Estudo Comparativo de Técnicas de Desagregação de Energia Residencial a partir de Medições de Baixa Frequência de Amostragem

Carlos Alejandro Urzagasti * **Lucas V. Hartmann** * **Jorge G. Lima** * **Thaysa Souza Lima** * **Fabiano Salvadori** *

* *Universidade Federal da Paraíba (UFPB)*
Programa de Pós-graduação em Engenharia Elétrica (PPGEE)
Laboratório de Redes Elétricas Inteligentes (LREI)
(e-mails: carlos.urzagasti@estudante.cear.ufpb.br, salvadori.fabiano@cear.ufpb.br).

Abstract: In this article, techniques for residential energy disaggregation are compared to identify and separate the consumption of different appliances. Traditional methods such as Combinatorial Optimization (CO) and Factorial Hidden Markov Models (FHMM) are contrasted with Deep Learning (DL) approaches like Recurrent Neural Networks (RNN) and Denoising Autoencoders (DAE), using data from the UK-DALE and DATAPORT databases. The results highlight the superiority of DL techniques in accuracy, despite the additional training time and computational resources required. Transfer Learning (TL) also poses challenges in generalizing models to different geographical contexts. This article underscores the importance of considering not only accuracy but also computational cost when choosing energy disaggregation methods, contributing to research in residential energy efficiency and emphasizing the need for new strategies.

Resumo: Neste artigo, são comparadas técnicas de desagregação do consumo de energia residencial para identificar e separar o consumo de diferentes eletrodomésticos. Métodos tradicionais, como Otimização Combinatória (CO) e Modelos de Markov Ocultos Factoriais (FHMM), são comparados com abordagens de Aprendizado Profundo (DL), como Redes Neurais Recorrentes (RNN) e Autoencoders Denoising (DAE), utilizando dados das bases UK-DALE e DATAPORT. Os resultados destacam a superioridade das técnicas de DL em precisão, apesar do tempo de treinamento e dos recursos computacionais adicionais. A Transferência de Aprendizado (TL) também apresenta desafios na generalização dos modelos para diferentes contextos geográficos. Este artigo ressalta a importância de considerar não apenas a precisão, mas também o custo computacional na escolha dos métodos de desagregação de energia, contribuindo para a pesquisa em eficiência energética residencial e enfatizando a necessidade de novas estratégias.

Keywords: NILM; energy disaggregation; machine learning; low sampling rate; UK-DALE; DATAPORT

Palavras-chaves: NILM; desagregação de energia; aprendizado de máquina; baixa taxa de amostragem; UK-DALE; DATAPORT

1. INTRODUÇÃO

O aumento do consumo de energia elétrica residencial nos últimos anos foi impulsionado principalmente pelo crescimento populacional, maior acesso à energia e avanços tecnológicos conforme a Agência Internacional de Energia (2023). Neste contexto, estudos conduzidos por Abrahão (2021); Manuel (2020) analisaram os perfis de consumo energético residencial ao longo do tempo e associaram o aumento do consumo de energia a práticas ineficientes, como o uso frequente de eletrodomésticos em modo *stand-by* e hábitos inadequados, como deixar luzes e aparelhos ligados desnecessariamente e operar eletrodomésticos fora de sua capacidade ideal. Diante disso, os autores Chatzigeorgiou and Andreou (2021) analisaram estratégias de mudança de comportamento em direção à eficiência com a implementação de *feedback*, os quais permitem aos usuários monitorar seu consumo de energia em tempo real através de medidores inteligentes (*Smart Meters*). Contudo, a medição eficaz do consumo total de energia permanece como um desafio significativo, ressaltando a necessidade de abordagens mais precisas e detalhadas.

Neste contexto, o Monitoramento de Carga Não Intrusivo (*Non-Intrusive Load Monitoring* (NILM)), proposto por Hart (1992), surge como uma solução viável, que envolve a determinação do consumo individual de eletrodomésticos através de um único ponto de medição na rede elétrica. A partir desta única medida, as contribuições individuais de cada dispositivo são obtidas por meio de uma abordagem

de Desagregação de Energia, que consiste em separar o consumo total de energia em diferentes componentes, identificando o consumo de energia de dispositivos individuais.

Nos últimos anos, diversas abordagens de desagregação de energia, baseadas em técnicas de aprendizado de máquina (*Machine Learning* (ML)), têm sido amplamente investigadas, conforme demonstrado em estudos como Jiang et al. (2021); Azad (2023); Gopinath et al. (2020). O aprendizado supervisionado, que usa dados rotulados, tem se destacado por mapear o consumo total de energia ao consumo específico de eletrodomésticos, enquanto o aprendizado não supervisionado foca em identificar padrões ocultos nos dados sem necessidade de rótulos. A transferência de aprendizado (*Transfer Learning* (TL)) também tem sido explorada para adaptar modelos previamente treinados a novos conjuntos de dados, aumentando a flexibilidade das soluções. Revisões recentes, como as de Bousbiat (2023); Azad (2023); Schirmer (2022), destacam a variedade de abordagens aplicadas à desagregação de energia nos últimos anos, ressaltando a importância de avaliar os desafios específicos de cada cenário para selecionar as técnicas mais adequadas para o NILM.

Consequentemente, as diversas técnicas implementadas trocam a complexidade física de instalar medidores individuais para cada eletrodoméstico pela complexidade computacional, resultando em uma opção economicamente mais viável. No entanto, a complexidade computacional surge devido à quantidade de dados que precisam ser processados Himeur et al. (2023). Conforme as revisões de técnicas realizadas por Schirmer (2019), taxas de amostragem são consideradas de alta frequência se forem obtidas a uma taxa maior que 1 Hz; caso contrário, são denominadas de baixa frequência, o que tem um custo computacional consideravelmente baixo.

Diante disso, este estudo investiga técnicas de desagregação de energia para medições de baixa frequência, baseando-se na literatura mais recente. A pesquisa compara essas técnicas em diferentes bases de dados e contextos geográficos, além de verificar suas limitações, visando avaliar sua aplicabilidade e eficiência em cenários residenciais.

2. FUNDAMENTAÇÃO TEÓRICA

Nesta seção, é apresentada uma breve revisão teórica sobre a desagregação de energia, abordando o conceito e a formulação do problema subjacente e são exploradas as bases de dados mais relevantes.

2.1 Formulação do problema de desagregação de energia

No âmbito da desagregação de energia, conforme Schirmer (2022), o processo do NILM pode ser compreendido em três etapas: 1) coleta de dados; 2) processamento dos dados; e 3) identificação e separação das fontes de consumo. Cada aparelho elétrico em uma residência contribui para o consumo total de energia de forma única.

Imagine que cada tipo de aparelho elétrico tem sua própria "assinatura" de consumo de energia ao longo do tempo. Essa "assinatura" é representada pela sequência de potência $P_i(t)$, onde i representa o tipo de aparelho e t é o tempo.

A potência total consumida por uma residência ao longo do tempo pode ser vista como uma combinação das potências individuais de cada aparelho. Essa soma total é essencialmente a soma de todas as "assinaturas" de potência dos aparelhos, conforme representado pela Equação 1:

$$P_{\text{agg}}(t) = \{p_1, p_2, \ldots, p_i, \ldots, p_n\} = \sum_{i=1}^{N} P_i(t) \qquad (1)$$

onde N é o número total de tipos de dispositivos, p_i representa a potência total consumida pela residência, e $P_i(t)$ é a sequência de potência do tipo i.

Durante a coleta de dados, podem ocorrer erros ou ruídos nos registros de consumo, distorcendo a visão do consumo real. As técnicas de desagregação identificam a contribuição de cada aparelho elétrico, mesmo diante dessas interferências.

Utilizando algoritmos avançados, as técnicas de desagregação analisam os padrões de consumo de energia ao longo do tempo para separar as "assinaturas" dde potência de cada aparelho. O processo inclui a identificação precisa dos dispositivos em operação, além da detecção de eventos e mudanças abruptas no consumo. O objetivo final é estimar com precisão a potência consumida por cada aparelho, permitindo que os usuários identifiquem os maiores responsáveis pelo consumo de energia e adotem práticas mais eficientes, resultando em economia de energia e otimização de recursos.

2.2 Base de dados

As bases de dados, ou *datasets*, são conjuntos de medições de grandezas elétricas, como tensão, corrente e potência, utilizadas em pesquisas de desagregação de energia. Estudos recentes mostram que as bases de dados *UK-DALE* e *DATAPORT* são amplamente utilizadas em estudos de NILM, principalmente por suas medições de baixa frequência, adequadas para análises em ambientes residenciais. Ambas as bases de dados fornecem dados extensos e detalhados, o que permite uma avaliação robusta das técnicas de desagregação. A Tabela 1 apresenta as características dessas duas bases de dados, com foco em medições de baixa frequência e sua relevância para pesquisas de desagregação de energia.

Tabela 1. Base de dados de baixa frequência.

Ano	Base de Dados	Características	Duração	Tx. de amos.
2015	UK-DALE	P,Q,V,I,S	665 dias	6 segundos
2018	DATAPORT	P	1460 dias	60 segundos

3. REVISÃO SISTEMÁTICA DA LITERATURA

O procedimento metodológico descrito nesta seção teve como objetivo a busca, seleção e análise dos trabalhos acadêmicos e científicos relevantes nas técnicas de desagregação de energia residencial de baixa amostragem. A análise abrange os últimos 10 anos, com ênfase nas pesquisas mais recentes em NILM, a partir de 2015, quando ocorreram avanços significativos na área. Para a realização da revisão sistemática foi utilizando a metodologia *Methodi Ordinatio*, proposta por Pagani and Kovaleski (2017), os

critérios de seleção consideraram ano de publicação, fator de impacto e número de citações, consultando as bases de dados *Web of Science, Scopus e Science Direct*. Foram utilizadas palavras-chave como *Electrical Energy Disaggregation*, *Non-intrusive Load Monitoring (NILM)*, *Residential Electrical Energy Consumption*, e *Low Frequency*. Após a aplicação de filtros, 1213 publicações iniciais foram reduzidas a um conjunto final de 17 artigos.

A análise dos artigos selecionados revelou que as técnicas de aprendizado profundo têm ganhado destaque nos últimos anos. As técnicas mais prevalentes identificadas foram Seq2point (*Sequence-to-Point Learning*), RNN (*Recurrent Neural Networks*), DAE (*Denoising Autoencoders*), FHMM (*Factorial Hidden Markov Models*), Seq2Seq (*Sequence-to-Sequence Learning*) e Online GRU (*Online Gated Recurrent Units*). Zhang et al. Zhang et al. (2023) introduziram o modelo Seq2point (*Sequence-to-Point Learning*), que trouxe melhorias significativas na desagregação de energia residencial, sendo comparado favoravelmente com abordagens como Seq2Seq (*Sequence-to-Sequence Learning*) em bases como UK-DALE e REDD. Jia et al. Jia et al. (2021) expandiram esta abordagem com convoluções dilatadas bidirecionais, aprimorando ainda mais os resultados em dados de baixa frequência.

Técnicas como RNN foram amplamente exploradas por Cimen et al. (2022) , que aplicaram uma abordagem baseada em reforço profundo para desagregação de energia em tempo real, adaptando-se a padrões de consumo dinâmicos. Weng et al. Weng and Zhang (2023) propuseram uma versão leve do Seq2point, voltada para aplicações de edge computing, mostrando eficiência na desagregação de energia em dispositivos com baixa capacidade de processamento.

Bonfigli et al. (2018) utilizaram DAE para remover ruídos dos sinais de energia, resultando em maior precisão na identificação de aparelhos. Por outro lado, os Modelos Ocultos de Markov Fatoriais (FHMM), originalmente propostos por Hart (1992), continuam sendo uma técnica tradicional de referência, embora menos eficiente em comparação com as abordagens modernas baseadas em aprendizado profundo.

Wang et al. (2023) também propuseram uma abordagem baseada em Online GRU, que tem demonstrado grande potencial para desagregação de energia em tempo real, especialmente em cenários de monitoramento contínuo de energia residencial. No entanto, observa-se uma carência de estudos comparativos abrangentes dessas técnicas, especialmente em medições de baixa frequência em ambientes residenciais. Além disso, há uma lacuna de estudos que explorem o desempenho dessas técnicas em diferentes bases de dados geograficamente distintas, como DATAPORT [1] e UK-DALE [2], o que limita a análise comparativa entre regiões.

Destaca-se também a relevância da ferramenta NILMTK *Non-Intrusive Load Monitoring Toolkit* (NILMTK) [3], proposta melhorada por Batra et al. Batra et al. (2019), para facilitar a pesquisa, análises comparativas e desenvolvimento de algoritmos de desagregação de energia não intrusivos, oferecendo uma variedade de métodos e ferramentas para avaliação de desempenho.

4. MATERIAIS E MÉTODOS

Nesta seção, os eletrodomésticos residenciais selecionados para a experimentação são definidos, juntamente com a seleção da base de dados mais apropriada em conformidade com essa escolha. Posteriormente, são descritas as técnicas a serem empregadas na experimentação e configuração dos modelos, bem como as métricas de desempenho que serão utilizadas para conduzir a análise comparativa.

4.1 Seleção dos eletrodomésticos

Com o propósito de selecionar os eletrodomésticos mais representativos em uma residência, este estudo considerou aqueles comumente utilizados no Brasil. Diversas pesquisas conduzidas por Fedrigo (2009); Manuel (2020); Abrahão (2021) identificaram os eletrodomésticos residenciais mais prevalentes na época de suas publicações e que exercem maior influência no consumo de energia. Uma tendência comum observada nessas investigações é a predominância de geladeiras, máquinas de lavar e micro-ondas, estima-se que esses aparelhos representem mais de 60% do consumo total de energia elétrica em uma residência padrão. Portanto, esses eletrodomésticos serão considerados para análise de desagregação de energia.

4.2 Seleção da base de dados e configurações

Com base nos eletrodomésticos selecionados (geladeiras, máquinas de lavar roupa e micro-ondas), foram analisadas as bases de dados que disponibilizam medições desses equipamentos. Portanto, para a análise experimental, foram selecionadas as bases de dados do UK-DALE, que inclui dados de 5 residências do Reino Unido, e da DATAPORT, que possui medições de aproximadamente 1000 residências de diferentes cidades, incluindo Puerto Rico, um território sob jurisdição dos Estados Unidos. Esses dados de Puerto Rico foram escolhidos por representarem medições mais recentes.

As residências 1 e 2 do UK-DALE foram escolhidas para este estudo por serem as únicas que possuem os eletrodomésticos selecionados (geladeira, micro-ondas e máquina de lavar), o que é fundamental para a análise de desagregação de energia. A Casa 1 foi monitorada de maio de 2013 até o final de 2017, enquanto a Casa 2 abrange o período de março de 2013 a abril de 2015. Para configurar os dados de treinamento e teste, foi utilizada uma divisão temporal: 80% dos dados de cada casa foram designados para treinamento, e os 20% finais para teste, garantindo uma avaliação consistente dos modelos.

A residência 4955 do Dataport foi usada para validação externa, permitindo testar os algoritmos com dados inéditos e assegurar sua generalização. Para todas as residências, foi adotada uma taxa de amostragem de 1 minuto para as medições de potência ativa, que foi o único parâmetro de entrada utilizado nos modelos de desagregação. A Tabela 2 apresenta os hiperparâmetros configurados e os algoritmos utilizados na análise comparativa. Esses algoritmos foram

[1] DAPORT: https://www.pecanstreet.org/dataport/
[2] UK-DALE:https://paperswithcode.com/dataset/uk-dale
[3] NILMTK-contrib: https://github.com/nilmtk/nilmtk-contrib

Tabela 2. Técnicas e configuração de hiperparâmetros

Técnica	Hiperparâmetros
Seq2point	epochs = 100, batch_size = 64, learning_rate = 0.0001, optimizer = Adam, sequence_length = 599
RNN	epochs = 150, batch_size = 128, learning_rate = 0.0005, optimizer = RMSProp, units = 128, layers = 2, dropout = 0.3
DAE	epochs = 100, batch_size = 128, learning_rate = 0.0003, optimizer = Adam, layers = [512, 256, 128], dropout = 0.4
FHMM	n_components = 3, tol = 0.01, covariance_type = 'diag', n_iter = 200
Seq2Seq	epochs = 200, batch_size = 128, learning_rate = 0.0005, optimizer = Adam, encoder_units = 128, decoder_units = 128
Online GRU	epochs = 150, batch_size = 128, learning_rate = 0.0005, optimizer = Adam, units = 128, dropout = 0.2

selecionados com base nas observações da revisão sistemática da literatura. Os testes foram realizados utilizando a biblioteca NILMTK em suas configurações padrões.

4.3 Métricas de desempenho

As métricas de desempenho utilizadas na avaliação da desagregação de energia são selecionadas a partir da ferramenta NILMTK. Essas métricas incluídas são específicas para essa tarefa e oferecem uma avaliação precisa do desempenho dos algoritmos na separação do consumo de energia de diferentes aparelhos. A seguir são citadas:

Erro relativo na energia total atribuída: (ETEA) Usada para avaliar a estimativa de energia consumida por diferentes aparelhos, comparando-a com a energia real medida. Quanto menor for o erro na energia total atribuída, melhor será o desempenho do algoritmo de desagregação de carga.

$$\text{ETEA} = \frac{|E_{\text{atribuída}} - E_{\text{real}}|}{E_{\text{real}}} \times 100\% \tag{2}$$

Fração da energia total atribuída corretamente (FETAC): Avalia a precisão do algoritmo de desagregação de energia, pois mostra o quão bem ele consegue identificar e atribuir a energia consumida por cada aparelho em relação à energia total consumida. Quanto maior for a sobreposição entre as frações atribuídas e reais, melhor será o desempenho do algoritmo.

$$\text{FETAC} = \frac{\sum_n \min(E_{n,\text{atribuída}}, E_{n,\text{real}})}{\sum_n E_{n,\text{real}}} \tag{3}$$

F-score: Esta equação combina precisão e recall em uma única métrica, oferecendo uma medida única do desempenho do modelo de classificação. Essa métrica é útil para avaliar modelos de classificação, pois considera tanto falsos positivos quanto falsos negativos. Quanto mais próximo de 1 for o F-score, melhor será o desempenho geral do modelo.

$$F\text{-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{4}$$

Tempo de treinamento (s): O tempo de treinamento, medido em segundos, representa a duração necessária para treinar o algoritmo de desagregação de energia.

Tempo de desagregação (s): Refere-se à quantidade de tempo necessária para aplicar o algoritmo treinado aos dados de consumo de energia em tempo real.

4.4 Metodologia proposta

A metodologia adotada para analisar e comparar técnicas de desagregação de eletrodomésticos residenciais de baixa frequência foi utilizada ferramenta NILMTK e suas contribuições, identificada na revisão sistemática da literatura por sua diversidade de algoritmos avançados e adaptabilidade a diferentes conjuntos de dados.

A abordagem metodológica foi delineada conforme o fluxograma proposto na Figura 1. Inicialmente, são definidos os parâmetros de entrada e taxas de amostragem, utilizando a base de dados UK-DALE. A partir da seleção dos algoritmos citados anteriormente, estes são configurados para treinamento, teste e validação. O desempenho é avaliado com métricas mencionadas na seção 4.3. O algoritmo Otimização Combinatória (CO) é utilizado como referência. Destaca-se que o CO representa uma abordagem mais simples para resolver o problema de desagregação de energia. Caso os resultados dos algoritmos mais avançados não superem os resultados do CO, indicando um F-score inferior, isso pode sugerir a necessidade de revisão ou readaptação desses algoritmos. Posteriormente, o aprendizado é transferido para a base de dados DATAPORT, visando testar a generalização dos modelos. Os resultados são comparados entre as bases de dados e, por fim, conclui-se sobre a eficácia das técnicas NILM.

5. RESULTADOS E DISCUSSÕES

Para testar os modelos, foi utilizado um notebook equipado com processador Intel Core i5 de 10ª geração, 16 GB de RAM e uma placa de vídeo GTX 1650, em um ambiente de desenvolvimento utilizando o *Visual Studio Code* e a linguagem *Python*. Os modelos foram implementados e executados de forma iterativa, explorando ao máximo os recursos disponíveis. Os resultados experimentais apresentados foram obtidos com uma frequência de amostragem de uma medição por minuto. Destaca-se que é possível selecionar diferentes frequências de amostragem a partir de 1 Hz.

5.1 Resultados de validação interna

Na primeira fase de análise, se analisou os resultados de desagregação de energia para os eletrodomésticos de UK-DALE, representativa do contexto residencial do Reino Unido. Conforme os resultados apresentados na Figura 2, os algoritmos CO e FHMM apresentaram desempenho inferior devido à sua menor capacidade de modelar a complexidade dos padrões de consumo de energia.

Por outro lado, os algoritmos de Aprendizado Profundo (*Deep Learning* (DL)), com sua capacidade de capturar relações não-lineares e padrões complexos, tendem a ter um erro total atribuído menor. Neste caso métricas como

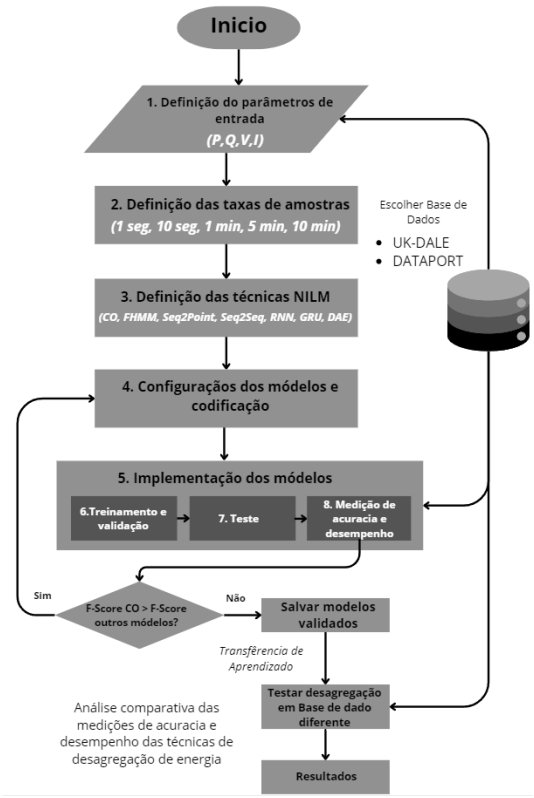

Figura 1. Delineamento da avaliação experimental. Fonte: Autor

ETEA, FTEAC e F-score foram utilizadas para avaliar o desempenho das técnicas de desagregação de energia. Os resultados indicaram que as técnicas de Aprendizado Profundo superaram os algoritmos tradicionais, apesentando um ETEA menor e FTEAC e F-score mais altos, evidenciando uma capacidade robusta de estimar e atribuir corretamente a energia consumida por diferentes aparelhos. Esses resultados sugerem que, em um ambiente controlado e homogêneo como o da UK-DALE. Além disso, os resultados demonstram um bom desempenho para baixas taxas de amostragem, destacando a eficácia das técnicas utilizadas mesmo em condições de baixa granularidade temporal.

5.2 Resultados de validação externa

Na segunda fase da análise, procurou-se validar os modelos treinados na UK-DALE em um contexto geográfico diferente, utilizando a base de dados DATAPORT, proveniente de Puerto Rico. Essa validação externa permitiu avaliar a capacidade de generalização dos modelos de desagregação de energia para ambientes residenciais com características distintas. No entanto, observou-se uma diminuição no desempenho dos modelos de aprendizado profundo durante essa transferência de aprendizado. Enquanto os algoritmos tradicionais, como CO e FHMM, mantiveram um desempenho mais estável, os modelos de aprendizado profundo apresentaram uma queda significativa no desempenho, especialmente em métricas como FTEAC e F-score. Essa observação sugere que os modelos de aprendizado profundo podem ser sensíveis às variações geográficas nos padrões de consumo de energia e nas características das redes elétricas residenciais. A capacidade reduzida de generalização desses modelos em ambientes diferentes daqueles em que foram treinados destaca a necessidade de desenvolver estratégias de transferência de aprendizado mais robustas e adaptáveis para promover avanços significativos na desagregação de energia residencial.

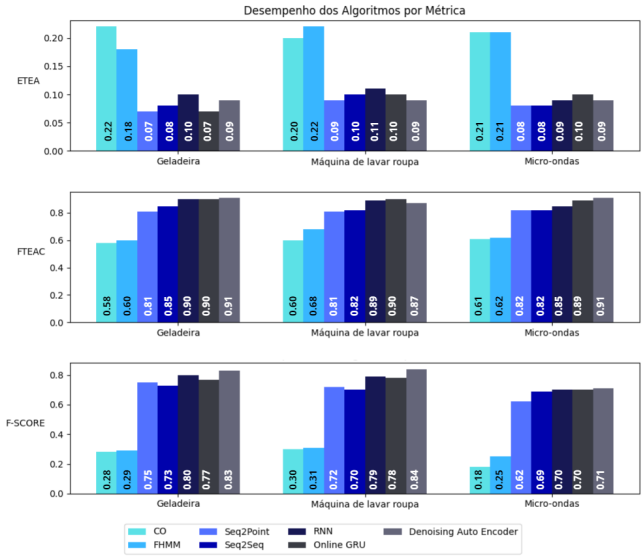

Figura 2. Avaliação de métricas do desempenho de desagregação de energia na base de dados de UK-DALE. Fonte: Autor

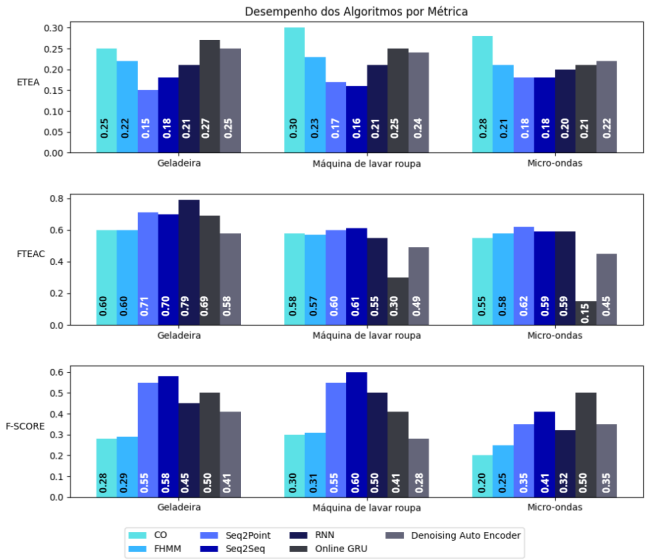

Figura 3. Avaliação de métricas do desempenho de desagregação de energia na base de dados de DATAPORT. Fonte: Autor

5.3 Análise de Desempenho e Custo Computacional

Os algoritmos de aprendizado profundo, demonstraram melhor desempenho na desagregação de energia em comparação com CO e FHMM. No entanto, essa melhoria no desempenho vem acompanhada de um maior custo computacional e tempo de treinamento, conforme a Tabela 3. Enquanto CO e FHMM conseguiram desagregar a energia em questão de segundos, os algoritmos de aprendizado profundo exigiram horas para treinar adequadamente e

alcançar resultados comparáveis. Assim, embora os algoritmos de aprendizado profundo se destaquem em precisão, é importante considerar seu custo computacional e tempo de aprendizado ao decidir sobre a escolha do método de desagregação de energia.

Tabela 3. Tempo médio de treinamento e desagregação de energia

Algoritmos	**Geladeira**	**Maq.lavar**	**Micro-ondas**
CO	4 seg	6 seg	5 seg
FHMM	15 seg	25 seg	18 seg
Algoritmos D.L.		1 hora a 4 horas	

6. CONCLUSÃO

As técnicas de aprendizado profundo mostraram-se superiores em termos de precisão na desagregação de energia residencial, superando as abordagens tradicionais como CO e FHMM. No entanto, essas técnicas também apresentaram um custo computacional significativamente maior, o que pode limitar sua aplicabilidade em cenários com restrições de recursos computacionais.

Além disso, foi observado que os modelos de aprendizado profundo enfrentam dificuldades de generalização quando aplicados em contextos geográficos diferentes, conforme demonstrado pelos resultados obtidos na validação externa com a base de dados DATAPORT. Por outro lado, os modelos tradicionais, como CO e FHMM, mostraram-se mais robustos nesse aspecto, mantendo uma generalização mais estável em diferentes bases de dados, apesar de sua menor precisão.

Por fim, ressalta-se a importância de encontrar um equilíbrio entre precisão e custo computacional ao selecionar métodos de desagregação de energia, especialmente em aplicações residenciais que demandam soluções mais eficientes e acessíveis, considerando também a capacidade de generalização dos modelos em diferentes cenários.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro do CNPq, Processos 302981/2023-3, 406662/2022-3, FAPESQ Edital Universal 09/202021 e do PPGEE/UFPB.

REFERÊNCIAS

Abrahão, K.S. (2021). Estimativa da evolução do uso final de energia elétrica no setor residencial do brasil por região geográfica. *Ambiente Construído*, 21.

Agência Internacional de Energia (2023). Electricity market report 2023. *IEA*. URL `https://www.iea.org/reports/electricity-market-report-2023`.

Azad, M. I., R. (2023). Non-intrusive load monitoring (nilm) using deep neural networks: A review. *arXiv preprint arXiv:2306.05017*.

Batra, N. et al. (2019). Towards reproducible state-of-the-art energy disaggregation. In *Proceedings of the 6th ACM international conference on systems for energy-efficient buildings, cities, and transportation*.

Bonfigli, R., Principi, E., Fiameni, S., and Squartini, S. (2018). Denoising autoencoders for non-intrusive load monitoring: improvements and comparative evaluation. *Energy and Buildings*, 158, 1461–1474.

Bousbiat, Hafsa, e.a. (2023). Neural load disaggregation: Meta-analysis, federated learning and beyond. *Energies*, 16(2), 991.

Chatzigeorgiou, I.M. and Andreou, G.T. (2021). A systematic review on feedback research for residential energy behavior change through mobile and web interfaces. *Renewable and Sustainable Energy Reviews*, 135, 110187.

Cimen, H., Wu, Z., and Zhang, S. (2022). Deep recurrent extreme learning machine for behind-the-meter energy disaggregation. *Energy and Buildings*, 258, 111827.

Fedrigo, N. S., G. (2009). Usos finais de energia elétrica no setor residencial brasileiro. Scientific research report, Universidade Federal de Santa Catarina, Florianópolis.

Gopinath, R., Mukesh Kumar, C., Chandra, P., and Srinivas, K. (2020). Energy management using non-intrusive load monitoring techniques – state-of-the-art and future research directions. *Sustainable Cities and Society*, 62, 102411. doi:10.1016/j.scs.2020.102411.

Hart, G. (1992). Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 80(12), 1870–1891.

Himeur, Y., Alsalemi, A., Bensaali, F., and Amira, A. (2023). Neural load disaggregation: Meta-analysis, federated learning and beyond. *Energies*, 16(1). doi: 10.3390/en16010201.

Jia, Z., Yang, L., Zhang, Z., Liu, H., and Kong, F. (2021). Sequence to point learning based on bidirectional dilated residual network for non-intrusive load monitoring. *International Journal of Electrical Power & Energy Systems*, 129, 106784.

Jiang, J., Kong, Q., Plumbley, M.D., Gilbert, N., Hoogendoorn, M., and Roijers, D.M. (2021). Deep learning-based energy disaggregation and on/off detection of household appliances. *ACM Transactions on Knowledge Discovery from Data*, 15(3). doi:10.1145/3441300.

Manuel, M.T.V.A. (2020). Padrões de consumo de energia no sector residencial: uma revisão bibliográfica. *Revista Brasileira de Gestão Ambiental e Sustentabilidade*, 7(16), 605–618.

Pagani, R.N. and Kovaleski (2017). Avanços na composição da methodi ordinatio para revisão sistemática de literatura. *Ciência da Informação*, 46(2).

Schirmer, P. A. Mporas, I. (2022). Non-intrusive load monitoring: A review. *IEEE Transactions on Smart Grid*.

Schirmer, P.A. (2019). Statistical and electrical features evaluation for electrical appliances energy disaggregation. *Sustainability*, 11.

Wang, M., Zhang, Y.L., and Weng, C.Y. (2023). Predicting energy consumption using lstm, multi-layer gru and drop-gru neural networks. *Sensors*, 23, 5863.

Weng, C.Y. and Zhang, Y.L. (2023). Lightweight seq2point learning for nilm in edge computing applications. *Artificial Intelligence Review*.

Zhang, C., Zhong, M., Wang, Z., Goddard, N., and Sutton, C. (2023). Sequence-to-point learning with neural networks for non-intrusive load monitoring. *Proceedings of the AAAI Conference on Artificial Intelligence*, 32, 6731–6738.