

# Identificação de Cargas Domésticas Utilizando uma Rede ART a Partir de Amostras de Potência Ativa e Reativa

Pedro Bittencourt e Silva  
COPPE  
Poli-UFRJ  
Rio de Janeiro, Brasil  
pedro.bittencourt@lps.ufrj.br

José Manoel de Seixas  
COPPE  
Poli-UFRJ  
Rio de Janeiro, Brasil  
seixas@lps.ufrj.br

Luiz Pereira Calôba  
COPPE  
Poli-UFRJ  
Rio de Janeiro, Brasil  
caloba@lps.ufrj.br

**Abstract**— This work trusts in known methodologies to feature extraction from on-off events, of residential appliances, from active and reactive power data series, it's proposed an ART network clustering to identify those loads based on the related event variation of active and reactive power. It's shown that unsupervised learning techniques could be used for appliance load identification, in special ART theory due its plasticity and ease to work on dynamic environments.

**Keywords**— *NIALM, Unsupervised Training, Artificial Neural Networks, Smart Grid*

## I. INTRODUÇÃO

A identificação de cargas domésticas é um tema de pesquisas recente, que teve seu início a partir do artigo seminal de Hart em 1992 [1]. Visa identificar e desagregar as cargas ligadas a um circuito, cargas que têm acionamento e desligamento independente. Atualmente o interesse na área tem como grande motivação a integração do controle pelo lado da demanda, na chamada “Smart Grid”, ou rede inteligente, onde a informação de consumo tem um papel vital em processos de eficiência energética [2], controle de carga [3], operação do sistema e integração de fontes renováveis [4].

Este trabalho visa analisar, sob a ótica de métodos de treinamento não supervisionados, as estratégias de identificação de cargas. Em particular a teoria da ressonância adaptativa (ART), desenvolvida por Grossberg et al. [5] em 1987, mostra características adequadas ao problema, como o aprendizado contínuo durante a identificação, a resiliência em descartar categorias espúrias e a capacidade de identificar novas categorias durante a operação.

## II. VISÃO GERAL

Pode se caracterizar o trabalho desenvolvido por uma seqüência de processos de tratamento de dados, a partir das

medições diretas de potência ativa (P) e reativa (Q), como ilustrado na Figura 1



Figura 1 - Etapas do processamento das informações de cargas domésticas

As sessões seguintes apresentam o detalhamento do processo e uma aplicação com dados reais.

## III. DADOS

Foram utilizados dados abertos publicados pela faculdade de Carnegie-Mellon [6]. Estes dados são referentes a uma residência-modelo, com os equipamentos descritos pela Tabela 1 abaixo:

Tabela 1 - Equipamentos na residência modelo

Tag	Id
101	Lâmpada de Mesa da Sala
102	Lâmpada de Chão da Sala
103	Porta da Garagem
108	Processador de Alimentos
111	Refrigerador
112	Sistema de Áudio e Vídeo da Sala
118	Computador 1
120	Laptop 1
123	Decodificador de TV a cabo / DVD
127	Compressor de Ar
128	Monitor LCD 1
129	TV
131	Impressora
132	Secador de Cabelos
134	Ferro de Passar Roupas
135	Tomada da Sala (Livre)
140	Monitor 2
147	Lâmpadas do Quintal

148	Lâmpada da Lavanderia
149	Lâmpadas do Escritório
150	Lâmpada do Closet
151	Lâmpada do Hall Superior
152	Lâmpada da Escada
153	Lâmpada da Cozinha 1
155	Lâmpada da Cozinha 2
156	Lâmpadas do Banheiro 1
157	Lâmpadas da sala de Jantar
158	Lâmpadas do Quarto
159	Lâmpadas do Porão

#### IV. FILTRAGEM

O processo de filtragem consiste na identificação e retirada de picos de curta duração, que ocorrem durante o chaveamento dos equipamentos. Para isso, foi utilizado um filtro de supressão de diferenças da forma:

$$S(n) = \begin{cases} S(n) & \text{se } S(n-1) - S(n) < \delta_{max} \\ S(n+1) & \text{se } S(n-1) - S(n) > \delta_{max} \end{cases}$$

Ou seja, se a diferença for maior que o limiar  $\delta_{max}$  o valor é substituído pelo próximo da série. Este filtro só é aplicável, pois os picos de transiente têm magnitudes de ordem de grandeza superior aos eventos de ligação e desligamento.

O procedimento de filtragem proposto garante que a variação máxima dos dados seja restrita a valores mais próximos da variação de potência no regime estacionário, por suprimirem os efeitos espúrios de variação de potência no transiente de acionamento e desligamento de equipamentos.

A residência modelo contém duas fases no sistema de abastecimento de energia elétrica, os dados são provenientes de medições em ambas, porém por questões de simplicidade este trabalho só considera uma delas (Fase B ilustrada na Figura 2).

As amostras fornecidas são de potência ativa (P) e reativa(Q) com taxa de amostragem de 60Hz. A Figura 2 ilustra os dados como foram fornecidos. Por possuírem picos na região de transiente, uma etapa de filtragem é necessária para evitar a detecção de falsos eventos (falsos positivos na extração de eventos).

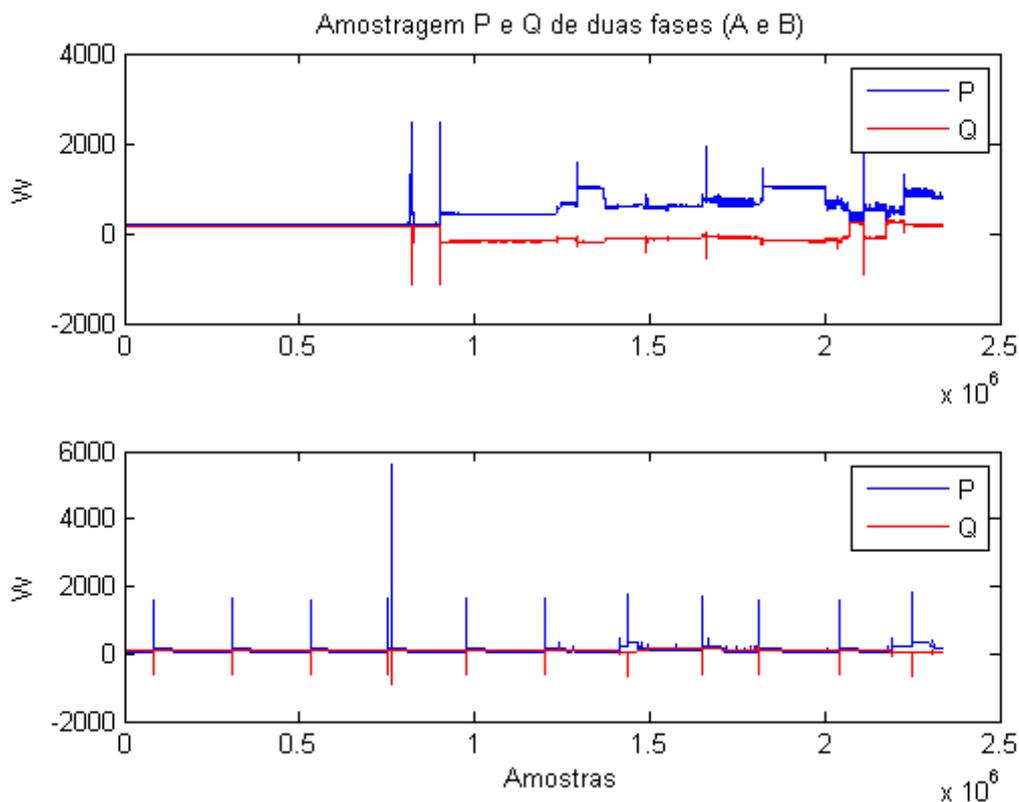


Figura 2 - Série temporal de cargas das fases A (superior) e B (inferior)

## V. EXTRAÇÃO DE EVENTOS E CARACTERÍSTICAS

Os eventos são extraídos da série temporal através de um algoritmo que avalia se a variação de potência ultrapassa um valor de limiar. Para a definição deste valor, foi desenvolvida uma metodologia a partir da diferença para caracterização de evento. São considerados eventos de acionamento ou desligamento quando:

- O módulo da variação de potência ativa é maior que 10W;
- As variações de potência reativa tem contrapartida simultânea na potência ativa;

A Figura 3 ilustra a série e a série de diferenças com o limiar demarcado (linha pontilhada).

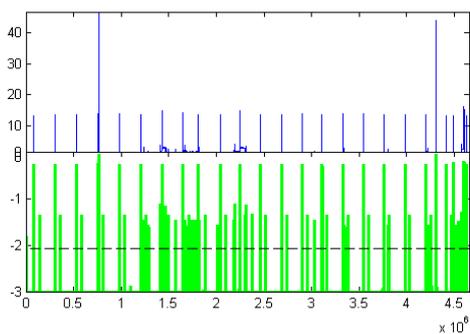


Figura 3 – A linha pontilhada no gráfico inferior representa o limiar de detecção de eventos.

Uma vez determinados os eventos de acionamento e desligamento um algoritmo de “casamento” forma os pares (acionamento/desligamento) de acordo com  $\Delta P$  e  $\Delta Q$ , formando assim, os eventos que serão agrupados pela rede ART. Neste trabalho, não são discutidos equipamentos com múltiplos estados, apenas considera-se o estado ligado ou desligado.

## VI. EVENTOS

A Figura 4 ilustra a disposição dos eventos detectados no plano  $\Delta P \times \Delta Q$ .

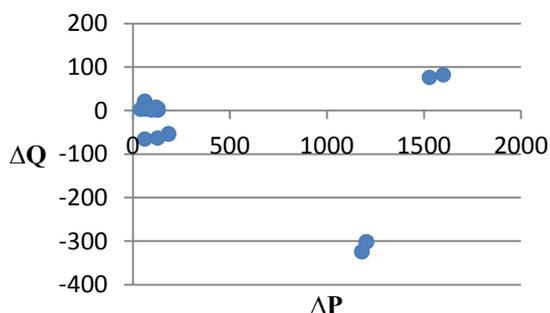


Figura 4 - Distribuição dos 58 eventos detectados

Percebe-se uma aglomeração em níveis baixos de potências reativas, devido à natureza resistiva das cargas ou a utilização de equipamentos com fator de potência corrigido internamente (neste caso, o refrigerador se encaixa nesta categoria). Inicialmente a média é retirada das amostras:

$$S_{\mu}(n) = S(n) - \bar{m}$$

## VII. REDES ART

Redes neurais artificiais baseadas na teoria da ressonância adaptativa foram propostas inicialmente por Grossberg et al. [5] em 1987, e se baseia em princípios biológicos de como o cérebro humano processa informação.

As redes do tipo ART se baseiam no conceito de memória, ou *template*, e na comparação com dados sensoriais recebidos com este *template*. Assim como o cérebro humano o processo de aprendizado de redes ART é adaptativo, baseado no reforço (ativação) neuronal e apresenta plasticidade o suficiente para memorizar novos padrões.

A rede proposta neste trabalho apresenta treinamento não supervisionado e é treinada durante a operação, ou seja, a rede sempre está em processo de treinamento e operação, simultaneamente. Quando a rede recebe um padrão para processar este é avaliado quanto a sua distância, no espaço de atributos, a todos os neurônios da rede. A rede é inicializada sem um *template* pré-definido, apenas com um neurônio de vigilância, que só é ativado se nenhum outro neurônio na rede for ativado (o padrão estiver dentro de seu raio de vigilância). Este neurônio é o responsável pela criação de um novo neurônio para representar o padrão novo.

Dado este modelo, o processo de operação, que consiste em apresentar eventos à rede para classifica-los, inicialmente cria os neurônios que representarão as classes pelo mecanismo apresentado a cima e caso seja apresentado um evento de uma classe já conhecida este será classificado pela ativação do neurônio mais próximo, ou seja, a classe mais próxima do evento.

## VIII. IMPLEMENTAÇÃO

Foi desenvolvido, durante o trabalho, um código na linguagem Lua [7] para treinamento e execução da rede ART. O processo de treinamento é dinâmico, no sentido em que o número máximo de neurônios não é pré-determinado.

Inicialmente, só há o neurônio de vigilância e o processo de treinamento adiciona neurônios, de acordo com a proximidade da entrada.

Dado o número reduzido de dimensões e amostras tratados neste trabalho, é possível reduzir o raio de vigilância. Consequentemente, aumentando o número de neurônios sem um esforço computacional excessivo.

Os seguintes passos são realizados no treinamento:

- Passo um: definição dos raios de vigilância iniciais. A partir da distribuição dos eventos no mapa  $\Delta P \times \Delta Q$  foi arbitrado  $r_0 = 30$ , por ser um valor que apresenta boa definição das classes sem a necessidade de muitos neurônios.
- Passo dois: Os domínios esféricos são determinados com o treinamento da rede ART, que com as entradas apresentadas na sessão anterior são as encontradas na Figura 5.
- Passo três: O código automaticamente verifica os neurônios vizinhos para formar a 'outstar' de OU, agrupando assim os neurônios que irão formar uma mesma classe. Neste caso em particular foram formadas quatro classes.

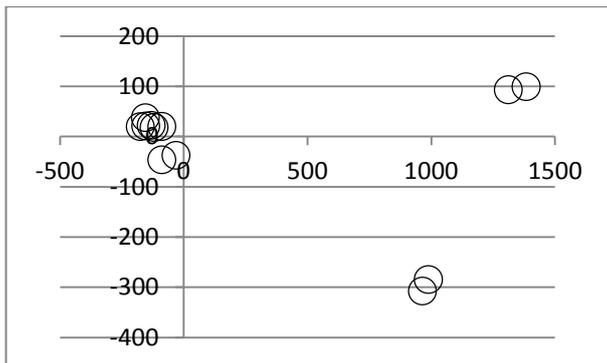


Figura 5 - Neurônios e seus raios de vigilância após o treinamento

Assim a topologia final da rede para este conjunto de entradas pode ser vista na Figura 6.

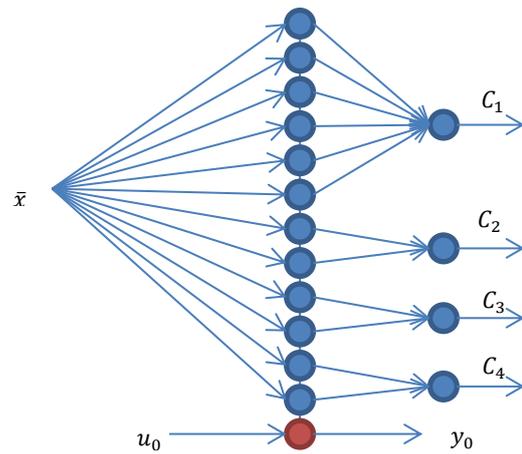


Figura 6 - Topologia completa com 'outstar' de OU

### IX. RESULTADOS

Para este trabalho, foi considerado apenas um subconjunto do total de dados, no qual estavam contidas apenas um numero reduzido de aparelhos, como listados na Tabela 2.

Tabela 2- subconjunto de dispositivos considerados

Tag	Id
111	Refrigerador
127	Compressor de Ar
156	Lâmpadas do Banheiro 1
158	Lâmpadas do Quarto
147	Lâmpadas do Quintal
108	Processador de Alimentos
132	Secador de Cabelos

Algumas classes foram confundidas devido a sua natureza elétrica, como, por exemplo, a carga pouco reativa da iluminação. Os agrupamentos finais representaram os seguintes equipamentos:

$$\begin{aligned}
 C_1 &= \{156,111,147\} \\
 C_2 &= \{158\} \\
 C_3 &= \{127\} \\
 C_4 &= \{108,132\}
 \end{aligned}$$

Um ponto notável é o refrigerador ser confundido com iluminação do banheiro e do quintal. Isso ocorre pelo fato do refrigerador utilizado no experimento original apresentar baixa potência reativa, similar às lâmpadas fluorescentes comumente utilizadas em banheiros e ambientes externos.

Outra carga confundida foi a do secador de cabelos com o processador de alimentos. Ponto compreensível, dado

que ambos os equipamentos têm motores elétricos com potências e características similares.

## X. CONCLUSÃO

Apesar da abordagem simples foi demonstrado que redes ART têm grande potencial para utilização na identificação de cargas, principalmente por sua implementação simples, flexibilidade nos processos de treinamento (esquecimento e consciência) e baixo custo computacional. Entretanto uma análise mais robusta envolvendo maior quantidade de dados deve ser realizada para validar os resultados. Eventos que ocorrem simultaneamente podem não ser detectados corretamente, porém esta questão pode ser minimizada através de algoritmos mais robustos de detecção, incluindo o processamento através da análise de componentes independentes para separação de transientes de eventos.

Outras possíveis melhorias neste trabalho envolvem principalmente: uma melhor aquisição de dados e adição de novos atributos nos eventos, como duração e distorção harmônica. O software de execução da rede ART pode ser aperfeiçoado adicionando-se raios de vigilância variáveis e diferentes processos de consciência e esquecimento.

## XI. AGRADECIMENTOS

Os autores agradecem a FAPERJ, CNPq e CAPES pelo apoio e ao CEPEL/Eletróbras pelas discussões acerca do tema.

## XII. REFERÊNCIAS

- [1] Hart, G.W., "Nonintrusive Appliance Load Monitoring," *Proceedings of the IEEE*, December 1992, pp. 1870-1891
- [2] Sinha, M. N.; Cox, R.W., "Improving HVAC system performance using smart meters," *Energytech, 2011 IEEE*, vol., no., pp.1,6, 25-26 May 2011 doi: 10.1109/EnergyTech.2011.5948511
- [3] Tomek, Stephan, Aliaksei Andrushevich, Pascal Walther, and Alexander Klapproth. "iHomeLab experience with NIALM for Smart Buildings."
- [4] Varaiya, P.P.; Wu, F.F.; Bialek, J.W., "Smart Operation of Smart Grid: Risk-Limiting Dispatch," *Proceedings of the IEEE*, vol.99, no.1, pp.40,57, Jan. 2011 doi: 10.1109/JPROC.2010.2080250
- [5] Grossberg, S. . "Competitive learning: From interactive activation to adaptive resonance". *Cognitive Science*, 11, 1987 pp. 23-63.

[6] K. Anderson, A. Ocneanu, D. Benitez, D. Carlson, A. Rowe, and M. Berges, "BLUED: A Fully Labeled Public Dataset for Event-Based Non-Intrusive Load Monitoring Research," in *Proceedings of the 2nd KDD Workshop on Data Mining Applications in Sustainability (SustKDD)*, Beijing, China, 2012.

[7] Ierusalimschy, R., de Figueiredo, L. H. and Filho, W. C., "Lua—An Extensible Extension Language." *Softw: Pract. Exper.*, 26,1996, pp. 635–652.