

IDENTIFICAÇÃO INTELIGENTE DE CARGAS ELÉTRICAS SIMILARES EM SMART GRID

RAYANA KRISTINA SCHNEIDER BARCELOS*, WANDERLEY CARDOSO CELESTE†, LUIS OTÁVIO RIGO JÚNIOR†, HELDER ROBERTO DE OLIVEIRA ROCHA‡, DANIEL JOSÉ CUSTÓDIO COURA§

**Instituto Federal de Brasília (IFB), QNN 26 Área Especial, s/n
Ceilândia
Brasília, DF, Brasil*

*†Universidade Federal do Espírito Santo (UFES), Rodovia BR 101 Norte, Km. 60
Litorâneo
São Mateus, Espírito Santo, Brasil*

Emails: rayana.schneider@ifb.edu.br, wanderley.celeste@ufes.br, luis.rigo@ufes.br,
helder.rocha@ufes.br, daniel.coura@ufes.br

Abstract— This article shows the result of applying characterization techniques to define load signatures in Smart Grids. The differential of this work is that the loads have the same technical data and are from the same manufacturer (loads with a high degree of similarity), making the identification process more difficult and describing a challenging condition. The prototype is a platform with four technically identical fluorescent lamps, allowing 16 possible operation configurations, this means, from no one lamp turned on to all the lamps turned on. A technique, based on the Shannon and Renyi entropy, is implemented and tested to define the load signature. Next, the signature sets, classified through Case-Based Reasoning (RBC), are submitted to an optimizer aiming to find the highest possible accuracy for the identification system. The lowest error rate obtained in this work is 22.69% and represents a good performance of the identification system, given the complexity of the problem. These initial results will serve as a reference for new solutions to this new problem.

Keywords— Load Identification, Load Signature, Smart Grid.

Resumo— Este artigo mostra o resultado da aplicação de técnicas de caracterização para definir assinaturas de carga em Smart Grids. O diferencial deste trabalho é que as cargas possuem os mesmos dados técnicos e são do mesmo fabricante (cargas com alto grau de similaridade), dificultando o processo de identificação e descrevendo uma condição desafiadora. O protótipo é uma plataforma com quatro lâmpadas fluorescentes tecnicamente idênticas, permitindo 16 configurações de operação possíveis, isto é, de nenhuma lâmpada acesa para todas as lâmpadas ligadas. Uma técnica, baseada na entropia de Shannon e Renyi, é implementada e testada para definir a assinatura da carga. Em seguida, os conjuntos de assinaturas, classificados por meio do Raciocínio Baseado em Casos (RBC), são submetidos a um otimizador com o objetivo de encontrar a menor taxa de erro possível para o sistema de identificação. A menor taxa de erro obtida neste trabalho é de 22,69 % e representa um bom desempenho do sistema de identificação, dada a complexidade do problema. Esses resultados iniciais servirão de referência para novas soluções para esse novo problema.

Palavras-chave— Identificação de Carga, Assinatura de Carga, Smart Grid.

1 Introdução

A utilização da energia elétrica está associada ao crescimento, ao desenvolvimento tecnológico de um país, ao conforto e à dignidade humana, sendo seu acesso indispensável nos dias atuais e um direito universal. Com o crescimento populacional e o aumento do consumo de energia elétrica, acentuado pelo avanço tecnológico, é necessário pensar em formas sustentáveis de produzir e consumir essa energia, seja por motivos financeiros ou pela finitude dos recursos energéticos do planeta (Chaves, G. de L. D. and Tosta, M. de C. R., 2016). Para alcançar esse objetivo, um dos caminhos é a utilização eficaz da energia elétrica.

O advento da tecnologia da informação e sua aplicação em redes de energia elétrica configurou o que é conhecido como rede inteligente ou *smart grid*. Nessas redes, as informações obtidas permitem diversas aplicações, dentre elas o gerenciamento ótimo da energia elétrica. Estudos fei-

tos em residências já mostraram que o gerenciamento permite economizar de 10% a 15% da energia (Ehrhardt-Martinez et al., 2010). Entretanto para gerenciar as cargas que compõem uma *smart grid*, é necessário, primeiramente, identificá-las no sistema.

O problema de identificação de cargas pode ser solucionado aplicando-se um sensor em cada carga. Desse modo, é possível saber qual carga está funcionando, ou não, e quanto ela está consumindo. Contudo, esse método é intrusivo. Em uma casa, por exemplo, seria necessário instalar um sensor em cada equipamento a ser monitorado, como chuveiros, tomadas e lâmpadas, o que pode requerer uma infraestrutura que normalmente não está disponível, aumentando o custo de instalação e manutenção da edificação. Por isso, outra metodologia tem sido desenvolvida, onde é instalado apenas um conjunto sensorial na entrada da instalação elétrica a ser monitorada, e com os dados de medição da demanda elétrica instantânea total, é

possível definir quais equipamentos estão ligados e qual seu consumo (instantâneo ou médio). Essa metodologia, proposta no início dos anos 90 por Hart, é conhecida como Non-Intrusive Load Monitoring (NILM)(Hart, 1992).

Um dos desafios do monitoramento não-intrusivo é desagregar o sinal total coletado pelo sensor, de modo a identificar quais cargas, pertencentes a uma base de dados previamente determinada, são as responsáveis por gerá-lo (Liang et al., 2010). Para isso, é preciso caracterizar cada carga, isto é, buscar em cada equipamento uma assinatura específica e, finalmente, verificar quais assinaturas estão presentes no sinal analisado. Sendo assim, o sistema de identificação passa por duas etapas: primeiro, há a definição e extração das características da onda, obtendo assim sua assinatura; depois, na segunda etapa, essas assinaturas são combinadas para descobrir quais as cargas estão em funcionamento.

Uma análise, feita na literatura, da primeira etapa mostra que, na busca por essa assinatura, diversas técnicas têm sido testadas: transformada de Fourier, transformada *Wavelet*, e cálculo da potência ativa, da reativa, da aparente e da admitância. Entretanto, não há ainda um consenso formado sobre quais são as características representativas universais (Azzini et al., 2012) (Zeifman and Roth, 2011). As técnicas e a obtenção das assinaturas podem ser feitas tanto no estado transitório como no estado estacionário do sinal analisado, dividindo o estudo em duas vertentes.

Sequencialmente, a segunda etapa compara a assinatura do sinal total coletado com as assinaturas individuais, e suas combinações, das cargas presentes na rede, visando definir, pela análise do sinal total, quais cargas estão ligadas. Nessa segunda etapa pode-se aplicar técnicas de classificação como redes neurais, *K-means*, raciocínio baseado em casos (RBC), dentre outros métodos, sendo também alvo de estudos para melhoria da acurácia do sistema de identificação como um todo. É importante notar que o sistema de identificação passa por essas duas etapas e que, apesar de serem etapas complementares, este trabalho foca no sinal em regime estacionário e na primeira etapa do processo de identificação: a caracterização através da definição da assinatura da carga.

O estado da arte, obtido através de uma revisão exaustiva da literatura científica referente ao tema aqui abordado, tem mostrado que é comum o uso de cargas que apresentem comportamentos e dados técnicos distintos entre si para testar o sistema de identificação implementado. Em muitos casos, as cargas constituem-se de equipamentos diferentes e que ainda sim são confundidas entre si no classificador quando possuem comportamento e potência parecidos. Os autores ressaltam que as taxas de erro do sistema de

identificação crescem à medida que equipamentos com assinaturas semelhantes estão presentes no cenário analisado, reforçando assim a dificuldade em se diferenciar cargas muito parecidas (Ahmadi and Marti, 2015)(Hassan et al., 2014) (Belley et al., 2014) (Sadeghianpourhamami et al., 2017).

Além disso, nas metodologias empregadas por diversos autores, as cargas são acionadas individualmente, isto é uma de cada vez, facilitando o processo de identificação, pois não há a necessidade de desagregar o sinal de demanda elétrica. Entretanto, tais situações são ideais e pouco contribuem com a obtenção de sistemas robustos o suficiente para tratar de situações reais. Sendo assim, a metodologia adotada neste trabalho se baseia no uso de cargas com alto grau de similaridade, acionadas ora individualmente e ora em conjunto, como de fato acontece em condições reais, para tratar do problema de identificação de cargas via NILM.

Recentemente, em (Paixão et al., 2016), foi tratado o problema de identificação de cargas com alto grau de similaridade, chamado pelo autor de cargas "idênticas". Naquele trabalho, o autor constrói uma plataforma experimental com quatro lâmpadas fluorescentes compactas, as quais podem ser acionadas ora individualmente e ora em conjunto (são 16 as configurações de acionamento utilizadas). Dos sinais de demanda, o autor extrai 14 características representadas em 150 amostras de cada configuração possível. Por fim, o autor utiliza uma série de ferramentas de classificação para treinar, validar e testar o sistema de identificação proposto.

No trabalho desenvolvido nesse artigo são utilizados os mesmos dados experimentais obtidos em (Paixão et al., 2016), entretanto é explorado um novo conjunto de características que permitam um melhor desempenho do sistema de classificação. Com o objetivo de buscar um conjunto ótimo de características, usa-se neste trabalho o classificador RBC (Raciocínio Baseado em Casos) durante as etapas de validação, treinamento e teste do sistema.

O caso que se estuda neste trabalho tem como diferenciais, em relação ao que é encontrado na literatura, a identificação de cargas com alto grau de similaridade, conforme já mencionado, além do fato de tais cargas poderem ser ligadas individualmente ou em conjunto, elevando, em muito, o grau de dificuldade do problema de identificação, porém, agregando componentes que aproximam o problema à realidade observada.

Na seção 2 é feita uma descrição da plataforma utilizada, da coleta de dados, das características que representam as cargas, do método de classificação aplicado e do otimizador implementado. Na seção 3 é mostrado e discutido o resultado da aplicação das técnicas descritas. Na seção 4 são comentadas as conclusões e as possibilidades em trabalhos futuros.

2 Metodologia

2.1 Plataforma Experimental e dados utilizados

A plataforma experimental é composta por quatro lâmpadas fluorescentes compactas da mesma marca e com os mesmos dados técnicos. Desse modo, as cargas são tecnicamente idênticas, porém supõe-se que, devido às diferenças nanométricas causadas, por exemplo, pelo processo de manufatura, elas não sejam perfeitamente iguais. Por isso, são chamadas aqui de cargas similares. Em seguida é aplicado um sensor de corrente, modelo SCT-013-000, no circuito de modo a medir a corrente instantânea total drenada pelo conjunto de lâmpadas, conforme pode ser visto na Fig. 1. Para coletar a tensão é colocado um transformador abaixador de 300 mA de corrente nominal com três fios no primário (127 ou 220 V) e três fios no secundário (+9V ou -9V) que também pode ser observado na Fig. 1. A tomada é utilizada por (Paixão et al., 2016) para ligar outros equipamentos, não sendo necessária para obtenção dos dados utilizados neste artigo.




Figura 1: Componentes da plataforma experimental

O diagrama esquemático da plataforma pode ser observado na Fig. 2, bem como os dados técnicos das lâmpadas na Tabela 1. É importante notar que a plataforma permite o acionamento individual e combinado das lâmpadas, totalizando 16 configurações que vão desde todas as lâmpadas desligadas até todas as lâmpadas ligadas. Esse é um ponto importante, pois não é analisado apenas o comportamento individual das cargas, mas sim todas as possíveis ligações entre elas: individuais e combinadas.

É coletado então um total 150 ciclos de tensão e 150 ciclos corrente para cada uma das 16 possíveis configurações de lâmpadas. Essa coleta é feita com um osciloscópio *Tektronix TDS2002B* e um *notebook* através do *software NI LabVIEW Signal Express Tektronix Edition*. Esses ciclos são obtidos após tempos distintos de funcionamento




Figura 2: Esquemático da plataforma experimental

Tabela 1: Dados técnicos das lâmpadas

Parâmetro	Valor
Potência ativa	15 W
Tensão nominal	127 V
Corrente elétrica	190 mA
Fator de potência	$\geq 0,5$
Eficiência luminosa	56,3 lm/W
Temperatura máxima do invólucro	85 °C
Faixa de temperatura ambiente	5 °C - 45 °C
Frequência nominal de alimentação	50/60 Hz
Tempo para atingir 80% do fluxo luminoso	60 s
Fluxo luminoso	844 lm
Vida mediana	6000 h

do circuito para garantir robustez, uma vez que a impedância das cargas é alterada devido a energia térmica do circuito. Os tempos utilizados são: após ser ligado, com 5 minutos de funcionamento, com 10 minutos, com 15 minutos e após 20 minutos de funcionamento. Para o trabalho que se desenvolve nesse artigo são utilizados os dados de corrente elétrica coletados na frequência de 25kHz. Desse modo, a matriz de dados que se utiliza na técnica de caracterização é composta por dados da corrente elétrica total do circuito, na frequência de amostragem de 25kHz, com 150 ciclos, coletados em momentos distintos, para cada uma das 16 configurações. Portanto tem-se no total 2.400 ciclos de corrente.

2.2 Método de caracterização

Para caracterizar eletricamente cada carga (lâmpada) da plataforma, e cada combinação possível delas, é implementada uma técnica de caracterização de cargas descrita no artigo (Bouhouras et al., 2014). Nessa técnica, são utilizados três coeficientes - entropia de Shannon (SE), entropia de Renyi (RE) e banda espectral de energia (SBE) para definir a assinatura de carga. O artigo (Bouhouras et al., 2014) não é implementado integralmente, apenas a parte referente à primeira etapa do sistema de identificação, isto é, a caracterização, é utilizada e algumas aproximações do autor são desconsideradas por se tratar de cenários

diferentes. A seguir é descrito o passo a passo para a obtenção das assinaturas nessa segunda técnica testada.

1. Define-se a quantidade n de ciclos que é considerada na extração das características. Nesse trabalho, define-se um ciclo. Como a frequência de amostragem é 25 kHz e a frequência da rede é 60 Hz, cada ciclo tem aproximadamente 417 pontos. Desse modo, forma-se o vetor corrente elétrica no domínio do tempo I_{ti}^a com $i = 1, 2, \dots, 417$ elementos, t se referindo ao domínio do tempo e a sendo o número de configurações possíveis $a = 1, 2, \dots, 16$.

2. Aplica-se a transformada discreta de Fourier no vetor corrente elétrica, obtendo-se o vetor corrente elétrica no domínio da frequência, isto é $[I_{ti}^a] \xrightarrow{FFT} [I_{fi}^a]$, onde f se refere ao domínio da frequência.

3. São definidas a largura da banda f_b e a quantidade de bandas n_b de frequência. Os elementos do vetor $[I_{fi}^a]$ são divididos em grupos, de acordo com a escolha desses valores. Cada banda B_j tem um intervalo de frequência dado pelo menor valor de frequência (l_j) e o maior valor de frequência (u_j), onde $j = 1, 2, \dots, n_b$.

4. Para cada banda B_j são obtidas a entropia de Shannon(SE), a entropia de Renyi(RE), a banda espectral de energia(SBE), a declinação de SE(dSE) e a declinação de RE(dRE), conforme as Equações (1) a (5), respectivamente.

$$SE_j^a = \sum_{l_j}^{u_j} |I_{fi}^a| \cdot (\log_2 |I_{fi}^a|) \quad (1)$$

$$RE_j^a = \frac{1}{(1-r)} \log\left(\sum_{l_j}^{u_j} |I_{fi}^a|^r\right), r = 2 \quad (2)$$

$$SBE_j^a = \frac{\sum_{l_j}^{u_j} |I_{fi}^a|^2}{\sum_{l_1}^{u_{n_b}} |I_{fi}^a|^2} \quad (3)$$

$$dSE_j^a = \tan^{-1}(SE_{j+1}^a - SE_j^a) \quad (4)$$

$$dRE_j^a = \tan^{-1}(RE_{j+1}^a - RE_j^a) \quad (5)$$

5. A assinatura de carga é definida como $\delta_k = [SE_j^a, RE_j^a, SBE_j^a, dSE_j^a, dRE_j^a]$, onde $k=1, 2, \dots, N$ refere-se a uma amostra da assinatura, sendo N o número de amostras da assinatura disponíveis para treinamento, validação e teste do sistema de classificação.

6. Após realizar as etapas 2 a 5, obtém-se uma matriz $\delta^{N \times 5}$, onde $N = 2400$ para o banco de dados utilizado neste trabalho. Além disso, cada coluna da matriz δ é normalizada conforme

a Equação (6). Isso é necessário para os classificadores diferenciarem as configurações entre si.

$$x_k' = \frac{x_k - \min(x)}{\max(x) - \min(x)} \quad (6)$$

2.3 Classificação

Como o intuito deste trabalho é analisar a variação dos métodos de caracterização da carga, foi usado um único método de classificação para todos os conjuntos de características considerados. O classificador utilizado foi o Raciocínio Baseado em Casos (RBC), o qual é apresentado em (Kolodner, 2014).

O método da Validação Cruzada (*Cross-Validation*) é utilizado para medir o desempenho do classificador. Inicialmente é feito um pré-processamento que embaralha os dados e separa o conjunto de teste (10% dos dados) do restante. Em seguida, o restante dos dados (90%) é dividido em k grupos. Estes k grupos são organizados em: conjunto de treinamento ($k-1$ grupos) e conjunto de validação (1 grupo). Este processo de organização é feito k vezes, alternando a escolha do conjunto de validação, entre os k conjuntos totais, de modo que o restante ($k-1$) sempre se transforma no conjunto de treinamento. Esse processo gera k classificadores, sendo que o melhor dentre eles, determinado através do erro sob o conjunto de validação, é escolhido e guardado, enquanto o erro médio das k avaliações, sob o conjunto de validação, é usado como resultado do treinamento realizado. Após este processo, o conjunto de teste, separado no início, é submetido ao melhor classificador para verificar a taxa de erro em um conjunto de dados desconhecido durante a validação cruzada. Esse processo completo gera três resultados: erro do treinamento, erro da validação e erro do teste, onde apenas o erro do teste é utilizado para fins de comparação entre classificadores. Em (Kohavi et al., 1995) é demonstrado que a Validação Cruzada com 10 subconjuntos ($k = 10$) é um bom método para análise de desempenho de classificadores inteligentes aplicados a problemas reais. Portanto, são utilizados neste trabalho 10 subconjuntos, mesmo valor de k utilizado em (Paixão et al., 2016).

O sistema de identificação define as assinaturas de acordo com a quantidade de bandas e a largura de banda escolhidos. Sequencialmente, classifica as assinaturas e gera a taxa de erro do sistema de identificação. Cada quantidade de bandas e largura delas irá gerar uma taxa de erro diferente no sistema de identificação. Através da figura 3 é possível observar a composição do sistema de identificação e em quais etapas são utilizadas as técnicas descritas nas sessões anteriores.




Figura 3: Composição do sistema de identificação

2.4 Otimizador

Conforme descrito anteriormente, cada quantidade de bandas e largura delas irá gerar uma taxa de erro diferente no sistema de identificação. Portanto, é implementado um otimizador para buscar a combinação que gera a menor taxa de erro do sistema de identificação.

O algoritmo implementado faz a busca pela menor taxa de erro do sistema de identificação da mesma maneira que um bando de pássaros, ou cardume de peixes, rastreia comida. Esse modelo de otimização é conhecido como *Particle Swarm Optimization*, ou PSO, e foi proposto inicialmente por (Kennedy and Eberhart, 1995).

O PSO é uma técnica simples de se implementar, robusta, que utiliza menos armazenamento de memória, tem capacidade de obter soluções globais de qualidade superior, com menos tempo computacional, e possui características substanciais de convergência maior que outras otimizações metaheurísticas (Abbas et al., 2017), sendo esses os motivos de sua implementação.

No PSO, o enxame de partículas é distribuído aleatoriamente num espaço de soluções, sendo que uma das posições das partículas pode ser considerada uma possível solução (Kennedy and Eberhart, 1995). As partículas têm uma velocidade associada, que indica sua tendência de movimento na próxima interação. Cada partícula do enxame se movimenta no espaço de soluções por meio de duas forças. A primeira é uma atração, de magnitude aleatória, para a melhor posição encontrada por ele mesmo ($Pbest$). A segunda é uma atração, também de magnitude aleatória, para a melhor posição encontrada por alguns ou por todos os membros do enxame ($Gbest$). Com essas informações, a posição e a velocidade de cada partícula são atualizadas a cada iteração do algoritmo até o enxame convergir (Fiorotti et al., 2017). O método do PSO, conforme (Fiorotti et al., 2017), é descrito a seguir:

Passo 1: Iniciar as variáveis do enxame de partículas.

- y representa a posição de uma partícula.
- U é um vetor d-dimensional de números reais aleatórios uniformemente distribuídos entre 0 e 1.
- y_{min} é o menor valor da variável y que compõe uma possível solução.

- y_{max} é o maior valor da variável y que compõe uma possível solução.
- D é a dimensão máxima das partículas.
- y_i é a posição de cada componente da partícula.

$$y_i = y_{min} + (y_{max} - y_{min}) * U, \quad \forall i = 1, \dots, D. \quad (7)$$

- v_i é a velocidade de cada componente da partícula.

$$v_i = (y_{max} - y_{min}) * U - y_i, \quad \forall i = 1, \dots, D. \quad (8)$$

- $Pbest_i = 0$, representa a melhor localização da partícula.
- $Gbest = 0$, representa a melhor localização do enxame.
- $Pbestfun_i = 0$.
- $Gbestfun_i = 0$.
- N é o número de partículas (tamanho do enxame).

$$N = 10 + 2 * \sqrt[3]{D}. \quad (9)$$

- w é o coeficiente de inércia.

$$w = \frac{1}{2 * \log(2)}. \quad (10)$$

- $c1$ é o parâmetro cognitivo.

$$c1 = 0.5 + \log(2). \quad (11)$$

- $c2$ é o parâmetro social.

$$c2 = c1. \quad (12)$$

Passo 2. Calcular o valor da função objetivo para todas as partículas.

- O vetor $Pbest_i$ recebe a posição atual de cada partícula.
- O vetor $Pbestfun_i$ recebe o valor da função-objetivo da partícula.
- $Gbest$ recebe a posição da melhor partícula do enxame.

- *Gbestfun* recebe a função-objetivo da melhor partícula do enxame.

Passo 3. Atualizar as posições e velocidades das partículas conforme as equações (13) e (14).

$$v_i = w * v_i + c1 * rand(1, D) * (Pbest - y_i) + c2 * rand(1, D) * (Gbest - y_i) \quad (13)$$

$$y_i = y_i + v_i. \quad (14)$$

Passo 4. Calcular a função objetivo $f(x)$ para todas as partículas.

Passo 5. Para cada partícula, comparar o valor da função objetivo atual com o valor de $Pbest_i$. Se o valor atual é melhor $Pbest_i$ recebe a posição atual e $Pbestfun_i$ recebe o valor da função objetivo atual.

Passo 6. Encontrar o melhor valor objetivo entre as partículas atuais e comparar com o $Gbest$. Caso haja melhora, $Gbest$ recebe a posição e $Gbestfun$ recebe a função objetivo da melhor partícula.

Passo 7. Refazer o processo a partir do passo 3 até que uma condição de parada seja encontrada. Cada vez que o processo é executado do passo 3 ao 6 significa que uma iteração (P) foi realizada.

O critério de parada pode ser definido como um valor específico a ser encontrado da função objetivo, ou com um número máximo de iterações a ser realizada pelo programa. O critério de parada adotado neste trabalho é P atingir o número de iterações máximo definido.

3 Análise dos resultados e discussão

A técnica de caracterização implementada utiliza características microscópicas, por isso é chamada aqui de T_{micro} , para representar cada carga, ou o conjunto delas. A quantidade de características e a taxa de erro do sistema de identificação variam de acordo com o número de bandas e a largura de banda escolhidos. Portanto, fixando-se o RBC como classificador, foi variado o número de bandas e a largura delas, de modo a encontrar a combinação desses dois itens que gera a menor taxa de erro possível para o sistema de identificação. Essa busca foi realizada através de um otimizador baseado no método da busca por enxame de partículas (PSO).

Para o PSO implementado, a posição y de cada partícula é representada por um par, onde um elemento do par é a largura de banda e o outro elemento é a quantidade de bandas escolhida. A função objetivo é aquela que gera a taxa de erro do sistema de identificação, tendo como entradas a largura das bandas e o número de bandas. Portanto, a dimensão D tem valor 2, pois existem dois parâmetros de entrada para obter a

taxa de erro(função objetivo), ou seja, a largura das bandas e a quantidade de bandas. O vetor y tem dimensão $N \times D$, portanto para este trabalho y é um vetor 14×2 . Cada variável tem seu valor mínimo(y_{min}) e máximo(y_{max})

-Largura mínima da banda(y_{min1}): 55Hz.

-Largura máxima da banda(y_{max1}): 1200Hz.

-Número mínimo de bandas(y_{min2}): 1.

-Número máximo de bandas(y_{max2}): 17.

-Número máximo de iterações(critério de parada: P):400.

-Dimensão do problema(D):2.

-Tamanho do enxame(N):14.

As larguras de banda cobrem desde a frequência fundamental(60Hz) até a vigésima harmônica. O número de bandas permite ir, também, desde a fundamental até a 17ª harmônica. Dessa forma, o PSO busca a combinação do número de bandas e largura delas, que gera a menor taxa de erro, em um universo amplo que permite $17 \times 1.146 = 19.482$ combinações possíveis.

Para validar o PSO é necessário verificar a sua convergência. Essa convergência é observada através de um gráfico, onde o eixo X contém o número da iteração e o eixo Y contém a menor taxa de erro obtida naquela iteração. O número de iterações neste trabalho é representado por P é foi definido como 400. Nas primeiras iterações, as taxas de erro tendem a diminuir de uma iteração para a próxima iteração, indo em direção à menor taxa de erro. Entretanto, após algumas iterações iniciais, o PSO alcança a menor taxa de erro e as novas iterações não mudam mais, estabilizando o valor encontrado. Quanto menor o número de iterações necessárias para atingir a menor taxa de erro, mais rápida é a convergência do PSO implementado. E em quanto mais iterações o PSO encontrar a mesma taxa de erro mínima, maior o indicativo de que aquele valor é, de fato, a menor taxa de erro possível.

Através da figura 4, é possível verificar a convergência do otimizador implementado.




Figura 4: Convergência do PSO implementado

Pode ser observado que o PSO converge para a

menor taxa de erro a partir da 25ª iteração e essa mesma taxa de erro é a menor taxa encontrada repetidamente até a 400ª iteração, estabilizando-se nesse valor e definindo-o como a menor taxa possível.

Com os valores definidos anteriormente, e utilizando o classificador RBC, o PSO convergiu para uma taxa de erro de 22,69%, sendo esse valor ótimo encontrado para 7 bandas com 327Hz de largura cada. Ou seja, utilizando o T_{micro} com 7 bandas e 327 Hz de largura em cada banda, a taxa de erro do sistema de identificação é de 22,69%.

O autor de (Paixão et al., 2016) utiliza a mesma plataforma experimental e o mesmo classificador para tratar do problema de identificação de cargas altamente similares. Portanto, o resultado alcançado por esse autor é utilizado para fins de comparação entre as técnicas de caracterização desenvolvidas neste trabalho e no trabalho de (Paixão et al., 2016). A técnica desenvolvida por (Paixão et al., 2016) consiste em representar a carga, ou o conjunto delas, através de 14 características obtidas por manipulações matemáticas dos dados de corrente e tensão coletados para aquela configuração. Diferente do trabalho apresentado aqui, as características utilizadas por ele são macroscópicas e microscópicas (Zeifman and Roth, 2011), por isso é chamado aqui de T_{macro} . As características macroscópicas utilizadas foram: corrente elétrica eficaz, potência aparente, potência ativa, fator de potência e potência reativa. As características microscópicas foram as componentes fundamental mais as 8 primeiras harmônicas ímpares do sinal de corrente decomposto pela transformada discreta de Fourier. A menor taxa de erro obtida pelo autor, utilizando o classificador RBC, a mesma plataforma e a mesma taxa de amostragem é de 29,58%.

Sendo assim, a técnica desenvolvida no presente trabalho atingiu uma taxa de erro menor que a taxa de erro obtida em (Paixão et al., 2016), evoluindo o estado da arte em um cenário desafiador e pouco explorado. A melhoria da taxa de erro do sistema de identificação pode ser observada na tabela 2.

Tabela 2: Melhoria da taxa de erro

Técnica	Taxa de erro obtida(%)
T_{macro} (Paixão et al., 2016)	29,58%
T_{micro}	22,69%

Fonte: Autora(2018)

Com relação à definição das assinaturas de carga, a técnica que considera apenas características microscópicas (T_{micro}) atingiu um resultado melhor que a que considera características microscópicas e macroscópicas(T_{macro}). Essa melhoria nos resultados confirma a representatividade das características microscópicas e aponta para o

aprofundamento no estudo desses tipos de características que, ao que parece, podem representar cargas de modo unívoco.

Outro ponto de destaque é o número de bandas e sua largura. A menor taxa de erro ocorre em 7 bandas com 327 Hz de largura cada, o que significa que são 2.289 Hz de frequência analisados. Essa faixa de frequência se estende desde a fundamental até a 38ª harmônica, sinalizando que, para a análise de cargas similares, é necessário observar componentes para além da 17ª harmônica.

Quanto ao que se encontra na literatura para cargas com baixo grau de similaridade, os resultados costumam ultrapassar os 90% de acerto. Cabe observar, entretanto, que os valores alcançados aqui são do início da pesquisa de um cenário desafiador e que, apesar de não alcançarem os valores presentes na literatura para cenários com cargas diferentes, são próximos a estes e muito superiores aos resultados de um sistema que escolhesse ao acaso a resposta ($1/16 = 6,25\%$ de chance de acerto).

4 Conclusões

Com base nos resultados obtidos, conclui-se que o método aplicado produz resultados satisfatórios. O método implementado nesse trabalho, baseado em características microscópicas, resulta em uma taxa de erro menor que a encontrada no trabalho anterior, baseado em características microscópicas e macroscópicas. Dessa forma, é dado mais um passo na evolução do estado da arte em um cenário desafiador e ainda pouco explorado: a identificação de cargas com alto grau de similaridade.

É importante ressaltar que o uso de 4 lâmpadas fluorescentes compactas altamente similares se mostrou conveniente por serem comuns em instalações elétricas e serem de baixo custo. Entretanto, não há impedimentos para que as cargas utilizadas fossem outras como, por exemplo, ventiladores, máquinas de lavar roupas ou computadores, desde que apresentassem alto grau de similaridade. A aplicação da técnica implementada nesse trabalho em cenários com outros tipos de cargas similares é colocada como sugestão para trabalhos futuros.

Para trabalhos futuros sugere-se:

1. Buscar novas técnicas para definir assinaturas de carga, a fim de melhorar a acurácia do sistema de identificação e obter novos resultados comparativos;
2. Aplicar as técnicas apresentadas em cenários que envolvam cargas, altamente similares, com comportamento diferente das lâmpadas fluorescentes, como por exemplo motores elétricos;
3. Aplicar as técnicas apresentadas em cenários que envolvam cargas com diferentes graus de similaridade. Dessa forma, o cenário seria composto por uma miscelânea de cargas elétricas,

sendo algumas indutivas, outras capacitivas, outras resistivas, como acontece em casos práticos.

Agradecimentos

Os autores agradecem à CAPES/Brasil pela bolsa de mestrado concedida, ao CNPq/Brasil (processo 443384/2014-2) e FAPES-ES/Brasil (Processo .67651259/14) pelo suporte financeiro a esta pesquisa.

Referências

- Abbas, G., Gu, J., Farooq, U., Asad, M. U. and El-Hawary, M. (2017). Solution of an economic dispatch problem through particle swarm optimization: A detailed survey-part i, *IEEE Access* **5**: 15105–15141.
- Ahmadi, H. and Martı, J. R. (2015). Load decomposition at smart meters level using eigenloads approach, *IEEE Transactions on Power Systems* **30**(6): 3425–3436.
- Azzini, H. A. D., Fardin, J. F. and Salles, E. O. T. (2012). Software para monitoramento não intrusivo de cargas residenciais com fins de auditoria energética, *IV Simpósio Brasileiro de Sistemas Elétricos (SBSE)*.
- Belley, C., Gaboury, S., Bouchard, B. and Bouzouane, A. (2014). An efficient and inexpensive method for activity recognition within a smart home based on load signatures of appliances, *Pervasive and Mobile Computing* **12**: 58–78.
- Bouhouras, A. S., Milioudis, A. N. and Labridis, D. P. (2014). Development of distinct load signatures for higher efficiency of nilm algorithms, *Electric Power Systems Research* **117**: 163–171.
- Chaves, G. de L. D. and Tosta, M. de C. R. (2016). *Gestão de Sistemas de Energia*, Editora CRV.
- Ehrhardt-Martinez, K., Donnelly, K. A., Laitner, S. et al. (2010). Advanced metering initiatives and residential feedback programs: a meta-review for household electricity-saving opportunities, *American Council for an Energy-Efficient Economy Washington, DC*.
- Fiorotti, R., Lima, E. S. M., Coswosk, B. C. et al. (2017). Otimização usando pso no controle pi de vazão de um túnel de vento atmosférico utilizando a técnica de gain scheduling, *Latin American Journal of Energy Research* **3**(2): 30–41.
- Hart, G. W. (1992). *Nonintrusive appliance load monitoring*, *Proceedings of the IEEE* **80**(12): 1870–1891.
- Hassan, T., Javed, F. and Arshad, N. (2014). An empirical investigation of vi trajectory based load signatures for non-intrusive load monitoring, *IEEE Transactions on Smart Grid* **5**(2): 870–878.
- Kennedy, J. and Eberhart, R. (1995). *Pso optimization*, *Proc. IEEE Int. Conf. Neural Networks, Vol. 4, IEEE Service Center, Piscataway, NJ*, pp. 1941–1948.
- Kohavi, R. et al. (1995). *A study of cross-validation and bootstrap for accuracy estimation and model selection*, *Ijcai, Vol. 14, Montreal, Canada*, pp. 1137–1145.
- Kolodner, J. (2014). *Case-based reasoning*, *Morgan Kaufmann*.
- Liang, J., Ng, S. K., Kendall, G. and Cheng, J. W. (2010). *Load signature study part i: Basic concept, structure, and methodology*, *IEEE transactions on power Delivery* **25**(2): 551–560.
- Paixão, A. R. d., Celeste, W. C., Júnior, L. O. R., Coura, D. J. C., de Oliveira Rocha, H. R. and das Dores Rissino, S. (2016). *Classificação inteligente aplicada ao problema de identificação de cargas elétricas "idênticas"*.
- Sadeghianpourhamami, N., Ruyssinck, J., Deschrijver, D., Dhaene, T. and Develder, C. (2017). *Comprehensive feature selection for appliance classification in nilm*, *Energy and Buildings*.
- Zeifman, M. and Roth, K. (2011). *Nonintrusive appliance load monitoring: Review and outlook*, *IEEE transactions on Consumer Electronics* **57**(1).