

IDENTIFICAÇÃO NÃO INVASIVA DO ACIONAMENTO DE CARGAS ELÉTRICAS RESIDENCIAIS UTILIZANDO ESTATÍSTICAS DE ORDEM SUPERIOR

RODRIGO B. LIMA¹, WILIAN S. LACERDA², DANTON D. FERREIRA³

^{1,3} Departamento de Engenharia-DEG / ² Departamento de Ciências da Computação-DCC,
Universidade Federal de Lavras

Caixa Postal 3037, Campus Universitário, CEP:37.200-000, Lavras-MG

E-mails: rodrigolx@yahoo.com.br, lacerda@dcc.ufla.br, danton@deg.ufla.br

Abstract—The consumption of electricity has increased over the years as well as the need to know the profile of consumers. The use of non-invasive monitoring of loads has benefits both for power distribution company and consumers. Some of the benefits of this work are related to the discrimination of the consumption of each load in the electricity bill, allowing consumers to better control the use of electricity and the feasibility analysis of use or not to use the White Tariff that came into effect in Brazil. For power distribution company, in addition to the possibility of identifying energy theft, this system provides important information for energy efficiency programs and for the characterization of loads attended from a temporary point of view. The methodology to be used is the extraction of second- and fourth-order cumulants extracted from the electrical current signals, these are the signature of each load. Then the most significant features are selected using Fisher's discriminant ratio. After the selection, the feature vector is presented to a classifier that makes the identification of the load triggered. In the end, the success rate of 99.6% was obtained, a representative result expecting the future identification of loads driven in parallel to the operation of others (simultaneous operation).

Keywords— Non-Invasive Monitoring, Electrical Loads Identifier, Intelligent Networks, Higher Order Statistics (HOS), Load Monitoring, Smart Systems.

Resumo—O consumo de energia elétrica tem aumentado ao longo dos anos, e com isso a necessidade de se conhecer o perfil dos consumidores. A utilização da técnica de monitoramento não invasivo de cargas traz benefícios tanto para concessionária de energia elétrica quanto para consumidores. Alguns dos benefícios deste trabalho está relacionado a discriminação do consumo de cada carga na fatura de energia elétrica, permitindo, aos consumidores, o melhor controle da utilização da energia elétrica e a análise de viabilidade de optarem ou não em utilizar a Tarifa Branca, que entrou em vigor no Brasil. Para as concessionárias de energia elétrica, além da possibilidade de identificar furto de energia, este sistema oferece informações importantes para os programas de eficiência energética e para a caracterização das cargas atendidas do ponto de vista temporal. A metodologia a ser utilizada consiste na extração de cumulantes de segunda e quarta ordens extraídos dos sinais de corrente elétrica, estes são a assinatura de cada carga. Em seguida são selecionados os parâmetros mais significativos utilizando o discriminante de Fisher. Após a seleção, os dados são apresentados a um classificador que faz a identificação da carga acionada. Ao final foi obtido o índice de acerto de 99,6%, um resultado representativo visando a futura identificação de cargas acionadas em paralelo ao funcionamento de outras (operação simultânea).

Palavras-chave— Monitoramento não Invasivo, Identificador de Cargas Elétricas, Redes Inteligentes, Estatística de Ordem Superior, Monitoramento de Cargas, Sistemas Inteligentes.

1 Introdução

Na última década os relatórios da Empresa de Pesquisa Energética apontaram um aumento no consumo residencial de 54%, devido ao aumento do poder aquisitivo da população e das reduções em IPI (Imposto sobre Produto Industrializado) para eletrodomésticos.

Contudo os clientes conseguem gerenciar o seu consumo? Sabem o que consomem mais ou quais os horários de maior consumo em sua residência? Em janeiro de 2018 entrou em vigor a Tarifa Branca para os consumidores residenciais, esta tarifa traz uma variação nos valores para o consumo em determinados horários do dia. O consumidor que optar por esta tarifa irá pagar um valor menor que a tarifa atual nos horários fora da faixa de 18 horas às 22 horas e valores maiores nesta faixa de horário.

A Agência Nacional de Energia Elétrica- ANEEL adverte que antes de optar pela Tarifa Branca, conheça seu perfil de consumo e a relação entre a Tarifa Branca e a Convencional. Quanto mais o consumidor deslocar

seu consumo para o período fora de ponta e quanto maior for a diferença entre essas duas tarifas, maiores serão os benefícios da Tarifa Branca. Contudo, se o consumo for maior nos períodos de ponta, a Tarifa Branca não é recomendada. Nesses casos, a nova modalidade de tarifa pode resultar em uma conta maior.

Atualmente não se tem um conhecimento detalhado do consumo nem pelos clientes nem pelas concessionárias. Para realizar as pesquisas de consumo, são necessárias equipes que vão a campo realizar enquetes para o levantamento de dados, embora não seja eficaz devido aos erros do tipo sistemático que tornam os dados não representativos, tais como informações faltantes devido a negativa de resposta por parte do entrevistado ou devido à manipulação dos dados por parte do entrevistador. Ainda pode-se citar outros erros, como por exemplo, o fator psicológico de cada indivíduo que quando questionado pode ceder informações diferentes dos seus hábitos de consumos reais ou ainda quando questionado quantas vezes acendem uma lâmpada no dia não conseguem informar corretamente.

Este detalhamento do consumo pode ser obtido utilizando técnicas de monitoramento invasivo e não

invasivo. No monitoramento invasivo instala-se os equipamentos de monitoramento entre a tomada e o eletrodoméstico para que seja monitorado a sua utilização e consumo. Esta abordagem se torna inconveniente devido ao cliente ter que registrar, em um diário, de tempo em tempo (cerca de 30 ou 60 minutos) o consumo do equipamento, além de dispendioso e as informações do diário serem imprecisas (XU e MILANOVIC, 2015).

No monitoramento não invasivo (Non-Intrusive Appliance Load Monitoring - NIALM) utiliza-se apenas um equipamento na entrada de energia elétrica do consumidor. Esta técnica tem maior privacidade para o consumidor e redução representativa no custo de hardware quando comparada com a técnica invasiva. Contudo, este método depende da resolução dos dados para identificar a assinatura de carga, como por exemplo a forma de onda. O sistema de monitoramento de cargas não invasivo é uma importante ferramenta quando se trata das casas inteligentes (*Smart Home*) e das redes inteligentes (*Smart Grids*).

O NIALM funciona como um sensor que permite ao consumidor residencial monitorar a corrente, tensão e potência consumida por seus eletrodomésticos, permitindo controlar o gasto mensal com energia elétrica e conhecer o perfil de utilização dos equipamentos eletroeletrônicos. Isto permite optar por tarifas que possam proporcionar economias nos faturamentos mensais ou configurar uma casa inteligente. Alguns trabalhos têm sido desenvolvidos nesta área, recentemente Laput et. al (2017) utilizou sensores de diversos tipos para monitorar o acionamento de cargas elétricas, torneiras e até mesmo um abrir de portas em uma residência.

Para as concessionárias de energia elétrica, este sistema permite monitorar o perfil dos clientes, discriminar a fatura de consumo, identificação de furto de energia e ainda contribui significativamente para os programas de eficiência energética. Além do mais, pode auxiliar as empresas concessionárias de energia elétrica a tomar decisões sobre áreas críticas, podendo ser em relação aos furtos de energia ou em relação a áreas geográficas com grande consumo e cargas prioritárias.

Este trabalho é uma continuação do que foi realizado por Guedes et. al (2015) e Guedes et. al. (2016). Neste artigo será tratada a fase inicial do projeto que é estabelecer um classificador para carga residencial acionada isoladamente. No entanto, não serão utilizados os algoritmos genéticos que foram aplicados em Guedes et. al. (2016).

2 Referencial Teórico

2.1 Estatística de Ordem Superior - EOS

A Estatística de Ordem Superior tem sido usada por muitos pesquisadores por ser menos afetada por ruídos gaussianos, pois a EOS de um ruído gaussiano é nula (MENDEL, 1991). A estatística de ordem superior pode levar a resultados mais representativos

quando utilizado em sistemas não lineares. Além disso são definidas em termos de Momentos que são utilizados para sinais determinísticos e Cumulantes para sinais aleatórios (MENDEL, 1991). O uso de EOS tem sido reportado na literatura por diversos autores. Com foco em energia elétrica existem diversos trabalhos como exemplo podem ser citados Quirós-Olozábal et al. (2016) que utilizaram curtoses para detecção de harmônicos e Guedes et al. (2016) que utilizaram cumulantes em seu trabalho de classificador de carga não invasivo. Segundo Ferreira et. al (2009), os cumulantes de segunda ordem não possuem boa representatividade quando aplicados a sinais elétricos.

Os cumulantes podem ser calculados utilizando as equações (1), (2) e (3) conforme propostos por Ribeiro et al. (2007).

$$\text{mod}(n + i, N) = [n + i] - bN, \quad (1)$$

$$\hat{C}_{2,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n] x[\text{mod}[n + i, N]] \quad (2)$$

$$\hat{C}_{4,x}[i] := \frac{1}{N} \sum_{n=0}^{N-1} x[n] x^3[\text{mod}[n + i, N]] \dots \quad (3)$$

$$\dots - \frac{3}{N^2} \sum_{n=0}^{N-1} x[n] x[\text{mod}[n + i, N]] \sum_{n=0}^{N-1} x^2[n],$$

em que b é o número inteiro obtido quando se desconsidera as casas decimais da divisão de $n+i$ por N , o que na verdade resulta no resto da divisão de $n+i$ por N , i é o i -ésimo atraso e $x[n]$ é o n -ésimo elemento do vetor \mathbf{x} que possui comprimento finito N .

2.2 Fisher's Discriminant Ratio – FDR

Duda et al. (2000) e Theodoridis e Koutroumbas (2009) apresentam o Fisher Discriminant Ratio – FDR tanto para classificação quanto para seleção de características, por ser uma técnica simples para discriminação de dados multi-dimensionais. Este trabalho adotará apenas a aplicação do discriminante como seleção de parâmetros. A média das amostras d -dimensionais da classe i é:

$$\boldsymbol{\mu}_i = \frac{1}{n_i} \sum_{x \in C_i} x \quad (4)$$

Então a função custo do critério da FDR como ferramenta de seleção de parâmetro é:

$$J_c = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^2 \circ \frac{1}{\sigma_1^2 - \sigma_2^2} \quad (5)$$

sendo $J_c = [J_1 \dots J_{L_i}]^T$, L_i é o número total de parâmetros, $\boldsymbol{\mu}_1$ e $\boldsymbol{\mu}_2$ são os vetores médias e σ_1 e σ_2 são os vetores variância dos dados das classes 1 e 2, respectivamente. O símbolo \circ é referente ao produto de

Hadamard, ou seja, $\mathbf{r} \circ \mathbf{s} = [r_1 s_1 \dots r_{L_r-1} s_{L_r-1}]^T$ (RIBEIRO et al., 2007). Para os maiores valores de \mathbf{J}_c , os i -ésimos elementos do vetor de parâmetros representam os parâmetros com melhor separabilidade entre classes.

2.3 Rede Neural Artificial - RNA

As redes neurais artificiais foram inspiradas no funcionamento do sistema nervoso humano. A RNA apresenta neurônios artificiais que realizam sinapses entre si trocando informações necessárias para a aprendizagem.

Pode-se representar um neurônio artificial como:

$$y = \sum_{i=1}^m w_i * x_i + b \quad (6)$$

onde y representa o sinal de saída do neurônio, w_i representa o valor dos pesos sinápticos atribuídos aos neurônios para uma entrada x_i , e b representa uma variável de polarização.

A forma com que os neurônios são conectados entre si define como deverão ser treinados. Em geral podemos classificar uma RNA como Redes *Feedforward* de camada única, Redes *Feedforward* de multicamadas (*Multilayer Perceptron - MLP*) e Redes Recorrentes. As Redes *feedforward* recebem este nome devido ao fluxo das informações, que segue sempre para frente, da saída de um neurônio para a entrada do próximo. Nas redes de camada simples, as informações das saídas dos neurônios da camada de entrada vão diretamente para a entrada dos neurônios da camada de saída. Este fato não acontece nas Redes Multicamadas, pois nestas RNA's as informações das saídas dos neurônios de entrada vão para a entrada dos neurônios da próxima camada até chegarem a camada de saída da rede, este fato pode ser observado na Figura 1. Nas Redes Recorrentes, as informações da saída de um neurônio, além de ir para as entradas dos neurônios da próxima camada, elas fazem um *looping* e alimentam, também, a entrada do mesmo neurônio do qual saíram. (Haykin, 2008).

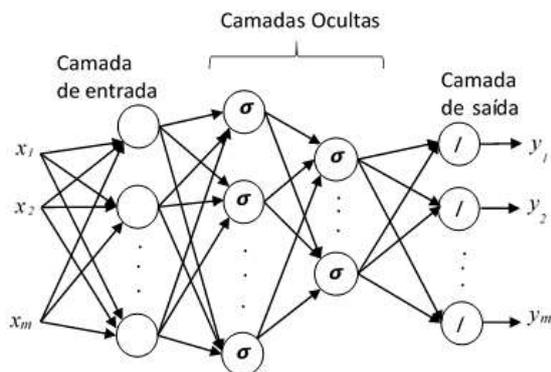


Figura 1. Exemplo de Rede Neural Artificial - Feedforward multicamadas.

2.4 Algoritmo de Aprendizagem

Os algoritmos de aprendizagem são algoritmos que realizam ajustes nos pesos dos neurônios a fim de

conseguir que a saída y , calculada pelo neurônio, seja igual a uma saída desejada T . Entre os algoritmos utilizados para treinamento supervisionado aplicado a RNA está o *Levenberg-Marquardt algorithm*.

Este algoritmo está baseado no método de Gauss-Newton. Considerando uma função não linear descrita em (7)

$$\mathcal{F}(Y) = X \quad (7)$$

onde $X \in \mathbb{R}^M$ e $Y \in \mathbb{R}^N$ são vetores e $M \geq N$.

Para estimar o vetor \hat{Y} , Newton (Press et al., 1992) assume a equação (8):

$$\mathcal{F}(\hat{Y} + \Delta) = \mathcal{F}(\hat{Y}) + J\Delta \quad (8)$$

sendo J a matriz jacobiana, ou seja, $J = \frac{\partial X}{\partial Y}$ e Δ indica um pequeno incremento de \hat{Y} . Minimizar o $\|\epsilon\|$ equivale a resolver a equação (9)

$$J^T J \Delta = J^T \epsilon \quad (9)$$

Levenberg (1944) propôs uma alteração na equação (9) para acelerar a convergência.

$$(J^T J + I\lambda)\Delta = J^T \epsilon \quad (10)$$

onde λ é inicialmente 10^{-4} , contudo a cada iteração o valor de λ é alterado. Se na equação (10) há uma redução do $\|\epsilon\|$, λ é dividido por 10, caso contrário é multiplicado por 10.

Esta equação, porém, possui instabilidades. Então Maquardt (1963) propôs uma alteração na equação (10) conforme demonstrado na equação (11).

$$(J^T J + \text{diag}(J^T J)\lambda)\Delta = J^T \epsilon \quad (11)$$

Atualmente o algoritmo é conhecido como Levenberg-Maquardt.

Durante a etapa de treinamento os dados são divididos em dois conjuntos, sendo um de treinamento (o qual será usado para treinar a RNA) e outro conjunto de validação (o qual é um conjunto de dados desconhecido para a RNA e será utilizado para validar o treinamento).

3 Metodologia

O método proposto consiste em três partes, a aquisição, o processamento e a classificação dos dados. Na Figura 2 estão apresentadas a principais etapas para o projeto.

3.1 Aquisição de Dados.

Quando um aparelho eletrodoméstico é ligado, devido às características construtivas de cada um deles, pode-se retirar informações importantes da corrente elétrica utilizada pelo equipamento e utilizá-la para

identificá-lo. Uma abordagem do transitório de liga e desliga foi realizada por Yang et al.(2015), onde o evento liga e desliga da carga foi monitorado de forma não intrusiva com o objetivo de determinar a duração da utilização da mesma. Optou-se, para este trabalho, utilizar o transitório de acionamento da carga presente na corrente elétrica. A Tabela 1 apresenta os equipamentos que constitui cada classe e a quantidade de eventos que foram amostrados para cada uma delas.

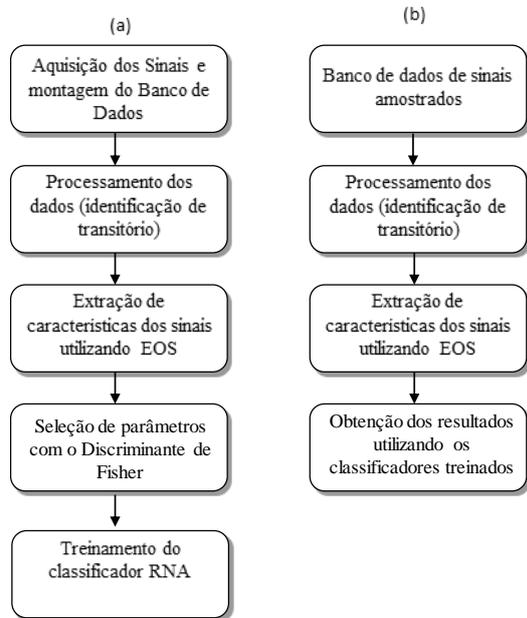


Figura 2. Fluxograma indicando as etapas do desenvolvimento do classificador. (a) fase de treinamento e (b) fase de validação.

Os dados foram adquiridos utilizando uma sonda de corrente FLUKE i200s, um dispositivo de aquisição de dados *National Instruments* USB – 6251 e um *notebook* Del vostro com o sistema operacional Windows 8.1, com processador Intel i5, 4Gb de memória RAM e uma interface do LABVIEW® 2015. Os dados foram amostrados a uma frequência de 15.360Hz, sendo 256 amostras por ciclo na frequência de 60Hz.

Tabela 1. Classes para equipamento isolado a ser monitorado.

Classes	Equipamento	Eventos
C1	Chuveiro	50
C2	Televisão de LED 40 polegadas	50
C3	Micro-ondas	50
C4	Lampada de Led	50
C5	Multiprocessador	50

Para cada uma das cargas foram realizados 50 eventos (será chamado de evento a coleta de dados referente a um acionamento da carga elétrica) de amostragem. Foram utilizados destes eventos, 35 na fase de projeto e 15 na fase de validação.

3.2 Processamento de Dados.

Esta etapa compreende a parte de segmentação dos dados e seleção dos parâmetros que melhor representam as classes.

3.2.1 Segmentação dos Dados:

Uma janela deslizante retangular de 16 ciclos foi aplicada em cada um dos eventos de amostragem, essa janela consiste em monitorar o sinal até que ocorra o transitório, ao encontrá-lo, então armazena-se as amostras referente a 1 ciclo antes da ocorrência e 15 ciclos depois. Para cada um dos sinais foram selecionados os ciclos contendo os transitórios e armazenados em um novo arquivo a fim de reduzir a dimensão dos dados de 41.868 amostras para 4.096, e com isto ocorre a redução do custo computacional. Exemplo dos dados antes e após a segmentação pode ser visto na Figura 3.

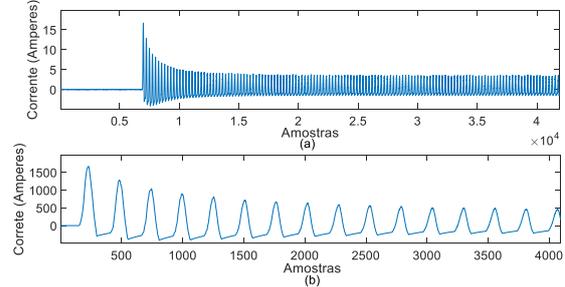


Figura 3. Amostra de sinal de corrente do multiprocessador de alimentos (a) dados antes de serem segmentados (41.868 amostras) (b) dados após a segmentação (4.096 amostras).

Na Figura 3(a) percebe-se que existem ruídos antes do acionamento da carga, optou-se por fazer desta forma para garantir que apenas o transitório fosse capturado. Na Figura 4 tem-se uma amostra do sinal de corrente em função da amplitude da corrente (Amperes) e número de amostras) para cada uma das classes adotadas no desenvolvimento desta pesquisa.

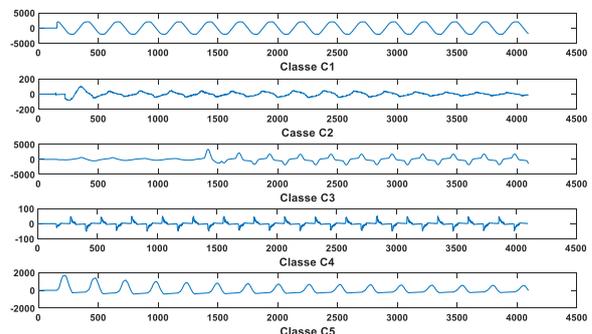


Figura 4. Amostra de sinal de todas as classes utilizadas neste trabalho.

3.2.2 Seleção de Parâmetros.

Na etapa de seleção de parâmetros, primeiramente foi realizada a extração dos cumulantes de segunda e quarta ordens utilizando EOS conforme Equações (2) e (3).

Posteriormente à extração dos cumulantes foi realizada a seleção daqueles que melhor representam cada classe, aumentando a possibilidade de classificação correta dos dados. Para realizar esta etapa utilizou-se o FDR, que é dado pela Equação (5) e, então, foi montado o vetor de parâmetros final que e foi, então, apresentado ao classificador.

3.3 Classificação.

No processo de classificação foi utilizada RNA com arquitetura MPL. Esta foi montada contendo o número de entradas correspondente a dimensão do vetor de parâmetros, inicialmente, 11 neurônios na camada oculta e 5 neurônios na camada de saída, sendo um para cada classe. Os pesos foram inicializados aleatoriamente.

Após testes preliminares, onde algoritmos como Levenberg-Marquardt, Bayesian Regularization, BFGS Quasi-Newton, Resilient Backpropagation e Scaled Conjugate Gradient foram utilizados para treinamento de 5 RNAs, após comparação dos resultados optou-se por utilizar o algoritmo Levenberg-Marquardt por ter obtido melhores resultados que os demais algoritmos.

O Classificador foi implementado no software Matlab 2015 e foi utilizado o toolbox de RNA. Foram implementadas 10 RNA's, para cada treinamento o banco de dados foi misturado e redividido e seus resultados foram avaliados e compuseram a média global para indicar o resultado do classificador.

Antes de ser entregue para a RNA, todos os dados foram normalizados entre -1 e 1 e divididos em conjunto de treino e conjunto de validação. O conjunto de validação é um conjunto desconhecido para a RNA treinada e serve para testar a capacidade de generalização da mesma.

4 Resultados e Discussão

No cálculo do Discriminante de Fisher, como pode ser observado na Figura 5, os cumulantes de segunda ordem são simétricos, ou seja, a segunda metade é igual a primeira, então utilizou-se apenas os primeiros 2.048 cumulantes de segunda ordem para compor a primeira parte do vetor de parâmetros, e os 4.096 cumulantes de quarta ordem, compondo o restante do vetor de parâmetros.

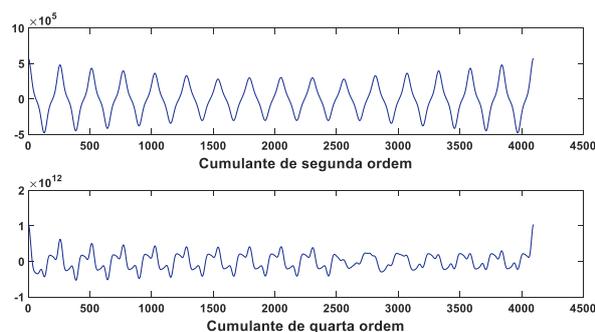


Figura 5. Cumulante de segunda e quarta ordem para o evento 3 da classe C3.

Tomando como exemplo as classes C3 e C5, foi realizada a comparação de C3 contra as demais classes e o parâmetro de índice 5.954 é o que melhor representa a classe C3, verifica-se na Figura 6 que para as cargas do tipo C3 o cumulante de quarta ordem é o que

melhor extraiu informações relevantes para a classificação.

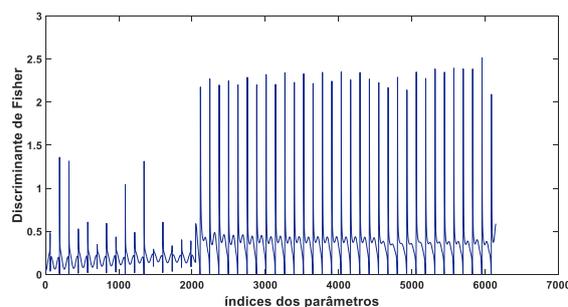


Figura 6. Discriminante de Fisher para a classe C3. Os primeiros 2048 índices são cumulantes de segunda ordem e de 2.049 a 6.144 são cumulantes de quarta ordem.

Fazendo a comparação dos parâmetros da classe C5 contra as demais classes, o parâmetro de índice 321 foi o que melhor representa a classe C5, pode-se perceber na Figura 7 que os cumulantes de segunda ordem foram os que melhor extraíram informações importantes para classificação desta classe de eletrodômicos.

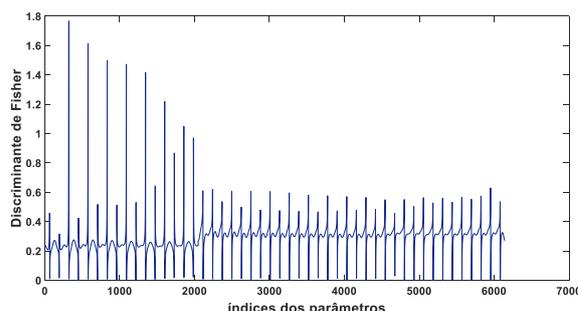


Figura 7. Discriminante de Fisher para a classe C5. Os primeiros 2048 índices são cumulantes de segunda ordem e de 2.049 a 6.144 são cumulantes de quarta ordem.

Este procedimento foi realizado para as cinco classes utilizadas neste trabalho. Foram armazenados em vetores os dois parâmetros mais representativos de cada classe. Com isso, a redução de dimensão foi de 6.144 para 10, o que é considerável em termos de redução do esforço computacional necessário.

A rede neural artificial MLP foi criada com 10 nós de entrada conforme dimensão do vetor obtido na etapa anterior, 5 neurônios na camada oculta e 5 na camada de saída. A camada de saída foi ajustada sendo um neurônio para cada classe. A camada oculta foi ajustada após investigações experimentais. Foram implementadas 10 RNA's e todas foram treinadas utilizando o algoritmo de treinamento Levenberg-Marquardt.

Na Tabela 2 está apresentado a matriz de confusão referente à RNA que obteve o melhor desempenho. Pode-se observar que ao apresentar o conjunto de dados de validação para a RNA treinada, a rede classificou corretamente todas as classes de carga elétrica.

Tabela 2. Matriz de confusão de melhor desempenho no teste de validação.

	C1	C2	C3	C4	C5
C1	15	0	0	0	0
C2	0	15	0	0	0
C3	0	0	15	0	0
C4	0	0	0	15	0
C5	0	0	0	0	15

A rede neural artificial que apresentou o pior resultado, comete dois erros, conforme pode ser observado na matriz de confusão apresentada na Tabela 3. A classificação de um dado da classe C2 como C4 pode ter ocorrido devido a semelhança entre as classes.

Tabela 3. Matriz de confusão de melhor desempenho no teste de validação.

	C1	C2	C3	C4	C5
C1	15	0	0	0	0
C2	0	14	0	1	0
C3	0	1	14	0	0
C4	0	0	0	15	0
C5	0	0	0	0	15

O índice de acertos global para as 10 RNA's foi de $99,6 \pm 0,9\%$, a rede com maior índice de acertos alcançou a marca de 100% e a RNA com menor índice foi de 97,33% de acertos.

5 Conclusão

Este trabalho conseguiu estabelecer o ponto de partida necessário para a implantação do projeto de classificação de cargas residenciais acionadas paralelamente a outras cargas já ligadas. O pré-processamento dos dados utilizando a Estatística de Ordem Superior e o Discriminante de Fisher foi de grande importância para reduzir o esforço computacional, onde a dimensão inicial de 55.224 foi reduzida para 10. Ademais, estas técnicas mostram ter um excelente desempenho quanto a extração de informações referentes às assinaturas elétrica das cargas presentes no sinal da corrente elétrica amostrada. O resultado geral obtido de 99,6% com a rede neural artificial foi significativo, aumentando assim as expectativas para a próxima fase. Mesmo com cargas de características construtivas similares a rede conseguiu classificá-las de forma correta e isto possibilita o início do trabalho com as cargas acionadas simultaneamente.

A próxima etapa será a implementação da rede neural artificial para a classificação de eletrodomésticos que são acionadas em paralelo com outras cargas elétricas já em funcionamento.

Agradecimentos

A Universidade Federal de Lavras, a CAPES e CNPq por permitirem que este trabalho fosse realizado.

Referências Bibliográficas

- DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern Classification. 2nd ed. New York: Wiley-Interscience, 2000. 654 p. ISBN 0471056693.
- FERREIRA, D. D. et al. HOS-based method for classification of power quality disturbances. Electronics Letters, London, v. 45, n. 3, p. 183-185, January, 2009.
- GUEDES, Juan Diego Silva et al. Non-Intrusive Appliance Load Identification Based on Higher-Order Statistics. IEEE Latin America Transactions, v. 13, n. 10, p. 3343-3349, 2015.
- GUEDES, J. D. S.; FERREIRA, D. D.; BARBOSA, B. H. G. A non-intrusive approach to classify electrical appliances based on higher-order statistics and genetic algorithm: a smart grid perspective. Electric Power Systems Research, [S.L.], v. 140, p. 65-69, Julho, 2016.
- HAYKIN, S. Neural Networks and Learning Machines. 3rd ed. New Jersey: Pearson, 2008. 906 p. ISBN 978-0131471399.
- LAPUT, G.; ZHANG, Y.; HARRISON, C. Synthetic Sensors: Towards General-Purpose Sensing. CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2017, Denver. Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems, New York: ACM, May, 2017. p.3986-3999.
- LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. Quarterly of Applied Math, Providence, v. 2, p. 164-168, 1944.
- MARQUARDT, Donald W. An algorithm for least-squares estimation of nonlinear parameters. Journal of the society for Industrial and Applied Mathematics, v. 11, n. 2, p. 431-441, 1963.
- MENDEL, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. Proceedings of the IEEE, [S.L.], v. 79, n. 3, p. 278-305, March, 1991.
- QUIRÓS-OLOZÁBAL, Á. et al. A novel FPGA-based system for real-time calculation of the Spectral Kurtosis: A prospective application to harmonic detection. Measurement, Grattan, v. 86, p. 101-113, February, 2016.
- PRESS, William H. et al. Numerical Recipes in C: The Art of Scientific Computing, Cambridge, 1992.
- RIBEIRO, M. V. et al. Detection of Disturbances in Voltage Signals for Power Quality Analysis Using HOS. EURASIP Journal on Advances in Signal Processing, [S.L.], v. 2007, p. 13, February, 2007.
- THEODORIDIS, S.; KOUTROUMBAS, K. Pattern Recognitions. Ed. 4. Boston: Academic Press, 2009. 984 p. ISBN 978-1-59749-272-0.
- XU, Y.; MILANOVIC, J. V. Artificial-Intelligence-Based Methodology for Load Disaggregation at Bulk Supply Point. IEEE Transactions on Power Systems, [S.L.], v. 30, n. 2, p. 795-803, March, 2015.

YANG, C.; SOH, C.; YAP, V. A systematic approach to ON-OFF event detection and clustering analysis of non-intrusive appliance load monitoring. *Frontiers in Energy, Beijing*, v. 9, n. 2, p. 231-237, February, 2015.