

IMPLEMENTAÇÃO DE UM SISTEMA DE IDENTIFICAÇÃO INTELIGENTE DE CARGAS ELÉTRICAS

Aloisio Ramos da Paixão

*Instituto Federal do Espírito Santo – Campus São Mateus
Rodovia BR 101 Norte, Km 58. Bairro Litorâneo, São Mateus-ES
apaixao@ifes.edu.br*

Wanderley Cardoso Celeste¹, Luís Otávio Rigo Júnior², Daniel José Custódio Coura³, Hélder Roberto de Oliveira Rocha⁴ e Sílvia das Dores Rissino⁵

*Universidade Federal do Espírito Santo, Centro Universitário Norte do Espírito Santo
Rodovia BR 101 Norte, Km 60. Bairro Litorâneo, São Mateus-ES*

*1) wanderley.celeste@ufes.br, 2) luis.rigo@ufes.br, 3) daniel.coura@ufes.br,
4) helder.rocha@ufes.br, 5) silvia.rissino@ufes.br*

Abstract - This paper presents the preliminary results of the application of pattern recognition techniques for identifying “identical” electrical loads. This problem has been presented in the literature as a challenge, in which the complexity increases as trying to identify increasingly similar equipment. So, it is implemented in this work an experimental platform containing an arrangement of 4 “identical” compact fluorescent lamps, where it is acquired 150 sets of characteristics from the electrical signals of voltage and current supplied to the arrangement for each of its 16 possible combinations. Each set is formed by 13 distinct electrical characteristics which represent the load signature. Three pattern recognition techniques are applied to identify when a given load is connected, resulting in an average accuracy of up to 85%. The same techniques are used to identify the specific configuration of the arrangement among the 16 possible, resulting in an average accuracy of up to 74%.

Keywords - Load signature, smart grid, electrical characteristic, classification methods.

Resumo - Este artigo apresenta os resultados preliminares da aplicação de métodos de classificação inteligente para a identificação de cargas elétricas “idênticas”. Tal problema tem sido apresentado na literatura como um desafio, cuja complexidade aumenta à medida que se deseja identificar cargas elétricas mais parecidas. Logo, implementa-se neste trabalho uma plataforma experimental contendo um arranjo composto de 4 lâmpadas fluorescentes compactas “idênticas”, de onde se obtém 150 conjuntos de características dos sinais elétricos de tensão e corrente fornecidas ao arranjo para cada uma de suas 16 combinações possíveis. Cada conjunto é composto de 13 características elétricas distintas que representam a assinatura de uma carga. Três técnicas de classificação inteligente são aplicadas para identificar quando uma determinada carga está ligada, resultando em um acerto médio de até 85%. As mesmas técnicas são usadas para identificar a configuração específica do arranjo dentre as 16 possíveis, resultando em um acerto médio de até 74%.

Palavras-chave - Assinatura da carga, rede elétrica inteligente, característica elétrica, métodos de classificação.

1 Introdução

A Agência Nacional de Energia elétrica (ANEEL), órgão regulador do setor elétrico brasileiro, aprovou em novembro de 2011 a alteração da estrutura tarifária aplicada ao setor de distribuição de energia, onde o novo regulamento prevê a aplicação de tarifas diferenciadas por horário de consumo, oferecendo tarifas mais baratas nos períodos em que o sistema é menos utilizado pelos consumidores. Para as unidades consumidoras que são atendidas em baixa tensão (127, 220, 380 ou 440 volts), a principal mudança é a criação da modalidade tarifária branca, que será uma alternativa à convencional.

Na tarifa convencional, o valor cobrado pela energia elétrica considera apenas o consumo de potência ativa dos equipamentos ao longo do tempo, desconsiderando o dia e o horário em que o consumo ocorreu. A tarifa branca é uma nova opção para os consumidores, onde o valor da energia elétrica será cobrado conforme o dia e o horário do consumo (Ferreira et al., 2015). Vale salientar que a adesão à tarifa branca só é possível com a instalação do medi-

dor eletrônico, também chamado de medidor inteligente, que é de responsabilidade da concessionária e sem ônus para os consumidores.

Nesse contexto, o monitoramento das instalações elétricas residenciais permite conhecer o padrão de consumo individual das cargas, possibilitando a implementação de sistemas de gerenciamento que podem ser aplicados em diversas áreas, pois as informações geradas pelo monitoramento podem beneficiar os consumidores, os órgãos reguladores do setor elétrico, concessionárias de distribuição de energia elétrica, entre outros.

Para monitorar individualmente as cargas elétricas é necessário saber o momento em que elas são ligadas e desligadas em uma instalação. Na abordagem tradicional, o monitoramento das cargas elétricas é feito medindo individualmente cada equipamento. No entanto, pode ser possível determinar o momento em que uma carga elétrica é ligada ou desligada utilizando um único medidor instalado no circuito de alimentação de uma unidade consumidora, desde que o medidor conte com um sistema de identificação de carga que utilize a assinatura elétrica

específica de cada equipamento/dispositivo para identificá-lo.

Vários trabalhos têm sido desenvolvidos nas últimas décadas na tentativa de se determinar a assinatura elétrica que torna um equipamento/dispositivo elétrico/eletrônico único, a fim de permitir uma identificação precisa. O trabalho apresentado por Hart (1992) pode ser considerado o marco inicial nesta busca. Entretanto, o estado da arte (Seção 2) tem mostrado que os métodos até então aplicados ainda não são robustos o suficiente para permitir uma identificação precisa, considerando que, na prática, há equipamentos/dispositivos com características elétricas muito distintas, bem como equipamentos/dispositivos com características elétricas similares que precisam ser rotulados (Seção 3). Além disso, em muitos casos, as características elétricas de uma carga podem se modificar em função de uma grande quantidade de fatores como, por exemplo, o tempo de funcionamento e a forma como o equipamento/dispositivo é utilizado nas diversas unidades consumidoras.

Logo, há uma grande quantidade de trabalhos que precisam ser realizados para tornar um medidor de energia elétrica suficientemente inteligente a ponto de saber, a qualquer tempo, qual equipamento/dispositivo de uma unidade consumidora foi ligado ou está em funcionamento em um determinado instante de tempo.

Neste sentido, o presente trabalho apresenta na Seção 3 uma metodologia desenvolvida com a finalidade de explorar uma das questões ainda pendente de solução que é a identificação de equipamentos/dispositivos “idênticos”. Para isso, é implementada uma plataforma experimental contendo quatro lâmpadas fluorescentes compactas de mesmo fabricante e com características técnicas idênticas, as quais podem ser ligadas/desligadas de forma individual e a qualquer tempo. A Seção trata ainda do ferramental utilizado na aquisição e processamento dos sinais elétricos, extração das características e o processo de classificação.

Na Seção 4 são apresentados os resultados preliminares até então obtidos, enquanto que na Seção 5 é feita uma discussão a respeito do trabalho até então realizado e de algumas possibilidades a serem tratadas em trabalhos futuros.

2 Revisão da Literatura

O problema de identificação de cargas baseado em características elétricas (*load signature*) é tratado na literatura desde os anos 1990 (Hart, 1992; Leeb, Shaw e Kirtley, 1995) e tem ganhado mais atenção nos anos recentes com o advento do conceito de *Smart Grid*, conforme se observa em (Bouhouras, Milioudis, Labridi, 2014; Šíra e Zachovalová, 2015; Zhou, Yang e Shen, 2013; Ahmadi e Mart, 2015).

Dentre as pesquisas recentes sobre o assunto, destacam-se os trabalhos apresentados em (Bouhouras, Milioudis, Labridi, 2014) e em (Ahmadi e Mart,

2015). O primeiro propõe um processo de identificação mais simples baseado no comportamento em regime estacionário do equipamento elétrico/eletrônico, com baixo consumo de recurso computacional e de memória, onde a caracterização da carga é baseada em apenas três coisas: Entropia de Shannon, Entropia de Renyi e energia da banda espectral. Os resultados obtidos pelos autores indicam que a técnica se mostrou bastante eficiente para casos de identificação de cargas individuais.

Em (Ahmadi e Mart, 2015), os autores analisam o regime transiente de equipamentos elétricos/eletrônicos distintos, usam transformada Wavelet e PCA (*Principal Component Analysis*) para a obtenção das chamadas autocargas (*eigenloads*), que são os autovalores associados aos autovetores que representam as características fundamentais de uma carga. Com isso, os autores conseguem determinar a classe de uma determinada carga, mas deixam em aberto o problema de identificação de uma carga específica dentro de uma mesma classe, isto é, as cargas “idênticas”. Além disso, os autores mencionam que o sistema proposto não é capaz de enquadrar as cargas nas respectivas classes quando duas ou mais cargas são ligadas simultaneamente, o que é uma grande limitação para um sistema prático.

A extração de características é uma tarefa central no processo de identificação, pois uma grande quantidade de informação ou o uso de características inadequadas podem contribuir para um baixo desempenho do classificador, ou ainda provocar um alto custo computacional (Hall e Holmes, 2003; Fernandes, Silva e Oleskovicz, 2010).

Ao observar a literatura, verifica-se que existe ainda uma indeterminação no conjunto de características que remete a uma assinatura elétrica única a ponto de permitir uma identificação robusta, precisa e adaptável (Azzini et al., 2012; Monzani, 2015).

3 Metodologia e Ferramentas

3.1. Plataforma experimental e aquisição de dados

Neste trabalho foi desenvolvida uma plataforma experimental, conforme apresentada na Figura 1, contendo 2 interruptores duplos, 4 receptáculos com 4 dispositivos/lâmpadas fluorescentes compactas de um mesmo fabricante e com características técnicas idênticas (Tabela 1), 1 transformador abaixador de tensão, com 3 fios no primário para alimentação em 127V ou 220V e 3 fios no secundário para as tensões 9+9V e corrente nominal de 300mA, e 1 sensor de corrente não intrusivo, modelo SCT-013-000 com capacidade de medição entre 0 e 100A. Na Figura 2 é apresentado o diagrama esquemático da plataforma experimental, onde se observa que as lâmpadas L1 a L4 podem ser ligadas/desligadas individualmente pelas chaves CH1 a CH4, respectivamente, bem como o posicionamento dos sensores de tensão, V, e de corrente, A, para medir os sinais elétricos de alimentação do conjunto de lâmpadas.




Figura 1. 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	$\geq 0,50$
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 segundos
Fluxo luminoso	844 lm
Vida mediana	6000 h




Figura 2. Diagrama esquemático da plataforma experimental.

Na aquisição dos sinais elétricos provenientes da plataforma, foram utilizados 1 osciloscópio Tektronix TDS2002B e 1 notebook executando o *software NI LabVIEW SignalExpress Tektronix Edition*, o qual é fornecido pelo fabricante do osciloscópio.

A Figura 3 apresenta o sinal de tensão e de corrente medidos para cada uma das lâmpadas individualmente ligadas. Nota-se que para a mesma tensão aplicada, as cargas consomem correntes elétricas cujas formas são de difícil distinção a olho nu.

Os sinais elétricos foram adquiridos para cada uma das 16 configurações de funcionamento da plataforma experimental, isto é, desde todas as lâmpadas ligadas até todas as lâmpadas desligadas.




Figura 3. Forma dos sinais elétricos para cada lâmpada individualmente ligada.

Para cada uma das 16 configurações de funcionamento da plataforma experimental foram utilizados 150 ciclos dos sinais elétricos de tensão e de corrente, sendo que em cada ciclo de 60 Hz dos sinais elétricos extraiu-se 13 características elétricas distintas, formando uma matriz de dados L com 2.400 linhas e 13 colunas, onde cada linha corresponde a um conjunto de características (um caso) e cada coluna corresponde aos valores amostrais de uma característica específica da carga.

As características elétricas utilizadas foram: valor eficaz da corrente elétrica dada por (1); amplitudes da componente fundamental e dos harmônicos ímpar (do 3º ao 17º) dada por (6); potência ativa dada por (3); potência total aparente dada por (4) e fator de potência dado por (5).

As características foram extraídas calculando-se o valor eficaz ou o valor médio quadrático (*rms* - *root-mean-square*) da corrente (I_{rms}) e da tensão (V_{rms}) a partir das equações (1) e (2), respectivamente.

$$I_{rms} = \sqrt{\frac{1}{T} \int_0^T i^2(t) dt} \quad (1)$$

e

$$V_{rms} = \sqrt{\frac{1}{T} \int_0^T v^2(t) dt}, \quad (2)$$

onde T é o período do sinal elétrico de tensão, $v(t)$, e da corrente, $i(t)$; Potência ativa, P , dada por

$$P = \frac{1}{T} \int_0^T v(t)i(t)dt; \quad (3)$$

Potência total aparente, dada pelo produto entre (1) e (2), isto é

$$S = V_{rms} I_{rms}; \quad (4)$$

Fator de potência, dado pela razão entre (3) e (4), isto é

$$FP = \frac{P}{S}. \quad (5)$$

As demais características correspondem à amplitude das principais componentes harmônicas observadas no sinal elétrico de corrente $i(t)$ fornecida ao arranjo, conforme mostrado no espectro de frequência da Figura 4. Para obter os valores das componentes fundamentais e dos termos harmônicos do espectro de frequência, aplicou-se a transformada discreta de Fourier (*Discrete Fourier Transform- DFT*), definida pela equação (6), isto é

$$X(k) = \sum_{j=1}^N x(j) \omega_N^{(j-1)(k-1)}, \quad (6)$$

onde $\omega_N = e^{(-2\pi)/N}$ e N é o comprimento do vetor de amostras.




Figura 4. Espectro de frequência do sinal de corrente.

Após o processo de extração das características, os valores foram normalizados para o processo de classificação, de modo que cada coluna da matriz de dados passa a assumir valores entre 0 e 1.

3.2. Métodos de Classificação

Com o objetivo de realizar o processo de identificação de cargas, foram testados três métodos de classificação: duas variações de Raciocínio Baseado em Casos (RBC) e uma Rede Neural Artificial (RNA). Estes métodos foram escolhidos porque são robustos e eficientes para resolução de problemas de classificação. Ademais, por se tratar de um trabalho

inicial, optou-se pela utilização de métodos com características distintas, a fim de se buscar o que melhor se adéqua ao problema proposto.

O RBC trabalha diretamente com similaridade entre casos, sem efetuar alteração na sua representação. Proposto por Kolodner (1993), o RBC é um método eficiente para identificação de situações de similaridades entre casos (conjunto de características). O primeiro RBC utilizado neste trabalho realiza a análise de similaridade entre os casos por meio da distância euclidiana. Para realizar a classificação de um caso novo, é feita uma busca no banco de casos para encontrar aquele que possui características mais próximas desse caso. O caso com características mais próximas é utilizado para definir sua classe (ainda não possui classificação, isto é, um caso novo).

O segundo RBC (denominado RBC+*K-Means*) realiza um passo inicial de agrupamento (*clustering*) dos casos já classificados por meio do método *k-means* (Hartigan, 1975), para $k=200$. Em sequência, compara o caso novo com o centro de cada agrupamento, por meio da distância euclidiana. Escolhido o agrupamento mais próximo, o algoritmo realiza a análise de similaridade do caso novo (também por distância euclidiana) apenas com os membros do grupo. Em ambos os métodos, a classe do caso mais similar é definida como resposta do classificador para o caso novo.

Já uma RNA consegue extrair características implícitas presentes no conjunto de casos, criando um modelo de representação cognitivo. Neste trabalho foi também implementado um classificador baseado em uma RNA denominada *Multi-Layer Perceptron* (MLP) com função de ativação sigmóide em todos os neurônios. O método de aprendizado utilizado para treinamento da rede foi o *Back Propagation* (Rumelhart, Hinton e Williams, 1986).

Foram testadas duas versões do classificador RNA-MLP, uma com 4 e outra com 8 neurônios na camada intermediária, as quais foram denominadas de MLP-4 e MLP-8, respectivamente. Em ambos os casos, a taxa de aprendizado aplicada foi de 0,25, com dois critérios de parada: erro médio máximo 0,1 ou número máximo de ciclos igual a 10000. A classe de resposta das redes é dada por 4 neurônios da camada de saída, onde cada neurônio representa o estado de funcionamento de uma lâmpada. O neurônio ativado (saída entre 0,5 e 1,0) indica que a lâmpada está ligada. Caso contrário (saída menor que 0,5) a lâmpada está desligada.

Ressalta-se que todos os métodos implementados realizam um processo inicial de aprendizado e, após esta fase, ao serem submetidos a um caso novo, recebem as 13 características deste caso como entrada e retornam como resposta o estado dos dispositivos (lâmpadas).

Os métodos implementados diferenciam-se em termos de esforço computacional nos processos de aprendizado e classificação. No aprendizado, o método RBC é mais rápido em comparação com os métodos RBC+*K-Means*, MLP-4 e MLP-8. Na classificação, os métodos MLP-4 e MLP-8 são mais

rápidos em comparação com os métodos RBC e RBC+K-Means.

3.3. Análise de Desempenho

Para a medição do desempenho dos classificadores foi utilizada a validação cruzada (*cross-validation*), com a seleção aleatória de 10% dos casos contidos em *L* (vide Subseção 3.1) para o conjunto de testes e os demais casos divididos em 10 conjuntos de treinamento e validação. Kohavi (1995) demonstra que a validação cruzada com 10 conjuntos é um bom método para análise de desempenho de classificadores inteligentes aplicados a problemas reais.

Os resultados obtidos são comparados nas etapas de treinamento, validação e teste. Para os classificadores RBC e RBC+K-Means, o treinamento é realizado com os próprios casos. Por este motivo, os erros de treinamento não são apurados.

4. Resultados

Os experimentos computacionais foram realizados e seus resultados estão descritos nas Tabelas 2 e 3. A Tabela 2 apresenta os resultados obtidos com o objetivo de determinar qual lâmpada (dispositivo) está ligada. A Tabela 3 apresenta os resultados dos classificadores para determinar qual das 16 configurações possíveis de funcionamento da plataforma experimental (classes) está em operação em um dado instante de tempo. Cada coluna das tabelas apresenta o nome do classificador e as taxas de erro obtidas nos conjuntos de treinamento, validação e teste. As menores taxas de erro representam os melhores resultados.

Tabela 2. Taxa de erro por dispositivo para 13 características.

Técnica	Taxa de erro por Conjunto		
	Treinamento	Validação	Teste
RBC	-	11,3%	15,0%
RBC+K-Means	-	12,5%	16,5%
MLP-4	17,7%	17,0%	19,4%
MLP-8	12,9%	11,3%	15,3%

Tabela 3. Taxa de erro por classe para 13 características.

Técnica	Taxa de erro por Conjunto		
	Treinamento	Validação	Teste
RBC	-	19,9%	25,8%
RBC+K-Means	-	23,1%	27,5%
MLP-4	52,5%	52,3%	59,2%
MLP-8	38,0%	31,5%	42,9%

De acordo com os resultados apresentados nas Tabelas 2 e 3, é possível observar que nos testes de identificação dos dispositivos e das classes os melhores resultados foram obtidos com o classificador RBC. Apesar das lâmpadas possuírem características elétricas idênticas, em 85% dos casos é possível identificar qual lâmpada encontra-se ligada e em 74,2% dos casos é possível determinar qual configuração de funcionamento da plataforma está em operação.

Em todos os testes realizados, os classificadores apresentaram uma maior dificuldade em determinar qual das 16 configurações de funcionamento da plataforma experimental está em operação (Tabela 3) quando comparada com a tentativa de determinar qual dos 4 dispositivo encontra-se ligado (Tabela 2).

No processo de classificação dos dispositivos (Tabela 2) os classificadores RBC e MLP-8 apresentaram desempenho similar. Porém, deve-se destacar que a técnica de RNA é computacionalmente mais custosa quando comparada com o RBC.

Para efeito de análise comparativa, observa-se que nos testes de classificação para os dispositivos (Tabela 2) e para as classes (Tabela 3), o MLP-8 conseguiu absorver melhor as características contidas nos dados quando comparado com MLP-4.

5. Conclusão

Foi tratado neste artigo o problema de identificação de cargas elétricas “idênticas”, o qual, até onde se pode observar na literatura, trata-se de um problema de difícil solução e que tem ganhado cada vez mais importância com o advento do conceito *smart grid*.

Para abordar tal problema, optou-se neste trabalho pelo desenvolvimento de uma plataforma experimental composta de um arranjo com 4 lâmpadas fluorescentes compactas com características técnicas idênticas, as quais podiam ser ligadas ou desligadas individualmente, possibilitando a aquisição dos sinais elétricos para 16 configurações de funcionamento.

Como contribuição relevante deste trabalho, pode-se destacar a criação de um banco de dados contendo 150 conjuntos de características para cada combinação possível do arranjo, totalizando 2.400 casos, com 13 características elétricas distintas, que correspondem a assinatura elétrica da carga. Destaca-se ainda que o conjunto de dados obtidos pode ser usado em trabalhos futuros para a extração de novas características que venham a melhorar o desempenho de classificação inteligente.

Quatro versões de métodos de classificação inteligente foram aplicadas, a fim de determinar qual (is) dispositivo(s) estaria(m) ligado(s) em um determinado momento. Com a ressalva de que os dispositivos utilizados no arranjo possuem características técnicas idênticas (Tabela 1), destaca-se que a técnica RBC foi a que mostrou um melhor desempenho, tendo em vista que o erro médio foi de 15% para a identifica-

ção de qual das 4 lâmpadas encontra-se ligada (Tabela 2) e de 25,8% para a identificação de qual das 16 configurações de funcionamento da plataforma experimental encontra-se em operação (Tabela 3).

Cabe destacar que em uma análise probabilística para a identificação dos dispositivos (4 lâmpadas), a chance de identificar corretamente qual dispositivo encontra-se ligado/desligado é de 25% e para as classes (16 combinações possíveis de funcionamento da plataforma experimental), a chance de identificar corretamente 1 das classes dentre as 16 possíveis cai drasticamente para 6,25%. Logo, a utilização de quaisquer das técnicas de classificação inteligente se mostraram muito superior a uma possível identificação ao acaso. Destaca-se ainda que para as 16 classes, cada dispositivo possui 50% de casos em que está ligado e 50% de casos em que está desligado. Além disso, todas as 16 combinações possíveis estão representadas de maneira igualitária na matriz de dados (150 amostras para cada classe).

Ressalta-se, por fim, que este trabalho não esgota o tema tratado, ao contrário, abre novas perspectivas de investigação tanto no sentido de uma melhor adaptação ao problema das técnicas aqui apresentadas, quanto na aplicação de novas técnicas de aquisição, pré-processamento, extração de características e classificação.

Agradecimentos

Os autores agradecem ao CNPq/Brasil (processo 443384/2014-2) e FAPES-ES/Brasil (Processo 67651259/14) pelo suporte financeiro a esta pesquisa.

Referências Bibliográficas

- Ahmadi, H. and Mart, J. R. (2015). Load Decomposition at Smart Meters Level Using Eigenloads Approach. *IEEE Transactions on Power Systems*, Vol. 30, n. 6, pp. 3425-3436.
- Azzini, H. A. D.; Fardin, J. F. e Salles, E. O. T. (2012). Avaliação das Capacidades de Software Baseado em Monitoramento não Intrusivo Voltado para Eficiência Energética. *Anais do XIX Congresso Brasileiro de Automação, CBA 2012*, pp. 2467-2474.
- 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*, n. 117, pp. 163-171.
- Fernandes, R. A. S.; Silva, I. N. e Oleskovicz, M. (2010). Identificação de Cargas Lineares e Não-Lineares em Sistemas Elétricos Residenciais Usando Técnicas para Seleção de Atributos e Redes Neurais Artificiais. *Revista Controle & Automação*, Vol.21, No.4, Julho e Agosto 2010, pp. 389-405.
- Ferreira, S. O.; Marangoni, F. e Konopatzki, E. A. (2015). Análise dos benefícios da adesão à tarifa branca como forma de gestão energética residencial. *XXXV Encontro Nacional de Engenharia de Produção (ENEGEP)*, Fortaleza, CE, 2015.
- Hall, M. A. e Holmes, G. (2003). Benchmarking Attribute Selection Techniques for Discrete Class Data Mining. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 15, No. 3, pp. 1-16.
- Hart, G. W. (1992). "Nonintrusive appliance load monitoring". *Proceedings of the IEEE*, vol. 80, no. 12, pp. 1870-1891.
- Hartigan, John A. (1975). *Clustering algorithms*. John Wiley & Sons, Inc.
- Kohavi, Ron. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Joint Conference on Artificial Intelligence*. Vol. 14, No. 2, pp. 1137-1145.
- Kolodner, Janet. L. (1993). *Case-Based Reasoning*. Morgan Kaufmann Series in Representation & Reasoning.
- Leeb, S. B., Shaw, S. R. and Kirtley, J. L. (1995). Transient event detection in spectral envelope estimates for nonintrusive load monitoring. *IEEE Transaction on Power Delivery*, vol. 10, n. 3, pp. 1200-1210.
- Monzani, R. C. (2015). Identificação de Cargas Residenciais Usando Rede Neural Artificial a Partir de Aquisição não Intrusiva. *XII Simpósio Brasileiro de Automação Inteligente, SBAI 2015*, pp. 890-895.
- Rumelhart, David E.; Hinton, Geoffrey E.; Williams, Ronald J. (1986). Learning representations by back-propagating errors. *Nature* 323 (6088): 533-536.
- Šíra, M. and Zachovalová, V. N. (2015). System for Calibration of Nonintrusive Load Meters With Load Identification Ability. *IEEE Transactions on Instrumentation and Measurement*, Vol. 64, n. 6, pp. 1350-1354.
- Zhou, K.; Yang, S. and Shen, C. (2013). A review of electric load classification in smart grid environment. *Renewable and Sustainable Energy Reviews*, n. 24, pp. 103-110.