

SISTEMAS DE IDENTIFICAÇÃO E DESAGREGAÇÃO DO CONSUMO DE ENERGIA ELÉTRICA DE CARGAS POR TRAJETÓRIA VI

Eduardo Mestre da Gloria¹, Wesley Angelino de Souza²

RESUMO: Atualmente, soluções computacionais são apresentadas para reduzir o consumo de energia e diversas técnicas estão sendo desenvolvidas para a obtenção de informações do sistema elétrico, incluindo a desagregação do consumo de energia elétrica por cargas. Entre técnicas para a desagregação, tem-se a trajetória VI, que através do comportamento de tensão e corrente, permite a identificação dos dispositivos ligados ou desligados em um determinado ponto de conexão elétrica. Desta forma, este trabalho tem como objetivo propor uma metodologia que pode ser adicionada aos medidores de energia residenciais, permitindo a divisão do consumo de energia por eletrodomésticos. Foi utilizado um sistema embarcado e sensores não intrusivos, e grandezas de tensão e corrente são coletadas em um ponto de medição, podendo ser um poste de energia ou uma tomada elétrica. Com tais grandezas, são geradas imagens de trajetórias VI, permitindo a construção da base de dados para se utilizar técnicas para reconhecimento de padrões, para assim identificar e distinguir diferentes eletrodomésticos de forma automática. Uma vez treinado, o modelo é capaz de identificar automaticamente quais aparelhos estão ligados no ponto de medição, utilizando apenas a imagem gerada a partir da captação da tensão e da corrente no instante. Com este propósito, foi utilizado o sistema embarcado Beaglebone Rev C para a coleta de dados dos sensores, e posteriormente, como sistema dedicado para a identificação automática utilizando um modelo de rede convolucional treinado através da base de dados Plug-Level Appliance Identification Dataset (PLAID). Com a análise de 11 eletrodomésticos, tem-se como resultado a acurácia de 95,4%. Finalmente, foi possível validar e ter um modelo treinado para o uso no sistema embarcado e estudar a metodologia de monitoramento não intrusivo de cargas.

Palavras-chave: Eficiência Energética, Medidores de Energia, Aprendizado Profundo.

1 INTRODUÇÃO

Nos últimos anos, com o avanço tecnológico e o aumento da população, o consumo de energia elétrica tem crescido significativamente. De acordo com a Agência Internacional de Energia, a demanda global por eletricidade deve aumentar em até 30% até o ano de 2040 (IEA, 2023).

Para enfrentar esse problema, soluções tecnológicas para a redução do consumo de energia elétrica em residências e indústrias têm se multiplicado, tendo técnicas sendo desenvolvidas e aprimoradas para alcançar esse objetivo. Entre essas técnicas, destaca-se a desagregação de cargas, que visa identificar diferentes dispositivos conectados a uma

¹ Graduando, Universidade Tecnológica Federal do Paraná, Cornélio Procópio, egloria@alunos.utfpr.edu.br

² Doutor, Universidade Tecnológica Federal do Paraná, Cornélio Procópio, wesleyangelino@utfpr.edu.br

rede elétrica, permitindo seu monitoramento e possibilitando o uso de forma mais sustentável (ZHANG, 2018).

A desagregação de cargas pode ser realizada utilizando a trajetória VI, um método gráfico que analisa a relação entre a corrente e a tensão de um equipamento ao longo de vários ciclos da rede elétrica (KELLY; KNOTTENBELT, 2015). Este método permite a identificação dos dispositivos em funcionamento em um ponto de observação, podendo ser uma tomada ou o poste de energia elétrica.

Considerando o cenário de desagregação de cargas utilizando a trajetória VI, este trabalho apresenta o desenvolvimento de um modelo de sistema inteligente para a identificação de cargas. O sistema utiliza sensoramento de tensão e corrente, além de redes neurais profundas, especificamente redes neurais convolucionais (CNN, do inglês *Convolutional Neural Network*), embarcadas em um sistema microcontrolado.

2 METODOLOGIA

Para fazer a desagregação de cargas de forma eficiente, foi utilizado um sistema embarcado *Beaglebone Black Rev-c*, responsável por integrar a coleta dos valores de tensão e corrente da rede elétrica, montar a trajetória VI da carga presente utilizando os valores provenientes dos sensores, a construção de um banco de dados com trajetórias VI de diferentes equipamentos, e identificação do equipamento utilizando um modelo de uma CNN treinada, que tem o potencial para diferenciar e identificar as diferentes cargas. O treinamento é feito em um computador através de uma base de dado ampla e com o treinamento da rede feita, ela é embarcada no microcontrolador para que ele faça classificações em tempo real das cargas que forem ligadas a ele.

2.1 Trajetórias VI

Uma trajetória VI consiste em um gráfico onde o eixo x representa a tensão medida em um determinado número de ciclos da rede elétrica, e o eixo y a corrente nesse mesmo período. O resultado dessa associação de tensão e corrente em alguns ciclos da rede é um gráfico, com um desenho característico do funcionamento, como apresenta a Figura 1.

Tem-se como premissa que cada eletrodoméstico tem uma trajetória VI característica, que se diferencia, mesmo que nos detalhes, das trajetórias VI de outros equipamentos. Dessa forma, com uma base de dados sobre diversos momentos de funcionamento do equipamento, é possível treinar algoritmos baseados em CNNs para diferenciar essas imagens, e consequentemente classificar os diferentes eletrodomésticos.




Figura 1 – Trajetória VI de diferentes equipamentos. Fonte: XIANG et al. (2022)

2.2 Beaglebone Black rev-c

O *Beaglebone Black rev-c* foi escolhido como microcontrolador neste projeto, tanto na captura de dados para montar uma base de dados de trajetórias VI, quanto para embarcar o modelo de CNN treinado para realizar as classificações, servindo assim como um medidor inteligente capaz de reconhecer cargas ligadas.

Esse microcontrolador foi o escolhido por conta do seu ADC que tem uma resolução de 12 bits, que é preciso o suficiente para as medições que serão feitas, e unidade de processamento em tempo real, permitindo a aquisição de dados em um co-processador, enquanto roda os algoritmos no processador principal. Além de ADC, o Beaglebone Black suporta o sistema operacional Linux, mais especificamente a distribuição Debian, podendo assim executar arquivos Python, linguagem utilizada para desenvolver o modelo de CNN proposta neste trabalho.

2.3 Base de dados PLAID

Plug-Level Appliance Identification Dataset (PLAID) (GAO, et al., 2015) é uma base de dados que reúne dados de tensão e corrente medidos de diversos equipamentos nos Estados Unidos, por medições realizadas em 55 residências, para 11 categorias de aparelhos, conforme apresenta a Tabela 1. Esse banco de dados foi usado para montar diversas trajetórias VI e testar a eficiência dessa abordagem utilizando CNN, como também com outros algoritmos de aprendizado de máquina. Com a base PLAID, montou-se um conjunto de trajetórias VI para treinar diferentes algoritmos, entre eles o *Random Forest*, *k-Nearest Neighbor*, *Decision Tree* e *Logistic Regression*.

Tabela 1 – Banco de dados PLAID

Tipo de Aparelho	Modelos	Medições
Ar-condicionado	14	66
Lâmpada Fluorescente Compacta	31	175
Ventilador	23	115
Geladeira	21	38
Secador de Cabelo	32	156
Aquecedor	7	35
Lâmpada Incandescente	23	114
Laptop	34	172
Micro-ondas	28	139
Aspirador de pó	8	38
Máquina de Lavar	9	26
TOTAL	230	1074

Fonte: Adaptado de GAO et al. (2015)

2.4 Rede Neural Convolucional (CNN)

Partindo do fato de que as trajetórias VI são eficientes na desagregação de cargas, é possível treinar uma rede neural convolucional capaz de diferenciar e classificar as diferentes imagens das trajetórias VI. Esse modelo de rede neural é treinado com o banco de dados PLAID, junto com os dados montado com os sinais de tensão e corrente adquiridos com o *Beaglebone Black Rev.C*, com valores que refletem as características das redes elétricas do Brasil, e dos equipamentos que aqui são usados. Com o modelo treinado, é possível embarcá-lo no microcontrolador para utilizá-lo como um medidor inteligente.

3 RESULTADOS E DISCUSSÃO

Após da análise de diferentes modelos, foi possível comprovar a eficiência da abordagem, uma vez que a maior acurácia de classificação chegou a 94,5% em uma das iterações com o algoritmo *Random Forest*.

Para medir a eficiência da abordagem, e poder analisá-la, foi montada uma matriz de confusão (Figura 2a), que demonstra quais foram os aparelhos que foram melhor classificados, e quais foram classificados erroneamente. A Figura 2b apresenta as diferenças entre os diferentes algoritmos utilizados em um gráfico que relaciona a acurácia desses modelos, com a frequência de amostragem dos sinais de tensão e corrente da base de dados PLAID.

Posteriormente, uma CNN foi implementada. Nesta etapa, as trajetórias VI foram simplificadas a imagens coloridas de 32x32 pixels. E a CNN foi treinada considerando

1200 imagens dos 11 eletrodomésticos e validado a acurácia utilizando 300 imagens diferentes. A arquitetura da CNN é apresentada na Figura 3. A acurácia global deste modelo foi de 95,4%, tendo assim como um modelo melhor e promissor para o uso para a desagregação do consumo de energia elétrica por eletrodomésticos.




Figura 2 – a) Matriz de confusão do *Random Forest*; b) Gráfico de comparação entre os modelos.

Fonte: GAO et al. (2015).




Figura 3 – Estrutura da Rede Neural Convolucional. Fonte: Própria autoria (2024).

Posteriormente, foi feito o uso de um sensor SCT013-100A para a coleta de corrente e o uso de resistor divisor para a tensão, conforme o circuito apresentado na Figura 4. Foi adicionado um offset de 0,9 Volts, considerando que o fundo de escala do ADC do Beaglebone Black Rev.C é de 1,8 Volts. Com a taxa de amostragem de 15,36 kHz, foram coletados os sinais de tensão e corrente (Figura 5a) e convertidos para trajetórias VI, conforme Figura 5b. Desta forma, com o modelo da CNN, tem-se a possibilidade de se identificar os eletrodomésticos.




Figura 4 – Circuitos dos condicionamentos de tensão e corrente. Fonte: Própria autoria (2024).




Figura 5 – a) sinais de tensão e corrente; b) trajetória VI extraída do sinal em a).

Fonte: Própria autoria (2024).

4 CONCLUSÃO

Com base na pesquisa desenvolvida, foi possível testar, comprovar e avaliar a eficácia da identificação de cargas por meio da sua desagregação por trajetória VI. As acurácias obtidas com os diferentes algoritmos de aprendizado de máquina tornam evidente o quanto essa abordagem tem potencial para contribuir com o objetivo de diminuir o desperdício de energia elétrica nas residências. Desse modo, os próximos passos serão a validação do modelo treinado da CNN embarcado no Beaglebone Black, utilizando as trajetórias VI extraídas.

REFERÊNCIAS

- GAO, Jingkun et al. A feasibility study of automated plug-load identification from high-frequency measurements. In: 1. IEEE Global Conference on Signal and Information Processing (GlobalSIP). Orlando, FL, USA: IEEE, 2015. v. 2015, p. 220–224.
- IEA, Agência Internacional de Energia. World Energy Outlook. Paris, 2023.
- KELLY, J.; KNOTTENBELT, W. Neural NILM: Deep neural networks applied to energy disaggregation. In: Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments. New York: ACM, 2015. p. 55-64.
- XIANG, Y. et al. Non-Invasive Load Identification Algorithm Based on Color Coding and Feature Fusion of Power and Current. **Frontiers in Energy Research**, v. 10, 9 maio 2022.
- ZHANG, C. et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring. In: Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI, 2018. v. 32, n. 1.