

Um cenário de implementação de um sistema neural não-invasivo de identificação de cargas elétricas

Charles B. do Prado, José Manoel de Seixas, Rodrigo Coura Torres

Resumo—Um sistema não-invasivo de monitoração cargas elétricas residenciais vem sendo desenvolvido. Baseado no processamento neural e na análise de componentes principais de discriminação. Com o agrupamento dos equipamentos eletrodomésticos dentro de seis classes, o sistema é capaz de classificar mais de 90% das amostras. Considerando um cenário de processamento de informação proveniente de um bloco de apartamento ou de um grupo de residências, o sistema foi implementado utilizando-se um processador digital de sinais com duplo núcleo de processamento, o que permite realizar um paralelismo de dados com alta velocidade.

I. INTRODUÇÃO

Nas últimas décadas, a preocupação com o uso eficiente e o planejamento de demanda de energia elétrica vem se acentuando em escala mundial. Esta preocupação advém principalmente do fato que os sistemas atuais de fornecimento de energia elétrica exigem elevados níveis de investimento, para suprir a demanda projetada para os próximos anos. O gerenciamento desta demanda permite, a custos menores, postergar ou mesmo evitar esses investimentos.

Em países em desenvolvimento, como o Brasil, as taxas anuais de consumo de energia elétrica vêm se elevando rapidamente [1]. Em parte, isso se deve porque o país está crescendo, o que significa mais demanda industrial, por serviços, mais oferta de empregos, etc. Entretanto, este crescimento, tipicamente, também significa desperdício de energia.

É extremamente importante, então, que as empresas distribuidoras de energia elétrica tenham o conhecimento do perfil de consumo dos habitantes de uma região, e até do país, para que os recursos disponíveis de fornecimento de energia elétrica sejam administrados de forma eficiente e os planos de expansão de fornecimento de energia elétrica sejam condizentes com as reais necessidades de demanda.

TABELA I
DISTRIBUIÇÃO DO CONSUMO ENERGÉTICO POR ATIVIDADES

Industrial	42%
Residencial	26%
Comercial	17%
Outros	15%

C. B. Prado, TV Globo-RJ, LPS/UFRJ (Laboratório de Processamento de Sinais), COPPE-Elétrica-UFRJ, e-mail: bezerra@lps.ufrj.br

J. M. Seixas, LPS/UFRJ, EP/UFRJ (Escola Politécnica), COPPE-Elétrica - UFRJ, e-mail: seixas@lps.ufrj.br

R. C. Torres, LPS/UFRJ, COPPE-Elétrica-UFRJ, e-mail: torres@lps.ufrj.br

O consumo de energia elétrica residencial responde por 26% da energia total, conforme indicado na tabela I [1]. Com uma tal participação no consumo energético nacional, o consumo residencial tem se tornado um foco de atenção dos órgãos governamentais na intenção de promover campanhas educativas de conservação e utilização correta dos recursos advindos da energia elétrica. Podemos citar, como exemplo, a campanha denominada PROCEL (Programa de Combate ao Desperdício de Energia Elétrica).

Atualmente, existem duas formas de levantamento de curvas de carga ou hábitos de consumo: as entrevistas e a medição. As entrevistas e questionários não necessitam de instrumental de medição e permitem abranger grandes regiões em curto espaço de tempo, mas os dados coletados não são precisos. Na medição, os equipamentos são instalados no local de interesse e as medidas são efetuadas. As medidas podem ser realizadas através de medição individualizada ou distribuída ou por medição centralizada.

A medição não-invasiva se mostra mais vantajosa, em relação aos outros métodos, pelo fato do monitoramento de cargas elétricas ser feito por um sistema que fica externo à residência. O levantamento de informações, tais como demanda de potência ativa e reativa, corrente, tensão, fase e temperatura, pode ser feita sem que o residente seja incomodado com a entrada de uma pessoa estranha em sua residência, para realizar o monitoramento das cargas elétricas.

O sistema não-invasivo de monitoração de cargas elétricas residenciais proposto neste trabalho é baseado na aquisição das amostras do transiente dos equipamentos eletrodomésticos. A identificação das classes de aparelhos eletrodomésticos é feita através de um discriminador neural obtido a partir da análise de componentes principais de discriminação [2]. Visando uma implementação prática do sistema, utiliza-se a tecnologia dos processadores digitais de sinais, o que alia velocidade de processamento e custo eficiente para uma solução que englobe um grupo de residências.

II. AQUISIÇÃO DE DADOS

O sistema de aquisição de dados utilizado é baseado na aquisição de informações da rede de distribuição em corrente alternada, a partir da resposta ao transiente de cargas domésticas ativadas cotidianamente em cada residência.

A Figura 1 ilustra o sistema de aquisição utilizado. Os transientes dos eletrodomésticos são adquiridos através de um conversor A/D de 8 bits, que, armazena, de forma direta, os picos de corrente, utilizando uma taxa de amostragem de 30 Hz, ao longo de 2 segundos, sendo adquirido

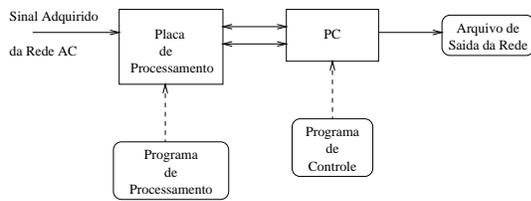


Figura 1. Sistema de Aquisição de Dados

um total de 160 amostras de pico de corrente. O programa de processamento, que aciona a aquisição das amostras, roda em um microcontrolador 8031, que se encarrega de enviar, por uma porta serial, os dados para uma unidade computacional visando uma análise posterior desses dados.

Tomando como base trabalhos já realizados, que sugerem o agrupamento da eletro-diversidade em classes com características afins [3], os equipamentos eletrodomésticos usados neste trabalho foram agrupados em seis classes, abaixo enumeradas.

1. Refrigeradores
2. Equipamentos resistivos e ventiladores
3. Equipamentos com motores universais
4. Lâmpadas incandescentes
5. Lâmpadas fluorescentes
6. Microondas

A Figura II mostra alguns transientes típicos de eletrodomésticos das classes 1, 3 e 6 respectivamente.

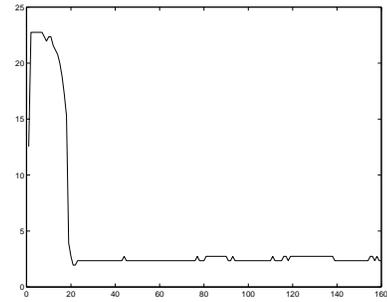
III. COMPONENTES PRINCIPAIS DE DISCRIMINAÇÃO

Para identificação das classes de eletrodomésticos citadas na seção anterior, projetamos um discriminador neural [4] com base na análise de componentes principais de discriminação [5].

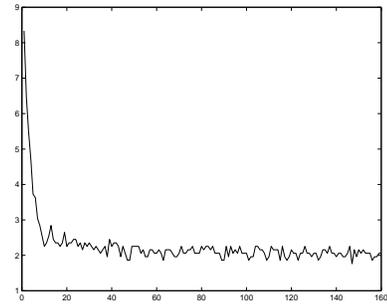
A análise de discriminação principal é uma técnica de projeção de um espaço de dados num espaço de discriminação. As direções das componentes principais, encontradas nesta análise, determinam uma máxima discriminação entre padrões diferentes do espaço de entrada. Além disso, em geral, este método produz um alto nível de compactação de dados [6].

A Figura 3 mostra como a análise de discriminação pode ser implementada, usando-se uma rede neural feed-forward escalável. A rede, inicialmente, é formada por um único neurônio na camada intermediária e é treinada como um classificador, através do método de backpropagation. Um critério de parada a se utilizar pode ser a obtenção da melhor eficiência de classificação com um simples neurônio na camada intermediária. Então, após a fase de treinamento, o vetor de pesos que conecta o espaço de entrada ao neurônio da camada intermediária representa a primeira componente de discriminação. A segunda componente de discriminação é obtida através da adição de um novo neurônio na camada intermediária, sendo a rede treinada apenas para os pesos que conectam a camada de entrada ao novo neurônio da camada intermediária. Os pesos que ligam a camada de entrada ao neurônio único

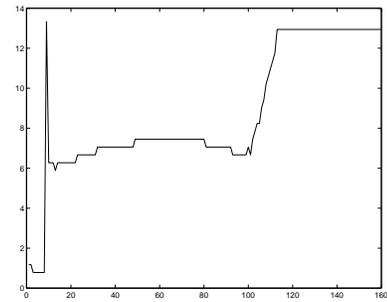
Figura 2. Transientes típicos de eletrodomésticos



(a) Refrigerador



(b) Equipamento de motor universal



(c) Refrigerador

da camada escondida da fase anterior são mantidos inalterados, conforme o treinamento realizado naquela etapa. O vetor de pesos que conecta a camada intermediária com a camada de saída é retreinado, para que a rede possa combinar otimamente as contribuições de cada componente principal. A segunda componente principal de discriminação é extraída quando a máxima eficiência de discriminação é obtida para esta topologia. Novas componentes são extraídas de forma similar, até o ponto em que a eficiência de discriminação não pode ser significativamente melhorada com a adição de novas componentes, na forma da adição de novos neurônios na camada escondida.

No caso do sistema de monitoração de cargas, o objetivo é identificar as sete classes de eletrodomésticos. Ao invés de

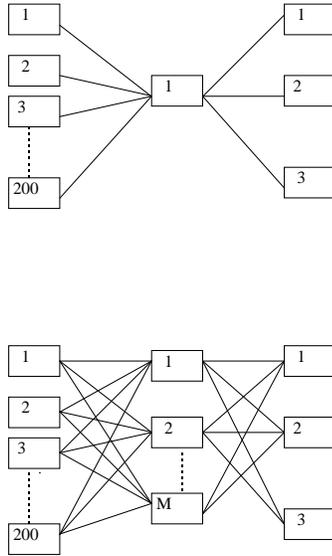


Figura 3. Extração de componentes de discriminação principal: primeira (acima) e M-ésima (abaixo) componentes.

TABELA II

TABELA DE ACERTOS POR CLASSES DE ELETRODOMÉSTICOS

Padrões de entrada	taxa de acerto
classe 1	85%
classe 2	93%
classe 3	76%
classe 4	50%
classe 5	100%
classe 6	100%

utilizarmos um neurônio de saída para cada classe e usarmos a máxima probabilidade para identificarmos o neurônio vencedor para cada evento de entrada, as saídas da rede neural foram codificadas binariamente. Desta maneira, somente três neurônios foram necessários para representar a identificação das sete classes de equipamentos domésticos.

Projetamos, então, o discriminador neural com 4 neurônios na camada intermediária, que representam as componentes principais de discriminação e com os 3 neurônios de saída codificados binariamente. Para treinamento, utilizou-se um conjunto de treinamento de 123 amostras de transientes de eletrodomésticos, representando 75% do conjunto total de amostras. As amostras restantes foram utilizadas para teste da rede neuronal. Obtivemos, sobre esse conjunto de dados, uma taxa de acerto global de 90%. A tabela II mostra classe por classe a taxa de acerto obtida pela rede neural.

Para definirmos cada um dos cenários de implementação prática do sistema de monitoração de carga elétrica residencial, enumerados abaixo, considerou-se, como fator diferencial entre eles, a quantidade de residências a serem monitoradas e o custo da implementação.

- Cenário 1 - Em cada residência, é instalada uma unidade de processamento, responsável por monitorar e adquirir dados referentes ao consumo elétrico residencial. Essa unidade processa os dados adquiridos e, após algum tempo, esses dados processados são transferidos para uma central de processamento, aonde poderá ser feita uma análise final. Neste cenário, temos, como principal vantagem, a utilização de um sistema de baixo custo, já que o seu foco de monitoração se restringe às cargas elétricas de uma única residência.
- Cenário 2 - Nesse caso, um grupo específico de residências ou um bloco de apartamentos pode ser monitorado. Para cada residência, uma unidade de aquisição de dados é instalada e os dados adquiridos são transferidos para uma unidade de processamento local que processaria esses dados. Podem, também, posteriormente, ser transferidos para uma unidade central para uma posterior análise. Neste cenário, a massa de dados a ser processado pela unidade de processamento local aumenta substancialmente, comparando-se com o primeiro cenário, o que poderia justificar a utilização de um processamento distribuído dos dados.
- Cenário 3 - Uma unidade simples de aquisição de dados é instalada em cada residência e os dados adquiridos são transferidos para uma unidade central de processamento. Como a massa de dados, neste cenário, é um somatório de residências monitoradas, poderemos ter um elevada quantidade de dados chegando na unidade central de processamento que, por sua vez, deverá ser rápida o suficiente para não descartar nenhum sinal enviado.

Com base nas características dos cenários de implementação, propomos dois tipos de implementação:

- 1 - Considerando-se a minimização de um hardware de aquisição e processamento, o enfoque local (cenário 1) utiliza um sistema de processador (microcontrolador ou DSP (Processador Digital de Sinais)) instalado em cada residência.
- 2 - Uma segunda maneira de implementação utiliza uma unidade de processamento central (possivelmente uma arquitetura paralela) sendo alimentada por dados adquiridos de diversas residências (cenário 2), de uma grande subestação ou grande agrupamento de residências (cenário 3), por exemplo.

V. IMPLEMENTAÇÃO

Desenvolvemos, neste trabalho, um sistema que nos permitiu emular os cenários de implementação descritos na seção anterior. Para tal, utilizamos como plataforma de desenvolvimento o ADSP 21160M, que estará sendo descrito, mais detalhadamente, na seção seguinte.

Cenário de monitoração	tempos - 1 evento
cenário 1	115 μ s
cenário 2	52 μ s

Para a implementação de sistemas de processamento digital de sinais, pode-se utilizar qualquer dispositivo digital programável. Os computadores de uso geral (tipo PC), embora sejam bastante rápidos e fáceis de programar, são caros e consomem muita energia, além de não possuírem tamanho reduzido. Uma FPGA (*Field Programmable Gate Array*) possui tamanho reduzido, excelente performance e baixo consumo, mas a implementação de sistemas complexos tomaria uma complexidade tal, neste tipo de dispositivo, que tornaria a escolha deste dispositivo pouco viável.

Em processamento digital de sinais, existem operações que são bastante comuns, como por exemplo somas com acumulação, operações modulares, forte iteratividade, entre outras. Assim sendo, um tipo de processador foi desenvolvido especialmente para aplicações de processamento digital de sinais. Os DSPs (*Digital Signal Processors*) exploram características inerentes do processamento digital de sinais, visando otimizar a execução do processamento e, desta maneira, atender aos requisitos em tempo real [7] que aplicações, como a apresentada neste trabalho, possuem. Suas principais qualidades so:

- **Hardware dedicado para multiplicar e acumular:** DSPs podem executar uma multiplicação com acumulação em apenas um ciclo, diferentemente de um PC, que normalmente leva em torno de 12 ciclos para realizar a mesma operação
- **Memória interna:** estes dispositivos são dotados de memória interna, com múltiplos barramentos, diferentemente de processadores de uso geral, que possuem um único barramento de acesso a memória.
- **Dispositivos internos de acesso a dados e instruções:** DSPs possuem unidades específicas para o controle de acesso a dados e a instruções, de forma que a unidade de processamento se atém exclusivamente ao processamento dos dados. O controle de acesso aos dados e as instruções são realizados por estes dispositivos internos, de tal forma que o controle de iterações e de acesso modular aos dados, por exemplo, podem ser realizados em paralelo com o processamento destes.
- **Facilidade de interfaceamento:** como um DSP normalmente entra como parte de um sistema maior, torna-se necessário o envio e recebimento de dados do mesmo. Assim, estes dispositivos são dotados de controladores internos próprios para a conexão de dispositivos externos, como CODECs, memórias, etc, reduzindo ao mínimo o *overhead* de processamento, ao mesmo tempo em que simplifica-se o desenvolvimento do código.

Para a implementação do sistema proposto, optou-se por utilizar o processador ADSP-21160M. Este processador é um DSP de 32 bits com *clock* de 80 MHz que forma um sistema de processamento completo *on-chip*. Ele integra uma memória SRAM interna de duas portas de 4 Mbits de capacidade, periféricos de *I/O* (portas seriais, dispositivos para multiprocessamento, etc) e uma unidade de processamento adicional (ALU, multiplicador e deslocador) para suporte ao processamento SIMD (*Single Instruction on Multiple*

Data) [8], [9], permitindo que a mesma instrução seja realizada em dois dados distintos. Desta maneira, como no caso da rede neural, que tem em seu processamento operações de produto interno, consegue-se dobrar o número efetivo de operações por ciclo, aumentando consideravelmente a eficiência de processamento, sem a necessidade de aumento do *clock* do processador. Assim, evitam-se problemas de aquecimento e consumo exagerado de energia.

B. Desenvolvimento do sistema de monitoração

Para desenvolvermos o sistema de monitoração de cargas elétricas residenciais utilizamos um kit de desenvolvimento, que nos permitiu desenvolver as aplicações na linguagem C ou C++ através do ambiente de programação VisualDSP++.

Foram desenvolvidos, os cenários 1 e 2, descritos anteriormente. Para emularmos o cenário 1, desabilitamos o processamento SIMD do ADSP-21160M, caracterizando-se assim um processamento de menor granularidade, na qual o foco seria a monitoração das cargas elétricas de uma única residência.

Para emularmos, o cenário 2, utilizamos o suporte ao processamento SIMD, permitindo-se um paralelismo de dados. Assim, emulamos uma aquisição de dados de mais de uma residência.

Embora, a implementação do cenário 3 possivelmente requeira uma arquitetura paralela, o ADSP-21160M com suporte SIMD habilitado, nos permitiu verificar o impacto de se processar uma grande quantidade de dados. Verificamos que o tempo de transmissão de dados para o processador tem uma parcela significativa no tempo total de processamento.

A tabela III mostra os tempos de processamentos, considerando 1 evento, para os cenários 1 e 2. Podemos verificar que ao habilitarmos o suporte SIMD do processador ADSP-21160M, emulando o cenário 2, o tempo de processamento foi reduzido em mais da metade quando comparado com o tempo obtido para o cenário 1.

VI. RESULTADOS E CONCLUSÕES

Um sistema neural não-invasivo de monitoração de cargas elétricas foi apresentado. Este sistema baseou-se na aquisição dos transientes de equipamentos eletrodomésticos através da linha de energia AC. Esse sistema utilizou uma rede neural para classificar eletrodomésticos de 6 classes diferentes. A rede neural foi projetada usando-se análise de componentes principais de discriminação, obtendo-se um classificador compacto e com uma alta eficiência.

Usando-se 4 componentes principais de discriminação, obtivemos uma eficiência de classificação de 90% para 6 classes de eletrodomésticos.

O sistema de monitoração foi implementado utilizando-se a tecnologia de processadores digitais de sinais. Usando-se o ADSP-21160M, emulamos os cenários 1 e 2, o que nos permitiu verificar a viabilidade da implementação desse sistema.

Atualmente, testes de multiprocessamento estão sendo feitos para emularmos o cenário 3, na qual é necessário um alto processamento de dados.

VII. AGRADECIMENTOS

Este trabalho foi parcialmente apoiado pela COPPE/UFRJ, CEPEL (Centro de Pesquisas de Energia Elétrica), CAPES, CNPq e FAPERJ.

REFERÊNCIAS

- [1] “Relatório analítico - mercado de energia elétrica,” <http://www.eletronbras.gov.br>, 2003.
- [2] L.P. Caloba, J. M. Seixas, and F. S. Pereira, “Neural discriminating analysis for a second-level trigger system,” *Computing in High Energy Physics*, 1997.
- [3] F. Sultanem, “Using appliance signatures for monitoring residential loads at meter panel level,” *IEEE Trans. Power Delivery*, Oct 1991.
- [4] J. Hertz, A. Krogh, and R. G. Palmer, *Introduction to the Theory of Neural Computation*, Addison - Wesley, 1991.
- [5] J. M. Seixas, L. P. Caloba, C. B. Prado, and J. C. R. Aguiar, “Neural discriminating analysis for a nonintrusive electrical load monitoring system,” *IX Simpósio Brasileiro de Arquitetura de Computadores - Computação de Alto Desempenho (SBAC - PAD)*, 1997.
- [6] W. S. Filho J. B. O.S. Filho D. O. Damazio M. N. Moura J. M. Seixas, Soares Filho, “A compact online neural system for classifying passive sonar signals,” *International Conference on Signal Processing Applications and Technology(ICSPAT)*, 1999.
- [7] John Gg Ackenhusen, *Real-Time Signal Processing*, Prentice Hall, 1999.
- [8] Analog Devices, *ADSP-21160: SHARC DSP Hardware Reference*, 2 edition, maio 2002.
- [9] E. S. T. Fernandes C. L. Amorim, V. C. Barbosa, *Uma Introdução à Computação Paralela e Distribuída*, VI Escola de Computação, Campinas-SP, 1998.