

# Monitoramento não-intrusivo de cargas elétricas com dispositivo computacional de baixo custo<sup>\*</sup>

Lucas Abdalla Menezes<sup>\*</sup> Rainer Zanghi<sup>\*\*</sup>

<sup>\*</sup> *Graduação em Engenharia Elétrica, Universidade Federal Fluminense, RJ, (e-mail: lucasabdalla@id.uff.br).*

<sup>\*\*</sup> *Departamento de Engenharia Elétrica, Universidade Federal Fluminense, RJ (e-mail: rzanghi@id.uff.br)*

---

**Abstract:** In electrical distribution systems, consumers increase their understanding of their energy consumption habits when monitoring them in real time. The measurement of total consumption makes it impossible to see the individual expenditure of each load. Load Disaggregation, allows individual consumption to be identified from a single reading point of the circuit. In this work, a low cost hardware solution was developed, capable of processing current readings and identifying load on / off events, using an embedded classifier.

**Resumo:** Em sistemas de distribuição de energia elétrica, consumidores aumentam seu entendimento sobre seus hábitos de consumo de energia quando os visualizam em tempo real. A medição do consumo total, impossibilita a visualização do dispêndio individual de cada carga. A desagregação das cargas, permite identificar o consumo individual a partir de uma única leitura do circuito completo. Neste trabalho, foi desenvolvida uma solução com hardware de baixo custo capaz de fazer o processamento de leituras de corrente e identificar eventos liga/desliga de uma carga, usando um classificador embarcado.

*Keywords:* Automation, Electrical Energy Distribution, Machine Learning.

*Palavras-chaves:* Automação; distribuição de energia elétrica; aprendizado de máquina.

---

## 1. INTRODUÇÃO

Em Sistemas Elétricos de Potência (SEP), mais especificamente no setor de Distribuição, onde a energia é entregue aos consumidores, diversas técnicas são aplicadas para tornar este consumo sustentável. Considerando os objetivos 7 (Energia Limpa e Acessível) e 12 (Consumo e Produção Responsáveis) dos 17 Objetivos de Desenvolvimento Sustentável (ODS) definidos pela ONU (IBGE, 2021), são crescentes as discussões acerca de métodos para um consumo consciente e redução do desperdício de energia elétrica. Como mostrado por Darby (2006); Carrie Armel et al. (2013), os consumidores finais mostram-se mais sensíveis a mudanças no hábito de consumo quando conseguem visualizar seus gastos em tempo real, ao invés da maneira tradicional a cada 30 dias. Em unidades de consumo na distribuição, técnicas que permitem identificar automaticamente quais cargas foram ligadas ou desligadas — e quando esses eventos ocorreram — são fundamentais para identificação destes hábitos ou perfis de consumo (Wild et al., 2015; Nait Meziane et al., 2017). Dentre estas técnicas, o monitoramento não-intrusivo de cargas — do inglês *Non-Intrusive Load Monitoring* (NILM) — é o nome dado ao reconhecimento das cargas operantes de um circuito por meio da análise de suas curvas de corrente e tensão, sem utilizar técnicas de sensoriamento intrusi-

vas que exijam seccionamento do circuito analisado. Esta abordagem é também chamada desagregação de cargas — do inglês *Load Disaggregation* (Hart, 1992).

Na literatura associada ao NILM (Zoha et al., 2012; Esquiagola et al., 2017; Ruano et al., 2019), é possível encontrar diversas técnicas propostas para: determinação das grandezas elétricas que fornecerão os dados sobre o sistema analisado (Baptista et al., 2018; Kolter and Johnson, 2011; Ruano et al., 2019); definição de critérios para aquisição e armazenamento destes dados (Azzini et al., 2014); abordagens de desagregação das cargas (Nait Meziane et al., 2017); apresentação das informações extraídas dos dados sobre as cargas (Biansoongnern and Plangklang, 2016; Ruzzelli et al., 2010).

Para o presente trabalho, foi realizada pesquisa em portais de publicações científicas (Springer Link, Science Direct, IEEE Xplore e Periódicos Capes), onde foram encontrados 2294 artigos de conferências e revistas sobre a Desagregação de Cargas, publicados entre 1992 e fevereiro de 2021. Mesmo com esse número expressivo de publicações sobre o tema, pouco foi discutido sobre a implementação de algoritmos e técnicas NILM para sistemas embarcados. Usando essas mesmas plataformas de pesquisa, foram encontradas 246 trabalhos com as palavras chave “NILM” e “*embedded*” no contexto das Engenharias.

Diferentemente de Pereira et al. (2017); Alcalá et al. (2017); Wild et al. (2015) — que utilizam sinais simulados,

---

<sup>\*</sup> O primeiro autor agradece o suporte financeiro do CNPq/UFF como bolsista do PIBIC.

ou ainda de Ruzzelli et al. (2010), que não avalia o esforço computacional do processamento e tratamento dos dados —, a presente pesquisa tem como objetivo estudar a viabilidade do uso de sistemas embarcados de baixo custo para aquisição de grandezas elétricas que serão utilizadas na identificação e reconhecimento de cargas em um circuito de uma residência.

## 2. MONITORAMENTO NÃO INTRUSIVO

O monitoramento não intrusivo (NILM) é a análise feita em uma carga sem o contato direto (Hart, 1992). Tratando do monitoramento de cargas elétricas, um circuito residencial alimenta diversos aparelhos conectados. No paradigma convencional de monitoramento, caso seja necessário observar o consumo de um desses aparelhos, um sensor deve ser conectado diretamente nos terminais de alimentação da carga. A proposta das técnicas de NILM é permitir a identificação de cada carga, a partir de apenas um medidor colocado no circuito geral que alimenta todas as cargas. Neste cenário, as cargas monitoradas devem ser desagregadas a partir de um sinal de entrada, composto por inúmeras outras cargas.

### 2.1 Escolha da grandeza elétrica medida

Considerando a literatura associada (Ruano et al., 2019; Zoha et al., 2012), a escolha da grandeza elétrica de interesse deve estar coordenada com as metodologias empregadas para desagregação de cargas e a frequência de amostragem do sinal medido. A Figura 1, considerando Ruano et al. (2019); Zoha et al. (2012), mostra quais grandezas são adequadas para análise da carga de acordo com as diversas faixas de frequência.

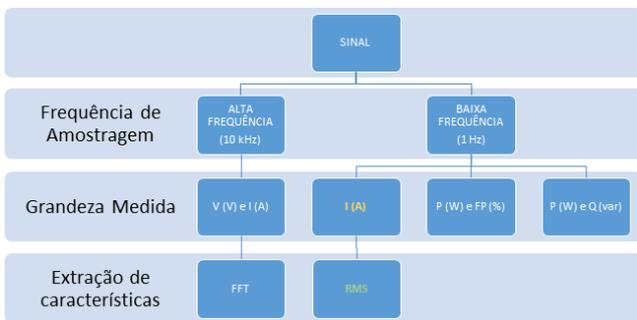


Figura 1. Características extraídas do sinal por faixas de frequência de amostragem

### 2.2 Eventos e Padrões de Consumo das Cargas

A Figura 2 ilustra como o valor RMS de corrente de um sensor, em um circuito com diversas cargas agrupadas, muda com a inserção de uma nova carga no circuito, para 3 momentos distintos. As pulsações de maior frequência representam a característica de centrifugação de uma máquina de lavar. Os degraus de período mais longo representam o acionamento e desligamento de um forno de micro-ondas.

Uma vez conhecidos os padrões de consumo de cada carga, e suas características transitórias, torna-se possível a desagregação, classificação ou diferenciação da carga desejada

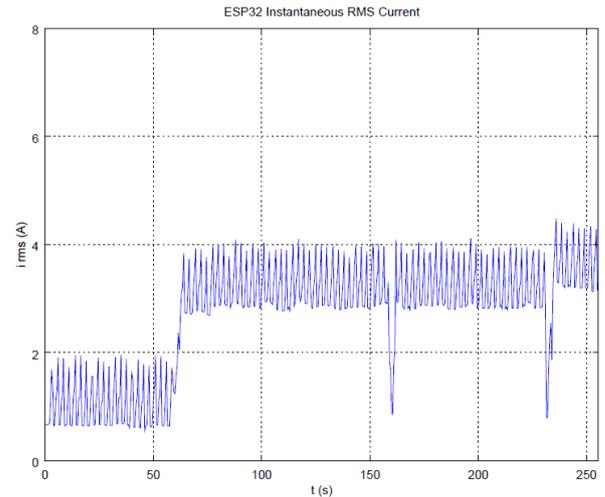


Figura 2. Variação do valor RMS de corrente com a inserção de cargas

das demais presentes no sinal. Como mostrado por Ruano et al. (2019), qualquer mudança entre regimes permanentes, é considerada um evento. Normalmente, eventos de inserção ou remoção de cargas do circuito, são mais facilmente detectados observando o sinal de corrente do circuito. Além disso, segundo Anderson et al. (2012), detectores de eventos podem ser agrupados em três abordagens distintas: filtros compatíveis, análises heurísticas e modelos probabilísticos. Os filtros compatíveis, podem ser caracterizados pela comparação das curvas dos eventos, com padrões já conhecidos. Esse método não requer treinamento nem conhecimento prévio das cargas monitoradas. Técnicas como a transformada de Hilbert e filtro de Kalman foram utilizadas por Alcalá et al. (2017) e são exemplos desta abordagem. A análise heurística, consiste na criação de premissas e regras acerca da carga estudada, como potência total demandada pela carga e variação de potência demandada ao iniciar o evento. Por fim, os Modelos probabilísticos, por meio de um treinamento prévio, são capazes de dizer a probabilidade de um evento observado ter ocorrido. Algumas metodologias de modelos probabilísticos conhecidas são as Redes Neurais Artificiais (RNA), Árvores de decisão, K-Vizinhos mais próximos e Regressão por Mínimos Quadrados (Ruano et al., 2019; Ciosek and Wróblewski, 2006).

## 3. REDE NEURAL ARTIFICIAL

Neste trabalho, uma Rede Neural Artificial tem o papel de fazer a classificação das formas ou assinaturas das cargas conhecidas num circuito (Biansongnorn and Plangklang, 2016; Morais and Castro, 2019) através de um aprendizado supervisionado. Uma RNA é composta por diversos nós (ou neurônios). Esses neurônios artificiais são os responsáveis por, dado um valor de entrada, computar uma saída considerando o peso da ligação com a entrada e a sua função de ativação para a saída. Uma rede composta por apenas um nó é chamada de Perceptron. Uma sequência de nós encadeados ou associados em paralelo com múltiplas entradas é chamado de Perceptron Multicamadas (MLP). Nessa topologia de rede, os neurônios são divididos em

camadas. A resposta de cada camada serve de alimentação para a camada sucessora. A primeira camada é alimentada com as *features* da rede, e a resposta produzida alimenta a camada escondida. A resposta produzida pela camada escondida é responsável pelo sinal de saída do sistema. Um algoritmo utilizado para aprendizado da rede é o de retropropagação (do inglês *back propagation*). Esse método tem a função de minimizar o erro entre a resposta obtida pela rede e a resposta desejada para uma mesma entrada. Para um domínio bem mapeado, uma rede bem treinada é capaz de fazer a classificação de valores de entrada próximos aos conhecidos (Morais and Castro, 2019).

### 3.1 Alimentação da rede

No aprendizado supervisionado de RNAs, para que haja o treinamento efetivo é necessário que exista uma resposta produzida a partir de uma entrada. Cada neurônio artificial da rede produz uma saída que serve de entrada para o neurônio da camada seguinte. Esse processo se repete, até que a resposta da rede inteira seja computada. Para um neurônio simples (ou Perceptron), os valores de  $x_1, x_2, \dots, x_n$  representam as entradas e  $w_1, w_2, \dots, w_n$  representam os respectivos pesos de cada entrada até o neurônio artificial. Os estímulos ao neurônio podem ser calculados pelo produto escalar do vetor de entradas pelo vetor de pesos (1). Uma vez calculado a soma dos estímulos ao neurônio, esse valor passa por uma função de ativação (2), gerando a resposta do neurônio correspondente àquela entrada.

$$E = \sum_{i=1}^n x_i * w_i \quad (1)$$

$$Relu(x) = \max(0, x) \quad (2)$$

### 3.2 Retropropagação

Os pesos representam uma diferença significativa entre dois neurônios de mesma topologia e mesmas funções de ativação. Para ajustar os pesos do neurônio e consequentemente da rede, utiliza-se o método de retropropagação. Esse método compara a resposta esperada ( $\hat{y}$ ) com aquela efetivamente produzida por um nó ( $y$ ), dada uma entrada. O erro é calculado somando a essa diferença uma penalidade  $W$  multiplicado por um parâmetro positivo ( $\frac{\alpha}{2}$ ) que controla sua magnitude. Utilizando a otimização por gradiente descendente, a função de erro (ou função de perda (3)) deve ser minimizada para que a rede reproduza uma resposta adequada.

$$Erro(\hat{y}, y, W) = \frac{1}{2}|\hat{y} - y| + \frac{\alpha}{2}|W| \quad (3)$$

### 3.3 Atualização dos pesos

Tomando num âmbito mais amplo o que foi dito no item anterior, uma diferença significativa entre duas redes de mesma topologia são os seus pesos. Após uma iteração de alimentação da rede na fase de treinamento, o erro da resposta é calculado e uma retropropagação é feita atualizando os pesos da rede na direção que minimiza o erro da resposta final.

## 4. METODOLOGIA PROPOSTA

Para o estudo descrito nesse artigo, foram utilizados sinais reais de uma das fases de alimentação de uma unidade residencial. A carga escolhida como alvo a ser desagregada do sinal total foi um forno micro-ondas. Foi escolhida a corrente RMS (*root mean square*) como grandeza de interesse coletada a baixa frequência (2 Hz). Essa escolha foi feita por conta da simplicidade do circuito de condicionamento de sinal usado e considerando as limitações de eficiência computacional em sistemas embarcados de baixo custo. A Figura 3 mostra o design da solução para captura dos valores e armazenamento para criação da base de dados. Todo o processo de coleta dos valores instantâneos e cálculo do valor RMS foram feitos em um sistema computacional de baixo custo ESP32 (ESPRESSIF, 2016), utilizando um Transformador de Corrente (TC) do tipo janela em um circuito de condicionamento de sinal simplificado. Foram pesquisados sistemas similares no mercado (Sense, 2021; Emporia, 2021) e verificados custos até 10 vezes maiores que o custo total do protótipo desenvolvido nesse trabalho.

A Figura 4, mostra o diagrama do circuito de condicionamento de sinal utilizado. A tensão induzida no enrolamento secundário do TC, pode ser amostrada a partir da diferença de potencial entre a “ponta” e a “capa” de um conector P2, tipo TRS. Para normalizar essa tensão à faixa de leitura do ESP32, foi utilizado um filtro passa-baixa (capacitor C2 em paralelo com a porta analógica) e um circuito de *Offset* de 1,67 V (Trimpot R1-R2, em conjunto com o capacitor C1). Vale ressaltar que a escolha dos componentes adotou os critérios de custo e simplicidade.

Um fluxograma simplificado de funcionamento do ESP32 é ilustrado na figura 5. As funcionalidades ilustradas nesta figura são descritas a seguir. Após a inicialização do ESP32 e sua conexão com a rede, é feita a sincronização do relógio interno via protocolo de sincronismo NTP (*Network Time Protocol*). A cada 100 microssegundos o temporizador interno do ESP32 causa uma interrupção de software e chama as funções de *callback* de amostragem. Essas funções são responsáveis por amostrar o valor atual de tensão na porta analógica e o instante em que foram amostradas. Após a captura de 256 amostras, é calculado o valor RMS de corrente proporcional aos valores de tensão lidos. A cada novo valor RMS calculado, esse é inserido num vetor tipo FIFO (*First In First Out*) de valores calculados. Esse vetor tem tamanho máximo de 256 valores RMS calculados. Quando um novo valor RMS é calculado, e o vetor de valores RMS está cheio, o valor RMS mais antigo é descartado, e o mais novo inserido. Foi criada, ainda no ESP32, uma rota que pode ser acessada pela rede, e disponibiliza os últimos 256 valores RMS calculados, junto com os seus respectivos tempos de geração ou estampa de tempo. O ciclo de captura de amostras é reiniciado a cada 500 milissegundos, por meio de um segundo temporizador presente no ESP32. Dessa forma o ESP32, a cada 256 ms, tem 244 ms para computar as requisições feitas e recebidas na rede.

Para armazenar essas amostras geradas pelo ESP32 em arquivos csv, foi criado um *web server* que faz a coleta de valores a cada 24 horas, e armazena as amostras RMS em um arquivo .csv. Após alguns dias de capturas pelo *web server*, os arquivos gerados foram utilizados para criação

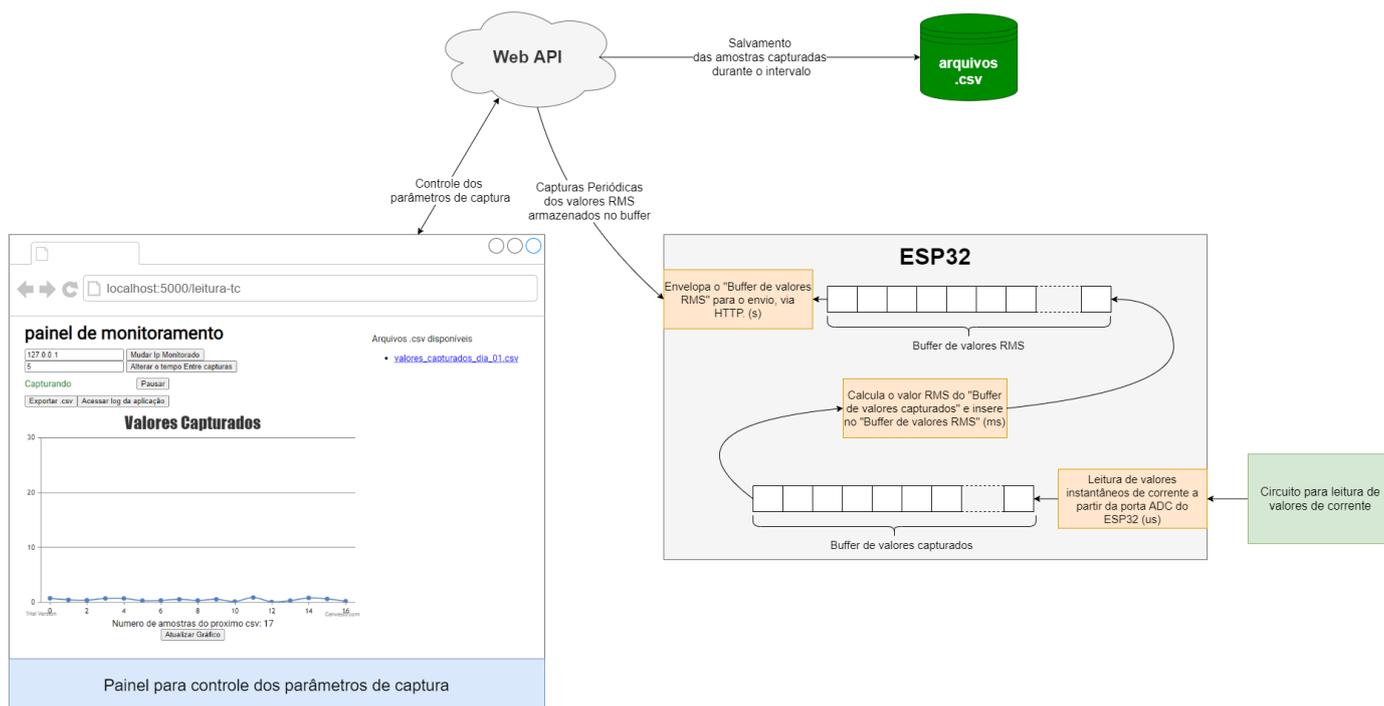


Figura 3. Design do Sistema

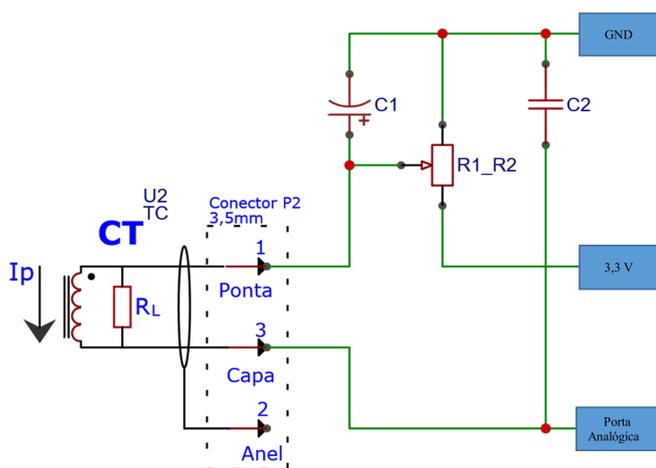


Figura 4. Circuito de condicionamento de sinal.

da base de dados. Essa base de dados, após tratada, serviu de entrada para o treinamento da rede neural artificial. Considerando as limitações computacionais e custo, foi escolhido como classificador uma RNA do tipo MLP. Para o presente trabalho, foram avaliadas diversas topologias para a RNA. Todos os resultados apresentados levam em consideração uma rede com 5 nós na camada de entrada, 4 camadas escondidas de 5, 8, 8 e 5 neurônios cada e uma camada de saída com 3 neurônios. Foi utilizada a função de ativação ReLU (2) para os neurônios das camadas escondidas. Para a camada de saída foi utilizada a função de ativação Softmax (Scikit-Learn, 2010). Como feito em Nait Meziane et al. (2017), para a entrada do classificador, foi escolhida uma janela de valores que contém as últimas 5 amostras RMS calculadas. Essa janela é atualizada a cada 500ms, removendo a amostra mais antiga e inserindo a mais nova no início da fila. Para preparar a base de

dados de treinamento e teste do classificador, os arquivos csv gerados pelo *web server* foram convertidos para o formato de janelas de tempo, compatível com as entradas da RNA. Para filtragem das janelas que seriam utilizadas no treinamento, foi utilizado o software Weka (1997). Depois de concluído o treinamento da RNA utilizando a biblioteca Scikit-Learn (2010) para Python, foi escrito um código em C para embarcar o classificador no ESP32.

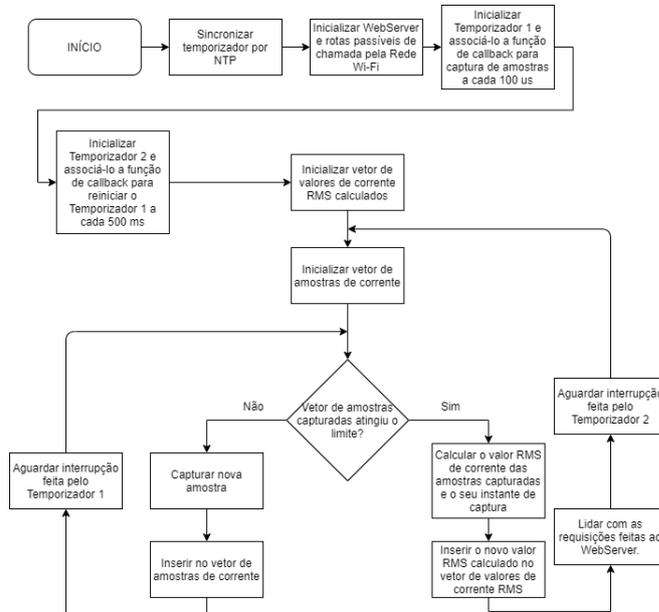


Figura 5. Fluxograma de funcionamento ESP32

## 5. RESULTADOS

Após feita a implementação da RNA no ESP32, foi criada uma rota no serviço *Wi-Fi* do dispositivo que mostra a

lista dos últimos 256 tipos de eventos detectados (resposta “ligando” ou “desligando” do classificador) e os horários em que ocorreram. Uma rede ideal deve ser capaz de detectar todos eventos de ligamento e desligamento da carga que será desagregada sem falsos positivos e negativos. Como o objetivo deste trabalho era a verificação da efetividade da solução de um classificador RNA embarcado em um dispositivo de baixo custo, que também faz a medição de corrente e cálculo de seu valor RMS, optou-se por realizar uma análise qualitativa do funcionamento da solução, descrita a seguir.

Após a conclusão de um período de 24 horas de funcionamento da solução, com alguns acionamentos do forno de micro-ondas, foi criado um script em *Python* para a visualização dos dados. A Figura 6 e 7 mostram um recorte temporal do gráfico gerado indicando a variação dos valores RMS ao longo de um período e os eventos que foram detectados pelo classificador embarcado no ESP32.

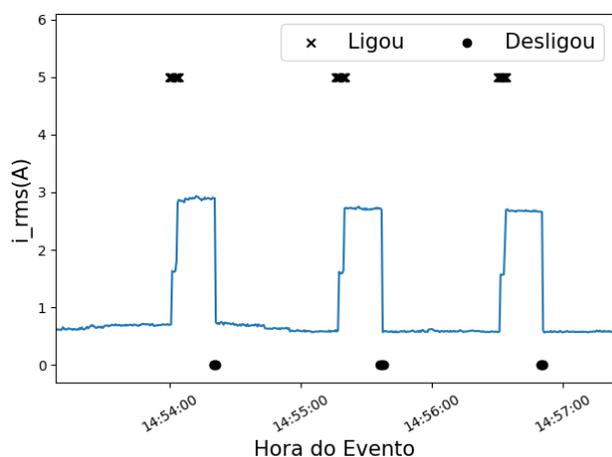


Figura 6. Gráfico com a corrente RMS e detecção de eventos sem perturbações externas

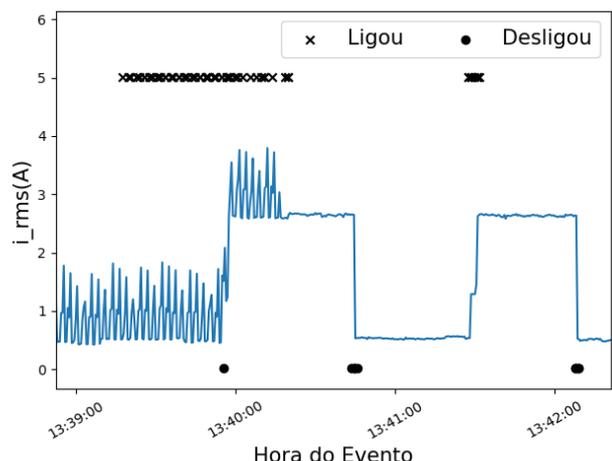


Figura 7. Gráfico com a corrente RMS e detecção de eventos com perturbações externas

Pelos resultados apresentados pelo gráfico da Figura 6, é possível perceber que o ESP32 foi capaz de reconhecer corretamente os seis eventos (3 de ligamento + 3 de desligamento) com precisão. Já na Figura 7, quando inseridas

outras cargas mais complexas no sinal composto, é possível perceber que o ESP32 foi capaz de reconhecer corretamente os quatro (2 de ligamento + 2 de desligamento) eventos apresentados na figura. Entretanto, o trecho anterior ao primeiro acionamento do micro-ondas mostra que a rede ainda está sensível a ruídos, e não consegue identificar cargas onde as variações de valores RMS assemelham-se ao do acionamento do micro-ondas. Para classificação dos eventos de desligamento, foi observado um número menor de falsos positivos comparado aos eventos de ligamento.

## 6. CONCLUSÕES

Pelos resultados observados, foi possível verificar a viabilidade de utilização de um dispositivo de baixo custo para identificar eventos em cargas conhecidas em uma rede elétrica, usando um classificador RNA. Neste mesmo dispositivo, foi feita a medição de corrente através de um circuito simplificado de condicionamento de sinal, o cálculo de seu valor RMS e um *web server* para leitura dos dados coletados e calculados com estampa de tempo. O desempenho do classificador na identificação de eventos de ligamento e desligamento de um forno de micro-ondas foi avaliado de forma qualitativa e os resultados mostraram que a abordagem é viável e promissora, mas carece de mais investigação para a redução de falsos positivos.

## AGRADECIMENTOS

À Pró-Reitoria de Pesquisa, Pós-graduação e Inovação (PROPI) da Universidade Federal Fluminense, por custear parte do estudo por meio de bolsas de iniciação científica PIBIC durante o período 2019-2020.

## REFERÊNCIAS

- Alcalá, J., Ureña, J., Hernández, Á., and Gualda, D. (2017). Event-based energy disaggregation algorithm for activity monitoring from a single-point sensor. *IEEE Transactions on Instrumentation and Measurement*, 66(10), 2615–2626. doi:10.1109/TIM.2017.2700987.
- Anderson, K., Bergés, M., Ocneanu, A., Benitez, D., and Moura, J. (2012). Event detection for non intrusive load monitoring. *IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society*, 3312–3317.
- Azzini, H.A.D., Torquato, R., and da Silva, L.C.P. (2014). Event detection methods for nonintrusive load monitoring. In *2014 IEEE PES General Meeting | Conference Exposition*, 1–5. doi:10.1109/PESGM.2014.6939797.
- Baptista, D., Mostafa, S., Pereira, L., Sousa, L., and Morgado-Dias, F. (2018). Implementation strategy of convolution neural networks on field programmable gate arrays for appliance classification using the voltage and current (v-i) trajectory. *Energies*, 11, 2460. doi:10.3390/en11092460.
- Biansongnern, S. and Plangklang, B. (2016). Nonintrusive load monitoring (nilm) using an artificial neural network in embedded system with low sampling rate. In *2016 13th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 1–4. doi: 10.1109/ECTICon.2016.7561398.
- Carrie Armel, K., Gupta, A., Shrimali, G., and Albert, A. (2013). Is disaggregation the holy grail of

- energy efficiency? the case of electricity. *Energy Policy*, 52, 213–234. doi:<https://doi.org/10.1016/j.enpol.2012.08.062>. URL <https://www.sciencedirect.com/science/article/pii/S0301421512007446>. Special Section: Transition Pathways to a Low Carbon Economy.
- Ciosek, P. and Wróblewski, W. (2006). The analysis of sensor array data with various pattern recognition techniques. *Sensors and Actuators B: Chemical*, 114(1), 85–93. doi:<https://doi.org/10.1016/j.snb.2005.04.008>.
- Darby, S. (2006). The effectiveness of feedback on energy consumption: A review of the literature on metering, billing and direct displays. 1–21. URL <http://www.google.com/search?q=Valuation+of+Non-Energy+Benefits+to+Determine+Cost-Effectiveness+of+Whole-House+Retrofit+Programs:+A+Literature+Review+Amann>.
- Emporia (2021). Emporia. <https://www.emporiaenergy.com/best-home-energy-monitor/>.
- ESPRESSIF (2016). Technical documents | espressif systems. <https://www.espressif.com/en/support/documents/technical-documents/>.
- Esquiagola, J., Costa, L., Calcina, P., Fedrechski, G., and Zuffo, M. (2017). Performance testing of an internet of things platform. In *Proceedings of the 2nd International Conference on Internet of Things, Big Data and Security - Volume 1: IoTBDS*, 309–314. INSTICC, SciTePress. doi:10.5220/0006304503090314.
- Hart, G. (1992). Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 80(12), 1870–1891. doi:10.1109/5.192069.
- IBGE (2021). Indicadores brasileiros para os objetivos de desenvolvimento sustentável. <https://odsbrasil.gov.br/>.
- Kolter, J. and Johnson, M. (2011). Redd: A public data set for energy disaggregation research. *Artif. Intell.*, 25.
- Morais, L.R. and Castro, A.R.G. (2019). Competitive autoassociative neural networks for electrical appliance identification for non-intrusive load monitoring. *IEEE Access*, 7, 111746–111755. doi:10.1109/ACCESS.2019.2934019.
- Nait Meziane, M., Ravier, P., Lamarque, G., Le Bunetel, J.C., and Raingeaud, Y. (2017). High accuracy event detection for non-intrusive load monitoring. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2452–2456. doi:10.1109/ICASSP.2017.7952597.
- Pereira, E.L., C.Cavaliere, D., and Resende, C.Z. (2017). *Método de identificação de cargas elétricas as técnicas Short-Time Fourier e Kernel PCA*. XIII Simpósio Brasileiro de automação Inteligente.
- Ruano, A., Hernandez, A., Ureña, J., Ruano, M., and Garcia, J. (2019). Nilm techniques for intelligent home energy management and ambient assisted living: A review. *Energies*, 12(11). doi:10.3390/en12112203.
- Ruzzelli, A.G., Nicolas, C., Schoofs, A., and O’Hare, G.M.P. (2010). Real-time recognition and profiling of appliances through a single electricity sensor. In *2010 7th Annual IEEE Communications Society Conference on Sensor, Mesh and Ad Hoc Communications and Networks (SECON)*, 1–9. doi:10.1109/SECON.2010.5508244.
- Scikit-Learn (2010). Scikit-Learn machine learning in python. <https://scikit-learn.org/>.
- Sense (2021). Sense. <https://sense.com/product/>.
- Weka (1997). Weka the workbench for machine learning. <https://www.cs.waikato.ac.nz/>.
- Wild, B., Barsim, K.S., and Yang, B. (2015). A new unsupervised event detector for non-intrusive load monitoring. In *2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 73–77. doi:10.1109/GlobalSIP.2015.7418159.
- Zoha, A., Gluhak, A., Imran, M.A., and Rajasegarar, S. (2012). Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey. *Sensors*, 12(12), 16838–16866. doi:10.3390/s121216838.