



JUAN DIEGO SILVA GUEDES

**MÉTODO DE MONITORAMENTO NÃO
INVASIVO DE CARGAS ELÉTRICAS
RESIDENCIAIS**

**LAVRAS – MG
2013**

JUAN DIEGO SILVA GUEDES

**MÉTODO DE MONITORAMENTO NÃO INVASIVO DE CARGAS
ELÉTRICAS RESIDENCIAIS**

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, para a obtenção do título de Mestre.

Orientador

Dr. Danton Diego Ferreira

Co-Orientador

Dr. Bruno Henrique Groenner Barbosa

**LAVRAS– MG
2013**

**Ficha Catalográfica Elaborada pela Coordenadoria de Produtos e
Serviços da Biblioteca Universitária da UFLA**

Guedes, Juan Diego Silva.

Método de monitoramento não invasivo de cargas elétricas residenciais / Juan Diego Silva Guedes. – Lavras : UFLA, 2013.

107 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2013.

Orientador: Danton Diego Ferreira.

Bibliografia.

1. Monitoramento não invasivo. 2. Cargas elétricas. 3. *Smart grids*. 4. Estatísticas de ordem superior (EOS). I. Universidade Federal de Lavras. II. Título.

CDD – 620.00113

JUAN DIEGO SILVA GUEDES

**MÉTODO DE MONITORAMENTO NÃO INVASIVO DE CARGAS
ELÉTRICAS RESIDENCIAIS**

Dissertação apresentada à Universidade Federal de Lavras como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, para a obtenção do título de Mestre.

APROVADA em 19 de Agosto de 2013

Dr. Danton Diego Ferreira	UFLA
Dr. Bruno Henrique Groenner Barbosa	UFLA
Dr. Geovanni Francisco Rabelo	UFLA
Dr. Fernando Lessa Tofoli	UFSJ

Dr. Danton Diego Ferreira UFLA
Orientador

**LAVRAS – MG
2013**

À minha esposa e família.

DEDICO

AGRADECIMENTOS

Agradeço inicialmente a Deus por todas as benfeitorias em minha vida como a Nossa Senhora de Guadalupe que sempre senti sua presença e proteção.

Aos meus pais Messias José Guedes e Deizimar Nazaré Silva Guedes pelas inúmeras orientações e carinho infinito durante toda minha caminhada.

Ao meu irmão Joális Silva Guedes pelo companheirismo e por estar presente em toda minha caminhada.

A minha querida esposa Karina Teixeira Magalhães Guedes pelo amor incondicional e compreensão durante todo o tempo.

A minha querida sobrinha Sophia e sua mãe Glads.

Ao Gumercindo, Gilda e Kassiana pelo acolhimento, amor e carinho.

Ao meu amigo, orientador e conselheiro Danton Diego Ferreira que tornou possível o desenvolvimento deste trabalho.

Ao meu Amigo e Co-orientador Bruno Henrique Groenner Barbosa que esteve presente todo o tempo com grandes contribuições.

Aos meus eternos amigos: Antônio Augusto, Gabriel, Luiz Henrique, Paulo Elias, Pedro Henrique, Pedro Boueri, Valdir e a todos os amigos da República Mausoléu, pela amizade de longos anos.

Ao Deilson Martins Fonseca, pela amizade e pelas oportunidades em tempos difíceis.

Ao Luis Carlos Lage Guerra, o eterno “Chefe” pelas inúmeras orientações e companheirismo na luta de todos os dias.

Aos professores e técnicos da UFLA, pelos valorosos conhecimentos transmitidos e companheirismo.

A CAPES / CNPQ / FAPEMIG pelo financiamento desta pesquisa e a UFLA que tornou possível a conclusão deste trabalho.

Ao orientador, co-orientador e professores, pelos valiosos conhecimentos transmitidos.

OFEREÇO

"Quatro coisas que não têm retorno: a palavra dita; a flecha lançada; o tempo passado; a oportunidade negligenciada."

Al Halif Omar Ibn

RESUMO

Sistemas não invasivos de medição de cargas elétricas possuem aplicações variadas e apresentam benefícios tanto para consumidores quanto para concessionárias de distribuição de energia elétrica. Esses sistemas permitem a discriminação da fatura e a detecção de furto de energia elétrica. Podem fornecer, ainda, informações valiosas para programas de eficiência energética, além de possibilitar uma melhor caracterização das cargas atendidas do ponto de vista temporal. Este trabalho apresenta uma nova metodologia para o monitoramento não invasivo de cargas elétricas residenciais. A metodologia propõe o uso de cumulantes de segunda e quarta ordem extraídos do sinal de corrente elétrica das cargas elétricas residenciais, durante o acionamento. Os cumulantes representam as assinaturas de tais cargas a fim de identificá-las quando acionadas. Em seguida, a seleção dos cumulantes mais significativos é feita utilizando-se duas abordagens: a) através do discriminante linear de Fisher e b) através do discriminante linear de Fisher seguido de Algoritmos Genéticos. Os cumulantes selecionados são então apresentados a um classificador que identifica a carga elétrica que foi acionada. Dois classificadores foram propostos: a) baseado em Redes Neurais Artificiais e b) baseado em Árvores de Decisão. Os resultados dessas abordagens são apresentados de forma comparativa apontando as vantagens e desvantagens de cada uma. Neste trabalho foram consideradas onze classes diferentes de cargas elétricas residenciais. Os sinais elétricos foram adquiridos experimentalmente.

Palavras-chaves: Monitoramento não invasivo. Cargas elétricas. Estatísticas de ordem superior (EOS). *Smart grids*.

ABSTRACT

Non-invasive appliance load monitoring is a modern technique that has several applications bringing benefits for both consumers and electrical utilities. These techniques allow bill discrimination and detection of energy losses. It also provides valuable information for energy programs, and creates a better characterization of the loads. This work presents a new approach for non-invasive residential electrical load monitoring. The innovation of the proposed approach is the use of cumulants of second and fourth order extracted from the electric current signal of the residential electrical loads as signatures of these loads. In order to reduce the dimension problem, two methods for feature selection were employed: a) Fisher's Linear Discriminant and Fisher's Linear Discriminant combined to Genetic Algorithms. The selected features are presented to a classifier, which identifies the residential electric load class of the processed signal. Two different classifiers were used: a) Artificial Neural Networks and b) Decision Tree. Results from these approaches were comparatively presented. This work has considered eleven different classes of residential electrical loads. Results were obtained out from experimental electric signals and a high performance is achieved.

Keywords: Non-invasive monitoring. Electrical loads. Smart grids. higher order statistical (HOS)

SUMÁRIO

	PRIMEIRA PARTE	10
1	INTRODUÇÃO	11
2	EMBASAMENTO BIBLIOGRÁFICO E METODOLÓGICO	17
	REFERÊNCIAS	52
	SEGUNDA PARTE - ARTIGOS	55
	ARTIGO 1 Sistema automático de monitoramento não invasivo de cargas elétricas residenciais	56
1	INTRODUÇÃO	60
2	METODOLOGIA	62
3	RESULTADOS E DISCUSSÕES	70
4	CONCLUSÕES	75
5	PROPOSTAS DE CONTINUIDADE	76
	REFERÊNCIAS	79
	ARTIGO 2 Uma nova abordagem ao monitoramento não invasivo de cargas utilizando Estatísticas de Ordem Superior e Algoritmos genéticos	81
1	INTRODUÇÃO	82
2	METODOLOGIA	85
3	RESULTADOS E DISCUSSÕES	97
5	CONCLUSÕES	100
	REFERÊNCIA	101
	ANEXO	106

PRIMEIRA PARTE

1 INTRODUÇÃO

Existe uma grande inquietação dos pesquisadores sobre o aumento do fornecimento de energia elétrica que cresce a cada dia. Recentemente, entrou em vigor uma nova versão dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) sob responsabilidade da Agência Nacional de Energia Elétrica - ANEEL (2012) (IEEE std 1195, 2009). Nela são detalhados os eventos de qualidade da energia, tais como afundamentos ou elevações de tensão, variações de frequência, presença de harmônicos na rede, entre outros fatores.

O grande desafio está em identificar as principais fontes poluidoras do sistema elétrico de forma eficaz, gerando punições aos poluidores da rede. Apesar de não ser possível ainda identificar com precisão essas fontes poluidoras, sabe-se que o consumidor residencial tem parcela substancial nessa contribuição, devido à utilização de cargas não lineares presentes em diversos eletrodomésticos, o que contribui com a circulação de harmônicos pela rede e afeta diretamente a qualidade da energia elétrica (NASCIMENTO, 2012).

Apesar do aumento da demanda elétrica, a tecnologia de transmissão e distribuição de energia não acompanhou essa evolução. Não houve uma grande revolução no setor elétrico como ocorreu no setor de telecomunicações (celulares, smartphones) e está na hora das concessionárias de energia elétrica se reinventarem, não somente no sentido tecnológico mas também em relação aos consumidores ou partes interessadas.

As redes elétricas inteligentes, hoje bastante discutidas e estudadas, tendem a provocar essa necessária revolução, não apenas técnica e tecnológica, mas também econômica, uma vez que novos modelos de negócio podem ser criados, contribuindo efetivamente para alavancar diversos setores da economia. Não existe ainda um conceito definido sobre o que são essas redes inteligentes

ou *smart grids*. Alguns especialistas focam mais na automação das redes, outros na cadeia de fornecimento de energia, outros ainda na melhoria dos canais de interação e serviços do consumidor (TOLEDO, 2012).

Independente do conceito adotado, o fato é que as *smart grids* precisam lidar com os desafios do presente e do futuro como:

- a) Inserção de novas fontes de energia (fontes renováveis).
- b) Mudança do perfil consumidor (carros elétricos).
- c) Necessidade de lidar com a bidirecionalidade energética e grande quantidade de informação em tempo real.
- d) Resposta a crescente expectativa das partes interessadas sobre a qualidade da energia.
- e) Gestão otimizada do significativo aumento da carga.

Esse aumento de demanda deve ser muito bem estudado, pois as características dos consumidores mudaram bastante durante as últimas décadas e ferramentas robustas para gerenciar esses novos tipos de consumidores se tornaram necessárias. Há décadas atrás a preocupação com a utilização da energia elétrica estava relacionada aos consumos industriais e residenciais e as cargas possuíam características bem definidas com aumento bastante previsível. Na atualidade, com a maior variedade de cargas e consumo em lugares distintos, como em veículos elétricos, obriga as concessionárias a possuírem uma rede mais flexível de modo a se adequarem a essa nova realidade.

Para realizar estudos de consumo de energia elétrica frequentemente é realizada coleta de dados por meio de enquete. A partir dos dados são feitas análises das informações coletadas. Por sua natureza, esses dados estão expostos aos erros do tipo sistemático, como informação faltante por questões sem resposta por parte do usuário ou devido à má manipulação dos dados por parte

da pessoa que faz a entrevista. Outro erro no levantamento de dados sobre o consumo tem a ver com o fator psicológico de cada consumidor, ou seja, os habitantes de um prédio podem fornecer informações distintas aos seus hábitos de consumo quando estão sendo questionados na matéria, fazendo com que os dados levantados não sejam representativos em termos de consumo naquele prédio. Isso também acontece quando as pessoas esquecem alguns hábitos de consumo, como por exemplo, não lembrar quantas vezes ligaram as luzes do banheiro.

Para que seja possível a implantação das redes elétricas inteligentes necessita-se de uma evolução no modo como as medições elétricas são realizadas. Com a necessidade de se reduzir o desperdício e melhorar o controle sobre o consumo, novas formas de monitoramento do consumo estão sendo desenvolvidas e testadas em todo o mundo. Entre elas, se destacam:

- a) **AMR** – *Automatic Meter Reading* (Leitura de Medidor Automática)

Sistema que acaba com a necessidade da visita do funcionário da concessionária ao consumidor, onde o medidor envia os dados do consumo direto à concessionária, possibilitando maior flexibilidade na forma de taxação que poderá ser anualmente, mensalmente ou até diariamente. Outro benefício é a maior compreensão do consumo por ambas as partes (consumidor e fornecedor) (APTEL, 2009).

- b) **AMI** – *Automatic Meter Infrastructure* (Infraestrutura de Medição Automática)

Sistema similar ao AMR, porém ele não só efetua a leitura e a envia à concessionária; seus medidores são dotados de novas tecnologias de *hardware* e *software* que o tornam capaz de mensurar, ler e analisar o consumo de energia e prover de maneira fácil o acesso a essas informações, tanto para a concessionária quanto para o consumidor. Esse tipo de informação de tempo em tempo possibilita uma ação em prol da redução do desperdício pelo consumidor (M&C ENERGY, 2011).

- c) **AMM** – *Automatic Meter Management* (Gerenciamento de Medidor Automático).

Esse sistema é uma extensão do AMI. O diferencial é que ele tem a capacidade de ajudar o consumidor a gerenciar o consumo, visando sempre reduzir o desperdício e obter maior eficiência energética (M&C ENERGY, 2011).

Os métodos citados são baseados em um processo altamente automatizado que vai desde a leitura à cobrança do consumo, conhecido também como “*smart metering*”. O principal componente do “*smart metering*” é o medidor de consumo, que atualmente adota-se o termo “*smart meter*” para referenciá-lo devido a algumas características especiais como, por exemplo, o uso de novas tecnologias de comunicação, dinamismo em obter e disponibilizar os dados, entre outras. Os *smart meters* são desenvolvidos por um seleto grupo de empresas e muitas vezes seu preço é bastante elevado.

Uma questão importante nesses novos medidores é que o sinal capturado por eles devem ser tratados e depois analisados. Uma importante ferramenta na análise destes sinais é o reconhecimento de padrões.

O reconhecimento de padrões tem como objetivo principal a classificação de sinais (padrões) em um número de categorias ou classes (THEODORIDIS; KOUTROUMBAS, 1999). As técnicas de reconhecimento de padrões são usadas para classificar e/ou descrever padrões através de um conjunto de propriedades ou características extraídas dos dados brutos ou pré-processados. A extração de características pode ser realizada por inúmeras técnicas (DUDA; HART; STORK, 2000) e geralmente é tratada como um problema estocástico.

O objetivo é extrair características com boa capacidade de discriminação entre as classes do problema. Contudo, a extração de características pode levar a um conjunto de parâmetros em alta dimensão e, portanto, técnicas de compactação de sinais são frequentemente utilizadas para reduzir o espaço de parâmetros a uma dimensão menor e de mais fácil visualização.

Essas etapas de extração de características e compactação de sinais estão diretamente relacionadas à capacidade de aplicação em tempo real dos sistemas de reconhecimento de padrões, uma vez que um reduzido conjunto de parâmetros (características) com boa capacidade de discriminação viabiliza a utilização de uma técnica de classificação mais simples, reduzindo, conseqüentemente, o tempo de processamento.

A capacidade de aplicação em tempo real é uma importante característica frequentemente requerida em sistemas de reconhecimento de padrões, entretanto, dependendo da aplicação alvo sistemas de reconhecimento de padrões *off-line* são desejados.

As técnicas de reconhecimento de padrões vêm sendo aplicadas em vários domínios. Um bom resumo sobre tais aplicações pode ser encontrado em (JAIN; DUIN; MAO, 2000).

Neste trabalho, um sistema de monitoramento não invasivo para redes de baixa tensão é apresentado. O sistema consiste na análise de dados relativos

ao consumo do cliente, de forma não invasiva, através de um medidor instalado na alimentação da residência ou comércio. Essa análise é realizada pelo emprego de técnicas avançadas de processamentos de sinais e inteligência computacional que, combinadas compõem um sistema que permite identificar o equipamento que entrou em operação.

Os sistemas de medição de cargas não invasivos (SMCNI) podem constituir uma importante ferramenta nas *smart grids* ou redes inteligentes. Especificamente, tais sistemas funcionam como sensores dos consumidores de baixa tensão, detectando informações sobre a característica do consumo e principais parâmetros tais como tensão, corrente e potência consumida.

Para a concessionária esses sistemas permitem a discriminação da fatura de energia elétrica dos clientes, possibilita a identificação de furtos de energia e contribui significativamente para programas de eficiência energética, pois indicam à concessionária zonas onde o fornecimento de energia pode ser realizado de maneira mais inteligente.

Adicionalmente, os SMCNI auxiliam a empresa fornecedora de energia na avaliação de equipamentos e/ou zonas críticas para a companhia, funcionando como uma ferramenta a mais na tomada de decisão. Consequentemente, o consumidor pode se beneficiar igualmente dessa tecnologia que permite um controle maior dos gastos da residência, proveniente de uma fatura discriminada.

Atualmente, diversos trabalhos tem como foco SMCNI (FIGUEIREDO; ALMEIDA; RIBEIRO, 2012; NASCIMENTO, 2012; RICARDO; SILVA; OLESKOVICZ, 2010; TSAI; LIN, 2011), demonstrando, assim, a inquietação dos pesquisadores sobre este tema.

2 EMBASAMENTO BIBLIOGRÁFICO E METODOLÓGICO

No contexto de monitoramento não invasivo alguns trabalhos já foram realizados como (RICARDO; SILVA; OLESKOVICZ, 2010) onde foram analisados seis equipamentos residenciais e onde foram extraídas as características, através de um analisador de qualidade de energia *Fluke 435®*. Seis redes neurais foram empregadas para identificar qual equipamento foi acionado. O trabalho de (TSAI; LIN, 2011) traz um estudo comparativo entre a classificação pelo método *k-Nearest Neighbor Rule* (K-NNR) e pelo *Back-Propagation Artificial Neural Network* (BP-ANN). Já Figueiredo, Almeida e Ribeiro (2012) analisaram cinco equipamentos e extraiu características de regime destes. Foram utilizadas Máquinas de Vetor de Suporte (SVM) em comparação a Redes Neurais de Base Radial (RBF) e ao método dos 5 vizinhos mais próximos (5-NN) a fim de identificar os equipamentos.

O trabalho proposto apresenta uma metodologia diferente que utiliza estatísticas de ordem superior (EOS), para extrair parâmetros com características da assinatura dos equipamentos elétricos residenciais. A motivação para o uso de EOS como parâmetros está na sua capacidade de representação de dados mesmo na presença de ruídos gaussianos, já que essas são filtros a ruídos gaussianos. Adicionalmente, trabalhos recentes mostraram que as EOS são ferramentas poderosas na representação de sinais elétricos para fins de classificação e detecção de distúrbios elétricos (FERREIRA et al., 2009).

Os dados coletados para a realização deste trabalho são de equipamentos comumente utilizados em residências e estão listados na Tabela 1.

Tabela 1 Equipamentos amostrados

Ordem	Equipamentos	Eventos
C1	Chuveiro	50
C2	Ferro Elétrico	50
C3	Lâmpada 20W Compacta	50
C4	Lâmpada 20W Fluorescente	50
C5	Lâmpada 60W Incandescente	50
C6	Liquidificador	50
C7	Forno Micro-ondas	50
C8	Misteira	50
C9	Multiprocessador	50
C10	TV LED 46 polegadas	50
C11	Ventilador	50

Neste trabalho foram utilizados os sinais de corrente de alimentação das cargas elétricas residenciais, já que esses caracterizam melhor o tipo de carga elétrica acionada do que os sinais de tensão. Durante o acionamento de uma carga elétrica existem basicamente duas características importantes que são refletidas na corrente elétrica e que podem ser utilizadas para diferenciar os vários acionamentos: transitórios de partida, que ocorrem no momento do acionamento e os transitórios de regime, que ocorrem durante a operação nominal do equipamento. Neste trabalho as análises se restringiram apenas a análise de transitórios de partida. Em propostas futuras pretende-se analisar também os transitórios de regime.

Foram coletados 50 eventos (acionamentos) de cada um dos equipamentos listados na Tabela 1. Os sinais foram coletados experimentalmente em uma dada residência, utilizando a placa de aquisição *NI USB-6251* mostrada na Figura 1 e uma ponteira de corrente (ver Figura 2) a uma frequência de amostragem de 15.360 Hz e utilizando uma interface via *LABVIEW*[®].



Figura 1 Placa de aquisição *NI USB-6251* fabricado por: National Instruments



Figura 2 Ponteira de corrente

Para recortar o regime transitório de acionamento de cada equipamento foi desenvolvido um detector de acionamento, baseado na inovação da energia do sinal que armazena um ciclo anterior ao instante de detecção do acionamento e três ciclos após o instante de acionamento detectado. Para a detecção de um dado evento discreto no tempo $x[n]$, o detector de inovação realiza a seguinte operação:

$$d = E_x[n + 5] - E_x[n - 5], \quad (1)$$

em que E_x é a energia do evento x em uma dada amostra n . Se d for maior do que um patamar (τ) previamente ajustado, considerando o conjunto de eventos de treinamento, então o acionamento é detectado. Desta forma, a uma frequência de amostragem de 15.360 Hz, tem-se 256 amostras por ciclo e um total de 1.024 amostras por acionamento.

As Figuras 3 a 13 mostram as formas de ondas de um acionamento de cada classe considerada na Tabela 1 e o respectivo sinal pré-processado, ou seja, o sinal contendo 1.024 amostras após a detecção do transitório do acionamento. Observe que algumas cargas, como o chuveiro, ferro de passar, misteira e ventilador possuem uma forma de onda com uma característica bem senoidal, o que torna as formas de onda similares. Logo, a discriminação entre essas classes, utilizando a forma de onda da corrente, como mostrado, pode requerer um algoritmo de classificação mais complexo. Portanto, neste caso, a utilização de uma transformação nos dados para extrair características relevantes à classificação é fundamental no projeto de um classificador mais simples para fins de monitoramento *online*.

Uma observação importante referente às figuras capturadas é relativa à mudança de escala, esta se deve ao ajuste realizado devido a ponteira de corrente

utilizar uma escala 1:100. Outra observação é que a corrente de acionamento da lâmpada é um pouco maior do que a esperada, devido ao aquecimento do filamento da lâmpada em repetidos acionamentos.

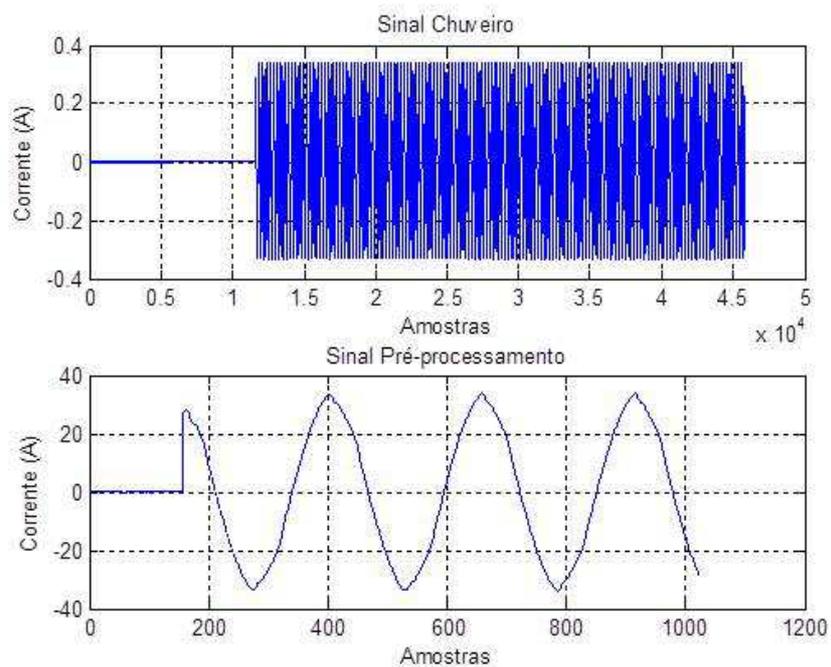


Figura 3 Sinal coletado do chuveiro

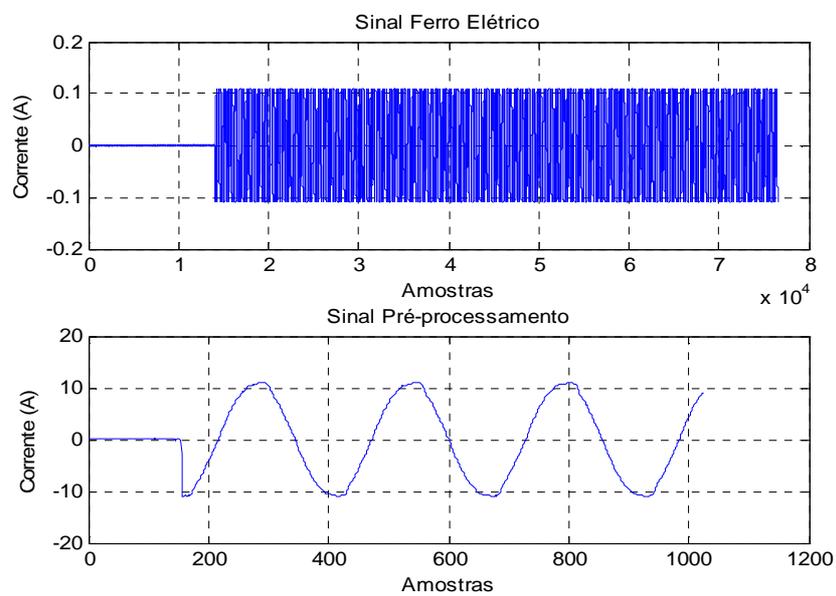


Figura 4 Sinal coletado do Ferro Elétrico

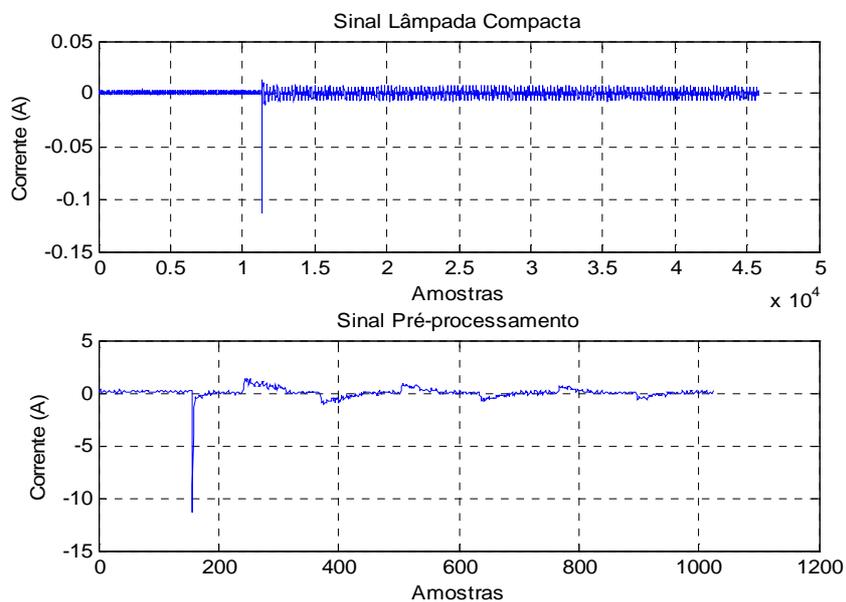


Figura 5 Sinal coletado da Lâmpada 20 W Compacta

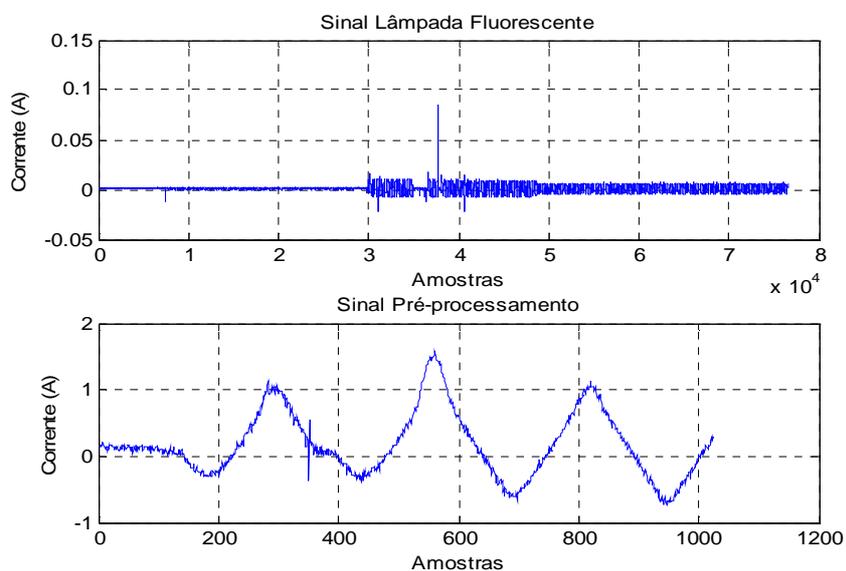


Figura 6 Sinal coletado da Lâmpada 20 W Fluorescente

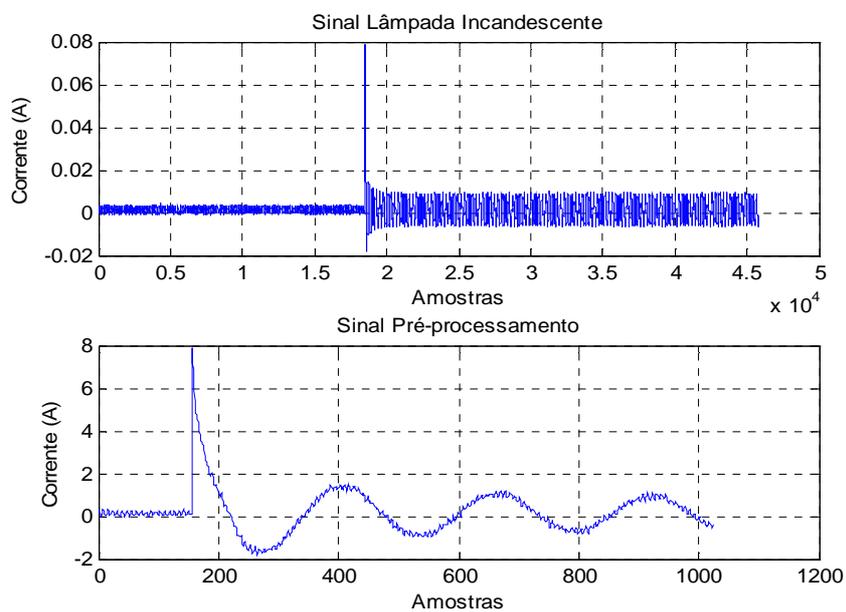


Figura 7 Sinal coletado da Lâmpada 100 W Incandescente

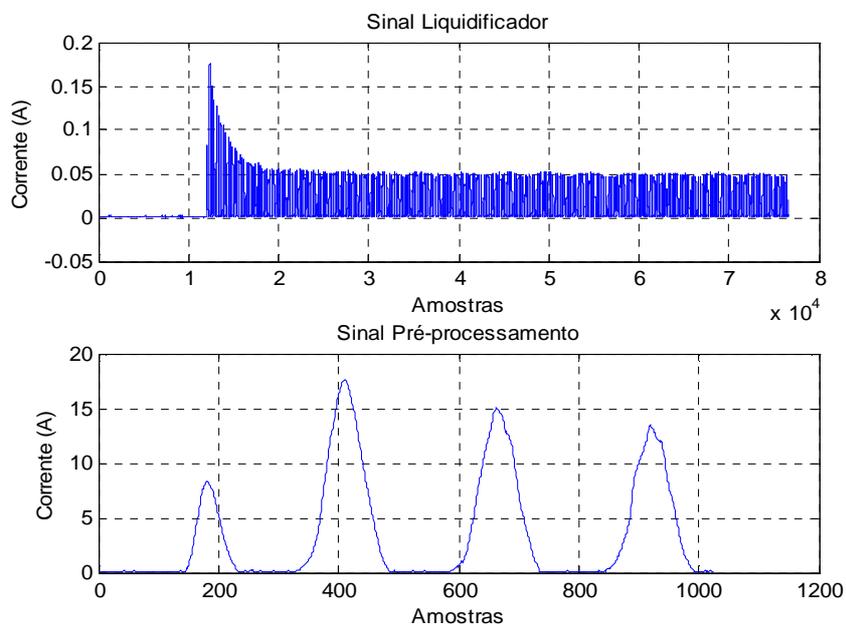


Figura 8 Sinal coletado do Liquidificador

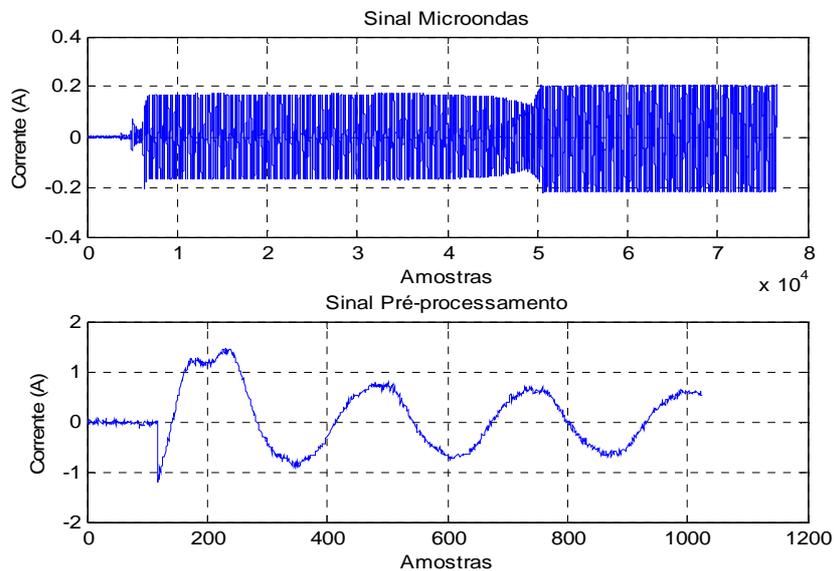


Figura 9 Sinal coletado do Micro-ondas

No acionamento do micro-ondas, depois de ocorrer uma estabilização da corrente, ocorre um novo acionamento. Esse acionamento é decorrente do acionamento da ventuinha do equipamento.

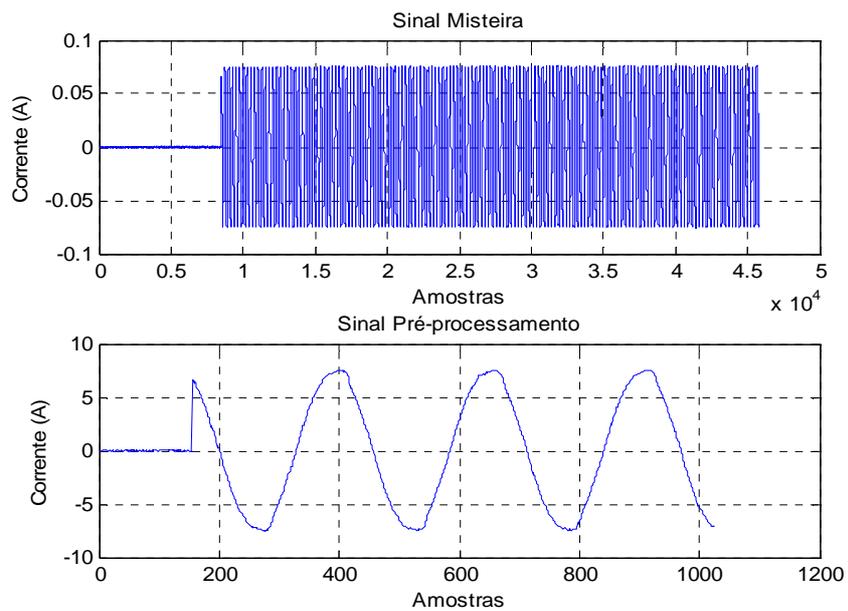


Figura 10 Sinal coletado da Misteira

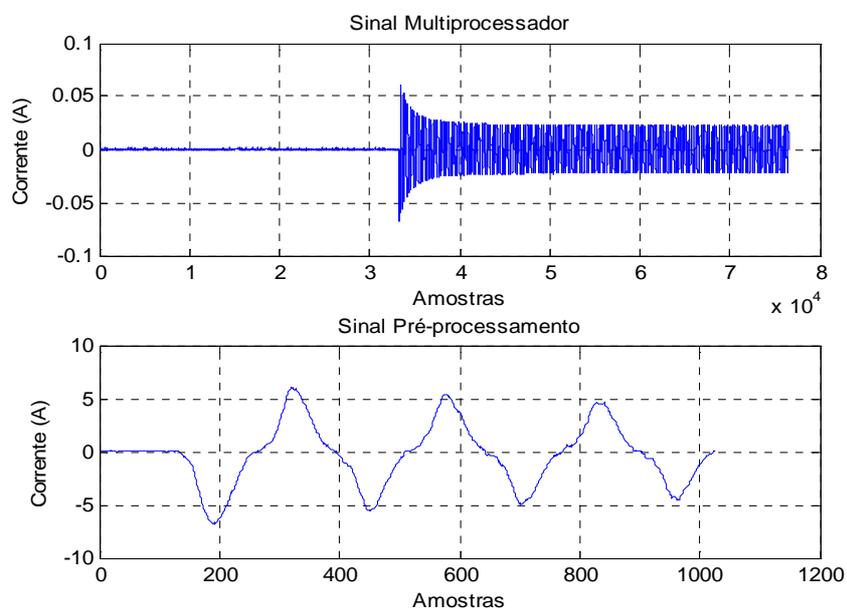


Figura 11 Sinal coletado do Multiprocessador

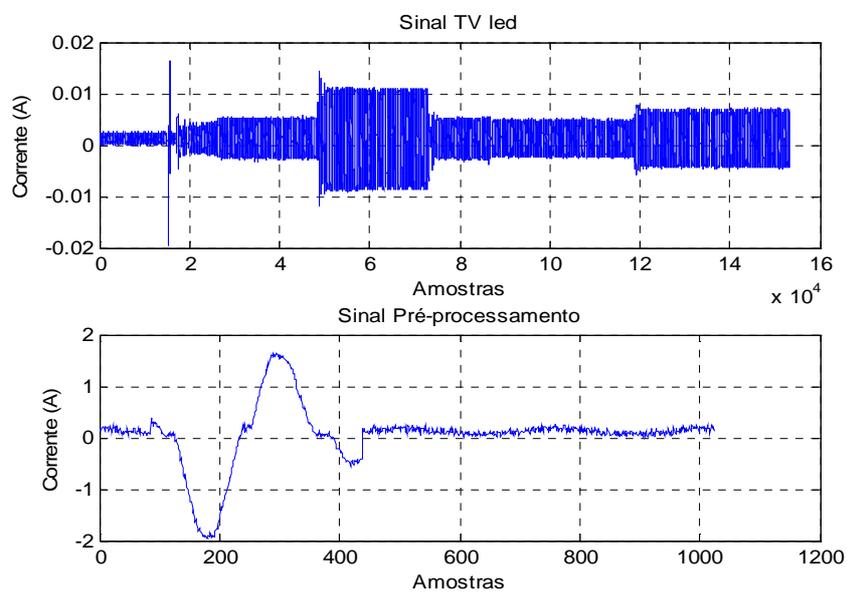


Figura 12 Sinal coletado da TV LED 46"

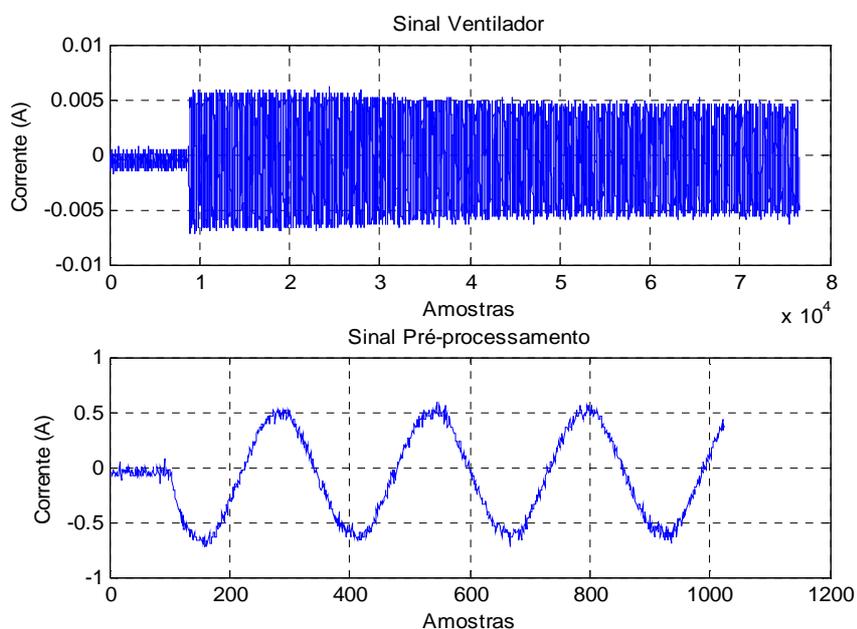


Figura 13 Sinal coletado do Ventilador

Após o pré-processamento dos dados (detecção do transitório de partida), a técnica de extração de parâmetros por estatísticas de ordem superior foi aplicada. Conforme mostrado em Ferreira et al. (2011), os cumulantes de terceira ordem pouco contribuem para a classificação de eventos provenientes de sinais elétricos e, portanto, apenas os cumulantes de segunda e quarta ordens foram utilizados.

A fim de selecionar apenas os melhores parâmetros extraídos pela EOS, duas técnicas foram empregadas:

- a) A técnica do discriminante linear de Fisher (FDR) (DUDA; HART; STORK, 2000). A motivação para o uso do FDR se deve a sua

simplicidade de implementação e a obtenção de resultados satisfatórios.

- b) A técnica de Algoritmos Genéticos (AG): Os Algoritmos Genéticos são um dos alicerces da Computação Evolutiva e podem ser definidos como modelos computacionais, inspirados na teoria da evolução de Darwin, nos mecanismos de seleção natural e na genética (ZUBEN, 2004). A motivação para o uso de AG foi pelo fato de permitirem se trabalhar com funções objetivas, de forma a se reduzir o número de parâmetros de entrada do classificador e maximizar o desempenho do mesmo.

Na etapa de classificação dois classificadores foram empregados:

- a) As Redes Neurais Artificiais devido à sua boa capacidade de aprendizagem para fins de classificação de padrões não lineares e generalização (HAYKIN, 2008).
- b) Árvores de decisão. Como o problema abordado envolve um número considerável de classes, optou-se pelo emprego de árvores de decisão que, favoravelmente a este cenário emprega a metodologia de “dividir pra conquistar”, apresentando resultados satisfatórios (DUDA; HART; STORK, 2000).

Do total de 50 sinais, 35 foram utilizados na fase de projeto (treino e teste) e 15 foram utilizados na fase de validação.

2.1 Técnicas utilizadas

2.1.1 Estatísticas de ordem superior (EOS)

Conforme Mendel (1991), as estatísticas de ordem superior (EOS) podem levar a resultados mais representativos quando empregadas em processos não Gaussianos e sistemas não lineares do que as estatísticas de segunda ordem. Sabe-se que um sinal gaussiano é completamente caracterizado pela sua média e variância. Conseqüentemente, as EOS de um sinal gaussiano são nulas ou possuem informações redundantes. Logo as EOS são menos afetadas por ruídos gaussianos do que as estatísticas de segunda ordem.

Dado que muitas aplicações práticas possuem ruído aditivo gaussiano, as EOS têm sido utilizadas com bastante frequência, conforme mostrado em Mendel (1991). No que tange ao monitoramento de sinais elétricos, as EOS têm sido utilizadas como parâmetros que alimentam sistemas de detecção e classificação de distúrbios elétricos com muito sucesso (FERREIRA et al., 2009; FERREIRA et al., 2011; RIBEIRO et al., 2007).

Conforme apontado em Mendel (1991), as EOS podem ser definidas em termos de momentos e cumulantes. Momentos são mais indicados para sinais determinísticos, enquanto que cumulantes são mais aplicados em sinais aleatórios. Como os distúrbios elétricos apresentam em sua maioria características não lineares, o uso de métodos baseados em cumulantes pode ser muito promissor na classificação e detecção de distúrbios. De fato, vetores extraídos do sinal de tensão com técnicas baseadas em EOS são capazes de fornecer, para cada classe de eventos de tensão, informações muito bem definidas, conforme resultados apresentados em Ferreira et al. (2011). As

expressões dos cumulantes de segunda, terceira e quarta ordem de um sinal aleatório $\mathbf{x}[n]$, quando $\mathbf{E}\{\mathbf{x}[n]\} = \mathbf{0}$, são respectivamente (MENDEL, 1991):

$$\mathbf{C}_{2,x}[l] = \mathbf{E}\{\mathbf{x}[n]\mathbf{x}[n+l]\}, \quad (2)$$

$$\mathbf{C}_{3,x}[l] = \mathbf{E}\{\mathbf{x}[n]\mathbf{x}^2[n+l]\}, \quad (3)$$

$$\mathbf{C}_{4,x}[l] = \mathbf{E}\{\mathbf{x}[n]\mathbf{x}^3[n+l]\} - 3\mathbf{C}_{2,x}[l]\mathbf{C}_{2,x}[0], \quad (4)$$

em que l é o l -ésimo atraso, e $\mathbf{x}[n]$ é o N -ésimo elemento do vetor \mathbf{x} .

Para um vetor com comprimento finito (N), as aproximações estocásticas oferecem as seguintes expressões:

$$\hat{\mathbf{C}}_{2,x}[l] := \frac{2}{N} \sum_{n=0}^{N-l} \mathbf{x}[n]\mathbf{x}[n+l], \quad (5)$$

$$\hat{\mathbf{C}}_{3,x}[l] := \frac{2}{N} \sum_{n=0}^{N-l} \mathbf{x}[n]\mathbf{x}^2[n+l], \quad (6)$$

$$\hat{\mathbf{C}}_{4,x}[l] := \frac{2}{N} \sum_{n=0}^{N-l} \mathbf{x}[n]\mathbf{x}^3[n+l] - \frac{2}{N^2} \sum_{n=0}^{N-l} \mathbf{x}[n]\mathbf{x}[n+l] \sum_{n=0}^{N-l} \mathbf{x}^2[n], \quad (7)$$

em que $l = 0, 1, \dots, N/2 - 1$.

Observa-se as Equações (5)-(7) não podem ser usadas se $l > N/2 + 1$, pois $n+l$ será maior que N . Desta forma, perdem-se informações no cálculo dos cumulantes. Em Ribeiro et al. (2007), é proposta uma abordagem alternativa, em que cada cumulante é calculado utilizando todas as N amostras de sinal disponível. Basicamente forma-se um tipo de *Buffer*

circular nos sinais de tal forma que se o valor de $n + i$ for maior que N em k unidades, esse valor é substituído por k , tomando com isso as amostras antecessoras ao valor i , que anteriormente não eram utilizadas. Na verdade é como se houvesse uma continuidade da última amostra para a primeira, fazendo com que o sinal seja virtualmente circular.

Matematicamente, a substituição de $n + 1$, quando $n + 1 > N$, pode ser dada por:

$$\text{mod}(n + i, N) = [n + i] - bN, \quad (8)$$

em que b é o número inteiro obtido quando se desconsideram as casas decimais da divisão de $n + i$ por N , o que na verdade resulta no resto da divisão de $n + i$ por N .

Assim, as expressões (5)-(7) podem ser estimadas, para N finito, por:

$$\hat{C}_{2,x}[i] := \frac{2}{N} \sum_{n=0}^N x[n]x[\text{mod}[n + i, N]], \quad (9)$$

$$\hat{C}_{3,x}[i] := \frac{2}{N} \sum_{n=0}^N x[n]x^2[\text{mod}[n + i, N]], \quad (10)$$

$$\hat{C}_{4,x}[i] := \frac{2}{N} \sum_{n=0}^N x[n]x^3[\text{mod}[n + i, N]] - \frac{2}{N^2} \sum_{n=0}^N x[n]x[\text{mod}[n + i, N]] \sum_{n=0}^N x^2[n],$$

(11)

em que $\text{mod}[n + i, N]$ é o resto inteiro da divisão de $n + i$ por N .

As aproximações apresentadas em (9)-(11) levam a uma boa simplificação para problemas onde é empregado um vetor de comprimento finito. Essas aproximações são mais indicadas quando o sinal é periódico. Portanto, considerando-se a natureza periódica dos sinais de tensão e corrente em sistemas elétricos de potência, essa é uma boa aproximação das EOS.

Pode-se observar que para um sinal com N amostras, tem-se N cumulantes para cada ordem de EOS. Para efeitos de classificação e detecção, a combinação de poucos desses cumulantes é suficiente para a obtenção de um bom desempenho, conforme mostrado em Ferreira et al. (2011) e Ribeiro et al. (2007). É importante ressaltar que as análises apresentadas em Ferreira et al. (2011) mostram que o cumulante de terceira ordem pouco contribui para a caracterização de sinais elétricos. Assim, neste trabalho serão considerados apenas os cumulantes de segunda e quarta ordem.

2.2 Discriminante linear de Fisher

O discriminante linear de Fisher (FDR - *Fisher Discriminat Ratio*) é uma técnica bastante simples para discriminação de dados multi-dimensionais. Conforme bem discutido em Duda, Hart e Stork (2000), o FDR tem duas principais e diferentes aplicações: pode ser usado como separador de classes e como ferramenta de seleção de parâmetros.

2.2.1 FDR como classificador

Para entender ambas as aplicações do FDR, suponha um espaço de n eventos d -dimensionais, $\mathbf{x}_1, \dots, \mathbf{x}_n$, em que n_1 pertence à classe 1 (**C1**) e n_2 à classe 2 (**C2**). Se a média das amostras d -dimensionais da classe i é:

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{x} \in C_i} \mathbf{x} \quad (12)$$

pode-se definir as matrizes *scatters* \mathbf{S}_b , \mathbf{S}_W e \mathbf{S}_B por:

$$\mathbf{s}_i = \sum_{\mathbf{x} \in C_i} (\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T \quad (13)$$

$$\mathbf{s}_W = \mathbf{s}_1 + \mathbf{s}_2 \quad (14)$$

e

$$\mathbf{s}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (15)$$

em que T significa transposto.

A matriz \mathbf{S}_W é conhecida por matriz *scatter* intra-classes e é proporcional à matriz de covariância dos dados. É também simétrica, semi-definida positiva e usualmente não singular se $n > d$. A matriz \mathbf{S}_B é também simétrica e semi-definida positiva. É chamada de matriz *scatter* entre classes.

Em termos de \mathbf{S}_W e \mathbf{S}_B , a função custo para o critério FDR como discriminante é escrita como:

$$\mathbf{J}(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{s}_B \mathbf{w}}{\mathbf{w}^T \mathbf{s}_W \mathbf{w}} \quad (16)$$

O vetor \mathbf{w} que maximiza $\mathbf{J}(\cdot)$ será:

$$\mathbf{w} = \mathbf{s}_W^{-1}(\mathbf{m}_1 - \mathbf{m}_2) \quad (17)$$

Assim, o vetor \mathbf{w} obtido representa a máxima razão entre a matriz *scatter* entre-classes e a intra-classes. Desta forma, o processo de classificação é convertido de um espaço D -dimensional para um espaço uni-dimensional. Nesse novo espaço pode-se obter um limiar que fará a separação entre os dados projetados em \mathbf{w} das classes 1 e 2.

2.2.2 FDR para seleção de parâmetros

Diferentemente do critério FDR para classificação, a função custo do critério FDR como ferramenta de seleção de parâmetros é:

$$\mathbf{J}_c = (\mathbf{m}_1 - \mathbf{m}_2)^2 \odot \frac{1}{\mathbf{D}_1^2 - \mathbf{D}_2^2} \quad (18)$$

Onde $\mathbf{J}_c = [J_1 \cdots J_{L_l}]^T$, L_l é o número total de parâmetros, \mathbf{m}_1 e \mathbf{m}_2 , e \mathbf{D}_1^2 e \mathbf{D}_2^2 são, respectivamente, os vetores de média e variância dos dados da classe 1 e da classe 2. O símbolo \odot refere-se ao produto de Hadamard $\mathbf{r} \odot \mathbf{s} = [r_0 s_0 \dots r_{L_l-1} s_{L_l-1}]^T$.

Pode-se entender que os i -ésimos elementos do vetor de parâmetros, referentes aos maiores valores de \mathbf{J}_c , representam os parâmetros que apresentam melhor separabilidade entre classes. Essa técnica é bastante útil em processos de classificação mais complexos, uma vez que torna possível selecionar os melhores parâmetros (que mais discriminam as classes envolvidas) e, conseqüentemente, reduzir o número de parâmetros utilizado na classificação. Essa redução de parâmetros é atraente em sistemas que necessitam de menor complexidade computacional, tais como sistemas que operam em tempo real. Ademais, o uso de um número reduzido de parâmetros pode levar ao projeto de

classificadores mais simples e com melhor desempenho, já que os parâmetros responsáveis pela interseção entre classes são, teoricamente, descartados.

2.3 Redes neurais artificiais

As redes neurais artificiais (RNA) (HAYKIN, 2008) apresentam uma grande versatilidade na resolução de diversos tipos de problemas, como em sistemas de reconhecimento de padrões, compressão de voz e imagem, pilotos automáticos de aviões, sistemas de previsão de taxa de câmbio, desenvolvimento de produtos, controle de processos, análises de eletroencefalograma (EEG) e eletrocardiograma (ECG) e vários outros problemas de diferentes áreas.

Das diversas arquiteturas (estruturas) de redes, a mais utilizada em aplicações de reconhecimento de padrões é a rede alimentada diretamente com múltiplas camadas. Conforme definido em Haykin (2008), esta rede consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O sinal de entrada se propaga para frente através da rede, camada por camada. Tais redes são normalmente chamadas de perceptrons de múltiplas camadas (MLP – *Multilayer Perceptron*) (ROSENBLANTT, 1962). A Figura 14 ilustra um perceptron com quatro camadas, sendo duas camadas ocultas.

Os perceptrons de múltiplas camadas têm sido aplicados com bastante sucesso para resolver diversos problemas complexos, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro (*error back-propagation*) (HAYKIN, 2008).

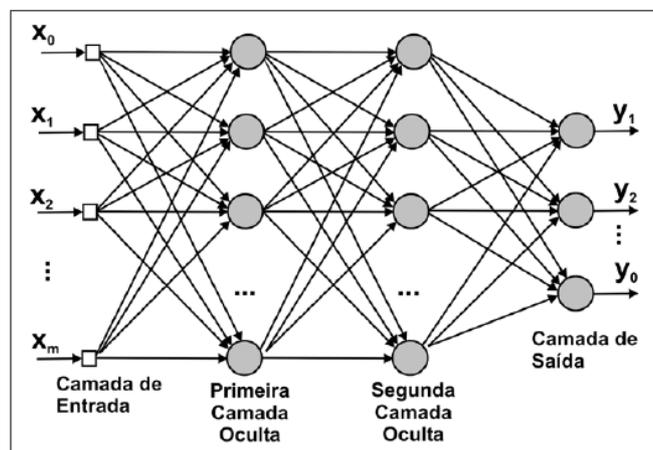


Figura 14 Perceptron de múltiplas camadas

As RNA extraem informações relevantes de padrões de informações que lhes forem apresentadas, criando assim uma representação própria. Essa etapa é conhecida por aprendizagem ou treinamento, e consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos de conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando.

Nesta etapa, destaca-se o algoritmo *Resilient Propagation* (Rprop) (RIEDMILLER; BRAUN, 1993), que tem capacidade de acelerar o processo de aprendizagem. A principal característica desse algoritmo é que os ajustes dos pesos (ω) e da taxa de aprendizado (η) dependem apenas dos sinais dos gradientes da função erro $E(\omega)$, não dependendo, portanto, da sua amplitude. A função $E(\omega)$ é responsável pela especificação de um critério de desempenho que está associado à rede (HAYKIN, 2008).

No algoritmo Rprop, os pesos e a taxa de aprendizagem são alterados apenas uma única vez a cada época de treinamento. Cada peso ω_{ij} possui sua

própria taxa de variação Δ_{ij} , a qual varia conforme a Equação (19) (RIEDMILLER; BRAUN, 1993).

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \text{se } \frac{\delta E^{(t-1)}}{\delta \Delta w_{ij}} \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \text{se } \frac{\delta E^{(t-1)}}{\delta \Delta w_{ij}} \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (19)$$

em que, $0 < \eta^- < 1 < \eta^+$. Assim, cada vez que a derivada parcial do peso correspondente ω_{ij} alterar o sinal significa que a última atualização foi muito excessiva e o algoritmo pulou o mínimo local. Como consequência, o valor de Δ_{ij} é reduzido pelo fator η^- . Se o sinal da derivada se mantém, o valor de Δ_{ij} é levemente aumentado para acelerar o processo de convergência. Os pesos da rede são então alterados conforme mostra a Equação (20).

$$\omega_{ij}^{(t+1)} = \omega_{ij}^{(t)} + \omega_{ij}^{(t)} \quad (20)$$

em que $\omega_{ij}^{(t)}$ é definido conforme equação (21)

$$\omega_{ij}^{(t)} = \begin{cases} -\omega_{ij}^{(t)}, & \text{se } \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} > 0 \\ +\omega_{ij}^{(t)}, & \text{se } \frac{\delta E^{(t)}}{\delta \Delta w_{ij}} < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (21)$$

2.4 Algoritmos genéticos

Os Algoritmos Genéticos (AG) são um dos alicerces da Computação Evolutiva e podem ser definidos como modelos computacionais inspirados na teoria da evolução de Darwin, nos mecanismos de seleção natural e na genética. Os Algoritmos Genéticos foram propostos por John Holland em 1975, e desde então têm sido aplicados em diversos domínios científicos.

Nos Algoritmos Genéticos, uma população inicial que representa um conjunto de possíveis soluções para o problema em questão evolui de acordo com os operadores genéticos de forma que melhores indivíduos sejam encontrados. O processo de evolução executado pelo algoritmo genético corresponde a um procedimento de busca em um espaço de potenciais soluções para o problema.

A codificação de cada indivíduo da população é representada por uma estrutura de dados que implementa um cromossomo, o qual contém a codificação (genótipo) de uma possível solução para o problema (fenótipo). Cada atributo do cromossomo é chamado de gene e os possíveis valores que esse gene pode assumir são denominados alelos (ZUBEN, 2004)

Segundo Zuben (2004), um algoritmo genético deve ter basicamente os seguintes componentes:

- a) Uma representação genética para possíveis soluções do problema.
- b) Possibilidade de criação da população inicial com as soluções candidatas.
- c) Uma função de avaliação que classifique as soluções em termos de sua adaptação ao ambiente.
- d) Operadores genéticos (cruzamento, mutação etc).

- e) Valores para os diversos parâmetros utilizados pelo algoritmo.

Os Algoritmos Genéticos, juntamente com Estratégias Evolucionárias (EE) e Programação Evolutiva (PE), formam uma classe de algoritmos de pesquisa baseados em evolução natural. Montando-se a árvore taxonômica dos algoritmos de pesquisa, os AG encontram-se no ramo chamado de Algoritmos Evolucionários.

Segundo Ribeiro, Treleaven e Alipi (1994), resumidamente, as técnicas de pesquisa são classificadas em:

- a) **Técnicas Baseadas em Cálculo** - usam um conjunto de condições necessárias e suficientes que devem ser satisfeitas pelas soluções de um problema de otimização.
 - i. **Métodos Diretos** - utilizam informações da função como derivadas de primeira e/ou de segunda ordem.
 - ii. **Métodos Indiretos** - procuram por um extremo local resolvendo um conjunto, normalmente não linear, de equações que resultam quando se coloca o gradiente da função objetivo igual a zero.
- b) **Técnicas Enumerativas** - procuram a solução pesquisando sequencialmente cada ponto do espaço de busca (finito e discreto). Uma dessas técnicas é conhecida como Programação Dinâmica.
- c) **Técnicas dirigidas por pesquisa aleatória** - baseadas em técnicas enumerativas, mas usam informações adicionais para dirigir a pesquisa.

- i. ***Simulated Annealing*** – técnica baseada no processo de evolução termodinâmica para dirigir a pesquisa para o estado de mínima energia.
- ii. **Algoritmos Evolucionários** - baseados nos princípios de seleção natural
 - Estratégias Evolucionárias
 - Algoritmos Genéticos
 - Programação Evolutiva

Algoritmos genéticos e estratégias evolucionárias são métodos que simulam, através de algoritmos, os processos da evolução natural (biológica) visando, principalmente, resolver problemas de otimização.

Esses algoritmos podem ser vistos como uma representação matemática algorítmica das teorias de Darwin e da genética, chamada de a nova sintaxe da teoria da evolução, cujos principais postulados podem ser resumidos:

- a) A evolução é um processo que opera sobre os cromossomos do organismo e não sobre o organismo que os carrega. Desta maneira, o que ocorrer com o organismo durante sua vida não irá se refletir sobre seus cromossomos. Entretanto, o inverso não é verdadeiro: os cromossomos do organismo são o projeto e terão reflexo direto sobre todas as características desse organismo (o indivíduo é a decodificação de seus cromossomos).
- b) A seleção natural é o elo entre os cromossomos e o desempenho que suas estruturas decodificam (o próprio organismo). O processo de seleção natural faz com que aqueles cromossomos que decodificaram organismos mais bem adaptados ao seu meio

ambiente, sobrevivam e reproduzam mais do que aqueles que decodificam organismos menos adaptados.

- c) O processo de reprodução é o ponto através do qual a evolução se caracteriza. Mutações podem causar diferenças entre os cromossomos dos pais e o de seus filhos. Além disso, processos de recombinação (“*crossover*”) podem fazer com que os cromossomos dos filhos sejam bastante diferentes dos de seus pais, uma vez que eles combinam materiais cromossômicos de dois genitores.

Estes postulados do processo de evolução biológica intrigaram John Holland, no início da década de 1970. Ele acreditava que, incorporando esses princípios em um programa de computador pudesse resolver, por simulação, problemas complexos, justamente como a natureza o fazia: produzindo cegamente organismos muitíssimo complexos para resolver o problema de sua sobrevivência. Ele iniciou o trabalho manipulando cadeias para representar os cromossomos, e cada organismo constituindo uma tentativa da solução do problema.

Seu algoritmo conseguia resolver problemas complexos de uma maneira muito simples. Como na natureza, o algoritmo não sabia o tipo do problema que estava sendo resolvido. Uma simples função de adequação fazia o papel da medida de adaptação dos organismos (cromossomos) ao meio ambiente. Assim, os cromossomos com uma adaptação melhor, medida por essa função, tinham maior oportunidade de reprodução do que aqueles com uma má adequação, imitando o processo evolucionário da natureza.

Em 1975, nos Estados Unidos, com o seu livro *Adaptation in Natural and Artificial Systems*, John Holland publicou o primeiro trabalho sobre AG. Esse livro foi uma compilação de ideias e trabalhos que ele já vinha desenvolvendo há alguns anos. Outra escola de pesquisadores desenvolveu, na

Alemanha, uma versão diferente, chamada de Estratégias Evolucionárias. Elas foram introduzidas inicialmente por Rechemberg, na década de 60 e mais tarde desenvolvidas por Schwefel (SOUCEK, 1992).

A partir da publicação do trabalho de Holland, a área de AG tem evoluído constantemente e atualmente usam-se algoritmos genéticos na solução de uma diversidade enorme de problemas de engenharia. Notam-se, também, esforços contínuos visando aprofundar os aspectos teóricos relativos a esses algoritmos.

Na resolução de problemas através da utilização de AG, dois aspectos devem ser considerados:

- a) Uma maneira de codificação da solução em 'cromossomos' - por exemplo, pode-se adotar uma representação binária da solução.
- b) Uma função de adequação – para indicar o valor de qualquer cromossomo, no contexto do problema, mostrando quanto esse valor dista da solução procurada.

Cada cromossomo representa uma tentativa de solução, no espaço de soluções possíveis do problema.

A técnica de codificar soluções pode variar de problema para problema e de algoritmo genético para algoritmo genético. No trabalho original de Holland, a codificação é feita usando cadeias de bits. Segundo Goldberg (1989), esta é a técnica que funciona melhor, pois a base binária apresenta maior número de esquemas por bit de informação. Entretanto, outras técnicas podem ser usadas como, por exemplo, a utilização direta de números reais.

A função de adequação é a maneira de se fazer a ligação entre o algoritmo genético e o problema a ser resolvido. Ela toma como entrada o cromossomo, que é uma tentativa de solução do problema e devolve um número

real, informando o desempenho desse cromossomo no problema; esse número representa o seu grau de adaptabilidade que informa quão longe ou perto esse cromossomo está da solução ótima do problema. Assim, a função de adequação faz no algoritmo genético o mesmo papel que o meio ambiente faria com os organismos vivos: fornece o grau de adaptação do organismo (cromossomo) ao ambiente e este valor será usado no processo de seleção para reprodução.

O algoritmo proposto por Holland é conhecido na literatura como *Simple Genetic Algorithm* ou *Standard Genetic Algorithm* ou simplesmente pela sigla SGA.

De acordo com Davis (1991) pode-se descrever o algoritmo, sucintamente, em seis passos:

Inicie uma população, de tamanho N , com cromossomos gerados aleatoriamente:

- a) Aplique a função de adequação em cada cromossomo dessa população.
- b) Crie novos cromossomos através de cruzamentos de cromossomos selecionados dessa população.
- c) Aplique recombinação e mutação nesses cromossomos.
- d) Elimine membros da antiga população, de modo a ter espaço para inserir esses novos cromossomos, mantendo a população com o mesmo número N de cromossomos.
- e) Aplique a função de adequação nesses cromossomos e insira-os na população.
- f) Se a solução ideal for encontrada ou se o tempo (ou número de gerações) se esgotou, retorne o cromossomo com a melhor adequação. Caso contrário volte ao passo (3).

Se tudo ocorrer bem, essa simulação do processo evolutivo irá produzir, à medida que as gerações forem se sucedendo, cromossomos cada vez mais bem adaptados, isto é, com melhor valor da função de adequação de maneira que no final obtém-se uma solução (cromossomo) com alto grau de adequação ao problema proposto.

Valores típicos para o tamanho da população estão entre 20 e 200.

2.5 Árvore de decisão

Árvore de Decisão (DT – *Decision Tree*) é um algoritmo de classificação supervisionada em que um dos resultados consiste em um conjunto de regras encadeadas do tipo “SE → ENTÃO”, que formam uma estrutura hierárquica semelhante à de uma árvore (DUDA; HART; STORK, 2000). Trabalha em cima de uma base de dados e determina a classe, com base nos atributos de entrada. Os componentes dessa estrutura basicamente são:

- a) Nós: regras que testam os valores (ou atributos).
- b) Folhas: a classificação em si.

A tarefa da DT é, portanto, mapear um conjunto de dados já rotulados, ou seja, descobrir o melhor conjunto de regras que leva àquela classificação, para, em seguida, aplicar as regras descobertas em valores desconhecidos e, assim, classificá-los.

Os dados utilizados na DT são rotulados, ou seja, cada uma das instâncias (padrões) lidas pelo algoritmo já tem uma classe pré-definida. Essas instâncias são compostas, além do rótulo, por um ou mais atributos os quais podem ser entendidos como parâmetros de entrada. Quanto maior o número de atributos

maior a possibilidade de uma árvore com mais nós e folhas, por gerar um maior número de combinações entre eles.

A execução da DT consiste em duas etapas:

- a) Treinamento: um conjunto de instâncias (compostos de um ou mais atributos) rotuladas é apresentado ao algoritmo e esse tem a tarefa de elaborar as melhores regras que mapeiem os atributos de entrada aos seus respectivos rótulos (atributos-classe).
- b) Teste: o conjunto de regras formado no treinamento é aplicado em instâncias não apresentadas na primeira etapa.

Durante as duas etapas é possível analisar a qualidade da classificação, que através do número de erros de classificação definirá se a árvore produziu ou não um bom conjunto de regras. Se sim, a árvore estará treinada para realizar outras classificações.

A DT tem como objetivo tentar minimizar erros de classificação e o número de nós e folhas (SANTOS, 2005). Possui a vantagem de exibir o conjunto de regras gerado no treinamento, o que facilita o seu entendimento, diferente de outros classificadores.

Para explicar o algoritmo de uma DT será utilizado como referência o algoritmo J48 (WITTEN; FRANK, 2005) encontrado, implementado no programa Weka (2008).

Uma DT pode ser desenvolvida para trabalhar com dados nominais ou numéricos. Em ambos os casos o seu algoritmo gera as regras baseando-se na análise de cada atributo, através dos seus valores e da sua relação com os demais parâmetros envolvidos. No caso de dados numéricos os valores utilizados são discretizados. No processo de análise utiliza-se de algumas definições que estão

relacionadas abaixo, seguidas das equações que as descrevem (QUINLAN, 1986; SANTOS, 2005; WITTEN; FRANK, 2005).

Para facilitar a descrição consideremos uma base de dados composta por n instâncias. Cada instância é composta por um conjunto de atributos e por um atributo-classe F , sendo que cada atributo A assume um valor v e o atributo-classe F assume um valor j .

- a) Probabilidade (p): A probabilidade da ocorrência de um valor para um atributo é calculada como o número de ocorrências do valor de um atributo, dividido pelo número de instâncias da base de dados. A probabilidade da ocorrência do valor v assumido por um atributo A pode ser dada por:

$$p(A = v) = \frac{n_v}{n}, \quad (22)$$

em que n_v é o número de ocorrências do valor v assumido pelo atributo A e n é o número de instâncias da base de dados.

- b) Entropia (H): a entropia de um atributo é um valor de aleatoriedade que quanto maior mais uniforme é a distribuição dos valores. Entropia zero indica concentração absoluta de um único valor para os atributos (Santos, 2005). A entropia de um atributo A , assim como a de um atributo-classe F , pode ser dada pela equação:

$$H(A) = -\sum_{v=1}^m p_v \log_2 p_v, \quad (23)$$

em que m , como dito anteriormente, é o número dos diferentes valores que são assumidos pelo atributo A e p_v é a probabilidade de A assumir o valor v .

- c) Probabilidade Condicional (pc): probabilidade de uma instância possuir o atributo-classe $F = j$ considerando que ele tem valor v para o atributo A :

$$pc(F = j|A = v) = \frac{n_{(F=j|A=v)}}{n_{F=j}}, \quad (24)$$

em que $n_{(F=j|A=v)}$ é o número de ocorrências de j como valor do atributo-classe F , quando o atributo A assume valor v ; e $n_{F=j}$ é o número de ocorrências do valor j para o atributo-classe F na base de dados.

- d) Entropia Condicional Específica (H_{CE}): Entropia do atributo A para as instâncias onde o atributo-classe F assume valor j :

$$H_{CE}(A|F = j) = -\sum_{v=1}^m pc_v \log_2 pc_v, \quad (25)$$

em que pc_v é a probabilidade de uma instância pertencer à classe j , sabendo-se que o seu atributo A tem valor v e m é a quantidade de valores distintos assumidos pelo atributo A .

- e) Entropia Condicional (H_C): Entropia condicional de um atributo A em relação ao atributo-classe F :

$$H_C(A|F) = \sum_i^K p(F = j_i) H_{CE}(A|F = j_i), \quad (26)$$

em que f_i é um valor possível que pode assumir o atributo-classe F e k é a quantidade de valores diferentes assumidos por F .

As equações descritas de (22) a (26) levam ao cálculo de um valor de entropia condicional para cada atributo existente na base de dados analisada. Esses valores permitem o cálculo do ganho de informação.

- f) Ganho de Informação (**IG**): valor que indica dependência ou correlação entre um atributo e a classe à qual a instância pertence, sendo que quanto maior o valor do **IG** maior a relação de dependência. O ganho de informação de um atributo A em relação à classe F pode ser dado por:

$$IG(A|F) = H(F) - H_c(A|F), \quad (27)$$

Se existe maior ganho de informação entre um atributo A e a classe F do que entre um atributo B e F , conclui-se que a classe F será atingida com menos perda de informação se partir de A do que se partir de B (SANTOS, 2005).

O algoritmo para a implementação de uma DT consiste, basicamente, em três passos (SANTOS, 2005):

- a) Testam-se todos os atributos. O que tiver maior ganho de informação será escolhido para a criação de um nó da árvore.
- b) Divide-se a árvore (criando nós e sub-árvores) partindo-se do atributo selecionado.
- c) Repetem-se recursivamente os passos anteriores até que não seja mais possível decidir por atributos.

A Figura 15 mostra o conjunto de regras gerado pelo algoritmo ID3 (QUINLAN, 1979, 1983) no exemplo “Saturday morning” (QUINLAN, 1986), que usa as instâncias relacionadas no Quadro 1. O problema trata a decisão de jogar ou não golfe, dada a situação climática da manhã de sábado (“Saturday morning”). Os atributos neste exemplo são: o tempo (ensolarado, nublado ou chuvoso), a temperatura (quente, ameno ou frio), a umidade (muito ou normal), e o vento (sim ou não); e o atributo-classe refere-se à decisão que será tomada (jogar ou não jogar golfe).

Além da árvore, dada por um conjunto de regras, o algoritmo J48 que será utilizado neste trabalho gera, como resultado, uma Matriz de Confusão que mostra o número de padrões classificados correta e incorretamente.

Quadro 1 Base de dados utilizada no exemplo “Saturday morning”

INSTÂNCIAS	ATRIBUTOS				CLASSE
	Tempo	Temperatura	Umidade	vento	
1.	ensolarado	quente	muito	não	não jogar
2.	ensolarado	quente	muito	sim	não jogar
3.	nublado	quente	muito	não	jogar
4.	chuvoso	ameno	muito	não	jogar
5.	chuvoso	frio	normal	não	jogar
6.	chuvoso	frio	normal	sim	não jogar
7.	nublado	frio	normal	sim	jogar
8.	ensolarado	ameno	muito	não	não jogar
9.	ensolarado	frio	normal	não	jogar
10.	chuvoso	ameno	normal	não	jogar
11.	ensolarado	ameno	normal	sim	jogar
12.	nublado	ameno	muito	sim	jogar
13.	nublado	quente	normal	não	jogar
14.	chuvoso	ameno	muito	sim	não jogar

Fonte: Adaptado de Quinlan (1986)

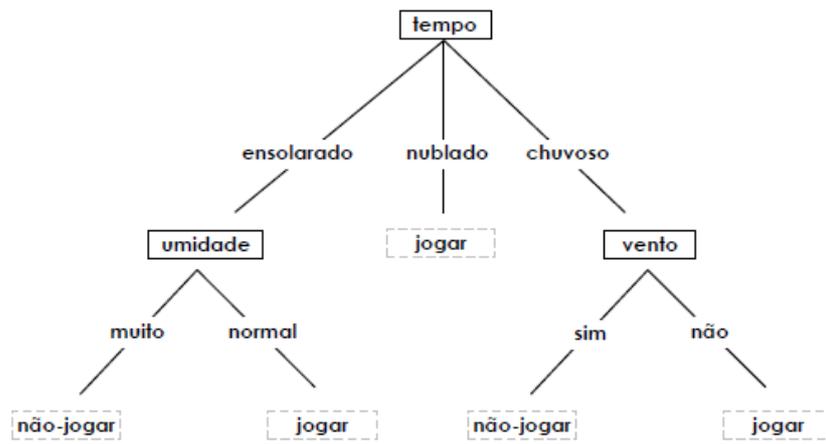


Figura 15 Árvore de decisão.

REFERÊNCIAS

- AGENCIA NACIONAL DE ENERGIA ELÉTRICA . Disponível em: <<http://www.aneel.gov.br/area.cfm?idArea=82>>. Acesso em: 22 jan. 2012.
- DAVIS, L. **Handbook of genetic algorithms**. New York: Van Nostrand Reinhold, 1991.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2nd ed. New York: Wiley-Interscience, 2000.
- FERREIRA, D. D. et al. **Exploiting higher-order statistics information for power quality monitoring**. Shanghai: Intech Open Access, 2011. p. 345-362. Disponível em: <http://cdn.intechopen.com/pdfs/14973/InTech-Exploiting_higher_order_statistics_information_for_power_quality_monitoring.pdf>. Acesso em: 23 jan. 2012.
- FERREIRA, D. D. et al. Sistema automático de detecção e classificação de distúrbios elétricos em qualidade de energia elétrica. **Sociedade Brasileira de Automática**, Campinas, v. 20, p. 53–62, 2009.
- FIGUEIREDO, M.; ALMEIDA, A.; RIBEIRO, B. Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems. **Neurocomputing**, Nijmegen, v. 96, p. 66-73, 2012.
- GOLDBERG, D. E. **Genetic algorithms in search, optimization, and machine learning**. Reading: A. Wesley, 1989.
- HAYKIN, S. **Neural networks and learning machines**. 3rd ed. New Jersey: Prentice Hall, 2008.
- JAIN, A.; DUIN, R.; MAO, J. Statistical pattern recognition: a review", **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, v. 22, n. 1, p. 4-37, Jan. 2000.
- MENDEL, J. M. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. **Proceedings of the IEEE**, New York, v. 79, n. 3, p. 278–305, 1991.
- NASCIMENTO, D. D. **Identificação não invasiva de cargas elétricas residenciais**. Rio de Janeiro: UFRJ/COPPE, 2012.

QUINLAN, J. R. Discovering rules by induction from large collections of examples. In: MICHIE, D. (Ed.). **Expert systems in the micro electronic age**. Edinburgh: Edinburgh University, 1979.

QUINLAN, J. R. Induction of decision trees. **Machine Learning**, Boston, v. 1, p. 81–106, Mar. 1986. Disponível em: <http://www.cs.utah.edu/~hal/courses/2008S_ML/quinlan86decision.pdf>. Acesso em: 20 jul. 2012.

QUINLAN, J. R. Learning efficient classification procedures and their application to chess end games. In: MICHALSKI, R. S.; CARBONELL, J. G.; MITCHELL, T. M. (Ed.). **Machine learning: an artificial intelligence approach**. Palo Alto: Tioga, 1983.

RIBEIRO, F. J. L.; TRELEAVEN, P. C.; ALIPI, C. Genetic algorithm programming environments. **IEEE Computer**, New York, v. 6, p. 28-43, 1994.

RIBEIRO, M. V. et al. Detection of disturbances in voltage signals for power quality analysis using HOS. **EURASIP Journal on Applied Signal Processing**, Heidelberg, Apr. 2007. Disponível em: <<http://asp.eurasipjournals.com/content/2007/1/059786/>>. Acesso em: 23 jan, 2013.

RICARDO, A. S.; SILVA, F. I. N. M.; OLESKOVICZ, M. Identificação de cargas lineares e não-lineares em sistemas elétricos residenciais usando técnicas para seleção de atributos e redes neurais artificiais. **Revista Controle & Automação**, Campinas, v. 21, n. 4, July/Aug. 2010. Disponível em: <http://www.scielo.br/scielo.php?pid=S0103-17592010000400006&script=sci_arttext>. Acesso em: 23 dez. 2012.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the rprop algorithm. **IEEE International Conference on Neural Networks**, Perth, p. 586–591, 1993. Disponível em: <<http://citeseerx.ist.psu.edu/showciting?cid=861272>>. Acesso em: 28 jan. 2012.

ROSENBLANTT, F. **Principles of neurodynamics**. New York: Spartan Books, 1962.

SANTOS, R. D. C. **Material da disciplina princípios e aplicações de mineração de dados**. São José dos Campos: INPE, 2005. Disponível em: <<http://www.lac.inpe.br/~rafael.Santos/Docs/CAP359/2005/dm07.pdf>>. Acesso em: 20 out. 2012.

SOUCEK, B. **Dynamic genetic and chaotic programming, the sixth generation**. New York: J. Wiley, 1992.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. San Diego: Academic, 1999.

TOLEDO, F. **Desvendando as redes elétricas inteligentes**. Rio de Janeiro: Brasport, 2012. 336 p.

TSAI, M. S.; LIN, Y. H. Modern development of an adaptive non-intrusive appliance load monitoring system in electricity energy conservation. **Applied Energy**, London, v. 96, p. 55-73, 2011.

WITTEN, I. H.; FRANK, E. **Data mining: practical machine learning tools and techniques**. 2nd ed. San Francisco: M. Kaufmann, 2005. 525 p.

ZUBEN, F. V. Computação evolutiva: uma visão pragmática, 2004. In: JORNADA DE ESTUDOS EM COMPUTAÇÃO DE PIRACICABA E REGIÃO, 1., 2000, Piracicaba. **Anais...** Piracicaba: JECOMP, 2000. v. 1, p. 25-45.

SEGUNDA PARTE - ARTIGOS

Normas do periódico: *Eletrônica de Potência* (SOBRAEP – Associação Brasileira de Eletrônica de Potência)

Artigo aceito

ARTIGO 1 Sistema automático de monitoramento não invasivo de cargas elétricas residenciais

Juan Diego Silva Guedes, Danton Diego Ferreira
Departamento de Engenharia, Universidade Federal de Lavras, Lavras, MG,
Brasil
e-mail: juandiegoguedes@yahoo.com.br, danton@deg.ufla.br

RESUMO

Este trabalho apresenta um novo método de monitoramento não invasivo de cargas elétricas residenciais. Basicamente, o método proposto extrai cumulantes de segunda a quarta ordem do sinal de corrente elétrica das cargas elétricas residenciais durante o acionamento e apresenta esses cumulantes a uma rede neural artificial previamente treinada. A saída da rede neural identifica a qual classe de carga elétrica residencial o sinal processado pertence. Neste estudo foram consideradas onze classes diferentes de cargas elétricas residenciais. Sinais elétricos experimentais foram utilizados e o desempenho global do método foi de aproximadamente 97 %.

Palavras-chaves: Monitoramento não invasivo. Cargas elétricas. *Smart grids*.

**NON-INVASIVE AUTOMATIC SYSTEM FOR RESIDENTIAL
ELECTRIC LOAD MONITORING**

ABSTRACT

This paper presents a new method for non-invasive residential electrical load monitoring. Basically, the proposed method extracts cumulants of second and fourth order from the electric current signal of the residential electrical loads and presents these cumulants to a previously trained artificial neural network for classification. The neural network output identifies the residential electric load class of the processed signal. This study considered eleven different classes of residential electrical loads. Results were carried out from experimental electric signals and the achieved overall performance was about 97%.

Keywords: Non-invasive monitoring. Electrical loads. Smart grids.

NOMENCLATURA

SMCNI	Sistema de monitoramento de cargas não invasivas.
EOS	Estatística de ordem superior.
FDR	<i>Fisher Discriminant Ratio</i> .
RNA	Redes neurais artificiais.

1 INTRODUÇÃO

Existe uma grande inquietação dos pesquisadores sobre o aumento do fornecimento de energia elétrica que cresce a cada dia. Atualmente entrou em vigor uma nova versão dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), sob a responsabilidade da Agência Nacional de Energia Elétrica (ANEEL) [1]. Nela são detalhados os eventos de qualidade da energia, tais como afundamentos ou elevações de tensão, variações de frequência, presença de harmônicos na rede, entre outros fatores.

O grande desafio está em identificar as principais fontes poluidoras do sistema elétrico de forma eficaz, gerando punições aos poluidores da rede. Apesar de não ser possível, ainda, identificar com precisão essas fontes poluidoras, sabe-se que o consumidor residencial tem parcela substancial nessa contribuição, devido à utilização de cargas não lineares presentes em diversos eletrodomésticos, o que contribui com a circulação de harmônicos pela rede e afeta diretamente a qualidade da energia elétrica [2].

Neste trabalho, um sistema de monitoramento não invasivo para redes de baixa tensão é apresentado. O sistema consiste na análise de dados relativos ao consumo do cliente de forma não invasiva, através de um medidor instalado na alimentação da residência ou comércio. Essa análise é realizada pelo emprego de técnicas avançadas de processamentos de sinais e inteligência computacional que, combinadas, compõem um sistema que permite identificar e classificar corretamente o equipamento que entrou em operação.

Os sistemas de medição de cargas não invasivos (SMCNI) podem constituir uma importante ferramenta nas *smart grids* ou rede inteligente. Especificamente, tais sistemas funcionam como sensores dos consumidores de baixa tensão, detectando informações sobre a característica do consumo e principais parâmetros tais como tensão, corrente e potência consumida.

Para a concessionária esses sistemas permitem a discriminação da fatura de energia elétrica dos clientes, possibilita a identificação de furtos de energia e contribui significativamente para programas de eficiência energética, pois indicam à concessionária zonas onde o fornecimento de energia pode ser realizado de maneira mais inteligente.

Adicionalmente, os SMCNI auxiliam a empresa na avaliação de equipamentos e/ou zonas críticas para a companhia, funcionando como uma ferramenta a mais na tomada de decisão. Consequentemente, o consumidor pode se beneficiar igualmente dessa tecnologia, pois ela permite um controle maior dos gastos da residência proveniente de uma fatura discriminada.

Atualmente diversos trabalhos têm como foco o SMCNI [2]-[10]-[11]-[12] demonstrando, assim, a inquietação dos pesquisadores sobre este tema.

O presente trabalho está organizado como segue. A próxima seção apresenta a metodologia empregada. Na Seção III, os resultados e discussões são apresentados e na Seção IV são mostradas as principais conclusões do trabalho. Direções para a continuidade do trabalho são discutidas na Seção V.

2 METODOLOGIA

A metodologia deste trabalho está dividida basicamente em duas partes: (a) Aquisição de sinais e (b) Processamento de sinais.

a) Aquisição de sinais

Neste trabalho foram utilizados os sinais de corrente de alimentação das cargas elétricas residenciais, já que esses caracterizam melhor o tipo de carga elétrica acionada do que os sinais de tensão.

Durante o acionamento de uma carga elétrica existem basicamente duas características importantes que são refletidas na corrente elétrica e que podem ser utilizadas para diferenciar os vários acionamentos: transitórios de partida, que ocorrem no momento do acionamento e os transitórios de regime, que ocorrem durante a operação nominal do equipamento. Neste trabalho as análises se restringiram apenas à análise de transitórios de partida. Em propostas futuras pretende-se analisar também os transitórios de regime.

As cargas elétricas de baixa tensão consideradas neste trabalho estão listadas na Tabela 1. Foram feitas 50 aquisições do sinal de corrente referente ao acionamento de cada uma dessas cargas. Esses sinais foram coletados experimentalmente em uma dada residência, utilizando a placa de aquisição *NI USB-6251* e uma ponteira de corrente a uma frequência de amostragem de 15.360 Hz e uma interface via *LABVIEW*[®].

Do total de 50 sinais, 35 foram utilizados na fase de projeto (treino e teste) e 15 foram utilizados na fase de validação.

Tabela 1 Cargas elétricas consideradas

ORDEM	EQUIPAMENTOS	EVENTOS
C1	CHUVEIRO	50
C2	FERRO ELÉTRICO	50
C3	LÂMPADA 20W COMPACTA	50
C4	LÂMPADA 20W FLUORESCENTE	50
C5	LÂMPADA 60W INCANDESCENTE	50
C6	LIQUIDIFICADOR	50
C7	FORNO MICRO-ONDAS	50
C8	MISTEIRA	50
C9	MULTIPROCESSADOR	50
C10	TV LED 46 POLEGADAS	50
C11	VENTILADOR	50

b) Processamento de sinais

O projeto do sistema proposto e fase operacional do mesmo são ilustrados pelo diagrama em blocos da Figura 1 (a) e (b), respectivamente. A primeira etapa do projeto do sistema consiste em segmentar o sinal elétrico monitorado em N amostras a partir do instante inicial do acionamento da referida carga elétrica. A detecção do instante do acionamento da carga foi feita utilizando-se um detector de energia a partir da definição experimental de um patamar.

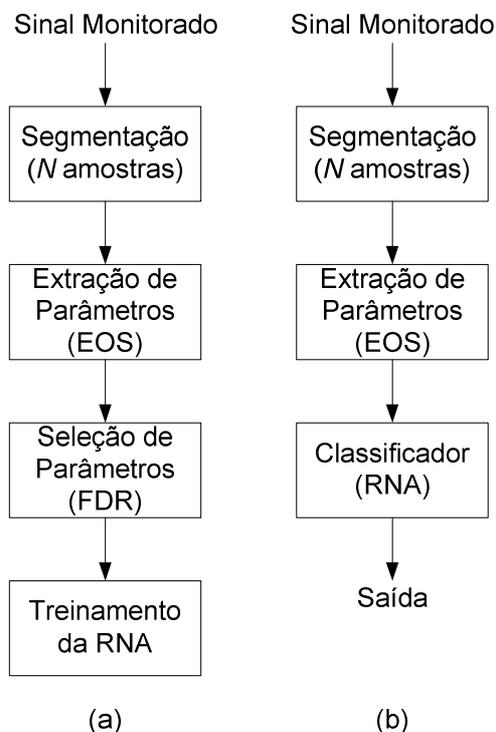


Figura 1 Sistema proposto: (a) fase de projeto; (b) fase operacional.

A Figura 2 ilustra a forma de onda da corrente elétrica referente ao acionamento de algumas cargas após a segmentação. Neste trabalho foram consideradas $N = 1.024$ amostras, o que é equivalente a quatro ciclos do componente fundamental do sinal.

Em relação às assinaturas das cargas elétricas referentes aos seus acionamentos elétricos, dois pontos importantes merecem atenção:

- a) Cargas com a mesma característica elétrica, como por exemplo, as cargas resistivas [Figuras 2 (a) e (b)], possuem assinaturas similares com diferenças marcantes apenas de amplitude. Isso pode dificultar

o processo de classificação, já que é comum a utilização de tais cargas simultaneamente, o que impossibilitaria a utilização do valor da amplitude da corrente e/ou valor eficaz (RMS) como parâmetro.

- b) Algumas cargas possuem um transitório de partida mais longo (além de 4 ciclos do componente fundamental), como é o caso da TV LED [(Figura 2 (e)]. O uso de apenas quatro ciclos do componente fundamental para esse tipo de carga pode dificultar o processo de classificação, uma vez que informações que poderiam contribuir para a formação de uma assinatura mais característica da carga são descartadas. Por outro lado, considerar trechos longos do sinal processado pode tornar o sistema mais complexo e inviabilizar o seu uso em tempo real.

A segunda etapa consiste em extrair as estatísticas de ordem superior (EOS) dos sinais (cumulantes de segunda e quarta ordem) [3]. Foi mostrado, recentemente, em [4], que essas estatísticas são capazes de revelar informações importantes à classificação de sinais elétricos transitórios. Adicionalmente, as estatísticas de ordem superior são mais apropriadas para lidar com processos não-Gaussianos e sistemas não lineares, do que as de segunda ordem [3].

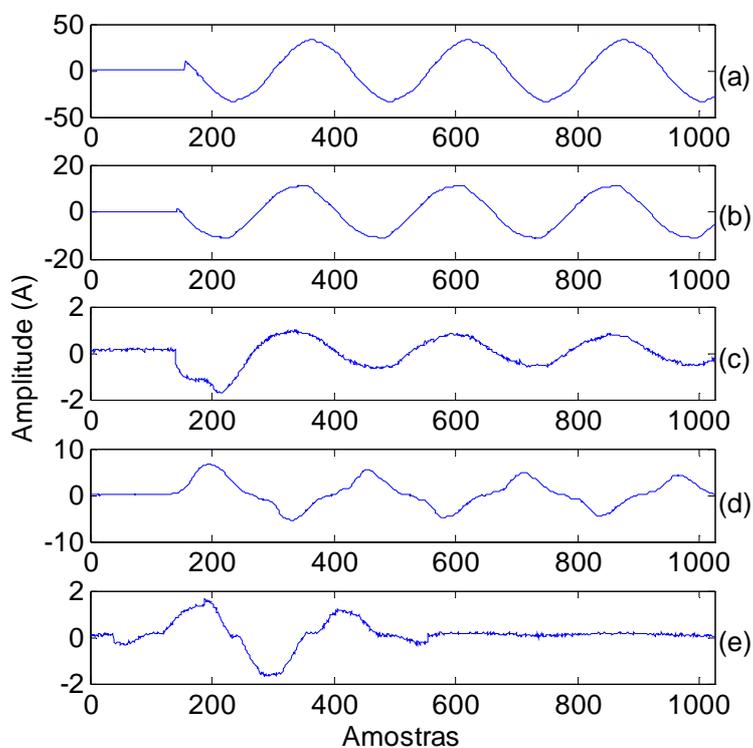


Figura 2 Correntes elétricas do acionamento dos equipamentos elétricos: (a) Chuveiro elétrico; (b) Ferro de passar; (c) Micro-ondas; (d) Multiprocessador e (e) TV LED.

Em outras palavras, os parâmetros EOS podem formar assinaturas dos eventos de acionamentos das cargas, proporcionando regiões de classificação muito bem definidas em um hiperespaço formado pelos parâmetros. As expressões dos cumulantes de segunda e quarta ordem de um sinal $x[n]$ com média zero e contendo N amostras do evento são definidas por (1) e (2), de acordo com [5].

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

$$\hat{C}_{4,x}[i] = \frac{2}{N} \sum_{n=0}^N x[n]x^3[n+i] - \frac{2}{N} \sum_{n=0}^N x[n]x[n+i] \sum_{n=0}^N x^2[n], \quad (2)$$

em que $i=0,1,2,\dots,N-1$ e a função $mod(a,b)$ é o resto inteiro da divisão de a por b .

A próxima etapa do projeto do sistema é responsável por fazer a seleção dos parâmetros (cumulantes) mais relevantes de cada classe, isto é, aqueles parâmetros que possuem a boa capacidade de discriminação entre as classes. Além de destacar os parâmetros mais discriminantes, essa etapa é implementada principalmente por proporcionar a redução da dimensão das características extraídas e, conseqüentemente, a complexidade computacional e o tempo de processamento. Para isso, a razão de discriminação de Fisher (FDR) [6] foi utilizada visando à seleção de um conjunto finito e representativo de características entre as obtidas por EOS, que forneça uma boa separação entre classes distintas. Decidiu-se utilizar o FDR pela sua simplicidade e obtenção de resultados satisfatórios. A função de custo vetor do FDR é dada pela Equação (3).

$$J_c = (m_1 - m_2)^2 \otimes \frac{1}{D_1^2 - D_2^2} \quad (3)$$

Em que $J_c = [J_1 \dots J_{L_l}]^T$, L_l é o número total de parâmetros, m_1 e m_2 , e \mathbf{D}_1^2 e \mathbf{D}_2^2 são, respectivamente, os vetores de média e variância dos vetores de

parâmetros das classes 1 e 2. O símbolo \odot refere-se ao produto de Hadamard $\odot s = [r_0 s_0 \dots r_{L-1} s_{L-1}]^T$. O i -ésimo elemento do vetor de parâmetros dado por (3) com o maior valor é selecionado para ser usado pelo classificador.

Aplicando esse procedimento para todos os elementos do vetor de parâmetros principal, os K parâmetros associados com os K maiores valores no vetor J_c são usados pelo classificador. A Figura 3 ilustra o vetor J_c referente às classes C6 (Liquidificador) e C1 (Chuveiro), em que os 1.024 índices são referentes aos cumulantes de segunda ordem das janelas de sinais com $N=1.024$ amostras. Os demais índices são referentes aos cumulantes de quarta ordem das mesmas amostras. Pode-se observar que para a classe C6 os cumulantes de segunda ordem são claramente os mais representativos, enquanto que para a classe C1, os cumulantes de quarta ordem são tão representativos quanto os de segunda ordem, com destaque para o de índice 1093.

Neste trabalho foram utilizados apenas dois parâmetros mais representativos de cada classe de cargas considerada (Tabela 1). Como são onze classes, o vetor final de parâmetros selecionados é composto por vinte e dois parâmetros (dois de cada classe), o que implica em uma redução de dimensão significativa de 1.024 para 22 dados.

O próximo bloco do sistema proposto [Figura 1 (a)] refere-se ao treinamento da rede neural artificial (RNA) para a classificação das cargas. Uma RNA é capaz de extrair informações relevantes de padrões de informações que lhe forem apresentadas, criando, assim, uma representação própria. Essa etapa é conhecida por aprendizagem ou treinamento e consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos de conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. O sinal de entrada se propaga para frente, através da rede, camada por camada. Tais redes são normalmente chamadas de perceptrons de múltiplas camadas (MLP - *Multilayer*

Perceptron) [7]. Os perceptrons de múltiplas camadas têm sido aplicados com bastante sucesso para resolver diversos problemas complexos, através do seu treinamento de forma supervisionada com um algoritmo muito popular, conhecido como algoritmo de retropropagação de erro (*error back-propagation*) [8].

Para o sistema de classificação aqui proposto utilizou-se uma rede MLP composta por três camadas (apenas uma camada oculta) [7], de modo a explorar as informações de EOS. Desta forma, o critério adotado para definição da classe do evento foi o do neurônio com maior valor de saída. Os pesos e bias foram inicializados de acordo com o algoritmo de Nguyen e Widrow [9]. A função de ativação utilizada foi a tangente hiperbólica e o algoritmo de treinamento foi o RPROP (*Resilient Back-propagation*) [7].

Cumprе ressaltar que o vetor de parâmetros foi normalizado pelo seu máximo absoluto antes de ser apresentado à RNA para treinamento.

A composição final da RNA foi de 22 neurônios de entrada, 11 neurônios na camada intermediária (camada oculta) e 11 nodos de saída, referente às 11 classes de cargas consideradas neste trabalho.

A fase operacional do método [Fig. 1 (b)] consiste, primeiramente, em segmentar o sinal monitorado em $N=1.024$ amostras. A partir dessas amostras os 22 parâmetros referentes às EOS são então obtidos utilizando-se (1) e (2). A última etapa consiste em normalizar o vetor de parâmetros EOS e apresentá-lo à RNA já treinada. É importante ressaltar que a etapa de seleção de parâmetros via FDR é realizada apenas na etapa de projeto.

3 RESULTADOS E DISCUSSÕES

Esta seção mostra os resultados do método proposto quando aplicado aos dados de validação. A matriz de confusão vista na Tabela 2 mostra o desempenho do método proposto para as 11 classes consideradas na Tabela 1 em percentual.

Tabela 2 Desempenho do método proposto em % (Topologia RNA 22x11x11)

	MATRIZ DE CONFUSÃO										
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
C1	100										
C2		73,3						26,7			
C3			100								
C4				86,6	6,7						6,7
C5					100						
C6						100					
C7							100				
C8		13,4						86,6			
C9									100		
C10										100	
C11											100
EG						95,1					

Com uma eficiência global (EG) (média dos desempenhos individuais) de aproximadamente 95% e desempenhos de 100% em oito das onze classes de cargas, o método mostrou-se bastante eficiente. O menor desempenho foi obtido pela classe C2 (Ferro elétrico) que confundiu 26,7% dos acionamentos com a classe C8 (Misteira). A classe C8, por outro lado, classificou 13,4% dos sinais como classe C1. Nota-se que o conjunto de parâmetros utilizado não levou a uma boa separação entre essas classes e a RNA, embora apresente boa capacidade de separar padrões não linearmente separáveis, não alcançou desempenho compatível com as demais classes neste caso.

Uma forma de aumentar o desempenho do método proposto é a utilização de mais do que dois parâmetros para cada classe. Com esse objetivo foram utilizados três parâmetros para as classes C2 e C8 e foram mantidos dois parâmetros para as demais classes, exceto para a classe C1 para a qual foi utilizado apenas um parâmetro.

Uma análise mais profunda nos parâmetros da classe C1 mostrou ser possível separá-la das demais classes linearmente utilizando-se qualquer um dos dois parâmetros selecionados para esta classe, conforme mostra a Figura 4.

A Figura 4 mostra o espaço de parâmetros gerado pelos dois parâmetros apontados pelo critério FDR como os que mais discriminam a classe C1 das demais. Esse espaço de parâmetros favoráveis motivou a utilização de apenas um parâmetro para representar a classe C1.

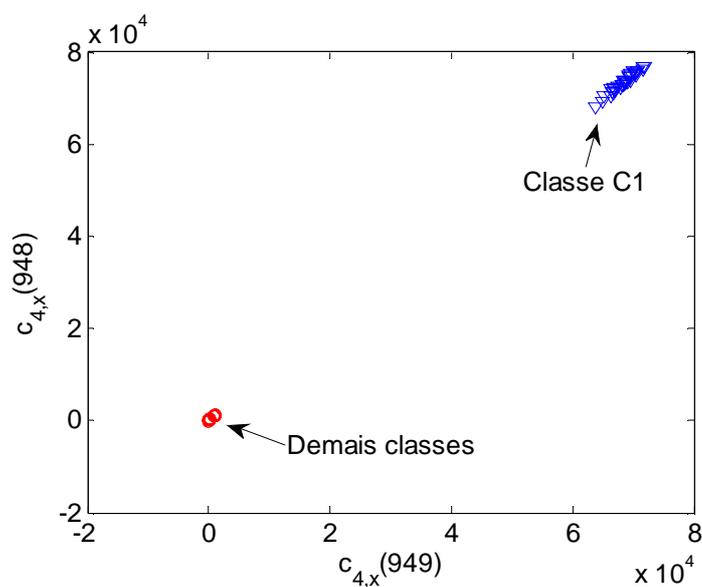


Figura 4 Espaço de parâmetros formado pelos cumulantes mais discriminantes da classe C1 (Chuveiro).

Em resumo, dois parâmetros foram adicionados (um para a classe C2 e um para a classe C8) e um parâmetro foi removido. Conseqüentemente, o novo vetor de parâmetros a ser apresentado à RNA passou a possuir 23 parâmetros. Assim, uma nova RNA foi treinada e a topologia final foi de 23 neurônios de entrada, 13 neurônios na camada oculta e 11 neurônios de saída. Os novos resultados alcançados são mostrados na Tabela 3. Observa-se que os desempenhos individuais das classes C2 e C8 foram elevados para 100% e eficiência global de 97,5%. Portanto, nota-se que é possível elevar o desempenho do método aumentando-se o número de parâmetros das classes com menor desempenho individual.

Tabela 3 Desempenho do Método Proposto em % (Topologia RNA 23x12x11)

	MATRIZ DE CONFUSÃO											
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	
C1	100											
C2		100										
C3			86,6		6,7						6,7	
C4				86,6	6,7						6,7	
C5					100							
C6						100						
C7							100					
C8								100				
C9									100			
C10										100		
C11											100	
EG												97,5

3.1 Comparação entre métodos

Nesta seção os resultados obtidos pelo método proposto são comparados com os obtidos pelo método em [12]. O trabalho apresentado em [12] foi escolhido para a comparação por apresentar bons resultados, com uma metodologia consistente que também utiliza redes neurais para a classificação.

Em [12] foram consideradas seis cargas elétricas residenciais (Lâmpada Incandescente, Lâmpada Fluorescente, Lâmpada Fluorescente Compacta, Ventilador, Computador Pessoal e Monitor) e uma rede neural foi treinada para cada carga. Cada rede neural possui seis entradas que correspondem às amplitudes das correntes fundamentais de harmônicas de 3^a, 5^a, 7^a, 8^a e 9^a ordens, as quais são fornecidas por equipamentos de qualidade de energia e foram previamente selecionadas por selecionadores de atributos. Essas entradas são propagadas por duas camadas escondidas, sendo a primeira com 26 neurônios e a segunda com 12 até a camada de saída composta por um único neurônio.

A Tabela 4 mostra os resultados de desempenhos do método proposto em comparação com os obtidos pelo método em [12]. Esses últimos foram extraídos do trabalho [12]. Observa-se que o método em [12] foi superior ao método proposto na classificação das classes C3 e C4 e obteve resultados próximos aos obtidos pelo método proposto para as demais classes abordadas em [12]. Entretanto, o método proposto é capaz de classificar 11 classes distintas de cargas enquanto que o método em [12] classifica seis.

Outro ponto importante a ser destacado é o fato de que o método proposto utiliza apenas uma rede neural com a configuração 23x12x11 e o método em [12] utiliza seis redes neurais com a configuração 6x26x12x1, o que mostra comparativamente a simplicidade do método proposto em termos de complexidade computacional.

Tabela 4 Desempenho dos métodos em %

CLASSES	MÉTODO EM [12]	MÉTODO PROPOSTO
C1	---	100
C2	---	100
C3	96,15	88,6
C4	96,15	88,6

“continua”

Tabela 4 “conclusão”

CLASSES	MÉTODO EM [12]	MÉTODO PROPOSTO
C5	99,77	100
C6	---	100
C7	---	100
C8	---	100
C9	100	100
C10	99,55	100
C11	99,77	100

4 CONCLUSÕES

Este trabalho apresentou um novo método para o monitoramento não invasivo de cargas elétricas residenciais. A inovação do método está na utilização de estatísticas de ordem superior para construir assinaturas das cargas elétricas em um reduzido espaço de parâmetros. A redução de dimensão alcançada para o melhor desempenho do método foi de 1.024 para 23.

As assinaturas construídas pelas estatísticas de ordem superior foram apresentadas a uma rede neural artificial que realizou a classificação das cargas com uma eficiência global de 97,5%. Isso mostra que embora as cargas tenham características de corrente similares entre si, como as cargas resistivas, por exemplo, o método conseguiu distingui-las com boa eficiência.

Adicionalmente, a redução de dimensão alcançada com os blocos extração e seleção de parâmetros são bastante favoráveis no que tange à complexidade do método, uma vez que com apenas 23 entradas foi possível alcançar uma boa eficiência, utilizando uma topologia de rede neural simples.

Em geral, os resultados aqui apresentados são promissores e podem ser bastante úteis em sistemas cujo objetivo é a identificação de cargas elétricas e como parte dos algoritmos de um medidor inteligente para *smart grid*.

5 PROPOSTAS DE CONTINUIDADE

Na prática, as cargas elétricas, sejam elas residenciais e/ou industriais, são acionadas simultaneamente ou com uma sequência não ordenada, na maioria das vezes. Esse tipo de acionamento não foi abordado neste trabalho e constitui-se em uma proposta fundamental na qual os autores pretendem investigar a partir deste trabalho.

Entende-se que a abordagem desse tipo de acionamento pode ocorrer de duas formas:

- a) Por meio de classificadores especialistas.
- b) Explorando o conceito “*dividir para conquistar*”.

A abordagem utilizando classificadores especialistas consiste em treinar um classificador especialista para cada classe de carga, considerando-se classes com acionamentos simultâneos e utilizar uma lógica de decisão que utiliza a saída de cada classificador e decide qual a classe de carga do sinal monitorado. Nesse tipo de abordagem é muito comum utilizar redes neurais artificiais [8] ou máquinas de vetor de suporte [8], que são ferramentas com alta capacidade de classificação.

A abordagem utilizando o conceito “*dividir para conquistar*” consiste em dividir o problema em problemas mais simples utilizando-se alguma ferramenta para depois se obter a informação desejada. Nesse tipo de abordagem é muito comum a utilização de árvores de decisão [6], que é um método linear, não paramétrico e com um custo computacional relativamente baixo. Por outro lado, é muito comum também utilizar ferramentas de decomposição de sinais e/ou filtragem de sinais para decompor o sinal monitorado em diferentes componentes, para que classificadores mais simples possam classificar as cargas

a partir desses componentes. Neste caso, espera-se que cada componente carregue informações relativas a uma carga elétrica. Para este fim, podem ser utilizadas ferramentas de processamento estatístico de sinais como Análise de Componentes Principais e Análise de Componentes Independentes [13], bem como ferramentas de filtragem de sinais, como filtros digitais [14] e transformada Wavelet [15].

Como propostas de continuidade deste trabalho, os autores pretendem abordar os acionamentos simultâneos conforme descrito anteriormente.

AGRADECIMENTOS

Os autores gostariam de agradecer à FAPEMIG, CAPES, CNPq e à UFLA pelos auxílios financeiros propiciados no decorrer das atividades de pesquisas.

REFERÊNCIAS

- [1] ANEEL - <http://www.aneel.gov.br/area.cfm?idArea=82> , acessado em 2012.
- [2] D. D. Nascimento, “Identificação não invasiva de cargas elétricas residenciais” – *Rio de Janeiro: UFRJ/COPPE*, 2012.
- [3] J. M. Mendel, “Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications,” *Proceedings of the IEEE* Vol. 79, no. 3, pp. 278–305, 1991.
- [4] D. D. Ferreira, C. A. G. Marques, A.S. Serqueira, J. M. Seixas, C.A. Duque, M.V. Ribeiro, “Exploiting Higher-Order Statistics Information for Power Quality Monitoring.” *Power Quality: Intech Open Access Publisher*, pp. 345-362, 2011.
- [5] M. V. Ribeiro, J. L. R. Pereira, “Classification of single and multiple disturbances in electric signals, EURASIP” *Journal on Advances in Signal Processing*, 18 pages, 2007.
- [6] R. O. Duda, P. E. Hart, D. G. Stork, “Pattern Classification,” *Wiley-Interscience*, 2000.
- [7] F. Rosenblatt, “Principles of neurodynamics.” New York: Spartan Books, 1962.
- [8] S. Haykin, “*Neural networks and Learning Machines*” 3 ed., Prentice Hall, 2008.
- [9] D. Nguyen, B. Widrow, “Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights, IJCNN”. *International Joint Conference on Neural Networks*, Vol. 3, pp. 21–26, 1990.
- [10] M-S. Tsai ,Y-H. Lin, “Modern development of an Adaptive Non-Intrusive Appliance Load Monitoring system in electricity energy conservation.” *ELSEVIER Journal* Vol. 96, pp. 55-73, 2011.
- [11] M. Figueiredo, A. Almeida, B. Ribeiro, “Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems.” *ELSEVIER Journal* Vol. 96, pp. 66-73. 2012.

- [12] A. S. Ricardo, F. I. N. Silva, M. Oleskovicz. “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, 2010.
- [13] A. Hyvärinen, J. Karhunen and E. Oja. *Independent Component Analysis*. A Wiley-Interscience Publication, 2001.
- [14] S.K. Mitra, *Digital Signal Processing: A Computer-Based Approach*, New York, NY: McGraw-Hill, 1998.
- [15] C. K. Chui, *An Introduction to Wavelets*. San Diego: Academic Press, 1992.

ARTIGO 2 Uma nova abordagem ao monitoramento não invasivo de cargas utilizando Estatísticas de Ordem Superior e Algoritmos genéticos

1 INTRODUÇÃO

O atual contexto mundial vem demandando dos países desenvolvidos e emergentes a busca por um sistema elétrico mais eficiente, confiável, flexível e otimizado, tanto em custos como em recursos, bem como que imponha uma participação menor do carvão mineral e petróleo na composição de suas matrizes energéticas [1]-[2]. Entretanto, esse é um setor que em qualquer parte do mundo tem se mantido praticamente inalterado por quase cem anos, mesmo ante os avanços extraordinários das telecomunicações, computação e eletrônica neste período. Por outro lado existe a necessidade do aumento do fornecimento de energia elétrica que cresce a cada dia.

Neste contexto, um processo de início recente promove a atualização do sistema elétrico com a incorporação dos avanços tecnológicos supramencionados. Esse processo encontra-se em curso tanto em países desenvolvidos (há mais tempo) como naqueles em desenvolvimento. Isto vem estabelecendo profundas mudanças no sistema elétrico existente e, na verdade, fazendo surgir um novo sistema, cuja denominação mundialmente atribuída é *Smart Grid* [3]-[4].

O Grupo Regulador Europeu de Eletricidade e Gás (ERGEG) define *Smart Grid* da seguinte forma: "*Smart Grid* é uma rede de energia elétrica que pode integrar eficientemente o comportamento e as ações de todos os usuários conectados a ela - geradores, consumidores e aqueles que fazem as duas coisas - a fim de garantir uma forma economicamente eficiente e um sistema de energia sustentável com baixas perdas e elevados níveis de qualidade e confiabilidade de abastecimento e segurança" [5].

Um fato importante, em se tratando de *Smarts Grids*, é que todo o sistema deverá interagir em tempo real, necessitando, assim, de medidores inteligentes que além de realizar medições de consumo, classifiquem os eventos

e informem o centro de gestão para que este seja capaz de tomar suas decisões, como despachar a energia durante situações normais e de emergência [6].

Com a evolução dos métodos computacionais e desenvolvimento de novas técnicas, buscam-se neste trabalho inovar em relação aos métodos de monitoramento não invasivo já existentes [7]-[8]-[9]-[10]-[11]. Uma ferramenta que vem ganhando bastante espaço neste contexto é a computação evolutiva e/ou evolucionária, que tem como base os algoritmos genéticos.

Os Algoritmos Genéticos (AG) são um dos alicerces da Computação Evolutiva e podem ser definidos como modelos computacionais inspirados na teoria da evolução de Darwin, nos mecanismos de seleção natural e na genética. Os Algoritmos Genéticos foram propostos por John Holland em 1975, que desde então têm sido aplicados em diversos domínios científicos.

Nos Algoritmos Genéticos, uma população inicial que representa um conjunto de possíveis soluções para o problema em questão evolui de acordo com os operadores genéticos, de forma que melhores indivíduos possam ser encontrados. O processo de evolução executado pelo algoritmo genético corresponde a um procedimento de busca em um espaço de potenciais soluções para o problema.

Neste trabalho, um sistema de monitoramento não invasivo de cargas (SMCNI) residenciais é proposto com o grande diferencial de utilizar, na extração de características relevantes do sinal, estatísticas de ordem superior (EOS), que combinadas com computação evolucionária multi-objetivo busca selecionar os melhores parâmetros extraídos pelas EOS para a classificação, bem como a busca pelo menor número destes, reduzindo, assim, a complexibilidade computacional na operação sem comprometer o desempenho classificador. De forma a se analisar diferentes classificadores, dois métodos conhecidos foram empregados: Árvores de decisão (*Decision Tree*)[15] e redes neurais artificiais (RNA)[17]. Os resultados foram apresentados de forma comparativa.

O monitoramento não invasivo de cargas SMCNI tem sido alvo de pesquisas no mundo todo [7]-[8]-[9]-[10]-[11] demonstrando, assim, a inquietação dos pesquisadores sobre este tema.

2 METODOLOGIA

A metodologia deste trabalho está dividida basicamente em duas partes: (a) aquisição de sinais e (b) processamento de sinais.

a) Aquisição de sinais

Os sinais utilizados foram de corrente de alimentação das cargas elétricas residenciais, já que esses caracterizam melhor o tipo de carga elétrica acionada do que os sinais de tensão.

Durante o acionamento de uma carga elétrica existem basicamente duas características importantes que são refletidas na corrente elétrica e que podem ser utilizadas para diferenciar os vários acionamentos: transitórios de partida, que ocorrem no momento do acionamento e os transitórios de regime, que ocorrem durante a operação nominal do equipamento. Neste trabalho as análises se restringiram a apenas análise de transitórios de partida. Em propostas futuras pretende-se analisar também os transitórios de regime.

As cargas elétricas de baixa tensão, consideradas neste trabalho, estão listadas na Tabela 1. Foram feitas cinquenta aquisições do sinal de corrente referente ao acionamento de cada uma dessas cargas. Esses sinais foram coletados experimentalmente em uma dada residência, utilizando a placa de aquisição NI USB-6251 e uma ponteira de corrente a uma frequência de amostragem de 15.360 Hz e uma interface via LABVIEW®.

Do total de cinquenta sinais, trinta e cinco foram utilizados na fase de projeto (treino e teste) e 15 foram utilizados na fase de validação.

Tabela 1 Cargas elétricas consideradas

ORDEM	EQUIPAMENTOS	EVENTOS
C1	CHUVEIRO	50
C2	FERRO ELÉTRICO	50
C3	LÂMPADA 20W COMPACTA	50
C4	LÂMPADA 20W FLUORESCENTE	50
C5	LÂMPADA 60W INCANDESCENTE	50
C6	LIQUIDIFICADOR	50
C7	FORNO MICRO-ONDAS	50
C8	MISTEIRA	50
C9	MULTIPROCESSADOR	50
C10	TV LED 46 POLEGADAS	50
C11	VENTILADOR	50

b) Processamento de sinais

O processamento dos dados deste projeto será dividido em dois métodos, que apesar de serem distintos possuem a etapa de extração e seleção em comum: Método (I) seleção de parâmetro por algoritmo genético e classificação por árvores de decisão (DT). Método (II) seleção de parâmetro por algoritmo genético e classificação por Redes Neurais Artificiais (RNA).

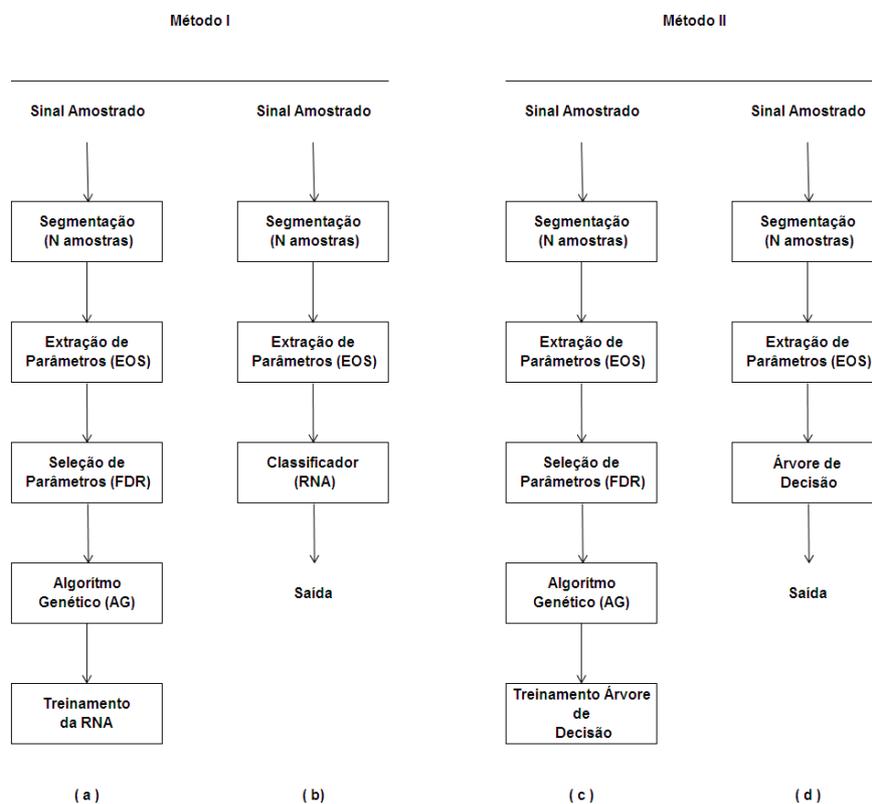


Figura 1 Sistemas propostos: Método I (a) fase de projeto, (b) fase operacional. Método II (c) fase de projeto, (d) fase operacional.

Como já mencionado anteriormente, a primeira etapa do projeto do sistema é comum aos dois métodos propostos e consiste em segmentar o sinal elétrico monitorado em N amostras, a partir do instante inicial do acionamento da referida carga elétrica. A detecção do instante do acionamento da carga foi feita utilizando-se um detector de inovação de energia a partir da definição experimental de um patamar. A Figura 2 ilustra a forma de onda da corrente elétrica referente ao acionamento de um multiprocessador e sua segmentação.

Neste trabalho foram consideradas $N = 1.024$ amostras, o que é equivalente a quatro ciclos do componente fundamental do sinal.

Em relação às assinaturas das cargas elétricas referentes aos seus acionamentos elétricos, um ponto importante merece atenção: algumas cargas possuem um transitório de partida mais longo. O uso de apenas quatro ciclos do componente fundamental para esse tipo de carga pode dificultar o processo de classificação, uma vez que informações que poderiam contribuir para a formação de uma assinatura mais característica da carga são descartadas. Por outro lado, considerar trechos longos do sinal processado pode tornar o sistema mais complexo e inviabilizar o seu uso em tempo real.

A segunda etapa do projeto consiste em extrair as estatísticas de ordem superior (EOS) dos sinais (cumulantes de segunda e quarta ordem) [12]. Foi mostrado recentemente em [13], que essas estatísticas são capazes de revelar informações importantes à classificação de sinais elétricos transitórios. Adicionalmente, as estatísticas de ordem superior são mais apropriadas para lidar com processos não-Gaussianos e sistemas não lineares, do que as de segunda ordem [12].

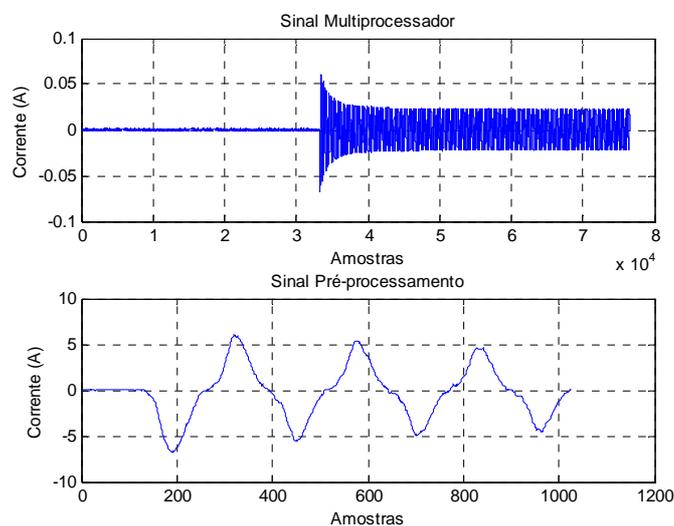


Figura 2 Correntes elétricas do acionamento de um multiprocessador e sua correspondente segmentada

Em outras palavras, os parâmetros EOS podem formar assinaturas dos eventos de acionamentos das cargas, proporcionando regiões de classificação muito bem definidas em um hiperespaço formado pelos parâmetros. As expressões dos cumulantes de segunda e quarta ordem de um sinal $x[n]$, com média zero e contendo N amostras do evento, são definidas por (1) e (2) de acordo com [14].

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

$$\hat{c}_{4,x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x^3(\text{mod}(n+i,N))$$

$$-3 \frac{1}{N^2} \sum_{n=0}^{N-1} x(n)x(\text{mod}(n+i, N)) \sum_{n=0}^{N-1} x^2(n) \quad (2)$$

em que $i=0,1,2,\dots, N-1$ e a função $\text{mod}(a,b)$ é o resto inteiro da divisão de a por b .

A próxima etapa do projeto do sistema é responsável por fazer a seleção dos parâmetros (cumulantes) mais relevantes de cada classe, isto é, aqueles parâmetros que possuem a boa capacidade de discriminação entre as classes. Além de destacar os parâmetros mais discriminantes, essa etapa é implementada principalmente por proporcionar a redução da dimensão das características extraídas e, conseqüentemente, a complexidade computacional e o tempo de processamento. Para isso, a razão de discriminação de Fisher (FDR) [15] foi utilizada visando à seleção de um conjunto finito e representativo de características entre as obtidas por HOS, que forneça uma boa separabilidade entre classes distintas. Decidiu-se utilizar o FDR pela sua simplicidade e obtenção de resultados satisfatórios. A função de custo vetor do FDR é dada pela Equação (3).

$$J_c = (m_1 - m_2)^2 \oslash \frac{1}{D_1^2 + D_2^2} \quad (3)$$

em que $J_c = [J_1 \dots J_{L_i}]^T$, L_i é o número total de parâmetros, m_1 e m_2 , e D_1^2 e D_2^2 são, respectivamente, os vetores de média e variância dos vetores de parâmetros das classes 1 e 2. O símbolo \oslash refere-se ao produto de Hadamard e $\oslash s = [r_0 s_0 \dots r_{L_i-1} s_{L_i-1}]^T$. O i -ésimo elemento do vetor de parâmetros, dado por (3) com o maior valor é selecionado para ser usado pelo classificador.

Aplicando este procedimento para todos os elementos do vetor de parâmetros principal, os K parâmetros associados com os K maiores valores no vetor J_c são usados pelo classificador. A Figura 3 ilustra o vetor J_c referente às classes C6 (Liquidificador) e C1 (Chuveiro), em que os 1.024 índices são referentes aos cumulantes de segunda ordem das janelas de sinais com $N=1.024$ amostras e os demais índices são referentes aos cumulantes de quarta ordem das mesmas amostras. Pode-se observar que para a classe C6 os cumulantes de segunda ordem são claramente os mais representativos, enquanto que para a classe C1 os cumulantes de quarta ordem são tão representativos quanto os de segunda ordem, com destaque para o de índice 1093.

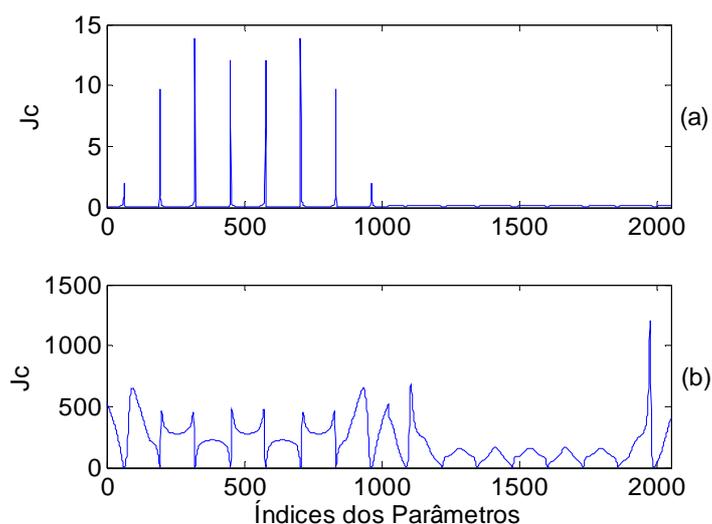


Figura 3 Razão de discriminação de Fisher (J_c) entre classes C6 e demais (a); e C1 e demais (b).

2.1 Método I

Foram selecionados apenas três parâmetros mais representativos de cada classe de cargas considerada (vide Tabela 1), de acordo com o critério FDR.

Como são onze classes, o vetor final de parâmetros selecionado é composto por sessenta e seis parâmetros (seis de cada classe), o que implica em uma redução de dimensão significativa de 1.024 para sessenta e seis dados.

O método FDR, apesar de sua simplicidade, independe do classificador a ser utilizado, ou seja, faz a seleção dos parâmetros mais relevantes baseando-se apenas na disposição dos dados em termos da média e desvio padrão dos dados de cada classe. Neste ponto, o uso de AG pode ser bastante promissor, já que o AG otimiza o desempenho do classificador de acordo com um conjunto de parâmetros reduzidos e selecionados para tal, ou seja, a seleção é feita em conjunto com o classificador, de forma a maximizar o seu desempenho. A Figura 4 ilustra o processo de otimização do AG, cuja função multi-objetivo é a de reduzir o número de parâmetros de entrada e maximizar o número de acertos do classificador. A população inicial do AG foi de 66 indivíduos (referentes aos 66 parâmetros selecionados via FDR) e 50 gerações.

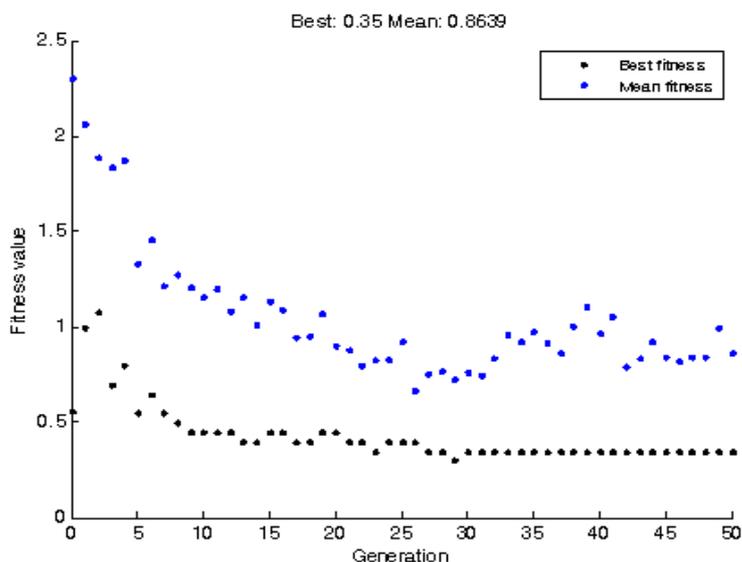


Figura 4 Algoritmo genético com RNA buscando o menor número de entradas e o maior acerto de classificação

O próximo bloco do sistema proposto [Figura 1 (b)] refere-se ao treinamento da rede neural artificial (RNA) para a classificação das cargas. Uma RNA é capaz de extrair informações relevantes de padrões de informações que lhe forem apresentadas, criando, assim, uma representação própria. Essa etapa é conhecida por aprendizagem ou treinamento e consiste em um processo iterativo de ajuste de parâmetros da rede, dos pesos de conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente que está operando. O sinal de entrada se propaga para a frente através da rede, camada por camada. Tais redes são, normalmente, chamadas de perceptrons de múltiplas camadas (MLP - Multilayer Perceptron) [16]. Os perceptrons de múltiplas camadas têm sido aplicados com bastante sucesso para resolver diversos problemas complexos, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro (error back-propagation) [17].

Para o sistema de classificação aqui proposto utilizou-se uma rede MLP, composta por três camadas (apenas uma camada oculta) [17], de modo a explorar as informações de EOS. Desta forma, o critério adotado para definição da classe do evento foi o do neurônio com maior valor de saída. Os pesos e bias foram inicializados de acordo com o algoritmo de Nguyen e Widrow [18]. A função de ativação utilizada foi a tangente hiperbólica e o algoritmo de treinamento foi o RPROP (Resilient Back-propagation) [17].

Cumprе ressaltar que o vetor de parâmetros foi normalizado pelo seu máximo absoluto antes de ser apresentado à RNA para treinamento.

A composição final da RNA, depois de realizada a seleção dos parâmetros via algoritmo genético (Figura 4), foi de seis neurônios de entrada, seis neurônios na camada intermediária (camada oculta) e onze nodos de saída, referente às onze classes de cargas consideradas neste trabalho. Desta forma, a combinação FDR, AG e RNA alcançou uma redução de dimensão de 1.024 para

seis, o que é bastante favorável para fins de implementação do método e aplicação em tempo real.

A fase operacional do método [Figura 1 (b)] consiste, primeiramente, em segmentar o sinal monitorado em $N=1.024$ amostras. A partir dessas amostras os seis parâmetros referentes às EOS, previamente selecionados pelo AG (vide Tabela 2), são então obtidos utilizando-se (1) e (2). A última etapa consiste em normalizar o vetor de parâmetros EOS e apresentá-lo à RNA já treinada. É importante ressaltar que a etapa de seleção de parâmetros via FDR e AG é realizada apenas na etapa de projeto.

Tabela 2 Parâmetros selecionados

PARÂMETROS SELECIONADOS	
RNA	DT
$\hat{c}_{2,x}(27)$	$\hat{c}_{2,x}(37)$
$\hat{c}_{2,x}(37)$	$\hat{c}_{2,x}(45)$
$\hat{c}_{2,x}(45)$	$\hat{c}_{2,x}(57)$
$\hat{c}_{2,x}(62)$	$\hat{c}_{2,x}(62)$
$\hat{c}_{4,x}(4)$	$\hat{c}_{4,x}(4)$
$\hat{c}_{4,x}(5)$	$\hat{c}_{4,x}(5)$

2.2 Método II

Algoritmos Genéticos (GAs: Genetic Algorithms) são algoritmos matemáticos inspirados nos mecanismos de evolução natural e recombinação genética. A técnica de Algoritmos Genéticos fornece um mecanismo de busca adaptativa que se baseia no princípio Darwiniano de reprodução e sobrevivência dos mais aptos [19].

As árvores de decisão tomam como entrada uma situação descrita por um conjunto de atributos e retorna uma decisão, que é o valor prognosticado para o valor de entrada. Os atributos de entrada podem ser discretos ou

contínuos. Para os exemplos tratados serão considerados apenas valores discretos. O aprendizado de valores discretos é chamado classificação [20]. A árvore de decisão chega à sua decisão pela execução de uma sequência de testes. Cada nó interno da árvore corresponde a um teste do valor de uma das propriedades e os ramos desse nó são identificados como possíveis valores do teste. Cada nó folha da árvore especifica o valor de retorno se a folha for atingida.

Nesse método utilizamos três parâmetros de classe C_2 e três parâmetros C_4 totalizando seis parâmetros por carga, como temos as cargas definidas (vide Tabela 1), totalizamos sessenta e seis parâmetros, o que consiste em uma considerável redução de 1024 para sessenta e seis parâmetros.

Deste modo, utilizamos um algoritmo genético com o intuito de selecionar desses sessenta e seis parâmetros quais seriam realmente suficientes para classificar essas onze classes de cargas do projeto proposto.

A primeira etapa [Figura 1 (c)] consiste em segmentar o sinal monitorado em $N=1.024$ amostras. A partir dessas amostras, os sessenta e seis parâmetros referentes às EOS são então obtidos utilizando-se (1) e (2). Deste modo aplicamos algoritmos genéticos com a função multi-objetivo de reduzir o número de entradas e maximizar a classificação destas onze cargas, para isso utilizamos uma população inicial de sessenta e seis indivíduos e um total de cinquenta gerações para a busca do melhor indivíduo como podemos ver na Figura 5. Dos sessenta e seis indivíduos foram selecionados pelo AG apenas seis parâmetros (Tabela 2).

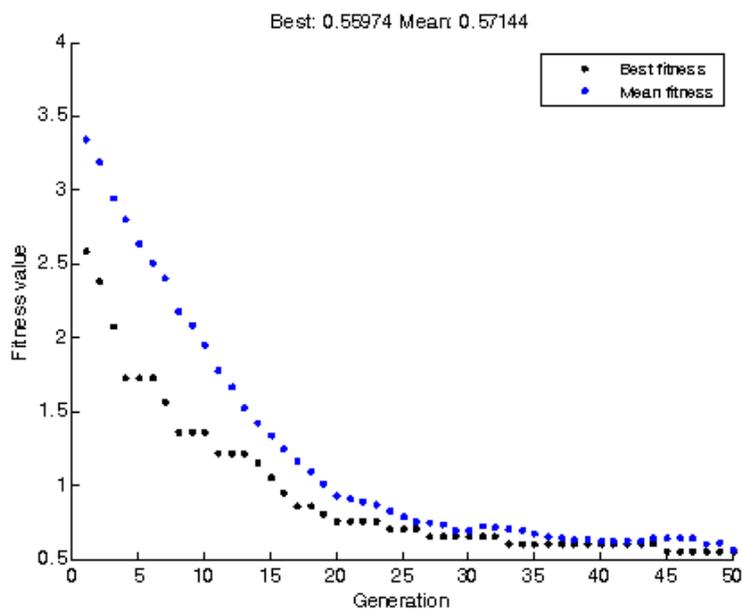


Figura 5 Algoritmo genético com DT buscando o menor número de entradas e o maior acerto de classificação.

Desta forma, juntamente com a busca do melhor indivíduo se treinasse uma árvore de decisão para conseguir classificar as onze cargas com o menor número de entradas, obtidas pelo algoritmo genético.

A etapa de validação ou operação [Figura 1 (d)] consiste em segmentar as amostras e extrair seus cumulantes. Sendo assim, utilizamos os parâmetros mais importantes selecionados anteriormente pelo AG e classificamos por meio da árvore de decisão proposta.

3 RESULTADOS E DISCUSSÕES

Esta seção mostra os resultados dos métodos propostos quando aplicado aos dados de validação.

No método I, onde se utiliza algoritmo genético e redes neurais, foram selecionados apenas seis parâmetros dos sessenta e seis disponíveis pelo FDR, o que gerou uma considerável redução na complexidade do método aliado a um alto desempenho (Eficiência Global (EG) = 100%), sendo capaz de acertar todos os dados de validação, conforme motrado na Tabela 3.

Tabela 3 Desempenho do Método Proposto I em % (HOS+FDR+AG+RNA)

		MATRIZ DE CONFUSÃO										
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	
C1	100											
C2		100										
C3			100									
C4				100								
C5					100							
C6						100						
C7							100					
C8								100				
C9									100			
C10										100		
C11											100	
EG						100						

O método II, que utiliza algoritmos genéticos com árvore de decisão, foi também alcançada uma redução de sessenta e seis parâmetros para seis. A eficiência global foi de 99,5% como pode ser visto na Tabela 4.

Tabela 4 Desempenho do Método Proposto II em % (HOS+FDR+AG+DT)

MATRIZ DE CONFUSÃO											
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11
C1	100										
C2		100									
C3			97		1.5						1.5
C4				97	1.5						1.5
C5					100						
C6						100					
C7							100				
C8								100			
C9									100		
C10										100	
C11											100
EG						99,5					

Interessante observar que o AG selecionou, dentre os seis melhores parâmetros, cinco parâmetros em comum entre os métodos propostos, conforme mostra a Tabela 2. Esses parâmetros levaram à maximização do desempenho da classificação mostrado em detalhe nas Tabelas 3 e 4.

A Tabela 5 mostra um comparativo entre os métodos propostos e um método proposto sem a prévia seleção de parâmetros feita pelo AG. Isso mostra que apesar do ganho em desempenho ser de aproximadamente 2%, a redução de complexidade computacional viabiliza a utilização de AG para este fim. Ademais, o emprego do AG acontece apenas na fase de projeto dos métodos.

Tabela 5 Desempenho Comparativo dos Métodos Propostos em %

	Método HOS+FDR+ RNA	Método HOS+FDR+AG+ RNA	Método HOS+FDR+AG+ DT
C1	100	100	100
C2	100	100	100
C3	88,6	100	97
C4	88,6	100	97
C5	100	100	100
C6	100	100	100
C7	100	100	100

“continua”

Tabela 5 “conclusão”

	Método HOS+FDR+ RNA	Método HOS+FDR+AG+ RNA	Método HOS+FDR+AG+ DT
C8	100	100	100
C9	100	100	100
C10	100	100	100
C11	100	100	100
Eficiência Global	97,5	100	99,5

5 CONCLUSÕES

Este trabalho apresentou um novo método para o monitoramento não invasivo de cargas elétricas residenciais. A inovação do método está na utilização de estatísticas de ordem superior para construir assinaturas das cargas elétricas em um reduzido espaço de parâmetros. A redução de dimensão alcançada para o melhor desempenho do método foi de 1.024 para 6.

As assinaturas construídas pelas estatísticas de ordem superior foram apresentadas pelo algoritmo genético que realizou a classificação das cargas com uma eficiência global de 100% e 99,5%. Isso mostra, que embora as cargas tenham características de corrente similares entre si, como as cargas resistivas, por exemplo, o método conseguiu distingui-las com boa eficiência.

Adicionalmente, a redução de dimensão alcançada com os blocos extração e seleção de parâmetros são bastante favoráveis no que tange à complexidade do método, uma vez que com apenas seis entradas foi possível alcançar uma boa eficiência utilizando uma topologia de rede neural simples.

Em geral, os resultados aqui apresentados são promissores e podem ser bastante úteis em sistemas cujo objetivo é a identificação de cargas elétricas e como parte dos algoritmos de um medidor inteligente para *smart grid*.

REFERÊNCIA

- [1] REIS, Lineu Belico dos e SILVEIRA, Semida. "Energia Elétrica para o Desenvolvimento Sustentável". 2ª ed. – São Paulo: Editora da Universidade de São Paulo, 2001.
- [2] "Strategic Research Agenda for Europe's Electricity Networks of the Future", RTD Info Magazine. European Commission, Directorate-General for Research Sustainable Energy Systems, Brussels, Belgium, 2007.
- [3] "Towards Smart Power Networks - Lessons learned from european research FP5 projects", RTD Info Magazine. European Commission, Directorate-General for Research Sustainable Energy Systems, Brussels, Belgium, 2005.
- [4] LEITE, Davi Rabelo Viana. et al. "Redes inteligentes: a transformação em realidade e o papel do regulador" In: Seminário Internacional sobre Smart Grid em Sistemas de Distribuição e Transmissão de Energia Elétrica, Belo Horizonte, Minas Gerais, Brasil, 2009
- [5] ERGEG [European Regulators' Group for Electricity and Gas]. Position paper on smart grids. An ERGEG public consultation paper. Ref: E09-EQS-30-04; 10 December, 2009.
- [6] Nagesh DYR, Krishna JVV, Tulasiram SS. A real-time architecture for smart energy management. Innovative Smart Grid Technol 2010:1–4.
- [7] M-S. Tsai ,Y-H. Lin, "Modern development of an Adaptive Non-Intrusive Appliance Load Monitoring system in electricity energy conservation." ELSEVIER Journal Vol. 96, pp. 55-73, 2011.
- [8] M. Figueiredo, A. Almeida, B. Ribeiro, "Home electrical signal disaggregation for non-intrusive load monitoring (NILM) systems." ELSEVIER Journal Vol. 96, pp. 66 73. 2012.
- [9] A. S. Ricardo, F, I. N. Silva, M. Oleskovicz. "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, 2010.

- [10] Ericson T. Households' self-selection of dynamic electricity tariffs. *Appl Energy* 2011;88:2541–7.
- [11] Wissner M. The smart grid – A saucerful of secrets?. *Appl Energy* 2011;88:2509–18.
- [12] J. M. Mendel, “Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications,” *Proceedings of the IEEE* Vol. 79, no. 3, pp. 278–305, 1991.
- [13] D. D. Ferreira, C. A. G. Marques, A.S. Serqueira, J. M. Seixas, C.A. Duque, M.V. Ribeiro, “Exploiting Higher-Order Statistics Information for Power Quality Monitoring.” *Power Quality: Intech Open Access Publisher*, pp. 345-362, 2011.
- [14] M. V. Ribeiro, J. L. R. Pereira, “Classification of single and multiple disturbances in electric signals, EURASIP” *Journal on Advances in Signal Processing*, 18 pages, 2007.
- [15] R. O. Duda, P. E. Hart, D. G. Stork, “Pattern Classification,” *Wiley-Interscience*, 2000.
- [16] F. Rosenblatt, “Principles of neurodynamics.” *New York: Spartan Books*, 1962.
- [17] S. Haykin, “Neural networks and Learning Machines.” 3 ed., *Prentice Hall*, 2008.
- [18] D. Nguyen, B. Widrow, “Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights, IJCNN”. *International Joint Conference on Neural Networks*, Vol. 3, pp. 21–26, 1990.
- [19] D. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, *AddisonWesley* 1989.
- [20] Stuart Russel, Peter Norvig. *Artificial Intelligence, a modern Approach*. Second edition, *Prentice Hall*, 2003.

DADOS BIOGRÁFICOS

Juan Diego Silva Guedes, nascido em 16/09/1984 em Lavras, MG é engenheiro eletricitista (2009) pela Universidade Federal de São João Del Rei – UFSJ.

Tem experiência profissional empresarial de cinco anos atuando em *Start-Up* de plantas industriais.

Atualmente é mestrando em Engenharia de Sistemas na Universidade Federal de Lavras – UFLA e professor do CEFET-MG Campus IX - Nepomuceno.

Suas áreas de interesse são: eletrônica de potência, processamento de sinais, redes neurais, algoritmos genéticos e máquinas elétricas.

Danton Diego Ferreira, nascido em 15/06/1982 em Lavras, Minas Gerais, Brasil. Obteve os títulos de Engenheiro Eletricista em 2005 pela Universidade Federal de São João Del-Rei (UFSJ), Mestre em Engenharia Elétrica em 2007 pela Universidade Federal de Juiz de Fora (UFJF) e doutor em Engenharia Elétrica em 2010 pela Universidade Federal do Rio de Janeiro (UFRJ/COPPE). Atualmente é Professor Adjunto da Universidade Federal de Lavras (UFLA), lotado no Departamento de Engenharia (DEG), Coordenador do Núcleo de Eletricidade e Automação do DEG e Coordenador Adjunto do Programa de Pós-graduação em Engenharia de Sistemas da UFLA. Suas áreas de interesse são: processamento de sinais e inteligência computacionais aplicados a Sistemas Elétricos de Potência, qualidade de energia elétrica e Smart Grids.

PERSPECTIVAS FUTURAS

Na prática, as cargas elétricas, sejam elas residenciais e/ou industriais, são acionadas simultaneamente ou com uma sequência não ordenada, na maioria das vezes. Esse tipo de acionamento não foi abordado neste trabalho e constituiu-se em uma proposta fundamental na qual os autores pretendem investigar a partir deste trabalho.

Entende-se que a abordagem desse tipo de acionamento pode ocorrer de duas formas:

- a) Através de classificadores especialistas.
- b) Explorando o conceito “*dividir para conquistar*”.

A abordagem utilizando classificadores especialistas consiste em treinar um classificador especialista para cada classe de carga, considerando-se classes com acionamentos simultâneos e utilizar uma lógica de decisão que utiliza a saída de cada classificador e define a classe de carga do sinal monitorado. Nesse tipo de abordagem é muito comum utilizar redes neurais artificiais [8] ou máquinas de vetor de suporte [8], que são ferramentas com alta capacidade de classificação.

A abordagem utilizando o conceito “*dividir para conquistar*” consiste em dividir o problema em problemas mais simples utilizando-se de alguma ferramenta para depois se obter a informação desejada. Nesse tipo de abordagem é muito comum a utilização de árvores de decisão [6], que é um método linear, não paramétrico e com um custo computacional relativamente baixo. Por outro lado, é muito comum, também, utilizar ferramentas de decomposição de sinais e/ou filtragem de sinais para decompor o sinal monitorado em diferentes componentes, para que classificadores mais simples possam classificar as cargas

a partir desses componentes. Neste caso, espera-se que cada componente carregue informações relativas a uma carga elétrica. Para este fim, podem ser utilizadas ferramentas de processamento estatístico de sinais como Análise de Componentes Principais e Análise de Componentes Independentes [13], bem como ferramentas de filtragem de sinais, como filtros digitais [14] e transformada Wavelet [15].

Como propostas de continuidade deste trabalho, os autores pretendem abordar os acionamentos simultâneos, conforme descrito anteriormente.

ANEXO

OS AUTORES AGRADECEM O APOIO RECEBIDO

