Revista de Informática Teórica e Aplicada - RITA - ISSN 2175-2745
Vol. 33, Num. 2 (2026) 28-35

RESEARCH ARTICLE

On the use of Image-Based Feature Extraction for Non-Intrusive Load Monitoring: A Comparative Analysis of Techniques and Window Sizes

Uso de Extração de Características Baseadas em Imagem para Monitoramento Não-Invasivo de Cargas: Uma Análise Comparativa das Técnicas e Tamanhos de Janelas

Juan Salin Corrêa[1]*, Ricardo Augusto Souza Fernandes[1]

Abstract: The techniques of Non-Intrusive Load Monitoring (NILM) aim to label or disaggregate loads into time series of electrical energy consumption, mainly in the context of residential consumers, considering the optimization of electricity usage in demand response programs. In this sense, many researches have been developed with different methodologies of consumption time series transformation into images, which consider different window sizes. Thus, this work compares and analyzes different transformation techniques for window sizes ranging from 1 to 10 minutes, verifying how the Convolutional Neural Network models behave for different loads from the UK-DALE (The United Kingdom - Domestic Appliance-Level Electricity dataset). Through the proposed methodology, it was possible to obtain f1-scores higher than 90% for three of the five considered loads, demonstrating the robustness of the time-series transformation into images.
Keywords: convolutional neural network — recurrence plot — gramian angular field — non-intrusive load monitoring

Resumo: As técnicas de monitoramento não-invasivo de cargas (NILM) buscam rotular ou desagregar cargas em séries temporais de consumo de energia elétrica, principalmente no contexto de consumidores residenciais, considerando para tanto a otimização do uso de energia elétrica em programas de resposta à demanda. Nesse sentido, várias pesquisas têm sido desenvolvidas com diferentes metodologias de transformação das séries temporais de consumo em imagens, as quais consideram diferentes tamanhos de janelas. Assim, este trabalho compara e analisa distintas técnicas de transformação para tamanhos de janelas que variam de 1 a 10 minutos, verificando como os modelos de Redes Neurais Convolucionais se comportam para diferentes cargas do conjunto UK-DALE (*The United Kingdom - Domestic Appliance-Level Electricity dataset*). Por meio da metodologia proposta, foi possível obter *f1-scores* maiores que 90% para três das cinco cargas utilizadas, demonstrando assim a robustez das transformações de séries temporais em imagens.
Palavras-Chave: rede neural convolucional — gráfico de recorrência — campo angular gramiano — monitoramento não-invasivo de cargas

[1] *Departamento de Engenharia Elétrica e de Computação, Universidade de São Paulo (USP), Brasil*
***Corresponding author**: juan.salin@usp.br
DOI: http://dx.doi.org/10.22456/2175-2745.150978 • **Received:** 15/10/2025 • **Accepted:** 03/11/2025
CC BY-NC-ND 4.0 - This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License.

1. Introdução

Com o crescimento do consumo de energia global e aumento no foco em proteção ambiental, a importância do gerenciamento de energia vem ganhando força. Uma forma de otimizar o consumo de energia são programas de resposta à demanda residencial [1]. De acordo com [2], é possível atingir até 10% de economia de energia com *feedback* indireto e de 5 a 15% de economia de energia com *feedback* direto, isto é, via medidor ou algum outro dispositivo associado. Assim, aliado a estes programas encontra-se a área do Monitoramento Não-Invasivo de Cargas (NILM, do inglês *Non-Intrusive Load Monitoring*). Proposto por Hart [3], NILM busca a rotulação das cargas ou desagregação de seus consumos, normalmente para o público residencial, partindo-se de medições obtidas apenas na entrada de energia elétrica [4, 5], ou seja, na conexão com a rede de energia elétrica de baixa tensão (de responsabilidade da concessionária).

As pesquisas na área de NILM são divididas entre baixo nível, as quais empregam medidores de alta taxa de amostra-

gem que permitem análises de sinais de tensão e corrente; e alto nível, com medidores de baixa taxa de amostragem, os quais são mais viáveis do ponto de vista financeiro e, normalmente, mais condizentes à realidade dos dispositivos de medição que encontram-se instalados nas residências, tanto no Brasil quanto em outros países [6, 7].

A partir deste contexto, utilizando dados disponíveis em domínio público amostrados em baixa frequência, este trabalho busca explorar e comparar técnicas de transformação de séries temporais em imagens no estágio de engenharia de características ao contexto de NILM. Mais especificamente, as técnicas de engenharia de características exploradas foram RP, GADF, GASF e TBG. Adicionalmente, foi analisada a influência da variação do tamanho das janelas temporais em conjunto com tais técnicas no processo de rotulação das cargas residenciais. Para tanto, o processo de rotulação se baseou em CNNs como modelos preditivos, tendo em vista que são amplamente aplicados neste tipo de tarefa.

O restante deste artigo está organizado de forma que uma breve revisão da literatura é apresentada na Seção 2; a Seção 3 traz uma visão geral das técnicas de transformação de séries temporais em imagens; a Seção 4 descreve a metodologia proposta para a rotulação de cargas residenciais e para se realizar a análise comparativa entre as técnicas de transformação de séries temporais em imagens e distintas janelas de dados; a Seção 5 traz os resultados e as discussões relativas aos mesmos; e, por fim, a Seção 6 apresenta as conclusões do artigo, bem como as propostas de trabalhos futuros.

2. Revisão da Literatura

Existem diversos trabalhos que envolvem a rotulação de cargas no contexto de NILM, sendo que alguns deles estão focados em classificação a partir da transformação dos dados em imagens. Dentre eles, os autores de [8] trabalharam com o conjunto de dados REDD (*The Reference Energy Disaggregation Data set*), transformando as janelas de dados de 90 segundos de consumo de energia em imagens através do uso de Campo Angular Gramiano da Diferença (GADF, do inglês *Gramian Angular Difference Field*) e Gráficos de Recorrência (RP, do inglês *Recurrence Plot*). Com isso, um modelo preditivo baseado em Rede Neural Convolucional (CNN, do inglês *Convolutional Neural Network*) foi empregado no processo de rotulação das imagens para se determinar a presença de cada carga residencial nas janelas de dados.

Em [6], os autores empregaram dados de tensão e corrente dos conjuntos COOLL (*Controlled On/Off Loads Library*), PLAID (*Plug-Level Appliance Identification Dataset*) e WHITED (*Worldwide Household and Industry Transient Energy Data Set*). Esses dados foram então transformados em trajetórias V-I e, na sequência, extraíram seus RPs sem utilizar um limiar, ao qual definiram como Gráfico de Distância. Por fim, as imagens obtidas foram classificadas a partir de modelos preditivos baseados em CNNs com Agrupamento de Pirâmides Espaciais.

Utilizando o conjunto de dados UK-DALE, em [9], os autores utilizaram dados adquiridos em baixa frequência e janelas de 60 segundos. A partir dessas janelas, os dados foram convertidos em coordenadas polares e, na sequência, foram extraídos Gráficos de Barras Temporais (TBG, do inglês *Temporal Bar Graphs*). Em seguida, os autores utilizaram a *Very Deep One Dimensional* CNN e a *Extreme Inception* como modelos preditivos.

Os autores de [10] propuseram o uso de *Variational Autoencoders* (VAE) com redes de *Instance Batch Normalization* (IBN-Net) para a desagregação de cargas na UK-DALE, enquanto os autores de [11] empregaram o sistema GT-NILM (*Generative, Transferable NILM*) aplicado ao mesmo conjunto de dados. Nesse último, a desagregação foi realizada através de modelos de difusão seguida por um identificador de estado baseado em CNN. Vale mencionar que Transferência de Aprendizado foi usada para adaptar os pesos às demais residências.

Uma abordagem baseada em fusão de características foi apresentada em [12], na qual os autores aplicaram a técnica do Campo de Transição de Markov para transformar os dados de corrente dos conjuntos de dados PLAID e AMPDs (*The Almanac of Minutely Power Dataset*). Empregaram o YOLOv8 para classificar as imagens. Além disso, também aplicaram a Transformada Rápida de Fourier, convertendo os sinais de corrente para o domínio da frequência e extraíram 11 características para rotular as cargas através de um modelo de *Extreme Gradient Boosting* (XGBoost) em conjunto com o resultado da classificação das imagens.

3. Geração das Imagens

Para o desenvolvimento do trabalho, conforme previamente mencionado, as metodologias selecionadas para geração das imagens utilizadas na etapa de extração de características foram: RP, GAF (GADF e GASF) e TBG.

3.1 Gráfico de Recorrência

Os RPs foram propostos por Eckmann, Kamphorst e Ruell [13, 14] em 1987, e são definidos como uma matriz de tamanho *NxN* que descreve a correlação da série temporal medindo a recorrência da trajetória $\vec{x}_i \in \mathbb{R}^d$ no espaço de estados. Sua representação pode ser expressa pela Equação 1:

$$R_{i,j}(\varepsilon) = \Theta(\varepsilon - \left\|\vec{x}_i - \vec{x}_j\right\|), \tag{1}$$

sendo que $\vec{x}_i$ representa uma amostra de $i, j = 1, \ldots, N$; ε é o limiar de ativação; $\Theta(\cdot)$ é a função *Heaviside* ($\Theta(x) = 0$, se $x < 0$, senão, $\Theta(x) = 1$); e $\|\cdot\|$ é a norma.

De acordo com [13, 14, 15], algumas características interessantes podem ser identificadas nos RPs, como por exemplo: (i) $R_{i,j} = 1 \mid {}^{N}_{i=1}$ – eles sempre possuem uma linha de identidade de valor unitário na forma de diagonal principal; (ii) diagonais menores indicam menor previsibilidade do sistema; e (iii) agrupamentos ou linhas indicam estados laminares (ou seja, estados que passaram por pequenas mudanças ao longo do tempo).

Com o intuito de melhor ilustrar a aplicação da técnica de RP, é possível visualizar na Figura 1 exemplos de cada carga explorada nesse trabalho de forma isolada, bem como um exemplo de sobreposição de cargas.

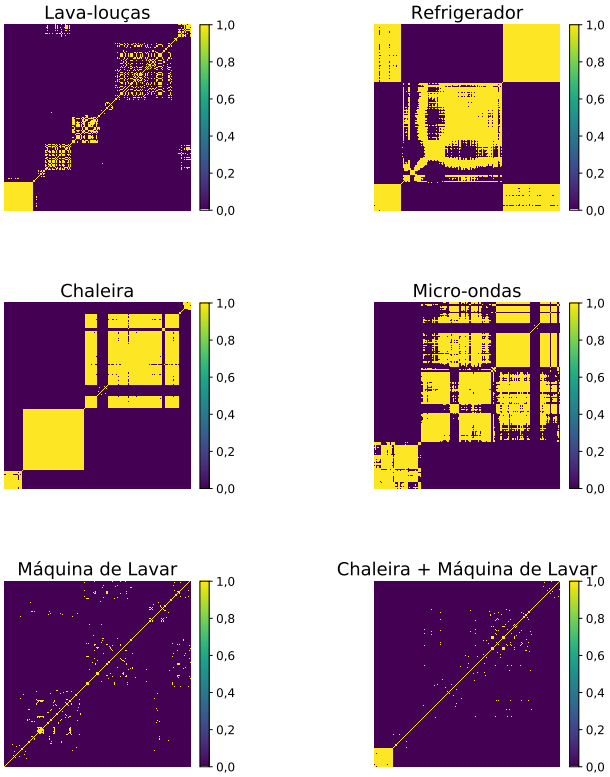

Figura 1. RPs extraídos do conjunto de dados UK-DALE.

3.2 Campo Angular Gramiano

Na técnica de Campo Angular Gramiano, dada uma série temporal $X = \{x_1, x_2, x_3, ..., x_n\}$, em que n é o número de amostras e cada uma delas é normalizada entre $[0, 1]$ (Equação 2). Em seguida, cada elemento é mapeado para o sistema de coordenadas polares (Equações 3 e 4):

$$\tilde{x}_i^{[0,1]} = \frac{x_i - min(X)}{max(X) - min(X)}, \tag{2}$$

$$\phi_i = arcos(\tilde{x}_i), \tag{3}$$

$$r_i = \frac{t_i}{M}, \tag{4}$$

sendo que ϕ_i e r_i representam a coordenada polar; t_i é o instante de tempo e M é um fator constante que regulariza a extensão do sistema de coordenadas polares. Desse modo, a matriz (e, consequentemente, a imagem) que descreve a correlação da série temporal pode ser desenvolvida de duas formas, sendo elas através da soma trigonométrica (GASF) ou da diferença (GADF) entre cada amostra representada em coordenada polar. A matriz GASF pode ser representada pela Equação 5, enquanto a matriz GADF pode ser representada por meio da Equação 6:

$$GASF = \begin{pmatrix} cos(\phi_1 + \phi_1) & \cdots & cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ cos(\phi_n + \phi_1) & \cdots & cos(\phi_n + \phi_n) \end{pmatrix}, \tag{5}$$

$$GADF = \begin{pmatrix} sin(\phi_1 - \phi_1) & \cdots & sin(\phi_1 - \phi_n) \\ \vdots & \ddots & \vdots \\ sin(\phi_n - \phi_1) & \cdots & sin(\phi_n - \phi_n) \end{pmatrix}. \tag{6}$$

Desse modo, a partir das matrizes supracitadas, é possível gerar as representações de GASF e GADF para cada janela. De forma ilustrativa, é possível visualizar nas Figuras 2 e 3 exemplos de cada carga explorados de forma isolada e um exemplo de sobreposição das cargas tanto para imagens geradas por GASF quanto por GADF, respectivamente.

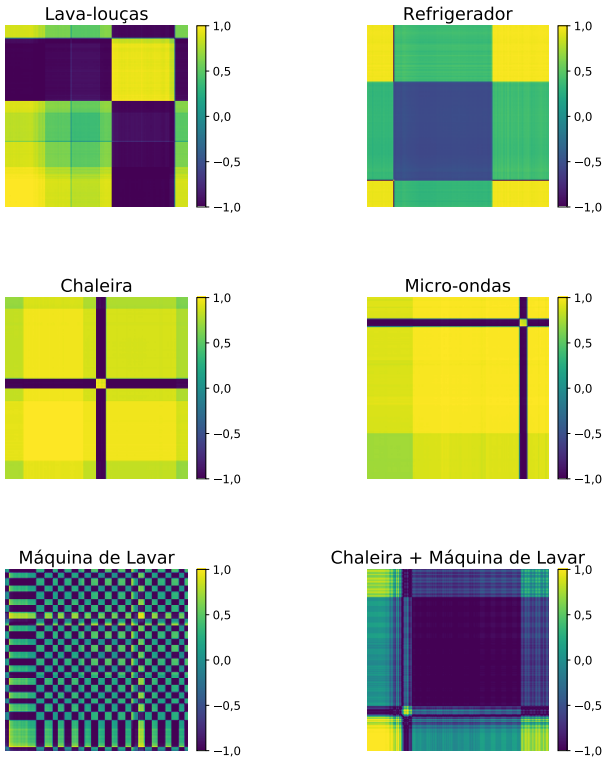

Figura 2. GASFs extraídas do conjunto de dados UK-DALE.

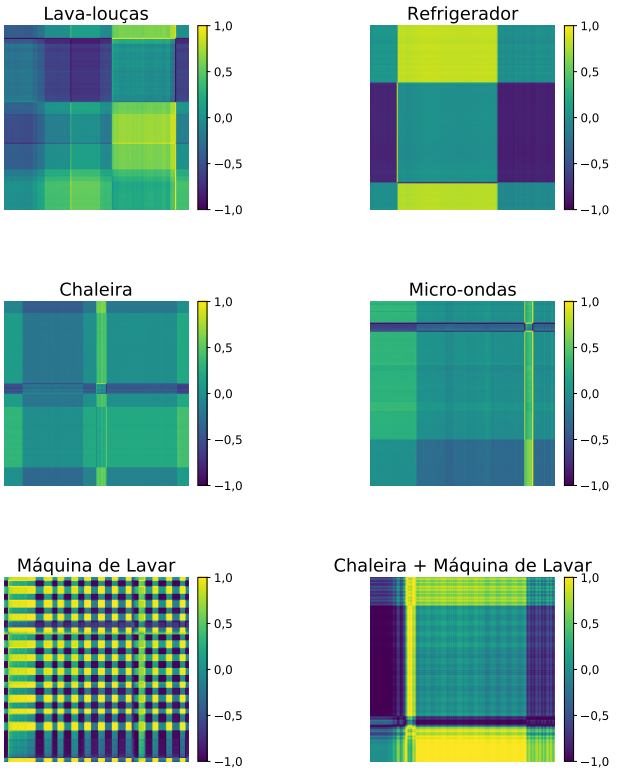

Figura 3. GADFs extraídas do conjunto de dados UK-DALE.

3.3 Gráfico de Barras Temporal

Proposto por Hwan Kim e Sungsu Lim [9] em 2021, um Gráfico de Barras Temporal explora a ideia de apresentar os dados de série temporal em coordenadas polares através de um gráfico de barras.

Assim, inicialmente os dados devem ser normalizados entre $[0, 1]$ e, na sequência, há a necessidade de realizar a conversão dos dados para a coordenada polar para, posteriormente obter o gráfico de barras usando esse sistema de coordenadas, sendo que o comprimento de cada barra representa o valor amostrado, ou seja, uma barra maior indica um maior valor.

De forma ilustrativa, é possível visualizar na Figura 4 exemplos de cada carga considerado do conjunto UK-DALE, bem como uma sobreposição de cargas representadas por meio de imagens obtidas com a técnica de TBG.

3.4 Tamanho da Janela Temporal

Definir o tamanho das janelas para cada carga é de suma importância para o modelo de classificação, tendo em vista que é comum que cargas diferentes estejam ligadas de forma concomitante à carga de interesse, além de que as próprias cargas possuem diferentes perfis enquanto ligadas, com diferentes durações, consumos e, em alguns casos, estados diversos. Para ilustrar a variação do tamanho das janelas analisadas, a Figura 5 apresenta um exemplo de ativação do micro-ondas para janelas de tamanho 2, 4, 6, 8 e 10 minutos em relação a cada uma das técnicas de transformação de imagens utilizadas.

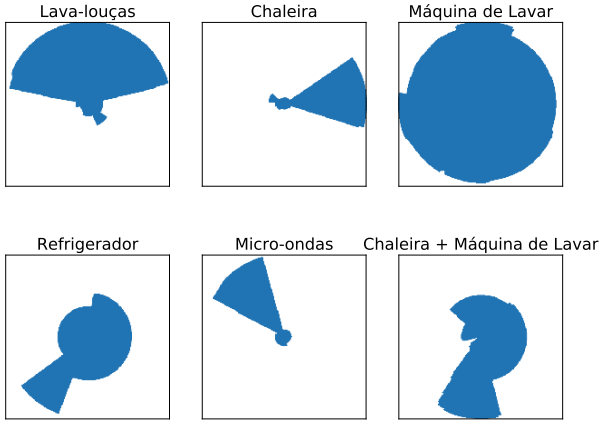

Figura 4. TBGs extraídas da base de dados UK-DALE.

4. Metodologia

A metodologia proposta consiste em: (i) organizar e limpar os dados do conjunto UK-DALE; (ii) empregar o estágio de transformação da série temporal em imagem, a partir de uma das técnicas (RP, GADF, GASF ou TBG); (iii) a partir deste conjunto de imagens, treinar e validar os modelos de classificação. Na Figura 6, é possível visualizar o *pipeline* da metodologia.

4.1 Organização e Limpeza dos Dados

O conjunto de dados utilizado é pública denominado UK-DALE, coletado para pesquisas no âmbito de NILM e é composto por dados de potência, tensão e corrente obtidos no painel principal e de tomadas específicas de 5 residências no Reino Unido [16]. Foram utilizados os dados dos 5 aparelhos de maior consumo, a saber: Lava-louças (LL), Refrigerador (RE), Chaleira (CH) Micro-ondas (MO) e Máquina de Lavar (ML). Além disso, os aparelhos representam diferentes categorias de ativação, como 2 estados (CH e MO), cíclico (RE) e multi-estados (LL e ML).

Baseando-se em [9], considerou-se as seguintes residências e horizontes para as séries temporais:

- Residência #1 – de 1º de Janeiro de 2014 a 16 de Janeiro de 2014;
- Residência #2 – de 20 de Maio de 2013 a 4 de Junho de 2013;
- Residência #5 – de 29 de Junho de 2014 a 14 de Julho de 2014.

4.2 Engenharia de Características

Após a organização e limpeza do conjunto de dados, os dados de potência ativa das cargas e de potência aparente do medidor principal foram janelados. O tamanho da janela foi variado de 1 a 10 minutos, com exceção do refrigerador que, devido à sua natureza de ativação cíclica, foi testado apenas com uma janela de 14 minutos. Para definição do estado (ligado ou desligado) de cada carga, estes foram calculados a partir de

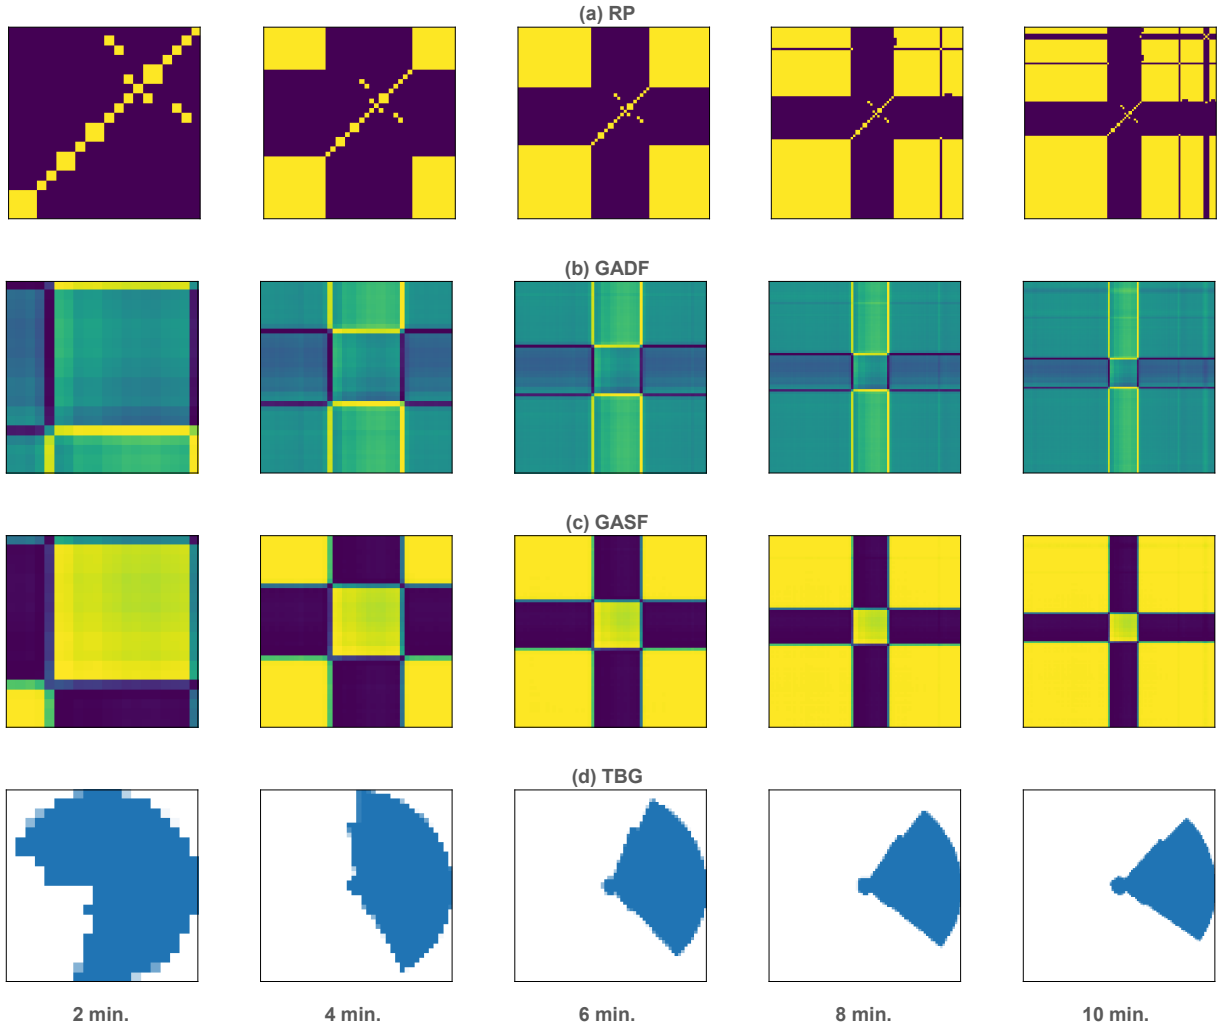

Figura 5. Imagens em diferentes tamanhos de janela

seus consumos médio de potência ativa na janela, cujo limiar foi baseado em [9]. Para CH e MO, estes limiares foram definidos como 20 e 200 W, respectivamente; os limiares para LL e ML foram ambos considerados como 10 W; e no caso da RE, seu limiar foi definido como 50 W.

Sendo assim, os dados de potência aparente do medidor principal foram então processados por meio das técnicas de transformação de séries temporais em imagens, para serem utilizadas como entradas dos modelos preditivos em conjunto com a rotulação da janela temporal (estado da carga).

4.3 Modelo Preditivo para Classificação

Tendo em vista que a CNN possui alta capacidade para aprendizagem de características em imagens e é vastamente utilizada no âmbito de visão computacional, este foi o modelo escolhido para classificação das imagens. A divisão entre treinamento, validação e teste do conjunto de imagens pode ser vista na Tabela 1.

Com isso, para cada combinação diferente de cargas, tamanho da janela e técnica de transformação de série temporal em imagem, foi obtido o melhor modelo de CNN por meio de uma *GridSearch*, variando os seguintes hiper-parâmetros: número de camadas convolucionais, número e tamanho das camadas densas.

Tabela 1. Divisão do conjunto de dados de entrada.

Conjunto	Casas	Proporção
Treinamento	#1 e #5	80%
Validação	#1 e #5	20%
Teste	#2	100%

Por fim, as métricas de avaliação de desempenho consideradas, baseando-se nos trabalhos que compõem o estado da arte acerca de rotulação de cargas residenciais, foram acurácia (acc) e *f1-score*.

5. Resultados e Discussões

Conforme previamente mencionado, para cada técnica de transformação de série temporal em imagem foram consi-

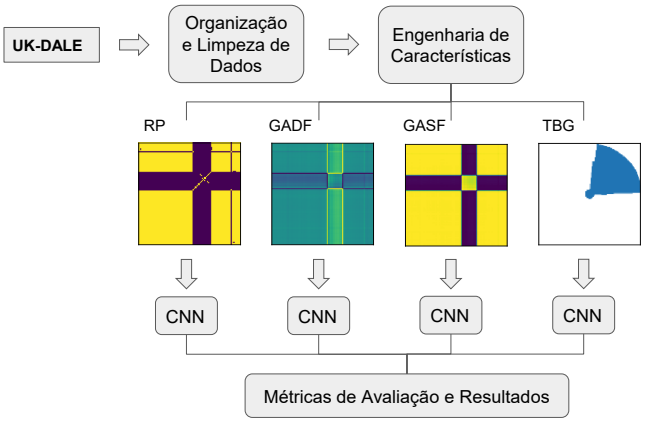

Figura 6. *Pipeline* da metodologia

deradas 10 distintas janelas temporais. Entretanto, deve-se destacar que apenas no caso do refrigerador não houve essa variação de janelas, sendo fixada uma janela de 14 minutos para sua classificação devido ao seu comportamento cíclico.

5.1 Comparação entre as Técnicas de Transformação de Séries Temporais em Imagens

A Figura 7 apresenta uma comparação entre as médias dos resultados para cada técnica de transformação utilizada sobre as janelas temporais.

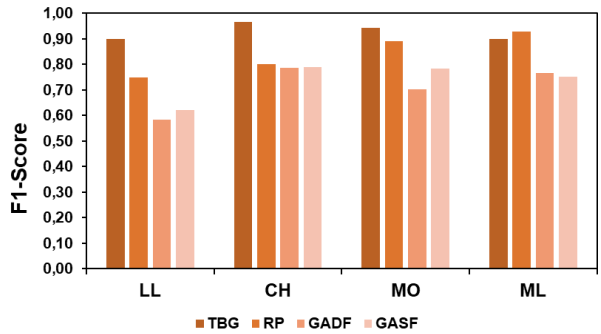

Figura 7. Média dos resultados por técnica utilizada.

A partir dos valores apresentados nota-se que a melhor técnica, em geral, foi o TBG seguido pelo RP (que superou a técnica na rotulação da ML). A variação dos valores apresentados de RP, em relação ao TBG, são explicados por: (i) disparidades no número de ativações em cada carga; (ii) duração do tempo de operação da carga; (iii) diferenças de robustez entre as duas técnicas acerca de variabilidade de dados e; (iv) ao comparar a LL com a ML, observa-se diferenças no comportamento multi-estados das duas cargas.

5.2 Análise do Tamanho das Janelas

A partir da Figura 8, é possível visualizar todos os resultados obtidos em termos de *f1-score*.

Analisando os resultados, nota-se que a variação no tamanho das janelas traz um uma diferente resposta para cada carga. Os modelos de classificação das cargas de dois estados (CH e MO), obtiveram melhores resultados com janelas menores, demonstrando que, na média, seus melhores resultados ocorrem com janelas de 3 minutos. Por outro lado, a rotulação de cargas multi-estados (LL e ML), alcançou melhores resultados para janelas de maior duração (na média, com 9 e 8 minutos, respectivamente). Os resultados estão de acordo com o esperado, tendo em vista que cargas multi-estados necessitam de maiores janelas para abranger as transições entre estados. Por fim, nota-se também que GADF e GASF se mostraram sensíveis ao tamanho da janela temporal do que as demais técnicas, sendo mais evidente para as cargas de dois estados.

5.3 Classificação do Refrigerador

Devido à natureza cíclica do refrigerador e do alto elevado chaveamento entre estados, houve a necessidade de realizar a classificação do mesmo considerando janelas temporais com intervalos de 14 minutos. Os valores obtidos ao empregar cada técnica de transformação da série temporal em imagem são mostrados na Tabela 2.

Tabela 2. Resultados obtidos para o refrigerador.

Técnica de Transformação	*f1-score*	Acc
TBG	0,56	0,59
RP	0,64	0,64
GADF	0,72	0,72
GASF	0,66	0,66
Média	0,64	0,65

Diferente do que foi obtido para as demais cargas, tanto o TBG quanto o RP não demonstraram a maior robustez no estágio de engenharia de características. Todavia, GADF e GASF mantiveram resultados semelhantes. O decréscimo nos resultados pode ser explicado pelo baixo valor apresentado no estado "ligado" da carga, o que dificulta sua classificação, principalmente em situações em que há sobreposição com outras cargas.

5.4 Validação dos melhores modelos

Com base nas melhores combinações encontradas a partir dos resultados médios apresentados, foi realizado novamente um processo de *grid search* com validação cruzada a partir de 5 *folds*. Os resultados para a melhor combinação dos modelos avaliados nesta etapa podem ser vistos na Tabela 3.

Através dos resultados obtidos nas combinações apresentadas, foi possível observar que para as cargas CH, MO, ML e RE o f1-score se manteve próximo ao obtido na execução anterior. Além disso, nota-se que os resultados da LL, CH e MO foram próximos entre a validação (mesmas casas) e teste (casa diferente), mostrando um potencial positivo para a utilização do modelo em casas não utilizadas no treinamento. Vale ressaltar que os resultados da carga LL tiveram uma redução com relação a execução anterior, além de um alto desvio padrão se comparado as outras cargas.

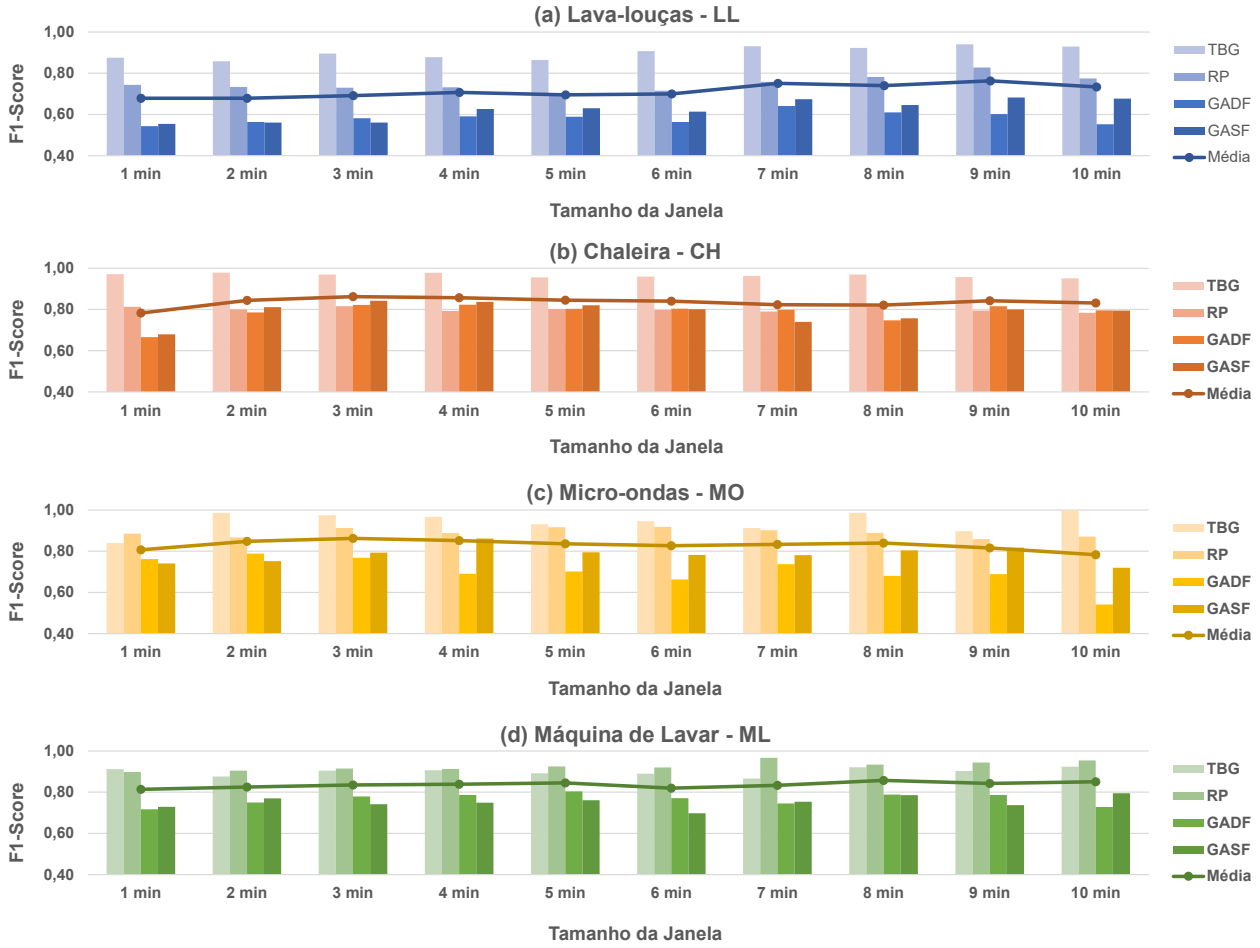

Figura 8. Resultados obtidos para cada carga, janela temporal e técnica de transformação utilizada.

Os resultados se mostraram promissores se comparados ao estado da arte neste conjunto de dados. Os autores de [11], sem considerar a etapa de adaptação por Transferência de Aprendizado que ocorre no conjunto de dados REDD, obtiveram um f1-score médio de 0,771, atingindo até 0,971. Por outro lado, os autores de [10] obtiveram um f1-score médio de 0,840, atingindo até 0,973, considerando a mesma etapa.

6. Conclusões

Este trabalho propôs uma comparação entre as técnicas de transformação de séries temporais em imagens para o estágio de engenharia de características (RP, GASF, GADF e TBG), bem como a análise de diferentes tamanhos de janelas temporais com o intuito de aprimorar o processo de rotulação do estado (ligado/desligado) de cargas residenciais. O processo de rotulação foi realizado por meio de CNNs, as quais tiveram seus hiper-parâmetros otimizados por meio de *Grid Search* e foram treinadas, validadas e testadas sobre o conjuntos de dados UK-DALE.

Os resultados demonstraram que as técnicas de GASF e GADF foram mais sensíveis às mudanças no tamanho das janelas do que TBG e RP. Além disso, apesar de TBG ter se apresentado como melhor técnica para a rotulação de lava-louças, chaleira e micro-ondas, o RP também pode ser considerado ao se tratar da rotulação de máquina de lavar. Por fim, é válido mencionar o GADF como a melhor técnica usada no processo de engenharia de características para a rotulação do refrigerador, a qual mostrou-se como a carga mais desafiadora, principalmente pelo seu comportamento cíclico e pela sua baixa potência em relação às demais.

Em suma, foi possível observar que os modelos preditivos apresentaram melhores resultados na rotulação de cargas de dois estados ao empregar janelas temporais curtas, enquanto os modelos apresentaram melhores respostas para cargas multi-estados ao considerar janelas temporais maiores. Também foi possível verificar durante um novo teste realizado com as melhores combinações para cada carga, o grande potencial da aplicação do método em casas não utilizadas no treinamento e a robustez dos modelos para todas as cargas, com exceção da lava-louças, que apresentou desvio padrão elevado.

Como trabalhos futuros, outras técnicas podem ser exploradas para geração das imagens além daquelas aplicadas nessa pesquisa, como o método de Matriz de Ângulo Relativo (RAM, do inglês *Relative Angle Matrix*) ou o Campo

Tabela 3. Resultados obtidos para as melhores combinações avaliadas.

Carga	Tamanho da Janela	Extração de Características	Acc (Validação) média	Acc (Validação) desvio padrão	Acc (Teste)	F1-Score (Teste)
LL	9 min.	TBG	0,817	0,067	0,812	0,812
CH	3 min.	TBG	0,975	0,027	0,969	0,969
MO	3 min.	TBG	0,978	0,029	0,963	0,962
ML	8 min.	RP	0,971	0,021	0,908	0,908
RE	14 min.	GADF	0,687	0,005	0,738	0,738

de Transição de Markov (MTF, do inglês *Markov Transition Field*), buscando tornar a comparação ainda mais robusta e buscar melhores resultados, principalmente para o caso do refrigerador. Além disso, dado o comportamento observado em janelas temporais maiores (cargas de multi-estado), análises preliminares com relação às propriedades dos sinais, bem como trabalhos com janelas temporais maiores podem ser considerados.

Agradecimentos

Este artigo foi financiado pela Pró-Reitoria de Pesquisa e Inovação (PRPI) [22.1.09345.01.2] - Universidade de São Paulo e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) [305215/2022-1, 134113/2025-0].

Contribuição dos Autores

Juan S. Corrêa: Conceitualização, Metodologia, Análise dos Resultados, Escrita; Ricardo A. S. Fernandes: Conceitualização, Supervisão, Análise dos Resultados, Revisão do Manuscrito.

Referências

[1] FONSECA, A. L. da; CHVATAL, K. M.; FERNANDES, R. A. Thermal comfort maintenance in demand response programs: A critical review. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 141, p. 110847, 2021.

[2] DARBY, S. Energy feedback in buildings: improving the infrastructure for demand reduction. *Building Research amp; Information*, Informa UK Limited, v. 36, n. 5, p. 499–508, out. 2008. ISSN 1466-4321.

[3] HART, G. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, v. 80, n. 12, p. 1870–1891, 1992.

[4] LI, M. et al. Dynamic time warping optimization-based non-intrusive load monitoring for multiple household appliances. *International Journal of Electrical Power & Energy Systems*, Elsevier BV, v. 159, p. 110002, ago. 2024. ISSN 0142-0615.

[5] AGUIAR, E. L. de et al. St-nilm: A wavelet scattering-based architecture for feature extraction and multilabel classification in nilm signals. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 7, p. 10540–10550, abr. 2024. ISSN 2379-9153.

[6] WENNINGER, M. et al. Recurrence plot spacial pyramid pooling network for appliance identification in non-intrusive load monitoring. In: *2021 20th IEEE International Conference on Machine Learning and Applications (ICMLA)*. [S.l.]: IEEE, 2021. p. 108–115.

[7] LIANG, J. et al. Load signature study—part i: Basic concept, structure, and methodology. *IEEE Transactions on Power Delivery*, v. 25, n. 2, p. 551–560, 2009.

[8] CAVALCA, D. L.; FERNANDES, R. A. S. Recurrence plots and convolutional neural networks applied to nonintrusive load monitoring. In: *2020 IEEE Power Energy Society General Meeting (PESGM)*. [S.l.: s.n.], 2020. p. 1–5.

[9] KIM, H.; LIM, S. Temporal patternization of power signatures for appliance classification in nilm. *Energies*, v. 14, n. 10, 2021.

[10] LANGEVIN, A. et al. Energy disaggregation using variational autoencoders. *Energy and Buildings*, v. 254, p. 111623, 2022.

[11] ZHANG, B. et al. Gt-nilm: A generative, transferable non-intrusive load monitoring system based on conditional diffusion models and convolutional neural networks. *IEEE Transactions on Consumer Electronics*, Institute of Electrical and Electronics Engineers (IEEE), p. 1–1, 2025. ISSN 1558-4127.

[12] WANG, J.; CHENG, L. An improved yolov8-xgboost load rapid identification method based on multi-feature fusion. *International Journal of Electrical Power amp; Energy Systems*, Elsevier BV, v. 166, p. 110573, maio 2025. ISSN 0142-0615.

[13] MARWAN, N. et al. Recurrence plots for the analysis of complex systems. *Physics Reports*, v. 438, p. 237–329, 2007.

[14] ECKMANN, J.-P.; KAMPHORST, S. O.; RUELL, D. Recurrence plots of dynamical systems. *Europhys. Letters*, v. 4, n. 9, p. 973–977, 1987.

[15] GRABEN, P. b. et al. Optimal estimation of recurrence structures from time series. *EPL (Europhysics Letters)*, v. 114, n. 3, p. 38003, 2016.

[16] KELLY, J.; KNOTTENBELT, W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific Data*, v. 2, n. 150007, 2015.