação esquemática do processo de filtragem.

A Figura 2 mostra a quantidade de artigos obtidos após cada etapa de filtragem.

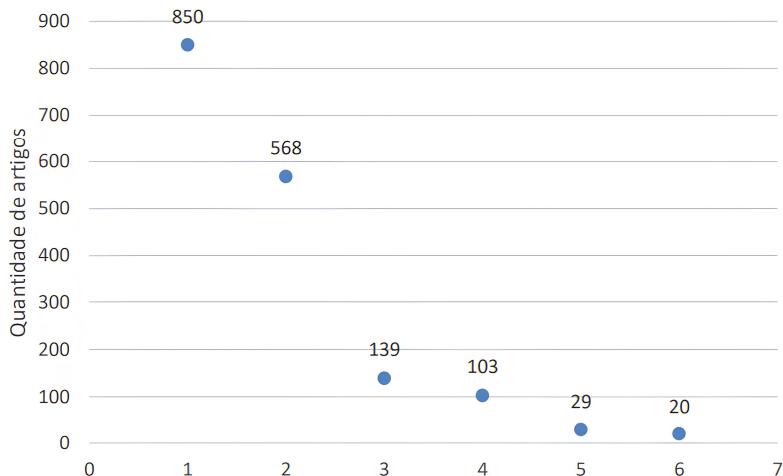


Figura 2. Quantidade de artigos por etapa de filtragem.

2.3 Análise bibliométrica

Com o portfólio bibliográfico final estabelecido, foi conduzida uma análise bibliométrica visando identificar padrões temporais, geográficos e temáticos da produção científica. Logo, pode-se observar que:

- A Figura 3 apresenta a distribuição por ano de publicação, com destaque para 2021, que representa 45% do total.
- A Figura 4 aponta a revista *IEEE Sensors Journal* como a mais relevante, com 4 artigos no portfólio, correspondendo a 20% do portfólio bibliográfico.
- A Figura 5 traz as palavras mais recorrentes nos títulos e mostra novas palavras-chave como: *learning systems* e *identification* que podem ampliar o portfólio de pesquisa.
- A Figura 6 demonstra a distribuição por países, com 55% dos autores sendo da China, destacando o país como uma referência dentro do cenário científico e tecnológico sobre o tema em questão.

- e) A Tabela 1 revela que os Estados Unidos lideram em número de citações, o que mostra que o país tem investido fortemente no desenvolvimento do tema.
- f) A Tabela 2 mostra a relevância dos autores, com destaque para Furse et al. (2020), com 211 citações, este artigo foi publicado na revista *IEEE Sensors Journal* a de maior relevância do portfólio a qual pertence aos Estados Unidos.

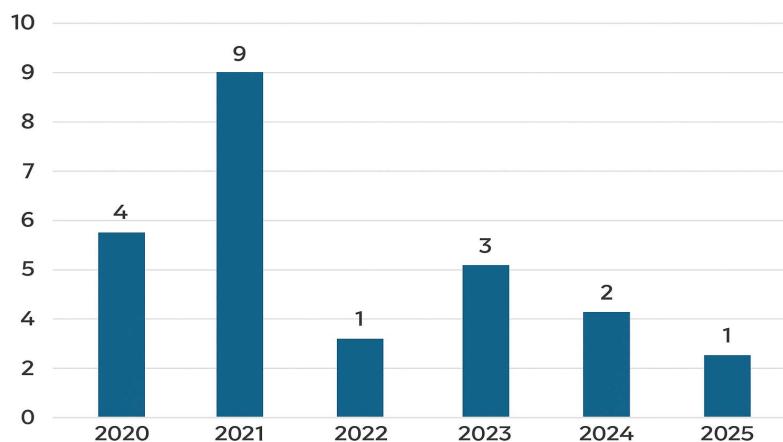


Figura 3. Número de artigos do portfólio bibliográfico por ano.

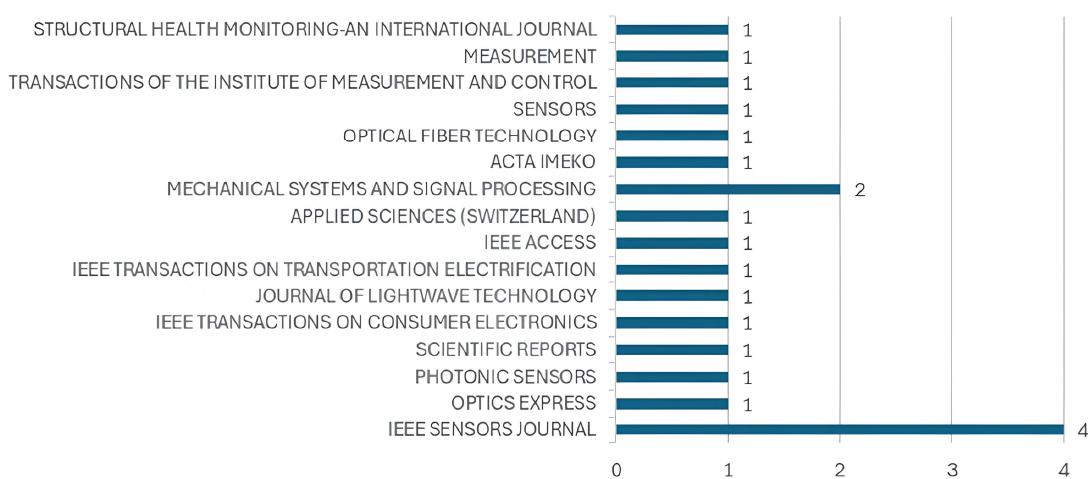


Figura 4. Quantidade de artigos do portfólio bibliográfico por revista.



Figura 5. Nuvem de palavras.

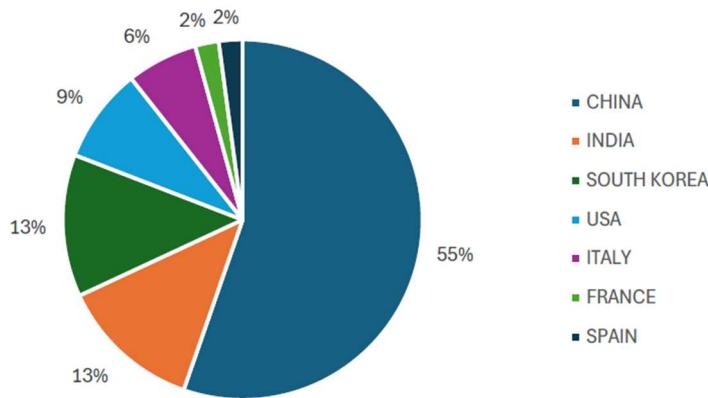


Figura 6. Produção de artigos por nacionalidade dos autores.

Tabela 1. Países com mais citações.

Países	N. de Citações
EUA	351
China	116
Índia	61
França	26
Bangladesh	18
Itália	18
Coreia	2

Tabela 2. Autores com mais citações por artigo.

Artigo	N. de Citações
Furse et al. (2021)	211
Peng et al. (2020b)	83
Rao et al. (2021)	80
Peng et al. (2020a)	39
Ghosh et al. (2021)	34
Awwad et al. (2020)	26
Ghosh et al. (2020)	20
Ma et al. (2022)	18
Ahammed et al. (2021)	18
Hu et al. (2020)	12

Essa análise bibliométrica revela a diversidade temática e metodológica da literatura, com aplicações que vão desde redes elétricas inteligentes a monitoramento por satélite, reafirmando o caráter interdisciplinar do tema.

2.4 Análise sistêmica

A análise sistêmica consiste na avaliação aprofundada do conteúdo dos artigos selecionados, considerando suas contribuições, metodologias e técnicas empregadas. A seguir, sintetizam-se os principais pontos observados em parte representativa do portfólio:

Zhou et al. (2021) propõe uma solução acessível para monitoramento de carga não intrusivo (NILM) em dispositivos residenciais de baixo custo. O algoritmo desenvolvido, baseado em redes neurais probabilísticas auto-organizáveis (SPNN), estima funções de densidade de probabilidade para classificar os dispositivos, com menor complexidade e melhor convergência em comparação a redes de retropropagação.

Apresenta-se em (Furse et al., 2020) uma revisão abrangente das abordagens aplicadas às redes elétricas e veículos, destacando métodos de reflectometria (TDR, STDR, SSTDR, FDR) e técnicas

automatizadas com algoritmos genéticos, redes neurais e ferramentas de otimização. O trabalho fornece referências relevantes para soluções futuras de monitoramento.

Peng et al. (2020b) integram inteligência artificial com sensoriamento por fibra óptica distribuída para prevenir degradação e intrusões em sistemas de dutos. Utilizam o sistema de sensorização acústica distribuída (DAS) com reflectometria óptica sensível à (Φ -OTDR), alcançando 94% de eficiência na detecção de defeitos.

Em complemento, Rao et al. (2021) realizam uma análise histórica da Φ -OTDR, destacando o centro de pesquisa de fibra óptica (FORC) da UESTC como líder na área e mostrando aplicações industriais do sensor acústico distribuído.

Peng et al. (2020a) utilizam retroespelhamento de Rayleigh e DAS com aprendizado de máquina não supervisionado via redes neurais convolucionais profundas para identificar eventos sonoros causados por locomoção humana, com 77,65% de acurácia.

Um algoritmo de colônia de abelhas (ABC) é proposto por (Ghosh and Chatterjee, 2021) para estimar correntes elétricas consumidas por aparelhos, com menor custo computacional, testado em ambiente residencial.

Awwad et al. (2020) apresentam técnica baseada em reflectometria óptica de fase diferencial no domínio do tempo ($\delta\Phi$ -OTDR) para detectar vibrações ao longo de 50 km de fibra óptica, utilizando arquitetura óptica com o processamento multiresolução, mostrando eficácia mesmo com ruído.

Um sistema baseado em ML é proposto por (Ma et al., 2022) para identificar falhas em cargas pulsantes de navios de guerra, com implementação em tempo real utilizando um processador digital de sinais (DSP).

Ghosh et al. (2020) apresentam algoritmo ABC modificado para identificação de consumo em medidores inteligentes com internet das coisas (IoT), com baixa demanda computacional e implementação simples.

É apresentado por (Ahammed et al. 2021) um Sistema de monitoramento de carga não intruso em tempo real (RT-NILM) baseado em IoT com coleta de corrente, tensão e potência, alcançando mais de 95% de acurácia na classificação de cargas.

Cazzulani and Pennacchi (2021) propõem um algoritmo de otimização para sensores OBR, com foco em estruturas complexas. A abordagem permite identificação modal com menor intrusão e boa resolução espacial.

Li et al. (2023a) utilizam algoritmo genético com decomposição de modo variacional (VMD) para aprimorar a supressão dos ruídos em sinais de DAS obtidos por Φ -OTDR, com melhora significativa na precisão.

Yang et al. (2024) combinam o algoritmo de busca Sparrow aprimorado (ISSA) com técnicas adaptativas para reduzir parâmetros de entrada em algoritmos baseados em Φ -OTDR, mantendo 95,83% de acurácia.

Hu et al. (2020) usam inteligência artificial aplicada à internet das coisas (AIoT) para desagregação de carga com redes neurais multicamadas e algoritmos genéticos paralelos, com validação de dados públicos e foco em eficiência e custo.

De acordo com Yin et al. (2023) o uso de reflectometria de domínio de frequência óptica (OFDR) com redes neurais para classificação espectral do espalhamento de Rayleigh, se mostra mais rápido e preciso que a correlação cruzada.

Tangudu e Sahu (2021) utilizam Rayleigh Φ -OTDR com algoritmos supervisionados para detecção de intrusão ao longo de 25 km de fibra, obtendo 100% de acurácia.

Li et al. (2023b) apresentam sistema para detecção precoce de incêndios via reflectometria ultrassônica e algoritmo competitivo imperialista (ICA), com alta eficiência na seleção de componentes relevantes.

O monitoramento de cargas não intrusivas (NILM) em tempo quase real é analisado por Bucci et al. (2021), com uso de redes neurais convolucionais (CNNs) para classificação de aparelhos multiestados a partir de suas características físicas.

Zhao et al. (2025) combinam OFDR, elementos finitos, regressão vetorial de suporte (SVR) e algoritmo de enxame de partículas (PSO) para detectar fissuras com precisão milimétrica em estruturas reais.

Park et al. (2024) utilizam reflectometria (tempo e frequência) com decodificação automática com e sem ruído (DAE e AE), rede geradora adversarial de séries temporais (TIMEGAN) para detectar falhas de arco em série (SAFs) em sistemas fotovoltaicos, reduzindo ruído e melhorando a precisão.

A análise sistêmica mostra uma diversidade metodológica e uma tendência crescente à integração entre IA, IoT e sensoriamento óptico. Os métodos NILM permanecem consolidados, enquanto os sensores por reflectometria surgem como uma tecnologia promissora. No entanto, observa-se uma lacuna na aplicação

dessa tecnologia a redes inteligentes com geração distribuída. Estudos futuros devem explorar essa integração, com uso de sensores para coleta de dados em tempo real e IA para tomada de decisão, com foco em manutenção preditiva, confiabilidade da rede e sustentabilidade energética.

3 Resultados e discussões

A análise do portfólio bibliográfico, construída a partir da metodologia Proknow-C e compreendendo o período de 2020 a 2025, teve como foco o uso de diferentes métodos de monitoramento de cargas elétricas e seus potenciais aplicações, especialmente quando integrados a algoritmos de aprendizado de máquina. Tais algoritmos desempenham papel essencial no tratamento de grandes volumes de dados e na automação de processos decisórios em sistemas energéticos inteligentes.

Os 20 artigos selecionados foram classificados em três categorias principais de abordagem:

- Métodos NILM (*Non-Intrusive Load Monitoring*);
- Métodos diversos baseados em aprendizado de máquina;
- Métodos baseados em sensores de reflectometria.

Esses métodos contemplam desde aplicações voltadas especialmente ao monitoramento de carga elétrica até estudos com finalidades mais amplas, como o sensoriamento acústico e a detecção de falhas estruturais. Tal diversidade reforça a versatilidade dos métodos analisados e a possibilidade de sua aplicação em contextos distintos, com destaque para sua relevância nos sistemas de redes inteligentes.

Cada uma das abordagens analisadas apresenta vantagens e limitações que devem ser consideradas conforme a natureza e a complexidade do problema a ser enfrentado. De modo geral, observou-se que:

- Os métodos NILM são consolidados e amplamente utilizados no ambiente residencial e predial, com ênfase na eficiência energética.
- Os métodos diversos incluem combinações inovadoras de técnicas de otimização, inteligência artificial e internet das coisas (IoT), mostrando-se eficazes em cenários variados.
- Os métodos baseados em reflectometria, embora ainda pouco aplicados diretamente ao monitoramento de carga elétrica, revelam elevado potencial técnico, especialmente por sua alta resolução, longo alcance e capacidade de detecção remota em tempo real.

Dentre os três grupos, destaca-se o potencial exploratório dos sensores baseados em reflectometria para aplicações futuras em redes elétricas inteligentes. Tais sensores, se integrados a sistemas de IoT e aprendizado de máquina, podem viabilizar a coleta e o processamento em tempo real de dados estratégicos, permitindo decisões proativas de manutenção e operação da rede. Essa capacidade é especialmente relevante em cenários de geração distribuída com fontes renováveis, contribuindo para a redução de falhas, a prevenção de apagões e a diminuição da emissão de gases de efeito estufa.

Ressalta-se, contudo, a limitação desta revisão, que segue o viés de seleção utilizado pelo autor, limitação temporal da busca, utilização das palavras-chave e a exclusão de outras bases de dados relevantes, restringindo a abrangência dos resultados presentes.

4 Conclusões

Conclui-se que, independentemente do método específico adotado, o monitoramento de cargas elétricas se configura como um elemento central para a modernização e a sustentabilidade do setor energético. Com o crescimento da demanda por eletricidade e os constantes avanços tecnológicos, compreender e aplicar estratégias inteligentes de gestão energética baseadas em aprendizado de máquina é uma condição indispensável para o desenvolvimento de infraestruturas energéticas mais robustas, eficientes e adaptáveis aos novos desafios.

Este estudo contribui para uma melhor compreensão dos estudos sobre classificação de cargas elétricas, tendo como principais resultados obtidos os seguintes:

- a) Ressalta a importância do monitoramento de cargas elétricas para modernização dos sistemas de redes elétricas inteligentes com foco em eficiência e sustentabilidade, de maneira especial considerando aumento na demanda e a integração dos sistemas com fontes renováveis.
- b) Os métodos NILM apresentam-se como consolidados e funcionais em sistemas residenciais e prediais, empregados de forma mais comum em estudos envolvendo eficiência energética.
- c) Os métodos diversos que se baseiam em aprendizado de máquina, trazem flexibilidade conectando desde inteligência artificial, a internet das coisas, aumentando de forma significativa as possibilidades de aplicação.

- d) Os métodos baseados em reflectometria, tem potencial considerável, mesmo sendo pouco explorado no campo de monitoramento de cargas em redes inteligentes, sendo estes métodos precisos, com capacidade de detecção em tempo real e a longo alcance.
- e) Mostra que há potencial em conectar algoritmos de aprendizado de máquina a reflectometria, buscando melhores resultados na precisão dos modelos de monitoramento de carga, aumentando a confiabilidade e eficiência de sistemas de monitoramento.
- f) As limitações desta revisão ocasionadas pelo viés de seleção do autor como recorte temporal e escolha de bases de dados trazem um ponto de vista diferente deste estudo o que por sua vez, não invalidam sua relevância.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa e Inovação do Espírito Santo FAPES, pelo incentivo financeiro através do fornecimento de bolsa de estudos e a Universidade Federal do Espírito Santo pela estrutura e conhecimento fornecidos.

Referências bibliográficas

- Ahammed, MT, Hasan, MM, Arefin, MS, Islam, MR, Rahman, MA, Hossain, E and Hasan, MT (2021) ‘Real-time non-intrusive electrical load classification over IoT using machine learning’. *IEEE Access*, v. 9, pp.115053–115067. <https://doi.org/10.1109/ACCESS.2021.3104263>
- Awwad, E, Dorize, C, Guerrier, S and Renaudier, J (2020), ‘Detection-localization-identification of vibrations over long distance SSMF with coherent-OTDR’. *Journal of Lightwave Technology*, v. 38, n.12, pp.3089–3095.
- Bucci, G, Ciancetta, F, Fiorucci, E, Mari, S and Fioravanti, A (2021), ‘Measurements for non-intrusive load monitoring through machine learning approaches’. *Acta IMEKO*, v.10, n.4, pp.90–96. https://doi.org/10.21014/acta_imeko.v10i4.1184
- Cazzulani, G, Silva, A and Pennacchi, P (2021) ‘Optimization of continuous sensor placement for modal analysis: Application to an optical backscatter reflectometry strain sensor’. *Mechanical Systems and Signal Processing*, v.150, p.107242. <https://doi.org/10.1016/j.ymssp.2020.107242>
- Empresa de Pesquisa Energética (EPE) (2024) ‘Balanço energético nacional 2024: Relatório síntese – ano base 2023’. EPE. <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-ben>
- Ensslin, L, Ensslin, SR, Lacerda, RTO and Tasca, JE (2010) ‘ProKnow-C: Knowledge development process – constructivist’ [Unpublished Brazilian patent application]. *Instituto Nacional da Propriedade Industrial*.
- Furse, CM, Kafal, M, Razzaghi, R and Shin, YJ (2020) ‘Fault diagnosis for electrical systems and power networks: A review’. *IEEE Sensors Journal*, v. 21, n. 2, pp. 888–906. <https://doi.org/10.1109/JSEN.2020.2987321>
- Ghosh, S and Chatterjee, D (2021) ‘Artificial bee colony optimization based non-intrusive appliances load monitoring technique in a smart home’. *IEEE Transactions on Consumer Electronics*, v. 67, n.1, pp.77–86. <https://doi.org/10.1109/TCE.2021.3051164>
- Ghosh, S, Manna, D, Chatterjee, A and Chatterjee, D (2020) ‘Remote appliance load monitoring and identification in a modern residential system with smart meter data’. *IEEE Sensors Journal*, v. 21, n. 4, pp. 5082–5090. <https://doi.org/10.1109/JSEN.2020.3035057>
- Hu, YC, Lin, YH and Lin, CH (2020) ‘Artificial intelligence, accelerated in parallel computing and applied to nonintrusive appliance load monitoring for residential demand-side management in a smart grid: A comparative study’. *Applied Sciences*, v. 10, n.22, p. 8114. <https://doi.org/10.3390/app10228114>
- Li, TX, Zhang, FD, Lin, J, Bai, XY and Liu, HZ (2023a) ‘Fading noise suppression method of Φ-OTDR system based on GA-VMD algorithm’. *IEEE Sensors Journal*, v. 23, n.19, pp. 22608–22619. <https://doi.org/10.1109/JSEN.2023.3306199>

- Li, X, Chen, J, Sun, L, Li, J and Zhao, X (2023b) ‘Research on sparse decomposition processing of ultrasonic signals of heat exchanger fouling’. *IEEE Sensors Journal*, v. 23, n.14, pp. 15795–15802. <https://doi.org/10.1109/JSEN.2023.3279413>
- Ma, Y, Maqsood, A, Oslebo, D and Corzine, K (2021) ‘Wavelet transform data-driven machine learning-based real-time fault detection for naval DC pulsating loads’. *IEEE Transactions on Transportation Electrification*, v. 8, n.2, pp.1956–1965. <https://doi.org/10.1109/TTE.2021.3130044>
- Ministério de Minas e Energia (MME) (2021) ‘Relatório Smart Grid: Grupo de Trabalho de Redes Elétricas Inteligentes’. *Ministério de Minas e Energia*. <https://www.gov.br/mme/pt-br/assuntos/secretarias/secretaria-nacional-energia-eletrica/relatorio-smart-grid-1/documentos>
- Park, HP, Kwon, GY, Lee, CK and Chang, SJ (2024) ‘AI-enhanced time–frequency domain reflectometry for robust series arc fault detection in DC grids’. *Measurement*, v. 238, p. 115188. <https://doi.org/10.1016/j.measurement.2024.115188>
- Peng, Z, Wen, H, Jian, J, Gribok, A, Wang, M, Huang, S and Chen, KP (2020a). ‘Identifications and classifications of human locomotion using Rayleigh-enhanced distributed fiber acoustic sensors with deep neural networks’. *Scientific Reports*, v.10, i n.1, p. 21014. <https://doi.org/10.1038/s41598-020-77147-2>
- Peng, Z, Jian, J, Wen, H, Gribok, A, Wang, M, Liu, H, Huang, S, Mao, ZH and Chen, p (2020b) ‘Distributed fiber sensor and machine learning data analytics for pipeline protection against extrinsic intrusions and intrinsic corosions’. *Optics Express*, v. 22, n. 16, p. 27277-27292. <https://doi.org/10.1364/OE.397509>
- Rao, Y, Wang, Z, Wu, H, Ran, Z and Han, B (2021) ‘Recent advances in phase-sensitive optical time domain reflectometry (Φ -OTDR)’. *Photonic Sensors*, v. 11, pp. 1–30. <https://doi.org/10.1007/s13320-021-0619-4>
- Rosa, C, Coimbra, M, Barbosa, P, Chantre, C and Rosental, R. (2022) ‘Microrredes: Benefícios e desafios para o setor elétrico brasileiro’. GESEL/UFRJ. https://www.gesel.ie.ufrj.br/app/webroot/files/publications/10_Rosa_2022_02_02.pdf
- Tangudu, R. and Sahu, PK (2021) ‘Rayleigh Φ -OTDR based DIS system design using hybrid features and machine learning algorithms’. *Optical Fiber Technology*, v. 61, p. 102405. <https://doi.org/10.1016/j.yofte.2020.102405>
- Yang, G, Luan, B, Sun, J, Niu, J, Lin, H. and Wang, L (2024) ‘Sparrow search mechanism-based effective feature mining algorithm for the broken wire signal detection of prestressed concrete cylinder pipe’. *Mechanical Systems and Signal Processing*, v. 212, p. 111270. <https://doi.org/10.1016/j.ymssp.2024.111270>
- Yin, G, Zhu, Z, Liu, M, Wang, Y, Liu, K, Yu, K. and Zhu, T, (2023) ‘Optical frequency domain reflectometry based on multilayer perceptron’. *Sensors*, v. 23, n.6, p. 3165.
- Zhao, L, Zhang, J, You, R. and Li, HN (2025) ‘Automatic detection of crack depth and width combining inverse finite-element and PSO-optimized SVR method with OFDR fiber-optic sensors’. *Structural Health Monitoring*, pp. 1–17. <https://doi.org/10.1177/14759217251327728>
- Zhou, Z, Xiang, Y, Xu, H, Wang, Y, Shi, D and Wang, Z (2021) ‘Self-organizing probability neural network-based intelligent non-intrusive load monitoring with applications to low-cost residential measuring devices’. *Transactions of the Institute of Measurement and Control*, v. 43, n.3, pp. 635–645. <https://doi.org/10.1177/0142331220950865>