



Metodologia de monitoramento e identificação de cargas elétricas utilizando aprendizado de máquina

Methodology for monitoring and identifying electrical loads using machine learning

Gabriel Viscardi Shibata¹, Michele Oliveira de Campos²,
Matheus Begosso Fontana³, Wesley Angelino de Souza⁴

RESUMO

Os setores de fornecimento e consumo de energia elétrica estão sendo significativamente impactados pela Internet das Coisas (IoT), enquanto o aprendizado de máquina tem desempenhado um papel crucial nessa transformação. Isso tem incentivado tanto os produtores quanto os consumidores a adotarem tecnologia para tornar a produção e o consumo de energia mais eficientes, automatizados e com melhor custo-benefício. Nesse contexto, este trabalho apresenta um sistema embarcado de monitoramento e desagregação do consumo de cargas, capaz de identificar e analisar o consumo de energia de cada eletrodoméstico, permitindo que os moradores tenham o monitoramento e possibilitando o controle sobre seus padrões de consumo, podendo tomar decisões informadas para economizar energia. Para isso, foi desenvolvido um sistema de medição com sensores para coletar dados de corrente com técnicas de desagregação de cargas para identificar a assinatura de cada dispositivo com base em um modelo de aprendizado de máquina para classificar os aparelhos e exibição da desagregação por meio de uma interface web. O sistema alcançou uma acurácia de 93,01% na identificação de eletrodomésticos, considerando a análise sobre seis tipos de eletrodomésticos.

PALAVRAS-CHAVE: aprendizado de máquina; desagregação de cargas; sistema inteligente.

ABSTRACT

The Internet of Things (IoT) significantly impacts the power supply and consumption sectors, while machine learning has played a crucial role in this transformation. This has encouraged producers and consumers to adopt technology to make energy production and consumption more efficient, automated, and cost-effective. In this context, this work presents an embedded load monitoring and disaggregation system capable of identifying and analyzing the energy consumption of each household appliance, allowing residents to monitor and control their consumption patterns and make informed decisions to save energy. A measurement system was developed to collect current data, identify each appliance using a machine learning model, and display the energy disaggregation through a web interface. The system achieved an accuracy of 93.01% in identifying household appliances, considering the analysis of six types of appliances.

KEYWORDS: machine learning, load disaggregation, intelligent system.

INTRODUÇÃO

No Brasil e no mundo, o consumo de energia elétrica tem aumentado progressivamente ao longo dos anos. Fatores relevantes para esse aumento incluem o crescimento populacional, o desenvolvimento de novas tecnologias e o crescimento econômico. Posto isto, a fim de otimizar o consumo de energia elétrica para os moradores residenciais, deve-se efetivar um consumo consciente. Para tanto, os moradores devem ser capazes de visualizar com detalhes o consumo de cada

¹ Bolsista do PIVIC. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Brasil. E-mail: gabrielshibata@alunos.utfpr.edu.br. ID Lattes: 0514071569912804.

² Bolsista do PIVIC. Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Brasil. E-mail: michelecampos@alunos.utfpr.edu.br. ID Lattes: 0582061260816236.

³ Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Brasil. E-mail: mbfontana@outlook.com. ID Lattes: 4397426705110706.

⁴ Docente no Departamento Acadêmico de Elétrica (DAELE). Universidade Tecnológica Federal do Paraná, Cornélio Procópio, Paraná, Brasil. E-mail: wesleyangelino@utfpr.edu.br. ID Lattes: 8594457321079718.




eletrodoméstico em sua residência para, então, tomar decisões frente à economia de energia, tendo assim o método chamado de monitoramento de cargas (AZZINI et al., 2019). Para reforçar esta importância, Carrie Armel et al. (2013) indica que o *feedback* ao usuário final sobre o consumo específico de seus aparelhos elétricos pode reduzir o consumo de energia da residência em até 12%.

À vista disso, a fim de monitorar o consumo de cargas, podem ser empregados medidores inteligentes, ou seja, sensores conectados a uma rede que captam e transmitem dados do consumo de energia elétrica da residência, podendo também ter inteligência embarcada, transformando o medidor inteligente em uma nova categoria de medidores, chamados de medidores cognitivos de energia (SOUZA; ALMEIDA, 2022). Entretanto, junto à extração destes dados coletados, é importante enviá-los para plataformas onde a informação é manipulada em relatórios e aplicações, tornando assim uma abordagem de Internet das Coisas (IoT) (RAMSON; VISHNU; SHANMUGAM, 2020).

Considerando tais aspectos, este trabalho tem como objetivo a construção de um método que corresponde ao monitoramento não-intrusivo de cargas (do inglês, *Non-Intrusive Load Monitoring - NILM*). Desta forma, é realizada a coleta de dados das grandezas elétricas em uma residência e, a partir desta coleta, são identificados os eletrodomésticos em funcionamento através de um modelo de análise de dados baseado em aprendizado de máquina (AM). Após a desagregação de cargas, há a integração do sistema a uma solução *web* capaz de gerar informação para o monitoramento e tomada de decisão para o usuário final, bem como a conscientização do consumo. As seções seguintes apresentam o desenvolvimento e resultados do trabalho.

MATERIAIS E MÉTODOS

O NILM constitui-se na medição do consumo de energia elétrica para a identificação de aparelhos que foram ligados ou desligados. O termo “não-intrusivo” significa que não é necessário nenhum outro sistema de medição setorizado ou individualizado por eletrodoméstico (AZZINI et al., 2019). Além disso, tem-se baixo custo na aquisição, facilidade de instalação e de manutenção dos sistemas NILM, visto que estes empregam apenas um equipamento de medição por residência. O NILM possui as etapas conforme descritas na Figura 1 e explicadas a seguir.



Fonte: Elaborado pelos autores (2023).

AQUISIÇÃO DE DADOS

Na fase de coleta de dados, os sinais elétricos são capturados no Ponto de Acesso à Corrente (PAC), que, em um contexto residencial, corresponde ao ponto de conexão da residência com a rede elétrica, como o poste de energia. Esses sinais são então convertidos em valores digitais para permitir o cálculo de diversas grandezas elétricas. No âmbito deste projeto, concentra-se na coleta dos sinais de corrente, bem como no cálculo das amplitudes das harmônicas e do valor eficaz da corrente. Essa etapa envolve um sistema composto por sensores para coleta, condicionamento do sinal e conversão do sinal analógico para digital, realizado através de um conversor analógico-digital (ADC). A coleta precisa dos dados é de extrema importância, especialmente devido à necessidade de



extrair informações das componentes harmônicas presentes no sinal de corrente. O método proposto neste projeto abrange a consideração das componentes harmônicas até a 31ª ordem da frequência fundamental da rede elétrica, que é de 60 Hz. De acordo com a teoria de Nyquist (BOUHOURAS et al., 2019), para garantir uma representação precisa das características do sinal elétrico, a taxa de amostragem deve ser de pelo menos 3,72 kHz, o que significa que o sistema precisa capturar o sinal instantâneo da corrente a essa taxa ou superior. Essa escolha de taxa de amostragem é crucial para capturar as harmônicas e outras características do sinal com precisão.


DETECÇÃO DE EVENTOS

A etapa de detecção de eventos correspondente à identificação de mudança do estado da corrente, para identificar se um eletrodoméstico está sendo ligado, se está em mudança de estado ou foi desligado. Desta forma, foi utilizado o algoritmo de blocos de assinatura de potência (PSB, do inglês *Power Signature Blob*), proposto por Souza, Garcia et al. (2019), no qual a identificação de cargas é disparada após o cálculo da diferença do sinal observando dois cenários: antes e depois de um aparelho ser ligado ou desligado. Isto permite com que haja o disparo para a extração de atributos e dos algoritmos classificadores somente em momentos no qual há mudança de estado de eletrodomésticos sendo ligados ou desligados.

EXTRAÇÃO DE ATRIBUTOS

A extração de atributos corresponde à conversão dos sinais instantâneos coletados (formas de onda das correntes) em um conjunto de características. Esta etapa corresponde ao processo de construção de variáveis de entrada para o processo de identificação ou reconhecimento de cargas. A Figura 2 apresenta um exemplo do processo de extração das harmônicas.

Figura 2 – Exemplo da extração de harmônicas do sinal de corrente



Fonte: Elaborado pelos autores (2023).

Neste método, os atributos são derivados da transformada rápida de Fourier (*Fast Fourier Transform* - FFT). As harmônicas são componentes senoidais de frequência igual ou múltipla da frequência fundamental da rede elétrica (60 Hz, no caso do Brasil) e as múltiplas da fundamental são evidenciadas na existência de componentes não lineares, tendo como exemplo as lâmpadas fluorescente, computadores e eletrônicos em geral. Para tanto, o algoritmo de Cooley-Tukey, apresentado na Eq. 1, conhecido como *Radix-2*, é o utilizado neste trabalho, no qual x é o dado no xetor de amostragem, N corresponde ao número de amostragens de entrada e k a um número inteiro variando de 0 a $N-1$.

$$X_k = \sum_{m=0}^{N/2-1} x_{2m} e^{-\frac{2\pi i}{N}(2m)k} + \sum_{m=0}^{N/2-1} x_{2m+1} e^{-\frac{2\pi i}{N}(2m+1)k} \quad (1)$$



Do algoritmo *Radix-2*, há o cálculo separado das transformadas discretas de Fourier (*Discrete Fourier Transform* - DFT) das entradas de índice par ($x_{2m} = x_0, x_2, \dots, x_{N-2}$) na primeira parcela da equação, e das entradas de índice ímpar ($x_{2m+1} = x_1, x_3, \dots, x_{N-1}$) na segunda parcela da equação. Dessa forma, é possível reduzir a complexidade linear do algoritmo, e conseqüentemente o esforço computacional, da ordem de $O(n^2)$ para $O(n \log(n))$ (WEISSTEIN, 2015). Para este trabalho, são consideradas as amplitudes das frequências harmônicas ímpares de 1 a 31.

IDENTIFICAÇÃO DE CARGAS

Nesta etapa crucial do projeto, a identificação das cargas ligadas ou desligadas é realizada por meio de algoritmos de reconhecimento de padrões. O ponto de partida para esse processo é a entrada do modelo, que é composta pelos dados obtidos na fase anterior de extração de atributos. O algoritmo escolhido para abordar o problema de classificação é o dos "*k*-vizinhos mais próximos" (*k*-NN), conhecido em inglês como "*k*-nearest neighbors." No contexto da classificação, o *k*-NN opera classificando uma entrada específica com base nos resultados obtidos a partir das amostras mais próximas, ou seja, as classes, presentes no espaço que engloba todas as amostras da base de dados (KELLER; GRAY; GIVENS, 1985). Para determinar essa proximidade e realizar as classificações, é utilizada uma métrica de distância entre os pontos de dados. A métrica de distância mais comum é a euclidiana, mas outras métricas também podem ser empregadas (SOUZA; LOTUFO; RITTNER, 2008). É importante ressaltar que as etapas de Identificação e Desagregação de Cargas foram implementadas em um microcontrolador ESP32, demonstrando a viabilidade de execução em um sistema embarcado. Isso será discutido com mais detalhes na seção subsequente.

RESULTADOS

Para a composição do sistema de desagregação de cargas, tem-se a necessidade de se coletar dados através dos sensores de corrente, a fim de identificar o consumo de cargas em ambientes específicos de uma residência, de manipular os dados coletados e transmiti-los via comunicação sem fio. O ESP32, que foi utilizado, é um dispositivo embarcado que integra periféricos como *Wi-Fi* e *Bluetooth*, com dois núcleos de microprocessadores de 240MHz.

Para a coleta dos sinais de corrente, foi utilizado o SCT-013-50A, que é um transformador de corrente não invasivo. Seu funcionamento se dá através do fluxo de tensão na bobina do núcleo primário, a qual induz uma tensão nas bobinas do núcleo secundário. O modelo escolhido possui um fator de conversão de 50A eficaz para 1V. O algoritmo de FFT e o *k*-NN (com $k=9$ e distância euclidiana, determinados por busca em grade) foram implementados no *firmware* do ESP32.

A calibração do sensor foi feita considerando a comparação de valores com o medidor comercial DMI P200 da ISSO. Após isso, o medidor foi instalado no quadro de distribuição conforme apresenta a Figura 3. Uma das duas fases observadas é correspondente às tomadas dos quartos, podendo assim realizar a observação das cargas de forma isolada. Três horas isoladas de funcionamento de seis cargas foram analisadas: secador de cabelo, ferro de passar roupas, liquidificador, torradeira, sanduicheira e *airfryer*. A Tabela 1 apresenta os valores médios das componentes harmônicas extraídos das correntes durante o funcionamento dos eletrodomésticos.

Conforme observa-se na Tabela 1, existem diferenças entre a maioria dos valores entre as cargas, exceto a torradeira e sanduicheira, que apresentam informações semelhantes. Esta semelhança interfere nos valores de acurácia na identificação dos eletrodomésticos realizado pelo




XIII Seminário de Extensão e Inovação XXVIII Seminário de Iniciação Científica e Tecnológica da UTFPR

Ciência e Tecnologia na era da Inteligência Artificial: Desdobramentos no Ensino Pesquisa e Extensão
20 a 23 de novembro de 2023 - Campus Ponta Grossa, PR



Figura 3 – Instalação do sistema no quadro de distribuição



Fonte: Elaborado pelos autores (2023).

Tabela 1 – Médias das magnitudes calculadas da FFT

Eletrodoméstico	Magnitudes															
	01	03	05	07	09	11	13	15	17	19	21	23	25	27	29	31
Secador de cabelo	6.17	0.15	0.21	0.11	0.1	0.11	0.09	0.09	0.09	0.07	0.07	0.06	0.06	0.05	0.05	0.06
Ferro de passar roupa	12.33	0.07	0.3	0.14	0.05	0.08	0.06	0.04	0.06	0.03	0.02	0.02	0.01	0.01	0	0
Liquidificador	1.05	0.62	0.18	0.08	0.04	0.05	0.04	0.03	0.03	0.02	0.02	0.01	0.01	0.01	0.01	0
Torradeira	4.6	0.04	0.11	0.05	0.03	0.04	0.04	0.03	0.02	0.02	0.02	0.01	0.01	0.01	0	0
Sanduícheira	4.67	0.04	0.12	0.05	0.03	0.04	0.03	0.02	0.02	0.02	0.01	0.01	0.01	0.01	0	0
Airfryer	8.7	0.07	0.27	0.1	0.04	0.06	0.07	0.04	0.05	0.03	0.02	0.02	0.02	0.02	0.02	0.05

Fonte: Elaborado pelos autores (2023).

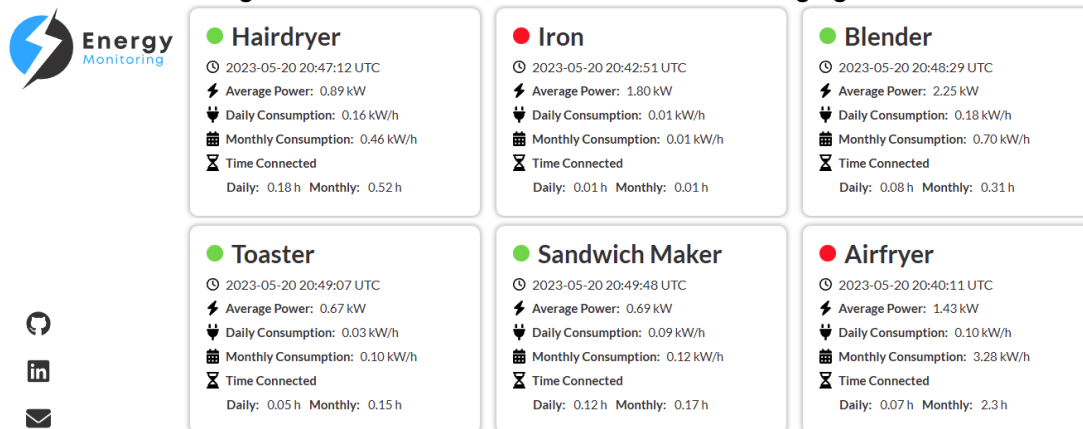
k -NN, conforme apresenta a Tabela 2. Por fim, os dados de início e fim das cargas desagregadas são enviadas a um banco de dados em um servidor, para assim alimentar uma interface desenvolvida em *web* para a visualização dos dados desagregados, conforme apresenta a Figura 4.

Tabela 2 – Resultados e Métricas para Modelo k -NN.

Eletrodoméstico	VP	VN	FP	FN	Precisão (%)	Recall (%)	f -score (%)
Secador de cabelo	135	335	4	5	97	96	97
Ferro de passar roupa	73	397	0	0	100	100	100
Liquidificador	80	390	1	1	99	99	99
Torradeira	63	407	13	13	83	83	83
Sanduícheira	54	416	13	13	81	81	81
Airfryer	65	405	4	3	94	96	95
Acurácia (%)	93.01						

Fonte: Elaborado pelos autores (2023).

Figura 4 – Interface de monitoria de consumo desagregado



Fonte: Elaborado pelos autores (2023).



CONCLUSÃO

Este trabalho descreve o desenvolvimento de um modelo preditivo para a desagregação de cargas elétricas, visando a identificação e monitoramento individual de dispositivos elétricos em uma rede elétrica. A desagregação de cargas é uma técnica fundamental para otimizar o uso de energia em residências e empresas. O modelo proposto utiliza as magnitudes ímpares das componentes harmônicas da fundamental até a 31ª ordem, obtidas por meio da Transformada Rápida de Fourier (FFT), como atributos para identificação. A escolha das magnitudes ímpares é relevante, já que diferentes dispositivos costumam criar distorções harmônicas ímpares no sinal elétrico. Para classificar as cargas, o algoritmo k-NN foi selecionado. Além disso, o projeto inclui a integração de sensores de corrente, possibilitando o monitoramento em tempo real do consumo de energia. Essa abordagem com um sistema embarcado torna a desagregação de cargas acessível para diversas aplicações práticas. Uma interface gráfica amigável foi desenvolvida para permitir que os consumidores finais monitorem e gerenciem seu consumo de energia de forma intuitiva. Os resultados mostram que o sistema é capaz de atingir uma acurácia de 93,01% na desagregação de seis eletrodomésticos, demonstrando sua eficácia na identificação e previsão de cargas elétricas.

Agradecimentos

Os autores agradecem ao Centro Integrado de Pesquisa em Controle e Automação (CIPECA) pelo suporte financeiro ou estrutural para o desenvolvimento deste projeto.

Conflito de interesse

Os autores declaram que não há conflito de interesse neste trabalho.

REFERÊNCIAS

- AZZINI, H. A. D. et al. Comparação das técnicas de monitoramento de cargas para a desagregação do consumo de energia elétrica. In: XXII Congresso Brasileiro de Automática. [S.l.: s.n.], 2019. P. 1–8.
- BOUHOUBAS, Aggelos S et al. A NILM algorithm with enhanced disaggregation scheme under harmonic current vectors. **Energy and Buildings**, Elsevier, v. 183, p. 392–407, 2019.
- CARRIE ARMEL, K. et al. Is disaggregation the holy grail of energy efficiency? The case of electricity. **Energy Policy**, v. 52, p. 213–234, 2013.
- KELLER, James M; GRAY, Michael R; GIVENS, James A. A fuzzy k-nearest neighbor algorithm. **IEEE transactions on systems, man, and cybernetics**, IEEE, n. 4, p. 580–585, 1985.
- RAMSON, S.R.J.; VISHNU, S.; SHANMUGAM, M. Applications of internet of things (IoT)—an overview. In: IEEE. 5TH international conference on devices, circuits and systems. [S.l.: s.n.], 2020. P. 92–95.
- SOUZA, W. A.; ALMEIDA, T. A. An effective CPT-based nonintrusive load monitoring for cognitive meters. **IEEE Transactions on Smart Grid**, v. 13, n. 3, p. 2148–2157, 2022.
- SOUZA, W. A.; GARCIA, F. D. et al. Load disaggregation using microscopic power features and pattern recognition. **Energies**, v. 12, n. 14, p. 2641, 2019.
- SOUZA, W. A.; LOTUFO, R. A.; RITTNER, L. Análise comportamental da Optimum-Path Forest em diferentes funções métricas. **Monografia de curso**, UNICAMP, 2008.
- WEISSTEIN, Eric W. Fast fourier transform. **Wolfram Research**, 2015.