

SISTEMA DE MONITORAÇÃO DE CARGA ELÉTRICA RESIDENCIAL COM
IMPLEMENTAÇÃO PARA DIFERENTES CENÁRIOS DE APLICAÇÃO

Charles Bezerra do Prado

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS
EM ENGENHARIA ELÉTRICA.

Aprovada por:

Prof. José Manoel de Seixas, D.Sc.

Prof. Luiz Wagner Pereira Biscainho, D.Sc.

Prof. Sandoval Carneiro Júnior, Ph.D.

Profa. Marley Maria Bernardes Rebuzzi Vellasco, Ph.D.

Prof. Augusto Santiago Cerqueira, D.Sc.

Prof. Adrião Duarte Dória Neto, Dr.

RIO DE JANEIRO, RJ - BRASIL

MARÇO DE 2006

PRADO, CHARLES BEZERRA DO

Sistema de Monitoração de Carga
Elétrica Residencial com Implementação
para Diferentes Cenários de Aplicação
[Rio de Janeiro] 2006

XI, 118 pp., 29,7 cm (COPPE/UFRJ,
D.Sc., Engenharia Elétrica, 2006)

Tese - Universidade Federal do Rio de
Janeiro, COPPE

1.Redes Neurais 2.Cenários de Aplicação

I.COPPE/UFRJ II.Título (série)

Agradecimentos

Gostaria de agradecer, primeiramente, a Deus por ter me sustentado e me guiado até aqui, na realização deste sonho. Muito obrigado por tudo.

À minha amada e querida esposa Danielle, por ter sido minha amiga, companheira, por ter me dado todo o apoio necessário para chegar até aqui. As palavras de agradecimento não caberiam nesta folha, você foi demais, obrigado por segurar essa carga sozinha, em cuidar de mim, de nossas filhinhas, para que eu pudesse superar as dificuldades e chegar até aqui; eu te amo muito, minha amada princesa.

Às minhas filhinhas, que com suas palavras amorosas e expressões sinceras de carinho me deram força para superar as dificuldades. Laís, Larissa e Júlia, vocês são flores que encantam e dão alegria a minha vida, amo vocês.

Aos meus pais, pelo incentivo e o apoio que sempre me deram, obrigado mãe por todo o esforço que fizeste para eu terminasse os meus estudos, quando ainda era um graduando de engenharia. Pai, obrigado pelo seu apoio e por sempre me incentivar a estudar e pelas muitas vezes que se sentou comigo, ainda criança, para me ensinar. Amo vocês.

Aos meus irmãos Kennedy, Sheyla e Andressa.

Ao prof. José Manoel de Seixas, que há uns dez anos acreditou em mim, e me concedeu uma bolsa de iniciação científica, ali eu comecei a descobrir o caminho que eu iria seguir. Obrigado por me orientar, ensinar e acreditar sempre em mim, e mesmo quando decidi trabalhar fora da Universidade não deixou de me incentivar. Deixo aqui todo o meu respeito e admiração por você.

Ao prof. Felipe França, pelo apoio, pelas palavras de incentivo, um amigo com que sempre posso contar.

Ao prof. Luiz Wagner pelas palavras de ânimo, obrigado mesmo.

Aos amigos de coração Marcos e Marluce Coelho, Moisés e Denise Freitas, Rogério Quaresma.

Aos meus sogros Jayme e Ana, obrigado pela ajuda que vocês deram a mim e a Danielle.

Ao meu chefe de trabalho Silvio Pereira, pelo apoio para que eu pudesse alcançar esse objetivo.

Aos colegas do DEPED (Departamento de Pesquisa e Desenvolvimento - TV Globo).

Aos colegas de faculdade Augusto Dantas, Fábio Freeland, Alexandre Ciancio, José Gabriel.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

SISTEMA DE MONITORAÇÃO DE CARGA ELÉTRICA RESIDENCIAL COM IMPLEMENTAÇÃO PARA DIFERENTES CENÁRIOS DE APLICAÇÃO

Charles Bezerra do Prado

Março/2006

Orientador: José Manoel de Seixas

Programa: Engenharia Elétrica

Um sistema de monitoração de carga elétrica residencial, considerando diferentes cenários de aplicação, é desenvolvido nesta tese. Esse sistema é projetado usando-se redes neurais e PCD (*Análise de Componentes Principais de Discriminação*) para a compactação dos sinais.

A PCD é uma técnica que procura representar os dados em componentes principais que permitem uma melhor identificação de classes diferentes. Esta análise pode permitir uma alta compactação dos dados, sendo utilizada para projetos de classificadores compactos e eficientes. Essa técnica é comparada com a PCA (*Análise de Componentes Principais*) e os resultados são apresentados. O sistema é projetado usando-se apenas sinais transitórios colhidos da rede de alimentação AC para diferentes eletrodomésticos.

Realizamos a implementação desse sistema em diferentes cenários de aplicação, considerando-se o custo e a complexidade do processamento. Para tal, utilizamos microcontroladores, DSPs (Processadores Digitais de Sinais) e plataformas de processamento paralelo. Mais de 98% de eficiência de classificação foi obtida para o sistema proposto.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

AN ELECTRICAL RESIDENTIAL LOAD MONITORING SYSTEM FOR
DIFFERENT SCENARIO OF IMPLEMENTATION

Charles Bezerra do Prado

March/2006

Advisor: José Manoel de Seixas

Department: Electrical Engineering

The implementation of different scenarios of an electrical load monitoring system is presented in this thesis. The system is based on neural processing and principal discriminating analysis (PCD).

The PCD method directly searches for the principal components that are capable to perform class identification. Thus, the discriminating analysis can be allows very high levels of data compression, which can be translated into efficient and compact classifier designs. This technique is compared to PCA (principal component analysis) and both results are presented. The system is based on acquiring samples of the transient response from AC power line for different household appliances.

System implementations using both microcontroller and digital signal processor technologies and multiprocessing are evaluated according to cost and processing restrictions arising from different system operation scenario. More than 98% of classification efficiency is achieved by the proposed system.

Sumário

1	Introdução	1
1.1	Motivação para o desenvolvimento do projeto	3
1.2	Objetivo	7
1.3	Organização da Documentação	9
2	Revisão Bibliográfica	11
2.1	Sistemas de monitoração não-invasiva de cargas elétricas	11
2.2	Redes Especialistas	13
2.3	Utilização de Redes Neurais no Setor Elétrico	13
3	Materiais e Métodos	15
3.1	Sistema de Aquisição de Dados - DAQ	16
3.1.1	Pré-processamento dos Sinais - Análise Espectral	24
3.2	Análise de Componentes Principais (PCA)	27
3.3	Análise de Componentes Principais de Discriminação	28
3.4	Projeto e implementação da Rede Neural	30
3.4.1	Classificador Neural - Amostras híbridas	31
3.4.2	Redes Especialistas	36
3.4.3	Classificador Neural - Transitório	41
3.5	Aquisição de Dados Móvel - DAQM	44
3.6	DAQxDAQM - Estudo de Correlação	48
3.7	Análise de Componentes Principais de Discriminação - Considerações	50
3.7.1	Rede Neural com 60 amostras de entrada	57
3.8	Superposição de transitórios	58

4	Cenários de Implementação	62
4.1	Cenário 1	63
4.1.1	Implementação usando o Microcontrolador HCS08	64
4.1.2	Considerações sobre o resultado	64
4.2	Cenário 2	67
4.2.1	ADSP-21160M	67
4.2.2	Implementação e Resultados	69
4.3	Cenário 3 - Implementação usando arquitetura paralela de processamento	71
4.3.1	Multiprocessamento usando ADSP 21060	71
4.3.2	Considerações sobre os resultados	73
4.4	Implementação usando uma máquina paralela	75
4.4.1	Programação no Sistema TN-310	79
4.4.2	Implementação em 1 processador	82
4.4.3	Implementação Paralela	84
5	Conclusões	89
A	Eletrodomésticos	102
B	Paralelismo	107
B.1	Paralelismo de Controle	107
B.2	Paralelismo de Dados	108
B.3	Paralelismo de Fluxo	109
B.3.1	Alguns fatores que reduzem a exploração do paralelismo . . .	110
B.4	Arquiteturas paralelas	112
B.5	Interconexões	114
B.6	Eficiência e “speed-up” de um processamento paralelo	117

Lista de Figuras

1.1	Distribuição do consumo energético por setores de atividade	4
2.1	Topologia de um sistema especialista para informações distintas	14
3.1	Sistema de Aquisição de Dados	17
3.2	Transitório típico de um refrigerador.	19
3.3	Transitório típico de um chuveiro elétrico - posição inverno	19
3.4	Transitório típico de um aspirador de pó	20
3.5	Transitório típico de um circulador	20
3.6	Transitório típico de uma lâmpada incandescente	21
3.7	Transitório típico de uma lâmpada fluorescente - reator convencional .	21
3.8	Mapeamento dos Eletrodomésticos no plano $Ix\theta$	23
3.9	Transitório de um refrigerador.	25
3.10	Transitório de um chuveiro elétrico - posição inverno	25
3.11	Transitório de um aspirador de pó	26
3.12	Curva de carga acumulativa da PCA	28
3.13	Extração de componentes de discriminação principal: primeira (acima) e M-ésima (abaixo) componentes.	29
3.14	Histograma das saídas da rede neural para eventos da classe 1(a), da classe 2(b) e da classe 3(c)	34
3.15	Histograma das saídas da rede neural para eventos da classe 5(a), da classe 6(b) e da classe 7(c)	35
3.16	Topologia de uma rede neural composta por sub-redes neurais especialistas para informações do transitório e do regime permanente	37
3.17	Curva do erro médio quadrático durante o treinamento da rede 8-4-7	39
3.18	Transitório típico de um refrigerador.	47

3.19	Transitório típico de um aspirador de pó	47
3.20	Transitório de típico de um microondas	48
3.21	Reconstrução Transitório da Classe 1 - Acima Primeira PCD - Abaixo Segunda PCD	52
3.22	Reconstrução Transitório da Classe 3 - Acima Primeira PCD - Abaixo Segunda PCD	52
3.23	Reconstrução Transitório da Classe 7 - Acima Primeira PCD - Abaixo Segunda PCD	53
3.24	Reconstrução Transitório da Classe 1 - Acima Primeira PCA - Abaixo Segunda PCA	53
3.25	Reconstrução Transitório da Classe 3 - Acima Primeira PCA - Abaixo Segunda PCA	54
3.26	Reconstrução Transitório da Classe 7 - Acima Primeira PCA - Abaixo Segunda PCA	54
3.27	Projeções das entradas nas 2 PCDs	56
3.28	Projeções das entradas nas 2 PCAs	56
3.29	Projeções das entradas nas 2 PCDs	58
3.30	Superposição da classe 1 com eventos da classe 5, iniciando da amostra 40	61
3.31	Superposição completa (60 amostras) da classe 1 com eventos da classe 5	61
4.1	arquitetura Interna do microcontrolador HCS08	65
4.2	Ambiente de programação e simulação - HCS08	66
4.3	Arquitetura Interna do ADSP-21160M - extraído de [82]	69
4.4	Memória Compartilhada do ADSP-21060 - extraído de [85]	72
4.5	Arquitetura do Sistema TN-310 e interconexões entre as duas placas de processadores.	76
4.6	Arquitetura Interna do Transputer T9000	77
4.7	Roteamento dos Pacotes.	77
4.8	Arquitetura Interna do ADSP 21020.	78
4.9	As diversas camadas de programação disponíveis no Sistema TN-310.	80
4.10	Montagem de um código executável	81

4.11	Exemplo de uma look-up table	83
4.12	Estrutura Básica mestre-escravo da Implementação do Sistema de Monitoração.	84
4.13	TN-310 - Conexões dos diversos nós de HTRAM	86
B.1	Paralelismo de Controle	108
B.2	Paralelismo de Dados	109
B.3	Paralelismo de Fluxo	110
B.4	Computador S.I.S.D	112
B.5	Computador S.I.M.D	113
B.6	Computador M.I.M.D	114
B.7	Computador M.I.S.D	114
B.8	Troca de mensagens entre processadores através de uma rede chave- amento	115
B.9	Sistema de memória compartilhada	116

Capítulo 1

Introdução

Uma das grandes preocupações nos dias de hoje é com o compromisso de um uso racional dos recursos naturais que proporcione a preservação do meio ambiente e a satisfação daqueles que se utilizam desses recursos. A energia elétrica advinda das usinas hidrelétricas, termelétricas ou usinas nucleares é uma das fontes de energia que o homem tem extraído da natureza, e por ser um recurso finito, o seu uso tem se tornado cada vez mais alvo de preocupação por órgãos governamentais e não-governamentais.

No Brasil, de acordo com dados da Eletrobrás [1], o consumo de energia elétrica aumentou de 40TWh em 1970 para 336TWh em 2003. Esse alto crescimento ocorreu devido a alguns fatores:

1. Crescente procura pelo serviço de eletricidade, seja pela modernização da sociedade, seja pelas tarifas favorecidas pelas quais o serviço foi prestado;
2. Preocupação com a adequação da oferta do serviço à demanda dos consumidores, seja pela expansão dos sistemas de geração e transmissão, seja pela preocupação permanente com a universalização do serviço.

O número total de consumidores passou de 6,8 milhões, em 1970, para 53,4 milhões em 2003, sendo 7,9 milhões de consumidores não-residenciais e 45,5 milhões de consumidores residenciais. Com isso a proporção de domicílios atendidos passou de 45%, em 1970, para 85% em 2003 [1].

O crescimento do consumo energético, além de estar diretamente relacionado com o crescimento populacional, também tem uma relação direta com o crescimento

econômico do país nas últimas décadas. De acordo com [1], a correlação das taxas de crescimento do PIB (Produto Interno Bruto) com as taxas de crescimento do consumo de energia elétrica, para o período entre 1970-2003, é de 0,75. Para um país como o Brasil, que está em desenvolvimento, faz-se necessário um acompanhamento profundo de como esse fornecimento de energia tem-se dado, para se permitir um crescimento sustentável da economia.

A qualidade e a eficiência, tanto no fornecimento como no uso da energia elétrica, são fundamentais para que o país possa planejar a expansão de suas indústrias, dos serviços de comércio e também atender a demanda que se impõe pelo crescimento populacional. Uma péssima qualidade, por exemplo, nas linhas de transmissão pode acarretar quedas de energia que acabam prejudicando as indústrias, o comércio e a população em geral. Por sua vez, um sistema ineficaz irá proporcionar desperdícios de uma energia que poderiam estar sendo utilizada para outros fins [2, 3].

A COELBA (Companhia de Eletricidade do Estado da Bahia) realizou, com participação de alguns municípios, um projeto de conscientização de alunos e professores da rede municipal quanto ao uso eficiente da energia elétrica. Este projeto é um exemplo da preocupação em se obter um uso mais racional da energia elétrica [4].

Atualmente, existem duas formas de pesquisas de hábitos de consumo:

- Levantamento através de entrevistas e questionários - Não se utiliza aparelhos de medição, faz uso de profissionais do governo que realizam a pesquisa através de questionários. Sua grande vantagem é a abrangência de grandes áreas, mas tem a desvantagem de adquirir informações imprecisas, pois um residente pode omitir algumas informações com relação a suas posses de eletrodomésticos, motivado pela presença de um “estranho” em sua residência. Normalmente essas pesquisas são chamadas de “Pesquisas de Posse de Eletrodomésticos e Hábitos de Consumo”, e é a mais utilizada, atualmente, no Brasil [5, 6, 7].
- Levantamento por medições - Para este tipo de pesquisa são utilizados equipamentos que estimam o consumo de energia elétrica [8], normalmente com um custo elevado de implementação. Para medições realizadas externamente à residência, considera-se o sistema como *não-invasivo*.

A técnica de monitoração não-invasiva se mostra mais vantajosa em relação aos outros métodos possíveis pelo fato de o monitoramento de carga elétrica ser feito por um sistema que interfere o mínimo possível com o cotidiano da residência. O levantamento de informações (tais como demanda de potência ativa e reativa, corrente, tensão, fase e temperatura) pode ser feito sem que o residente seja incomodado com a invasão de uma pessoa estranha em sua residência para realizar o monitoramento da carga elétrica.

No desenvolvimento de projetos de equipamentos que venham a adquirir dados de consumo energético de forma não-invasiva, é importante ressaltar a necessidade de uma implementação flexível às mudanças no uso da energia elétrica, por exemplo, com o surgimento de um novo eletrodoméstico, de um processamento veloz dos sinais, para se evitar perdas de informações, e de um custo aceitável para utilização, se preciso, em grande escala.

1.1 Motivação para o desenvolvimento do projeto

Com a crescente demanda das últimas décadas no fornecimento de energia elétrica em escala mundial, a preocupação em conhecer as características ou o histórico desse crescimento tem se tornado extremamente importante. Frequentemente surgem questionamentos como: em que setor de consumo (industrial, comercial, residencial, etc.) esse crescimento se dá de forma mais acentuada? Como adquirir dados que nos permitam monitorar esse crescimento? A formulação destas questões direciona a tomada de ações por parte do governo e das empresas fornecedoras de energia, perseguindo um crescimento sustentável no fornecimento de energia elétrica.

No Brasil, as taxas anuais de consumo de energia elétrica vêm se elevando. Podemos verificar, com base no relatório anual 2003/2004 [1] de consumo energético fornecido pela Eletrobrás, que as taxas de energia por setores de atividades vêm crescendo nos últimos anos. Esse relatório aponta, também, para um contínuo aumento dessas taxas para os próximos 10 anos. Essas projeções futuras são extremamente importantes para um planejamento de expansão e melhorias do setor elétrico.

Para o setor residencial, que responde por cerca de 1/4 da demanda total

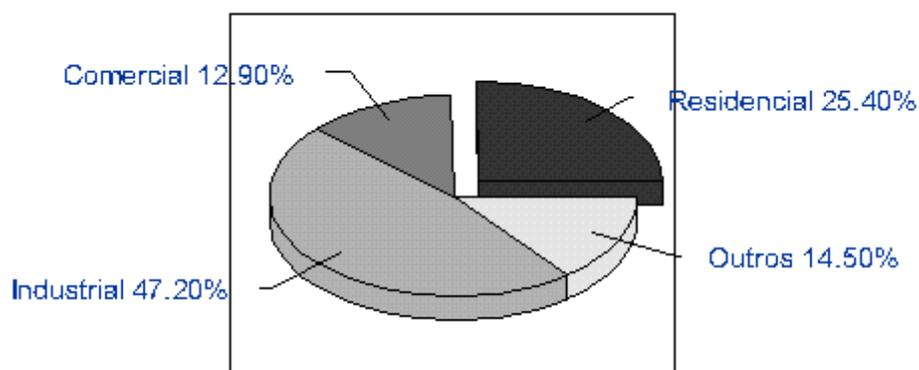


Figura 1.1: Distribuição do consumo energético por setores de atividade

(310TWh) de energia elétrica (Figura 1.1), ocorreu no biênio 2003/2004 um crescimento em torno de 3% [9]. Esse crescimento nos últimos anos tem se caracterizado por uma preocupação do governo e dos órgãos fornecedores de energia em adquirir dados de posse e utilização de eletrodomésticos [5], não só com fins de monitoramento do crescimento do consumo, como também para verificar de que forma a introdução de novos eletrodomésticos podem impactar o fornecimento de energia elétrica.

O PROCEL (Programa ao Combate ao Desperdício de Energia Elétrica) é um exemplo de projeto desenvolvido pela Eletrobrás com a finalidade de conscientizar a população da necessidade de economizar energia elétrica, principalmente em horários em que o consumo se mostra mais elevado (“horários de pico”). Este programa visa também a determinar um padrão de qualidade para os diversos equipamentos eletrodomésticos, para se minimizarem as perdas associadas aos equipamentos que consomem além do especificado pelas normas técnicas. Ainda como parte do projeto, entre o período de 1996 e 2000, o PROCEL e algumas concessionárias de energia realizaram levantamentos de posse e de utilização de eletrodomésticos em cidades como Porto Seguro e Vitória da Conquista (Bahia), Santarém (Pará), etc. [7].

O uso indevido da energia elétrica também é uma fonte de preocupação para

o governo e as concessionárias de energia elétrica, pois esse consumo não entra em nenhum relatório de consumo. Hoje, em grandes cidades como Rio de Janeiro e São Paulo, verifica-se um aumento do índice de energia “roubada” (os chamados “gatos” de residências). Uma medida preventiva, em alguns bairros do Rio de Janeiro, vem sendo realizada pela Light (concessionária de energia no município do Rio de Janeiro) através da instalação de aparelhos medidores de energia nos postes, e não mais no interior das residências, evitando, assim, que a energia que chega na residência seja desviada antes de se chegar nos medidores. Mas o custo para se modificar milhares de residências torna inviável essa medida. Como, então, monitorar e detectar fraudes no uso da energia elétrica residencial?

Hoje, no Brasil, não é possível obter-se uma auditoria para a utilização de energia por um usuário final. Se imaginarmos que isso seria possível, empresas ou pessoas poderiam solicitar às concessionárias que fizessem uma auditoria para fornecer informações detalhadas do uso de energia, indicando as horas do dia de maior consumo e os equipamentos responsáveis pelo possível aumento de consumo. Resultados dessa auditoria seriam úteis tanto para o usuário final, que poderia tomar ações para melhorar a utilização da energia, como para as próprias concessionárias e governo, que teriam dados que forneceriam características detalhadas de como o usuário tem utilizado a energia elétrica disponível. Mas como adquirir esses dados de forma não-invasiva, isto é, sem estar 24h por dia numa residência, observando os hábitos desse consumidor?

Em alguns países da Europa, como a Suécia, o fornecimento de energia elétrica ao consumidor pode ser feito por diferentes empresas privadas, o cliente pode escolher a companhia que lhe fornecerá a energia elétrica. Essas empresas, por sua vez, tentam atrair os clientes oferecendo preços acessíveis, qualidade no serviço, um bom atendimento ao cliente e outras vantagens. Caso essas empresas possam monitorar e, assim, conhecer o perfil de seu usuário, serviços diferenciados ao cliente podem ser oferecidos como a monitoração e previsão de falhas de equipamentos eletrodomésticos: um serviço de manutenção, neste caso, poderia entrar em contato com o cliente e avisar sobre a possibilidade de ocorrer defeito num equipamento. Através dessa monitoração, essas empresas conheceriam o perfil sócio-econômico de seu cliente; essas informações poderiam ser requisitadas por outras empresas, como

bancos, lojas de eletrodomésticos para oferecimento de serviços ou venda de produtos, etc.; seria um *Marketing* de produtos e serviços direcionados para clientes específicos. Hoje, na Europa, essa troca de informações dos clientes entre empresas acontece de forma mais freqüente. Então, dentro desse contexto, um sistema de monitoração não-invasiva poderá ser útil para as empresas de fornecimento de energia elétrica.

Com o crescimento das cidades no Brasil, um conhecimento contínuo de como esse crescimento tem impactado a demanda de energia elétrica é fundamental para se realizar um planejamento eficiente no fornecimento de energia elétrica, que atenda às necessidades de consumo elétrico de indústrias, comércio e moradores daquela região. Essa monitoração poderá evitar ou postergar gastos elevados para contornos de situações inesperadas, como por exemplo um aumento elevado de carga elétrica não esperado, que pode ocasionar interrupções no fornecimento de energia, devido à queima de transformadores.

A motivação para o desenvolvimento deste trabalho vem da tentativa de responder as perguntas colocadas anteriormente. Monitorar o uso e consumo de energia elétrica residencial pode ser uma ferramenta poderosa para direcionar projetos que melhorem ou aumentem o fornecimento de energia elétrica de uma determinada região de nosso país ou, ainda, para alcançar um dos pontos que listamos abaixo:

- Monitoração de falhas no fornecimento de energia elétrica. E, conseqüentemente, um acionamento dos serviços de manutenção ao cliente de forma mais eficaz;
- *Marketing* de produtos específicos (eletrodomésticos e até outros) para um determinado perfil sócio-econômico de um usuário, obtido a partir da monitoração;
- Em um possível processo de privatização no fornecimento de energia elétrica, fornecer aos clientes a possibilidade de acompanhar o seu consumo diário, sendo esta uma forma de o cliente validar o custo de utilização da energia elétrica cobrado pela concessionária;
- Monitorar novos eletrodomésticos que venham a ser introduzidos no mercado, caracterizando o impacto desses produtos no consumo energético, de forma

que essa monitoração permita a qualificação ou não deste produto. O selo PROCEL de equipamentos eletrodomésticos, é exemplo de um processo de qualificação e acompanhamento de novos eletrodomésticos que aparecem no mercado; equipamentos com esse selo dão ao consumidor a garantia de serem equipamento eficientes, evitando desperdícios no consumo de energia elétrica.

1.2 Objetivo

Este trabalho está inserido em uma linha de pesquisa cujo objetivo é desenvolver um sistema de monitoração não-invasiva de cargas elétricas em residências usando rede neurais no processamento principal desses dados, para se obter resultados finais que indiquem claramente o perfil de consumo de uma residência ou de diversas residências. Os sistemas neurais que estudaremos identificarão as diversas cargas residenciais (refrigeradores, ventiladores, equipamentos eletrônicos e outros que veremos mais a frente) a partir de sinais amostrados da rede elétrica. A caracterização desses sinais será feita através da aquisição de amostras da resposta ao transitório de corrente e de variáveis relativas ao estado estacionário de diferentes classes de eletrodomésticos.

No entanto, nem sempre é possível se obter uma quantidade de dados considerável que represente estatisticamente os eletrodomésticos, o que implica a necessidade de projetarmos sistemas compactos e pouco complexos. E como um mesmo tipo de equipamento eletrodoméstico apresenta diferenças em suas especificações técnicas (corrente, potência utilizada, etc.) para cada fabricante, torna-se necessário agrupar em classes equipamentos com características semelhantes.

A implementação de um sistema de monitoração está diretamente ligada ao número de residências a serem monitoradas (granularidade) e ao custo dessa implementação. Uma monitoração com menor granularidade seria aquela em que a Eletrobrás, por exemplo, quisesse levantar o perfil de consumo de cada residência (a menor unidade de monitoração) de uma determinada região, para tomada de alguma ação preventiva ou de planejamento de expansão no fornecimento de energia. Aumentando-se a granularidade, um sistema de monitoração poderia ser um que monitorasse um condomínio de casas ou um bloco de apartamentos, o que implicaria

uma implementação mais complexa, uma vez que cresce a quantidade de dados armazenados e que serão processados. Ainda maior granularidade teria um sistema com uma arquitetura paralela, por exemplo, adquirindo e processando dados de área de abrangência de um bairro por exemplo; nitidamente, este se constituiria um sistema muito complexo e de alto custo. Neste trabalho estaremos implementando sistemas capazes de adquirir e processar pequenas, médias e grandes quantidades de dados de monitoração de cargas elétricas residenciais.

Abaixo, definimos os cenários de implementação propostos neste trabalho.

- 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, onde 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 bloco de residências, uma unidade de aquisição de dados é instalada e os dados adquiridos são transferidos para uma unidade de processamento local que processa esses dados. Podem, também, ser transferidos posteriormente 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 ao 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 uma elevada quantidade de dados chegando à unidade central de processamento, que, por sua vez, deverá ser rápida o suficiente para não descartar nenhum sinal enviado;
- Cenário 4 - É um cenário híbrido. Ele considera que a aquisição será feita por

um dispositivo com um microcontrolador (cenário 1) para cada residência a ser monitorada e posteriormente esses dados serão colhidos e analisados por central de processamento (cenário 3). Este cenário foi proposto pelo CEPEL (Centro de Pesquisas de Energia Elétrica - Eletrobrás), para que neste trabalho verificássemos a sua viabilidade.

Com base nas características dos cenários de implementação, propomos quatro 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) de uso geral instalado em cada residência;
- 2 - Uma segunda maneira de implementação utiliza uma unidade de processamento central (um DSP com capacidade de multiprocessamento) sendo alimentada por dados adquiridos de alguns blocos residenciais (cenário 2) ou de um prédio de apartamentos;
- 3 - A terceira implementação considera a aquisição de grandes agrupamentos de residências (cenário 3). Utilizaremos uma arquitetura paralela com 4 DSPs e um sistema de plataforma paralela composto de 16 DSPs;
- 4 - Esta implementação será um hibridismo de 1 e 3. A aquisição dos dados de uma residência será feita através de um microcontrolador, realizando uma possível compactação dos dados, e o processamento desses dados feito em uma máquina externa, que poderá ser uma plataforma paralela.

1.3 Organização da Documentação

Esta tese é estruturada em 5 capítulos. Logo após esta introdução, o capítulo 2 apresenta uma revisão bibliográfica sobre sistemas de monitoração de cargas elétricas, com enfoque para os não-invasivos, também relata a utilização de redes especialistas e a utilização das redes neurais no setor elétrico.

O capítulo 3 descreve os dois sistemas de aquisição de dados utilizados neste trabalho. O método de análise de componentes principais de discriminação (PCD)

é apresentado e utilizado para projetos de classificadores neurais compactos e com altas eficiências, os resultados são comparados com outros métodos. Ainda, neste capítulo é realizado um estudo de correlação entre os dados adquiridos por cada um dos sistemas de aquisição. Este capítulo traz um estudo que indica quais informações do espaço de entradas foram extraídas pelas redes neurais projetadas através da análise PCD. Finalmente, a última seção descreve o comportamento de um classificador neural quando ocorrem eventos superpostos.

O capítulo 4 aborda os cenários de implementação. Discuti-se as tecnologias usadas para o desenvolvimento desses cenários, como: Microcontroladores, DSPs e máquinas paralelas, e os resultados obtidos. E finalmente, o capítulo 5 faz uma análise crítica das inovações que esse trabalho trouxe, apresenta as conclusões e propostas de trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

2.1 Sistemas de monitoração não-invasiva de cargas elétricas

Um dos primeiros trabalhos realizados sobre monitoração não-invasiva de cargas elétricas foi o desenvolvido pelo professor Fred Schweppe e pelo Dr. George Hart, na década de 1980 [8], ambos da Universidade de Massachussets, sendo até hoje considerado a principal referência de diversos outros trabalhos que se seguiram nesta área.

Este trabalho apresenta uma metodologia de análise de cargas individuais ou de grupos de cargas de uma residência através da identificação da mudanças de valores de potência ativa e reativa (estado estacionário). Essas mudanças de valores em estado estacionário, chamadas de eventos, correspondem aos instantes em que as cargas são ligadas e desligadas, e são descritos pela magnitude e sinal das potências ativa e reativa. Logo, eventos adquiridos com igual magnitude e sinais opostos tendem a caracterizar um determinado tipo de carga elétrica. Esse processo de detecção de mudanças de valores em estado estacionário foi a base da implementação de um versão comercial deste trabalho.

Em [8] é descrito um algoritmo para desagregar cargas a partir da alteração dos valores da potência ativa e reativa. O algoritmo é dividido em cinco etapas, abaixo enumeradas:

- Passo 1 - Um detector de alteração de potência é usado para se obter os valores

de potência devido ao acionamento ou desligamento de um equipamento;

- Passo 2 - Esses valores são mapeados num espaço 2D de potência ativa x potência reativa (plano ΔP x ΔQ);
- Passo 3 - Valores iguais (ou bem próximos) mas opostos pelo sinal são agrupados, formando pares que representam o acionamento ou desligamento de um equipamento;
- Passo 4 - Valores não representados conforme o item anterior ou são agrupados a pares já existentes, usando um algoritmo de máxima semelhança, ou podem representar um novo agrupamento ou simplesmente são descartados. Neste caso é considerado que ocorreu um evento espúrio;
- Passo 5 - Os pares de agrupamento são associados ao consumo de energia de cargas conhecidas para se determinar o uso de cada uma das cargas individuais. Obtém-se, assim, o perfil de consumo daquela residência.

A partir deste trabalho inicial, outros trabalhos surgiram com propostas de melhorias sobre este [10, 11, 12, 13, 14, 15, 16, 17]. Esses trabalhos apresentam, em sua grande parte, modificações no algoritmo apresentado anteriormente, com relação à forma como se detectam as transições de potência, com relação ao agrupamento em classes etc. De qualquer forma consideram-se somente informações em regime permanente.

Os estudos citados acima, que consideraram informações em regime permanente, deram bons resultados quando a monitoração se referiu a uma única residência, pois neste ambiente, os eventos ocorrem esporadicamente e se observa uma pequena quantidade de cargas. Para uma análise que considere, por exemplo, blocos de residências ou uma grande quantidade de cargas, os dados de potência ou de outras informações em regime permanente não são suficientes para se obterem os mesmos resultados, o que implicou uma abordagem que considerasse o transitório como informação relevante para melhor discriminação das cargas.

Trabalhos que apontam para uma análise diferente foram propostos por Steven B. Leeb [18, 19, 20, 21], também da Universidade de Massachussets. Neste

caso, propõe-se uma análise de identificação de cargas elétricas considerando-se informação do transitório do equipamento quando este é ligado. Para se identificar cada um dos eventos, utiliza-se filtro transversal ou filtro casado. Estes filtro, em resumo, faz a correlação ou produto escalar entre o evento identificado e os padrões existentes (*templates*). O transitório é associado à classe do *template* que apresentar maior saída no filtro.

2.2 Redes Especialistas

Um sistema especialista [22] baseia-se no conhecimento, sendo especialmente projetado para emular a especialização humana em algum domínio específico. Um sistema especialista é fundamental para soluções de problemas complexos e muito específicos.

As redes neurais especialistas [23, 24, 25, 26, 27, 28, 29, 30], analogamente à definição acima, seriam sistemas capazes de aprender e se especializar em um conjunto de dados que representam uma determinada característica do sistema. Para cada informação de natureza diferente desse sistema, pode-se utilizar uma rede neural para se especializar nessa informação. Cada rede neural especialista funciona como um extrator de características para cada um dos tipos de informação, assim se obtêm sistemas com conhecimento profundo em informações diferentes. Esse conhecimento específico, adquirido por cada rede especialista, pode posteriormente ser uma base de informação para um outro sistema, que pode analisar essa informação para tomada de alguma decisão, que pode ser: detecção de algum padrão de entrada, separação de eventos e etc.

A Figura 2.1 representa a topologia de um sistema neural composto por duas sub-redes neurais especialistas em informações diferentes e uma terceira rede neural funcionando como uma agregadora do conhecimento extraído pelas sub-redes neurais.

2.3 Utilização de Redes Neurais no Setor Elétrico

Hoje em dia, muitos trabalhos têm sido desenvolvidos com o objetivo de identificar automaticamente padrões, tendo como enfoque a inteligência computa-

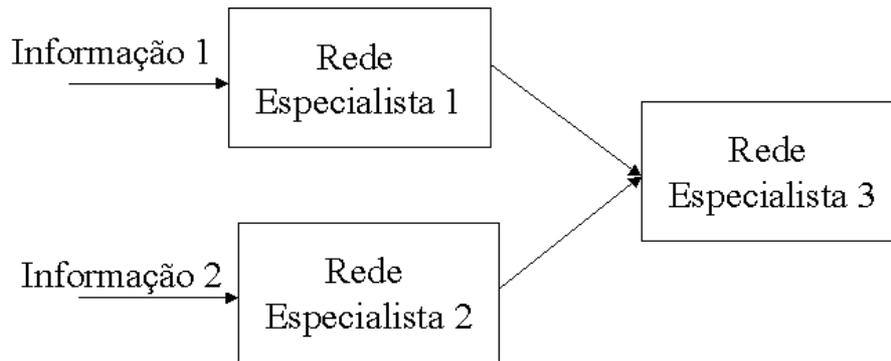


Figura 2.1: Topologia de um sistema especialista para informações distintas

cional, empregando-se rede neurais e sistema híbridos com lógica nebulosa [31, 32]. Para os casos em que as redes neurais têm sido utilizadas, os resultados obtidos têm sido bons, por exemplo, no reconhecimento de voz, sinais de sonar, caracteres manuscritos e outros [30, 33, 34, 35, 36].

Com relação ao setor elétrico, encontramos diversos trabalhos que se utilizam de redes neurais, principalmente para detecção, localização e classificação de falhas na geração e transmissão de energia elétrica [37, 38, 39, 40, 41, 42]. Dentre essas aplicações, aquela que mais se assemelha à identificação de eventos liga/desliga de cargas elétricas é a localização de falhas em redes de transmissão/distribuição. O parâmetro usado para identificação é a forma de onda do transitório.

As rede neurais também vêm sendo utilizadas em trabalhos que permitam se ter uma previsão de carga elétrica a ser demandada para uma região de consumidores. Existem dois tipos de previsão :

1. *Short-Term* - é a previsão de carga para um período em torno de 24h.
2. *Long-Term* - é a previsão de carga para períodos de um mês até anos à frente.

Um previsão para períodos curtos (*Short Term*) permite economia e uma operação segura do sistema de energia elétrica [43, 44, 45, 46, 47, 48, 49]. As previsões para períodos maiores (*Long Term*) são essenciais para um planejamento de expansão eficiente do sistema elétrico [50, 51, 52, 53, 54, 55].

Capítulo 3

Materiais e Métodos

As pesquisas de posse de eletrodomésticos e hábitos de consumo [5, 6] realizadas nos últimos anos no Brasil serviram como referência para definirmos e selecionarmos os equipamentos eletrodomésticos mais utilizados em uma residência. No anexo A, listamos os eletrodomésticos mais presentes em residências no Brasil.

Um outro ponto que consideramos foi a definição quanto à informação relevante na definição do sinal de um eletrodoméstico. Os trabalhos anteriores apontam para a utilização de dados como potência ativa e potência reativa em regime permanente [8, 10, 11, 12, 13] e regime transitório da corrente de partida [18, 19, 20]. Como já visto, anteriormente, os resultados dos sistemas de monitoração que se utilizam dos dados de potência dos eletrodomésticos deram bons resultados quando a quantidade de cargas a serem monitoradas se restringiu à de uma única residência. Por outro lado, a utilização da informação do transitório de corrente permitiu uma abrangência maior na quantidade de cargas que poderiam ser monitoradas.

Estaremos considerando como uma das base de dados aquela que foi utilizada em [56]. A aquisição desses dados foi realizada em laboratório, no CEPEL (Centro de Pesquisa de Energia Elétrica), sendo adquirido tanto informações de regime permanente, como também os transitórios de partida de corrente dos eletrodomésticos. Na seção seguinte, detalharemos os processos de aquisição dos dados de transitório e regime permanente, as análises propostas neste trabalho e as considerações sobre o resultados que obtivemos, comparando-os com os resultados obtidos em [56].

Uma outra base de dados a ser analisada neste trabalho se refere à aquisição de dados que realizamos em parceria com o CEPEL, utilizando uma unidade de aqui-

sição residencial móvel. Esta unidade, ainda em forma de protótipo, foi utilizada para adquirir transitórios de eletrodomésticos em 6 residências do bairro Anchieta, no município do Rio de Janeiro. Na seção 3.5, descrevemos detalhadamente o equipamento do CEPEL utilizado para esta aquisição, a caracterização dos transitórios de corrente adquiridos, e as análises e resultados que propusemos para esses dados. E ao final, comparamos qualitativamente os nossos resultados com a análise atualmente utilizada pelo CEPEL para monitoração de cargas elétricas. Realizaremos, também, uma análise de correlação dos dados dessa aquisição com os dados adquiridos em [56] de forma a apontar a viabilidade de usarmos conjuntamente esses dados e se o modelo de análise que adotaremos será robusto a conjuntos de dados que abrangem os mesmos eletrodomésticos mas apresentam diferenças em sua forma de aquisição.

Propusemos para ambas aquisições estudos de compactação dos sinais transitórios de corrente. Buscaremos sempre em nossas análises uma representação mínima do espaço de entradas, isto é, uma representação que contenha somente as informações relevantes do espaço original. Para compactação desses sinais proporemos a técnica PCD (Análise de Componentes Principais de Discriminação) e mostraremos a vantagem dessa escolha comparando com a análise PCA (Análise de Componentes Principais).

A necessidade de uma técnica de compactação está contida dentro de nossa proposta inicial de podermos desenvolver plataformas de implementação que atendam à dicotomia de custo de implementação e quantidade de dados (que cresce proporcionalmente com o número de residências) a serem processados, garantindo que cada um dos cenários propostos neste trabalho seja realizável. Então, compactar os sinais adquiridos nos traz a potencialidade de implementações mais simples e com custos reduzidos, permitindo, assim, a implementação de cada um dos cenários propostos neste trabalho (seção 1.2).

3.1 Sistema de Aquisição de Dados - DAQ

Este sistema, que foi utilizado em [56], adquiriu transitórios de corrente de partida dos eletrodomésticos e informações de regime permanente (ângulo de fase

entre corrente e tensão, e corrente aparente) dos equipamentos eletrodomésticos.

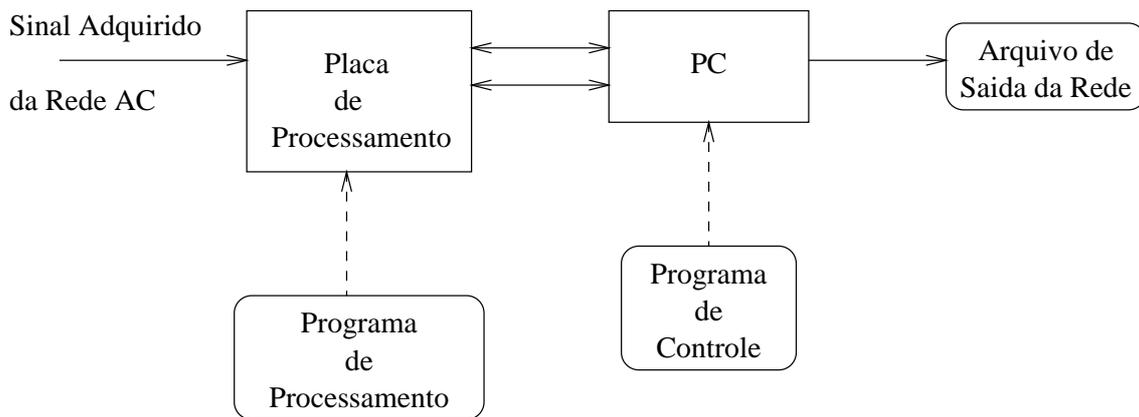


Figura 3.1: Sistema de Aquisição de Dados

A Figura 3.1 mostra como os dados foram adquiridos da linha AC. A resposta ao transitório foi obtida a partir de amostras do sinal em um osciloscópio digital (que na Figura está indicado como placa de processamento), sendo estas amostras guardadas posteriormente em um disco rígido. Para se obter as amostras do transitório de um equipamento, o equipamento foi conectado à linha AC que alimenta o sistema de aquisição de dados.

Em [56], para cada eletrodoméstico foi utilizada uma taxa de amostragem de 512 amostras por segundo, durante um intervalo de 2 segundos. Esta taxa foi escolhida para se preservar as informações espectrais do sinal original (sinal de 60Hz) e também se obter informações sobre o 3º harmônico de corrente do transitório. Para adquirir esses transitórios utilizou-se:

1. Um osciloscópio digital da HP (Hewlett-Packard), modelo HP 1631D, com largura de banda de 100MHz.
2. Unidade de acionamento de disco flexível da HP, com capacidade de armazenamento de 1 Mbyte em disco flexível de 3-1/2".

Para se adquirir os dados de regime permanente, utilizaram-se os seguintes equipamentos:

1. Transdutor combinado de potência ativa e reativa (Watt e VAr) da RIS (Rochester Instrument System, Inc)

2. Multímetro com duplo *display* da Fluke
3. Transformador de corrente, fabricado pelo CEPEL, com largura de banda $> 100\text{Mhz}$ e relação de transformação 2600:1

Adquiriram-se valores de potência ativa e reativa, bem como o valor de tensão em regime permanente. O trabalho realizado por George Hart [8] sugere a representação destas informações sobre um plano formado pelos eixos de potência ativa P , e reativa, Q , ou ainda numa representação sobre o plano de corrente aparente (I) versus ângulo de fase (θ). Ambas indicam representações de variáveis linearmente independentes. No entanto, optou-se pela representação de ângulo de fase versus corrente aparente, por proporcionar maior facilidade em sua implementação física, na qual se poderia utilizar um transformador de corrente acoplado a um conversor A/D, por exemplo. Já as representações usando os dados de potência exigiriam uma implementação mais complexa para obtenção dos dados [8].

Essas informações da forma de onda do transitório e do regime permanente (valor da fase e da corrente) permitiu que se agrupassem os diversos equipamentos de eletrodomésticos em classes com características similares. Tomaram-se como base trabalhos apresentados na revisão bibliográfica que sugerem o agrupamento da eletro-diversidade em classes [10], considerando-se o efeito elétrico predominante, que pode ser:

- Amplitude da corrente ou potência demandada;
- Fator de potência;
- Forma do transitório de partida, normalmente da corrente;
- Conteúdo harmônico.

As definições das classes de eletrodomésticos foram feitas com base nas principais características dos transitórios, bem como nas características em regime permanente.

Nas Figuras 3.2, 3.3, 3.4, 3.5, 3.6 e 3.7 são apresentados transitórios de corrente típicos das classes de eletrodomésticos considerados.

Para agrupamentos de eletrodomésticos com base na envoltória dos 6 transitórios, as principais características consideradas foram:

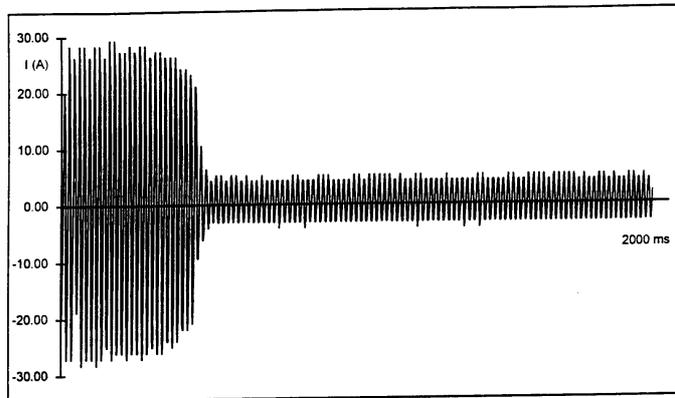


Figura 3.2: Transitório típico de um refrigerador.

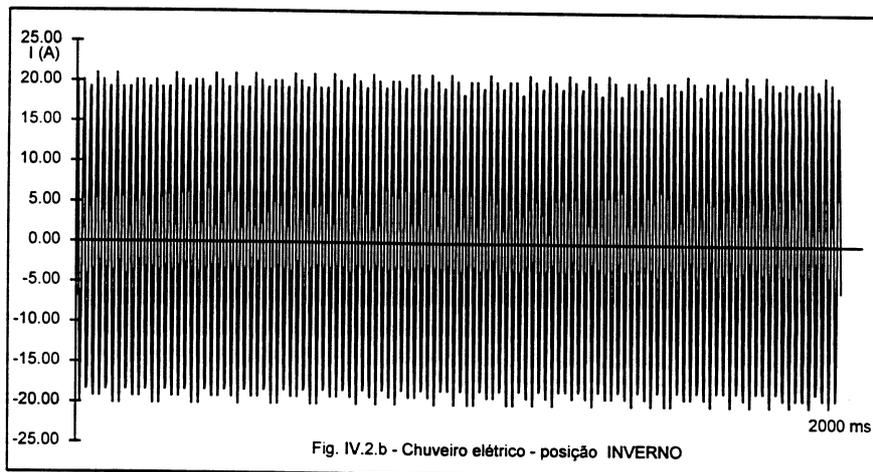


Figura 3.3: Transitório típico de um chuveiro elétrico - posição inverno

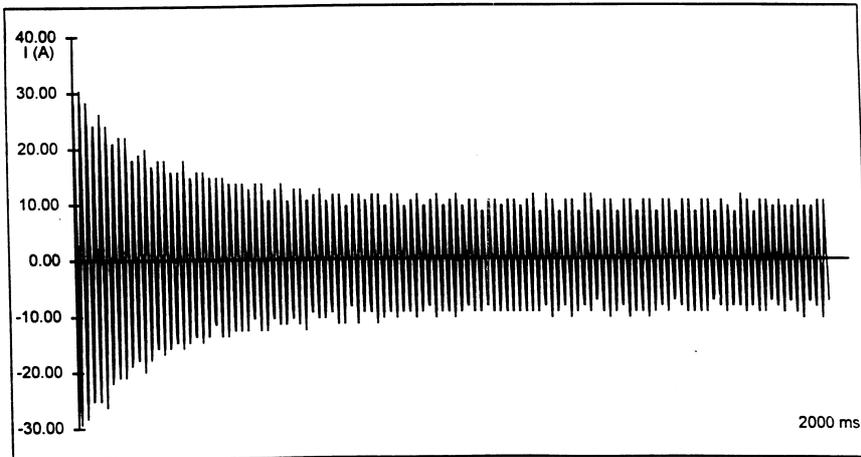


Figura 3.4: Transitório típico de um aspirador de pó

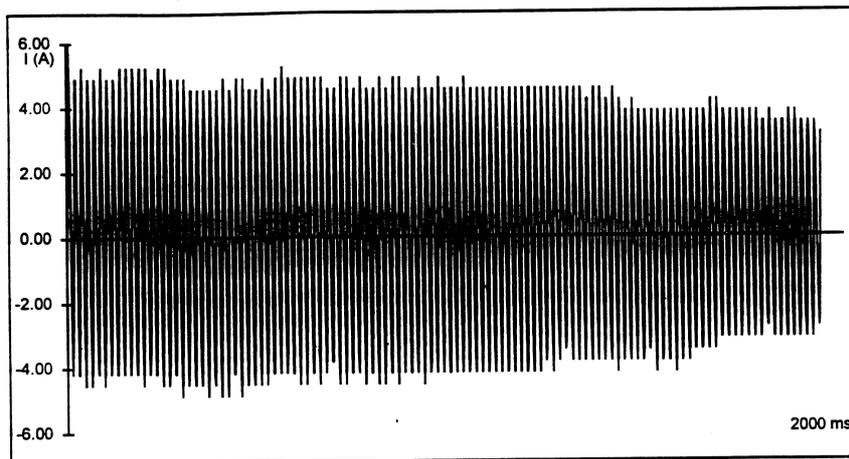


Figura 3.5: Transitório típico de um circulador

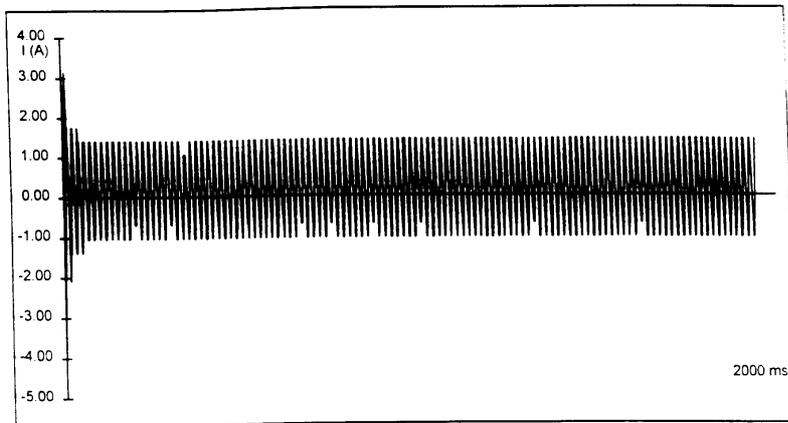


Figura 3.6: Transitório típico de uma lâmpada incandescente

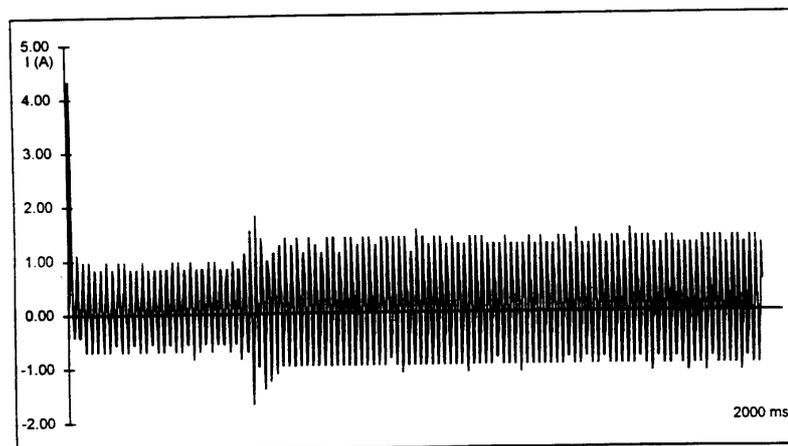


Figura 3.7: Transitório típico de uma lâmpada fluorescente - reator convencional

1. Dois patamares - amplitudes decrescentes - característicos de equipamentos de refrigeração: refrigeradores, *freezers*, condicionadores de ar.
2. Nível constante - característico de cargas resistivas para aquecimento, como chuveiros, torradeiras, ferros de passar, cafeteiras, etc.
3. Queda rápida (estabilização em menos de 10 ciclos de 60Hz) - característica de lâmpadas incandescentes e alguns equipamentos eletrônicos.
4. Queda exponencial intermediária (estabilização entre 10 e 60 ciclos de 60Hz) - características de motores universais, como liquidificadores, batedeiras e furradeiras. Também característica de alguns equipamentos eletrônicos de maior potência, como televisores de 20 polegadas ou mais.
5. Queda lenta (estabilização em mais de 60 ciclos de 60Hz) - características de motores de ventilação como circuladores e ventiladores.
6. Dois patamares - amplitudes crescentes - características de lâmpada de descarga. Neste caso, lâmpadas fluorescentes são praticamente o único exemplo em residências.

Para a caracterização em regime permanente, foi feito um mapeamento no plano $I \times \theta$ (Figura 3.8), onde I é a corrente aparente e θ é o ângulo de fase entre a tensão e a corrente. Nesta Figura, os quadriláteros de 1 a 7 definem as regiões ocupadas por eletrodomésticos de características semelhantes de regime permanente.

Os agrupamentos obtidos, de acordo com o mapeamento no plano $I \times \theta$ (ver Figura 3.8), foram:

1. Refrigeradores e *freezers*;
2. Equipamentos resistivos (ferros de passar roupa, chuveiros elétricos, secadores de cabelo, etc);
3. Lâmpadas incandescentes;
4. Motores universais (liquidificadores, batedeiras, aspiradores de pó etc);
5. Ventiladores em geral e circuladores;

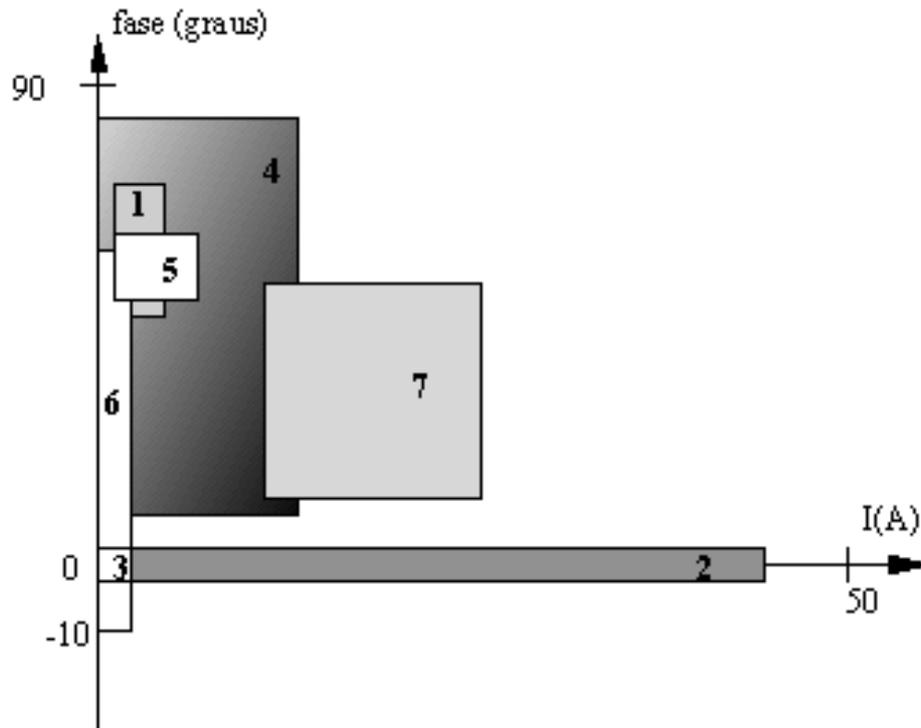


Figura 3.8: Mapeamento dos Eletrodomésticos no plano $I \times \theta$.

6. Equipamentos eletrônicos (videocassetes, televisões, etc) e lâmpadas fluorescentes;
7. Condicionadores de ar.

Verificamos que a caracterização das cargas elétricas domésticas por meio da envoltória dos transitórios permitiria a definição de 6 classes e pelas características de regime permanente, 7 classes deveriam ser criadas para completa caracterização destas cargas.

Em [56] foi construído um modelo para definição das classes de eletrodomésticos baseado principalmente nas características do transitório de partida. A separação por transitórios de partida dos eletrodomésticos foi usada pois os agrupamentos dos equipamentos eram mais evidentes e menos superpostos em comparação aos agrupamentos obtidos utilizando-se as características de regime permanente dos eletrodomésticos. Obtiveram-se as seguintes classes:

1. Refrigeradores.
2. Equipamentos resistivos.

3. Equipamentos de agitação, movimento, mistura.
4. Equipamentos de ventilação.
5. Equipamentos eletrônicos.
6. Lâmpadas incandescentes.
7. Lâmpadas fluorescentes.

3.1.1 Pré-processamento dos Sinais - Análise Espectral

Sobre as 1024 amostras obtidas no transitório, métodos de pré-processamento foram desenvolvidos para se obter uma redução da dimensão do espaço de amostras original, mantendo a preocupação com a preservação das informações originalmente relevantes. Esperava-se em [56] que essa preservação do conteúdo espectral do sinal original contribuisse para um discriminador neural mais eficiente. Argumentaremos nas seções seguintes sobre esse critério adotado, comparando-o com as análises de compactação do sinal transitório que propusemos.

Os transitórios adquiridos tinham suas formas definidas pela envoltória de 60Hz, de maneira que essas envoltórias foram extraídas tomando-se apenas os módulos de picos de corrente. Esses picos foram localizados através de uma janela deslizante, que procurou o valor máximo entre dois cruzamentos por zero. Desta maneira, foram obtidas de cada transitório 200 amostras. Após a obtenção das 200 amostras, foi retirado dessas amostras o valor médio das 20 últimas amostras, para se retirar da resposta transitória qualquer contribuição residual da resposta de estado estacionário.

As Figuras 3.9, 3.10 e 3.10 mostram alguns transitórios de eletrodomésticos já com 200 amostras.

Verificamos em [56] que os passos adotados para reduzir o espaço de 200 amostras do transitório foram:

1. Um estudo da concentração de energia das amostras de amplitude indicou que o somatório acumulado de energia, normalizado, continha 95% da energia total no trecho inicial de 50 amostras. Isso representou uma redução a 1/4 do período de aquisição.

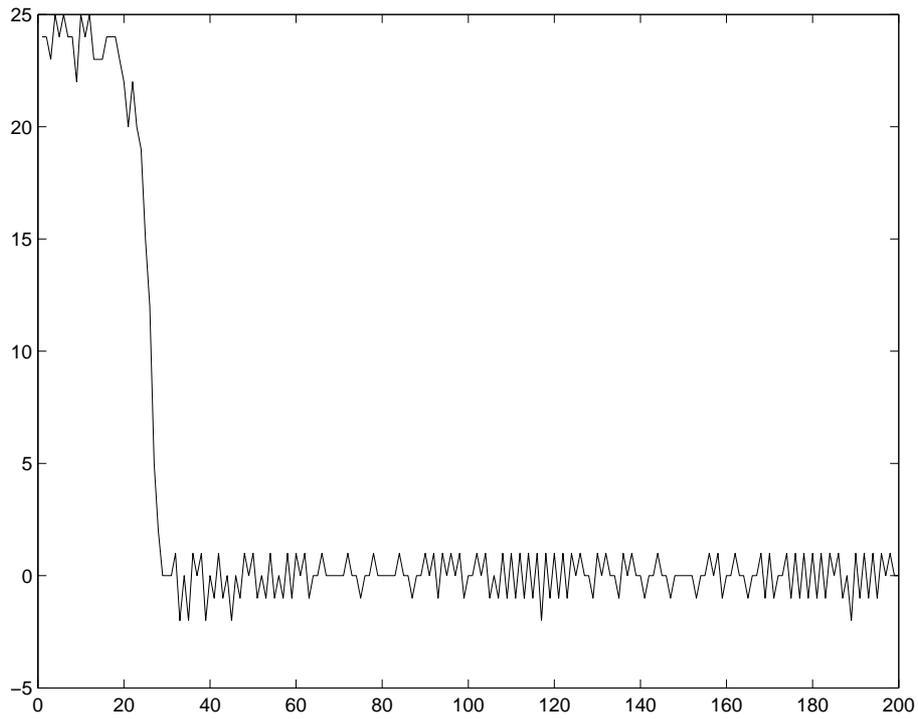


Figura 3.9: Transitório de um refrigerador.

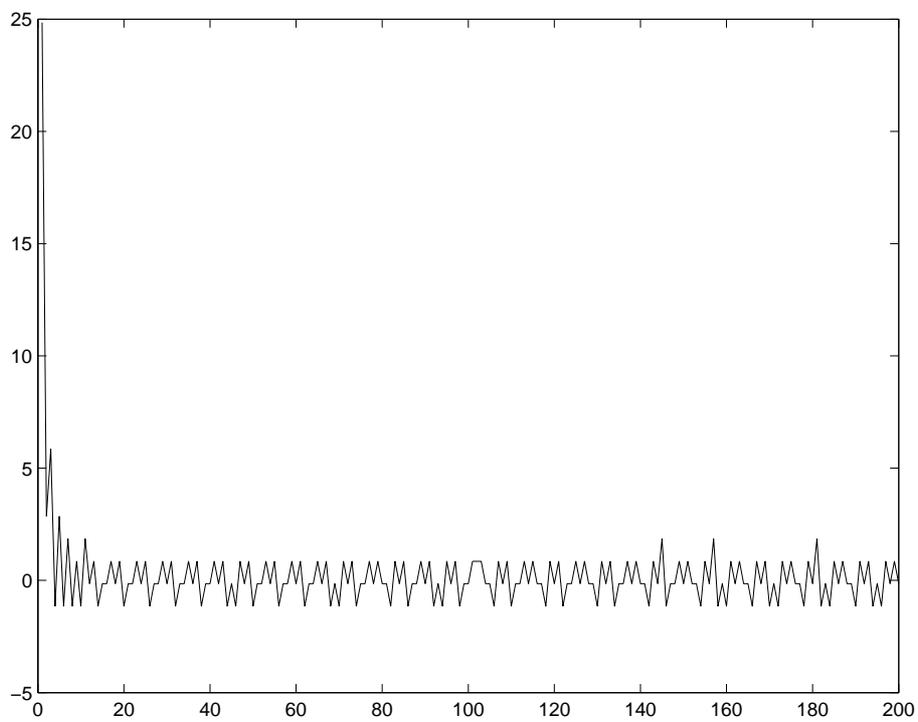


Figura 3.10: Transitório de um chuveiro elétrico - posição inverno

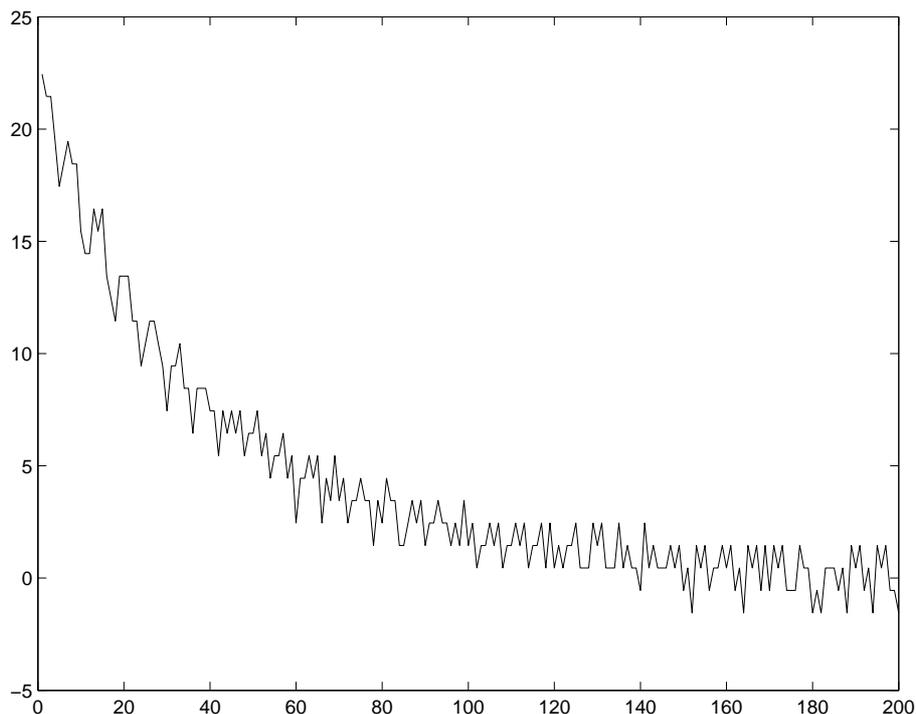


Figura 3.11: Transitório de um aspirador de pó

2. Sobre essas 50 amostras foi feita uma análise espectral de frequência através da Transformada Rápida de Fourier (FFT), com o objetivo de se definir uma taxa mínima de retenção de amostras que preservasse o conteúdo de informação espectral destes sinais.

Este estudo indicou que quase todos os espectros dos transitórios de corrente apresentavam queda significativa em torno de 10Hz, com exceção das classes 6 e 7, que continham informações relevantes até 30Hz, devido a um impulso de corrente que ocorria nos 10 primeiros ciclos.

Assim, foram definidas duas taxas de amostragem. Para os 10 primeiros ciclos do transitório, aplicando-se o teorema de Nyquist [57], foi utilizada uma taxa de retenção de amostras de 60Hz ($2 \times 30\text{Hz}$), e para os demais ciclos foi utilizada uma taxa que representasse sinais com corte abaixo de 10Hz, o que pelo teorema de Nyquist, corresponde a uma taxa de amostragem de 20Hz.

Adotando-se o procedimento acima, foram retiradas 16 amostras do transitório, sendo 10 amostras com período de 16,7ms e 6 amostras com período de 50ms.

3. Nestas amostras da resposta transitória foram incluídas 2 amostras em estado-estacionário, totalizando um vetor com 18 componentes.

A principal justificativa em [56] para se agrupar em um mesmo vetor de dados amostras do transitório e as amostras em estado-estacionário é de que a rede neural proposta teria em sua camada de entrada uma caracterização mais definida de cada classe, ao se fornecerem dados de naturezas diferentes, e conseqüentemente poderia encontrar hiperplanos que melhor discriminassem as classes de eletrodomésticos.

3.2 Análise de Componentes Principais (PCA)

A análise de componentes principais é conhecida como uma técnica poderosa de reconstrução de sinais estocásticos que permite a redução da dimensionalidade do espaço de entrada [58, 59, 60]. Através de uma análise de variância, o espaço de entradas é mapeado em um outro espaço, cujos vetores da base apontam para as direções de maior energia dos processos estocásticos [61, 62] do espaço de entrada original. Esta análise de variância procura no espaço original as direções que tenham as maiores variâncias, isto é, os autovetores que apresentam os maiores autovalores para que sobre estes autovetores o espaço de entradas seja mapeado. Quando, após esse mapeamento, verificamos que o somatório cumulativo da concentração de energia se dá em um número de componentes menor que o espaço de entrada, eventualmente podem-se desconsiderar os demais autovetores, que têm variância pouco significativa. Assim, temos uma redução da dimensionalidade do espaço de entrada, que pode ser bastante atraente em aplicações diversas.

Aplicamos a PCA para o conjunto de dados dos eletrodomésticos considerando as 200 amostras colhidas para cada sinal transitório, conforme discutido na seção 3.1. Da PCA, observou-se que apenas 7 componentes principais retinham mais de 90% da energia total, vejam na Figura 3.12. Essa alta compactação dos dados de entrada reafirma a eficiência dessa técnica na redução da dimensionalidade em espaços de entrada de dimensões elevadas.

Na seção 3.4 projetaremos um sistema de reconhecimento de eletrodomésticos utilizando a PCA como pré-processamento para redução da dimensionalidade do espaço de entradas, e discutiremos a viabilidade de utilizarmos essa técnica no projeto

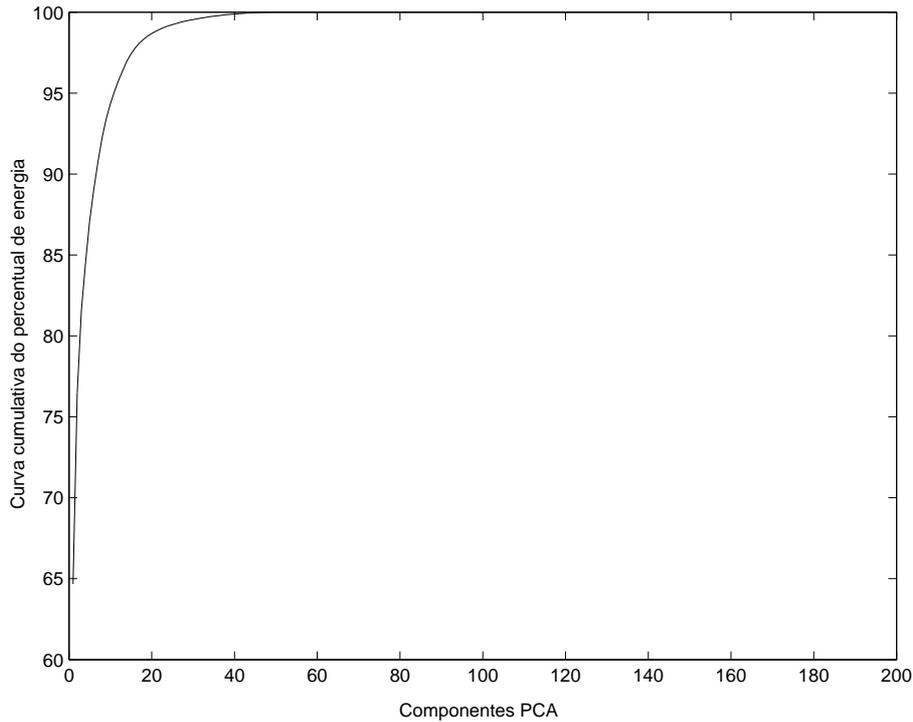


Figura 3.12: Curva de carga acumulativa da PCA

de um sistema de monitoração e identificação de eletrodomésticos.

3.3 Análise de Componentes Principais de Discriminação

A análise das componentes principais de discriminação (PCD), diferentemente da PCA, não busca preservar as informações contidas no espaço de entrada original para uma possível reconstrução [63]. As direções das componentes principais, encontradas nesta análise resultam na máxima discriminação entre padrões diferentes do espaço de entrada. Em alguns casos este método pode resultar em um alto nível de compactação do espaço de dados [64, 65, 66]; isto ocorre quando o número de componentes principais de discriminação encontradas é bem menor que a dimensão do vetor de entradas.

A Figura 3.13 mostra como as componentes principais de discriminação foram obtidas usando-se uma rede neural escalável, treinada de forma cooperativa. Observe nesta figura que as saídas estão representadas por três neurônios que rea-

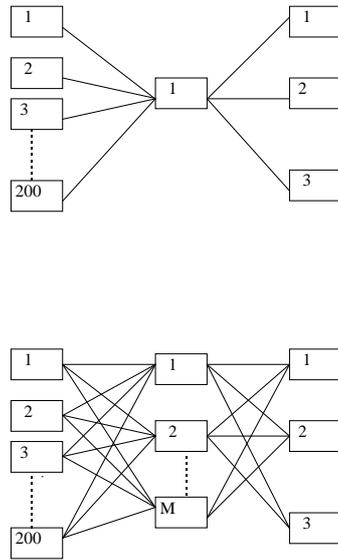


Figura 3.13: Extração de componentes de discriminação principal: primeira (acima) e M-ésima (abaixo) componentes.

lizam a codificação binária para as sete classes de eletrodomésticos. Mais a frente justificaremos o uso dessa codificação.

Inicialmente, a rede é formada por um único neurônio na camada intermediária e é treinada como um classificador através do método de *backpropagation* [67]. O critério de parada usou a eficiência máxima de classificação com um simples neurônio na camada intermediária. Após esta primeira fase de treinamento, o vetor de pesos que conecta o espaço de entrada ao neurônio da camada intermediária representa a primeira componente de discriminação extraída. 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 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 nova configuração de rede. 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.

A metodologia de obtenção das componentes de discriminação que apresentamos busca construir um classificador neural com máxima eficiência de classificação com um número mínimo de neurônios na camada intermediária. Obviamente, existe um custo de implementação que aumenta com o acréscimo de neurônios na camada intermediária; quanto mais neurônios na camada intermediária maior será o tempo de processamento do classificador neural.

Nesse trabalho, projetaremos classificadores neurais utilizando esta técnica de compactação de sinais, e mostraremos tratar-se de uma metodologia bastante interessante na identificação de cargas elétricas residenciais. Compararemos os seus resultados com os métodos tradicionais de classificadores neurais e também realizaremos um estudo de comparação entre as análises PCA e PCD e como podemos correlacioná-las.

3.4 Projeto e implementação da Rede Neural

As redes neurais, com suas características computacionais, se diferenciam de outras técnicas convencionais de reconhecimento de padrões pela potencialidade de mapear uma espaço de entrada complexo e não-linear em um outro espaço representativo para a classificação e diferenciação dos padrões de entrada. Os classificadores em geral são utilizados para agrupar padrões, uma vez que selecionam a saída que melhor representa um padrão de entrada. Para aqueles casos em que a relação entrada-saída não é bem definida, as redes neurais são extremamente úteis. Através de métodos adequados, pode-se treinar a rede para realizar classificações dos padrões de entrada. Para esse treinamento é apresentado, quando possível, um conjunto estatisticamente representativo dos padrões de entrada a serem classificados, de forma que a rede possa ser capaz de classificar corretamente outros padrões de entrada não apresentados durante o treinamento. O ponto principal, então, é

garantir um treinamento que permita à rede neural agregar a capacidade de generalização [67, 68, 69]. Neste trabalho, um outro fator importante para termos escolhido redes neurais acontece por conter uma estrutura de fácil implementação. As operações matemáticas envolvidas são basicamente produtos internos (mapeamentos de um espaço de entradas em um outro espaço) e aplicação de uma função de ativação, que geralmente é a tangente hiperbólica ou uma função linear. Existem, hoje dispositivos de processamento, como os DSPs, que já são otimizados para esses tipos de operação, e para processamentos rápidos, o que torna mais atrativa ainda a utilização das redes neurais [70, 71, 72, 73, 74]. Afinal, um dos principais focos dessa tese é obter implementações com alta capacidade de processamento para fins de monitoração de uma grande massa de dados de equipamentos eletrodomésticos.

Consideraremos nesta seção três projetos de classificadores neurais:

1. Um classificador neural formado a partir das amostras conjuntas do transitório e do regime permanente.
2. Uma rede neural formada a partir de duas redes neurais especialistas: uma com base no transitório e a outra com base nas amostras do regime permanente.
3. Com base na informação do transitório, um vetor de 200 amostras, dois classificadores neurais: um com pré-processamento obtido com a análise PCA e um segundo obtido através da análise PCD.

3.4.1 Classificador Neural - Amostras híbridas

Verificamos anteriormente que, após a análise espectral dos transitórios, foi possível obter 16 amostras que contivessem ainda a informação espectral do espaço original de 200 amostras. Para cada uma dessas aquisições foram acrescentadas duas amostras da resposta de regime permanente, que são o ângulo de fase e a corrente aparente.

Utilizamos um conjunto com 100 eventos (transitório e regime permanente) de diferentes eletrodomésticos, de acordo com [56] este conjunto alcança mais de 95% do consumo no setor residencial, no entanto por dificuldades de adquirir-se uma grande quantidade de eventos por classe de eletrodomésticos não foi possível ter-se um conjunto de dados estatisticamente representativo. Para o conjunto de treino

utilizamos 74 eventos e para o conjunto de teste, 26 eventos. Após cada iteração de treinamento, foi apresentado o conjunto de teste à rede neural e verificado o seu desempenho. O processo de treinamento da rede neural foi suspenso quando, a partir de um determinado passo de treinamento, a eficiência da rede neural (a taxa de acerto, considerando-se os eventos de teste) se mostrava inalterada. Como o conjunto de testes apresentava um número pequeno de eventos, ao final do treinamento foi feita a verificação da taxa de acertos da rede neural considerando-se todos os eventos (conjunto de treino e teste). Para a determinação da classe vencedora, consideramos aquela que apresentou a maior saída da rede neural (que assume valores entre -1 e 1).

Para o treinamento e análise da rede neural em *software*, um código foi desenvolvido em FORTRAN para gerenciar as rotinas do pacote JETNET 2.0 [75]. O JETNET 2.0 constitui um conjunto de subrotinas que podem ser chamadas de acordo com este código de gerenciamento, oferecendo um ambiente bastante flexível para o desenvolvimento do projeto do classificador neural.

O arquivo de configuração permite definirmos diversos parâmetros, tais como:

1. Número de camadas da rede neural
2. Número de neurônios de entrada
3. Número de neurônios da camada intermediária
4. Número de neurônios da camada de saída
5. Taxa de aprendizado
6. Momento
7. Número de passos de treinamento
8. Valor inicial dos pesos
9. Época
10. Função de ativação

Tabela 3.1: Tabela de contingências - rede neural 18-7-7

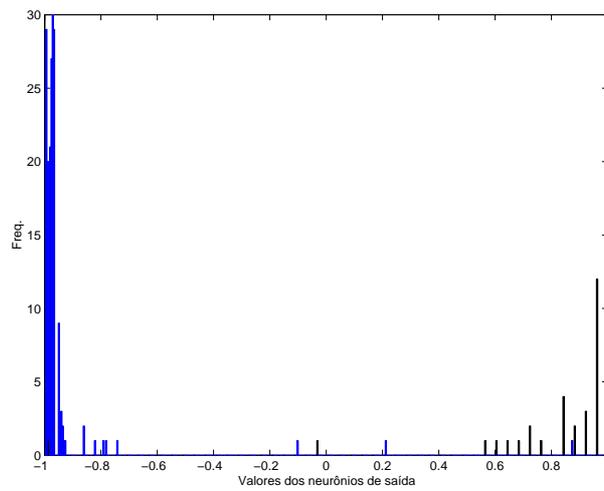
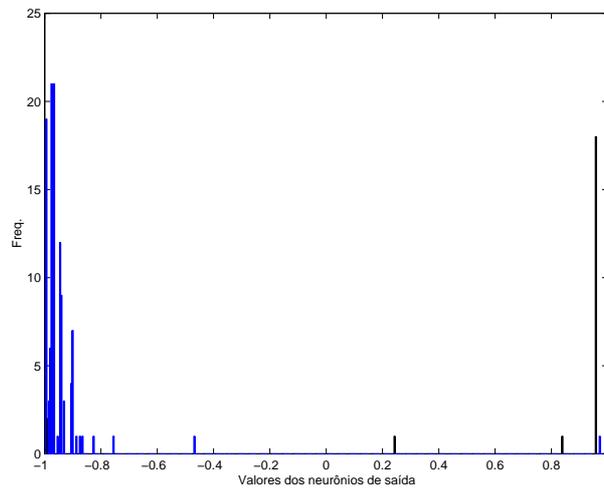
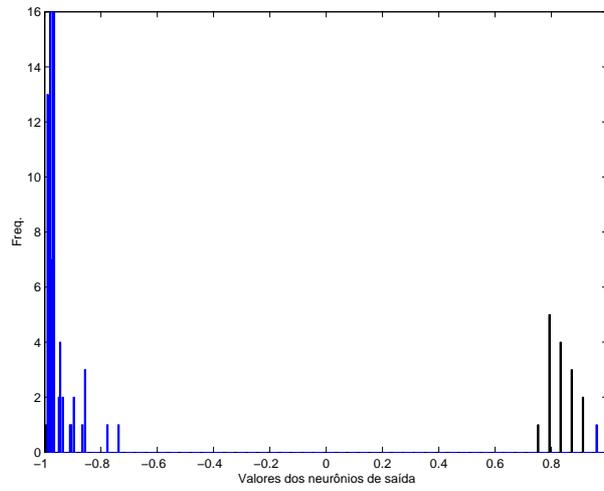
3	.	1
.	5
.	.	6	1	.	.	.
.	.	.	2	.	.	.
.	.	2	.	2	.	.
.	2	.
.	2

Projetamos uma rede neural classificadora com 18 neurônios na camada de entrada, 7 neurônios na camada intermediária e 7 neurônios na camada de saída. Esta configuração foi a mesma proposta em [56]. Foram necessários 50.000 passos de treinamento, com uma taxa de aprendizado de 0,02 e com um decaimento desta taxa de 0,999995 a cada passo de treinamento para se obter uma taxa de acerto de 86% com erro médio quadrático de 0,00073 [76]. Para elucidar melhor o resultado apresentamos uma tabela de contingências ou de confusões, Tabela 3.1, que nos dá uma visão mais detalhada dos erros de classificação cometidos pela rede neural. As linhas da tabela representam as classes esperadas e as colunas representam as classes obtidas pelo classificador neural. Resultados fora da diagonal principal indicam erros de classificação cometidos. A diagonal principal para erro zero, considerando-se os 26 eventos do conjunto de teste, seria 4,5,7,2,4,2,2. Para melhor entendimento, representaremos os zeros da tabela por pontos.

Os gráficos (ver Figuras 3.14 e 3.15) que se seguem representam histogramas das saídas das redes neurais apresentando-se todos os eventos (treino e teste) de cada classe de eletrodomésticos. As raias em preto indicam a saída da rede neural para um evento da classe que se espera ser a vencedora e as demais raias (em azul) representam as outras saídas da rede neural.

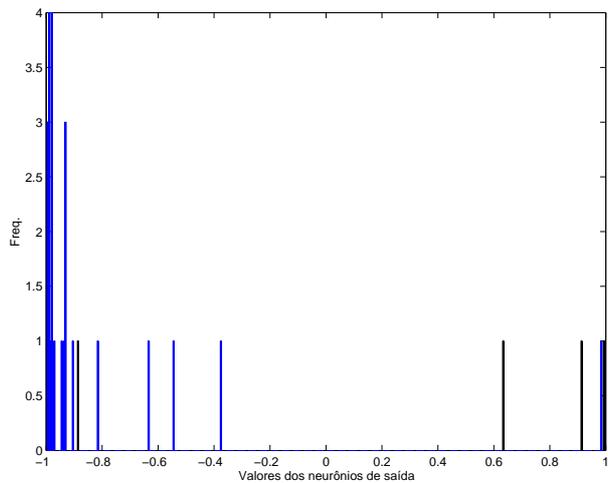
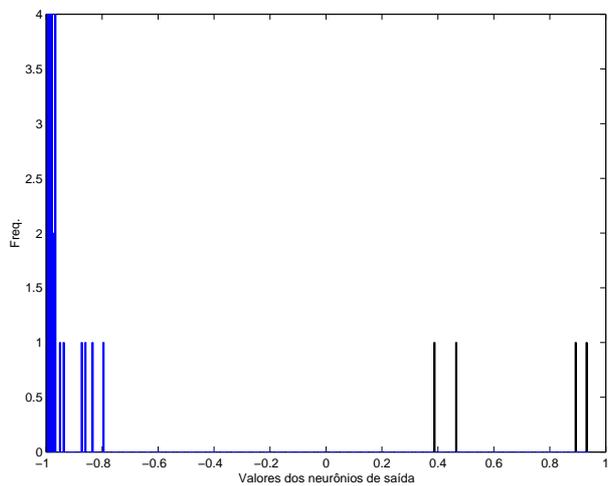
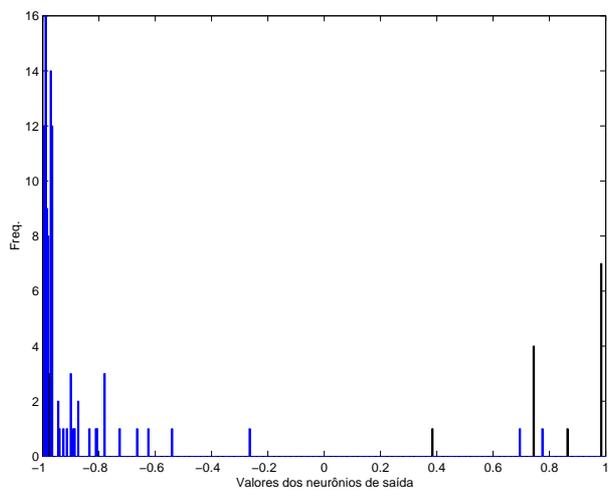
Podemos observar nos gráficos acima que a rede apresentou para as saídas vencedoras valores próximos de 1, e para as demais saídas valores próximos de -1, o que indica que a rede foi capaz de aprender e distanciar a classe vencedora das demais classes. As Tabelas 3.2, 3.3 mostram, respectivamente, a diferença dos

Figura 3.14: Histograma das saídas da rede neural para eventos da classe 1(a), da classe 2(b) e da classe 3(c)



(c) Classe 3

Figura 3.15: Histograma das saídas da rede neural para eventos da classe 5(a), da classe 6(b) e da classe 7(c)



(c) Classe 7

Tabela 3.2: Diferenças entre 1° colocado e 2° colocado

Média	1,7993
Mediana	1,9209
Desvio-padrão	0,2859

Tabela 3.3: Diferenças entre esperado e 1° colocado

Média	-1,1963
Mediana	-1,1123
Desvio-padrão	0,6495

valores entre o neurônio vencedor e o 2° colocado, para as classificações corretas, e a diferença de valores entre o neurônio que se esperava vencedor e o 1° colocado, no caso de classificações erradas.

Os resultados expressos, na Tabela 3.2 mostram uma baixa incidência de classificações duvidosas ou decididas por pequena margem. Este comportamento dispensa a utilização de esquemas sofisticados de discriminação da saída vencedora. Provavelmente um comparador do nível zero é suficiente.

3.4.2 Redes Especialistas

Em muitas aplicações, o espaço de entrada pode vir a ser composto por informações de natureza diversa. Para estes casos, uma possível técnica de implementação seria a utilização de rede neurais especialistas em cada conjunto de informações que compõe o espaço de entrada. O objetivo é se obter redes neurais composta por sub-redes neurais especializados em informações distintas: transitório e amostras do regime permanente (ângulo de fase e corrente aparente). Cada uma dessas sub-redes especialistas funcionaria como um extrator de características relevantes. Para essa extração utilizaremos a análise PCD, e assim esperamos que uma rede neural projetada a partir da composição das características extraídas por esses dois sistemas tenha um resultado melhor do que o apresentado na seção anterior, que considerava o vetor de entradas da rede como sendo a composição do transitório

e as duas amostras do regime permanente. A Figura 3.16 mostra a topologia de uma rede neural composta de sub-redes neurais especialistas para as informações do transitório e do regime permanente.

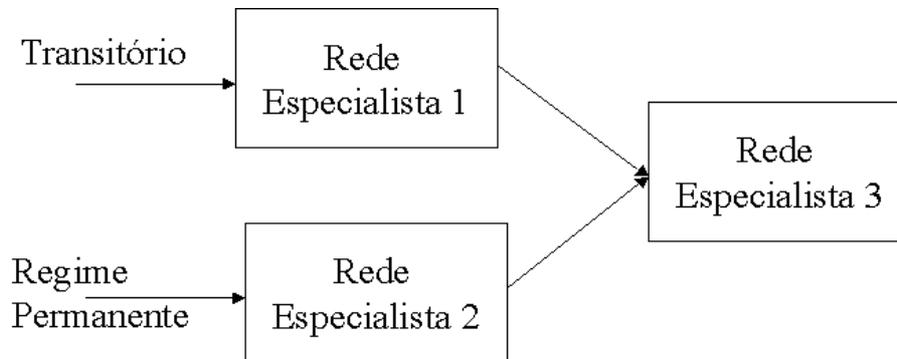


Figura 3.16: Topologia de uma rede neural composta por sub-redes neurais especialistas para informações do transitório e do regime permanente

Cada sub-rede neural especialista será treinada de modo a se obter a máxima eficiência de classificação, considerando-se cada informação na qual se pretende especializar a rede. Para se combinar os resultados obtidos por cada rede treinada existem duas maneiras. Uma possibilidade é simplesmente combinar todos os nós de saída das sub-redes especialistas como entradas para uma rede global classificadora que correlacionaria as respostas das sub-redes especialistas e determinaria uma classificação final baseada nas características globais. Uma segunda possibilidade é a combinação das informações extraídas no sub-espaço representado pelas saídas das camadas intermediárias de cada sub-rede especialista; para este caso teremos cada sub-rede especialista agindo como extrator de características, uma vez que a projeção das entradas na camada intermediária de uma rede neural para fins de classificação é o conjunto de informações relevantes que lhe possibilitará a classificação de um padrão de entrada. Para o caso do sistema de monitoração de cargas, o qual processa dados da resposta transitória e do regime permanente, uma rede neural especialista foi utilizada para extração de características do transitório e uma outra rede especialista para extração de características do regime permanente.

Cada uma dessas sub-redes especialistas foi treinada usando-se a análise de componentes principais de discriminação, discutida na seção 3.4.1, na identificação das sete classes de eletrodomésticos. Tanto a sub-rede neural especialista na resposta

transitória quanto a sub-rede neural especialista na resposta estado-estacionário foram construídas obtendo-se quatro componentes de discriminação principal. As topologias das sub-redes neurais especialistas foram:

- 16-4-7 - os 16 nós de entrada da rede neural representando as amostras do transitório, 4 nós na camada intermediária que são as PCDs extraídas, e 7 nós de saída representando as sete classes de eletrodomésticos.
- 2-4-7 - os 2 nós de entrada da rede neural representando as amostras do regime permanente, 4 nós na camada intermediária, que são as PCDs extraídas, e 7 nós de saída representando as sete classes de eletrodomésticos.

Considerando-se os dados adquiridos pelo sistema DAQ , a combinação das características extraídas de ambas as sub-redes especialistas foi feita das duas maneiras indicadas. Na primeira, os dois conjuntos de saída das sub-redes especialistas foram combinados formando quatorze nós de entrada para a rede global. Na segunda, os dois conjuntos de nós da camada intermediária de cada sub-rede especialista foram combinados, formando oito nós de entrada para a rede global. A rede global, em ambos os casos, foi treinada utilizando a extração de componentes de discriminação principal e com os nós de saída da rede representando as sete classes de eletrodomésticos. As redes neurais tiveram as seguintes topologias:

- 14-4-7 - 14 nós de entrada representando a combinação das saídas das redes 16-4-7 e 2-4-7, 4 neurônios na camada intermediária indicando as PCDs e 7 neurônios na saída representando as classes de eletrodomésticos.
- 8-4-7 - 8 nós de entrada representando a combinação das 4 saídas das camadas intermediárias, respectivamente, das redes 16-4-7 e 2-4-7, 4 neurônios na camada intermediária indicando as PCDs e 7 neurônios na saída representando as classes de eletrodomésticos.

A Figura 3.17, mostra o decaimento do erro médio quadrático durante o processo de treinamento da rede global 8-4-7.

Para a rede neural de discriminação obtida através dos nós de saída de cada sub-rede especialista a eficiência de classificação foi de 90%. Para a rede neural

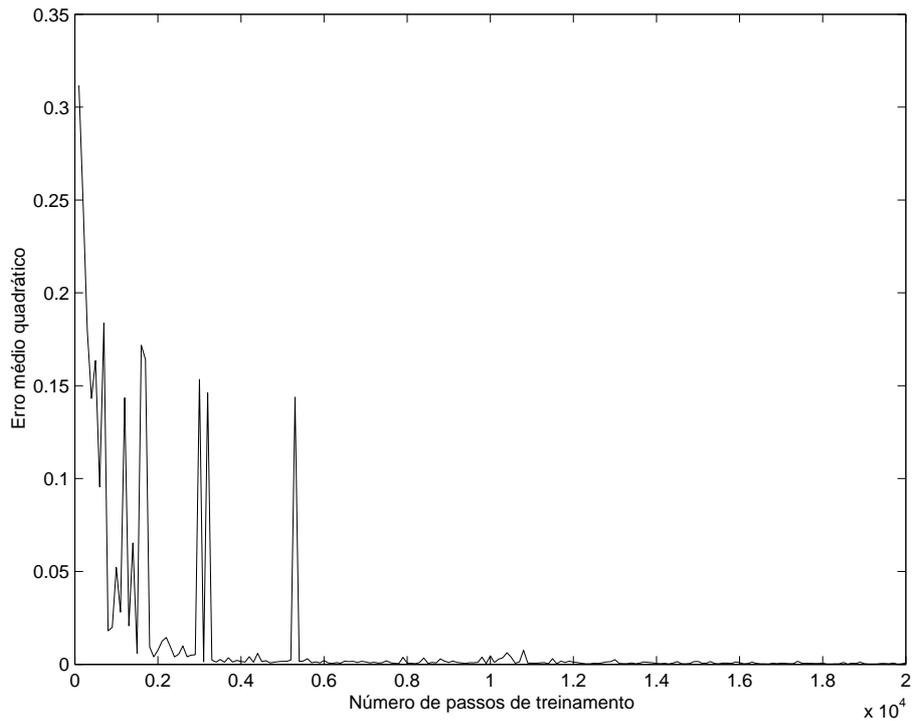


Figura 3.17: Curva do erro médio quadrático durante o treinamento da rede 8-4-7

construída a partir dos nós de saída das camadas intermediárias de cada sub-rede especialista a eficiência também foi de 90%. Esta última técnica é, também, mais rápida porque reduz a complexidade da rede global. Entende-se por complexidade da rede neural o número de operações matemáticas necessárias para se processar um evento de entrada. Assim, uma rede neural global com a topologia 8-4-7 apresentará um complexidade menor do que a rede neural global com topologia 14-4-7, o que torna a rede neural 8-4-7 mais atrativa para implementação de um sistema de monitoração de cargas [77].

As Tabelas 3.4 e 3.5 mostram, respectivamente, a diferença dos valores entre o neurônio vencedor e o segundo colocado, para as classificações corretas e a diferença de valores entre o neurônio que se esperava vencedor e o primeiro colocado, no caso de classificação errada. Encontra-se, novamente, uma baixa incidência de classificações duvidosas ou decididas por pequena margem.

Tabela 3.4: Diferenças entre 1° colocado e 2° colocado

Média	1,7478
Mediana	1,8298
Desvio-padrão	0,2470

Tabela 3.5: Diferenças entre esperado e 1° colocado

Média	-1,55
Mediana	-1,814
Desvio-padrão	0,5820

3.4.2.1 Considerações sobre os resultados

Por restrições estatísticas do conjunto de dados, como já mencionamos, utilizamos 74 eventos para treino da rede e 26 eventos para realização dos testes, para se verificar a generalização da rede neural. Uma diferença percentual de 4% entre as taxas de acerto da rede 8-4-7 (90% de acerto) e da rede neural 18-7-7 (86%) pode indicar somente a flutuação estatística dos dados e não necessariamente que a primeira rede neural foi melhor do que a segunda.

A rede neural formada por sub-redes especialistas com a topologia 8-4-7 apresenta uma configuração em que o número de operações matemáticas necessárias para se processar um evento é menor do que o número necessário quando consideramos a rede neural 18-7-7, o que, para fins de implementação em cada um dos cenários que propomos, torna as redes neurais formadas por sub-redes neurais especialistas mais atrativas, uma vez que realizaremos implementações mais rápidas que com a rede global.

As redes neurais formadas a partir de sub-redes neurais especialistas nos permitem fazer algumas considerações importantes:

- 1) Quando projetamos uma sub-rede neural especialista considerando a informação do transitório e uma sub-rede neural especialista com base nos dados em regime permanente, cada uma delas apresentou uma taxa de acerto em torno de 75%, o que nos faz concluir que a composição dessas informações foi

fundamental para obtermos uma taxa de acerto global melhor. Essa melhora aconteceu para os dois sistemas neurais apresentados, muito embora, como já mencionado, a rede neural composta de sub-redes neurais especialistas foi capaz de aprender melhor ao considerarmos separadamente os conjunto de dados de entrada.

- 2) Podemos supor, inicialmente, que a redução do espaço de entradas do transitório de 200 amostras para 16 amostras causou uma degradação nesta informação, para fins de classificação. Por isso se fez necessário acrescentar as 2 amostras de regime permanente para melhorar o resultado final de classificação. Na seção 3.4.3 projetaremos um classificador neural baseado somente nas 200 amostras do transitório, o que nos permitirá analisar melhor essa suposição.

3.4.3 Classificador Neural - Transitório

Na seção anterior, elaboramos o projeto e a análise de discriminadores neurais considerando as informações de transitório e de regime permanente, e assim fizemos quando consideramos o projeto de uma rede neural cuja entrada foi a composição dessas duas informações ou quando propusemos redes neurais formadas por sub-redes neurais especialistas. Nesta seção, entretanto propomos uma análise que considera a compactação dos dados de entrada e um classificador neural obtido a partir desse espaço de entradas reduzido; mas, diferentemente da seção anterior, só consideramos a informação do transitório. A intenção é provar que essa informação é suficiente para se obter um discriminador compacto e com eficiência comparável com a que obtivemos anteriormente.

Projetamos um sistema neural usando a análise de componentes principais de discriminação para encontrar o número mínimo de neurônios na camada intermediária, com o compromisso de obter a máxima eficiência de classificação [64]. Para representação da saída utilizamos 3 neurônios com codificação binária. A codificação binária foi motivada por duas razões: a primeira, o fato de que as informações necessárias para separação de padrões decorrem da projeção do vetor de entrada no vetor resultante da camada intermediária, e por isso espera-se que uma representação codificada dos neurônios de saída da rede neural não influencie o processo de apren-

dizado da rede neural; a segunda razão é que o número de operações matemáticas (multiplicação, soma e funções de ativação) para o processamento de um evento diminui, o que implica diretamente um tempo de processamento menor, o que, como veremos no capítulo seguinte, será extremamente importante nas implementações analisadas.

A análise PCD foi utilizada para projeto do discriminador neural integrado com o processo de extração das componentes de discriminação. Para o treinamento da rede neural, em cada passo de extração de uma PCD, utilizamos uma taxa de aprendizado de 0,02 decaindo a uma taxa de 0,99995 por época de treinamento. Neste processo só foram extraídas 2 PCDs, e o classificador obteve uma taxa de acerto global de 98%. A tabela de contingências 3.6, considerando-se os 26 eventos de teste, mostra que a rede apresentou somente um erro, que foi para a classe 7, e isto ocorreu também para os eventos dessa classe utilizados para treino.

Tabela 3.6: Tabela de contingências - rede neural 200-2-3

4
.	5
.	.	7
.	.	.	2	.	.	.
.	.	.	.	4	.	.
.	2	.
.	1	1

O resultado obtido é bastante significativo, pois comprova que a rede neural em um espaço de entrada mais representativo do transitório consegue obter uma eficiência de 98%, taxa de acerto superior à da rede neural projetada sobre um espaço de entrada que considerava conjuntamente as informações do transitório e regime permanente 90% para a implementação feita na seção 3.4.2 com redes neurais formadas por sub-redes neurais especialistas.

Esse resultado indica que só fez sentido utilizar as informações do regime permanente porque a informação do transitório fora compactada, análise vista na seção , de 200 amostras para somente 16 amostras, deteriorando o sinal original para fins

de classificação. Nesta análise de compactação, o objetivo era preservar o conteúdo espectral do sinal original, no entanto redundou no projeto de um classificador mais complexo.

Em nossa análise, não só obtivemos uma compactação maior, pois obtivemos somente 2 PCDs (redução 200:2), como melhoramos o desempenho global da rede neural, o que comprova a potencialidade da análise PCD. E mais, ao se obter uma compactação tão elevada estamos já preparando o caminho para projetos de implementação menos complexos.

3.4.3.1 Projeto com PCA

Verificamos na Figura 3.12 que a energia acumulada das sete primeiras PCs extraídas representam mais de 90% da energia total, o que indica que essas primeiras componentes poderiam ser utilizadas para representar os sinais que originalmente tinham 200 amostras. Projetamos redes neurais considerando como entrada as projeções dos transitórios sobre as direções dadas por PCA. A Tabela 3.7 mostra as taxas de acerto global para as redes neurais projetadas a partir da primeira PC e progressivamente até a décima quinta PC extraída. Fizemos o número de neurônios da camada intermediária igual ao número de PCs, e codificamos a saída da rede neural binariamente.

As melhores taxas de acertos verificadas na Tabela 3.7 foram obtidas a partir da topologia 10-10-3. Esse resultado indica que foi necessário utilizar mais do que as 7 primeiras componentes da PCA (direções da energia contendo mais de 90%) para se obter resultados satisfatórios. A partir da topologia 15-15-3, não obtivemos nenhuma melhoria na eficiência da rede neural: a eficiência obtida de 90% foi inferior ao resultado que obtivemos na seção anterior para a rede neural com 2 PCDs (200-2-3), que foi de 98%.

A principal conclusão que podemos tirar é que as redes neurais projetadas a partir da PCA implica um projeto muito complexo, uma vez que é necessário processar as 200 amostras do transitório para se obter as direções das PC, o que computacionalmente exige que se calcule um total de produtos e somas igual à dimensão do espaço de entradas, neste caso 200. Este cálculo teria que ser feito, considerando o melhor resultado da rede neural (ver Tabela 3.7), 15 vezes.

Tabela 3.7: Taxas de acertos

Topologia	Eficiência da rede
1-1-3	20%
2-2-3	30%
3-3-3	77%
4-4-3	80%
5-5-3	80%
6-6-3	81%
7-7-3	82%
8-8-3	82%
9-9-3	86%
10-10-3	86%
11-11-3	86%
12-12-3	86%
13-13-3	86%
14-14-3	87%
15-15-3	90%

Devido ao extenso trabalho computacional necessário em uma possível implementação, não utilizaremos a análise PCA para o projeto e implementação de redes neurais neste trabalho.

3.5 Aquisição de Dados Móvel - DAQM

Para esta aquisição de dados, utilizamos um dispositivo de aquisição móvel (DAQM) para fins de monitoração de cargas elétricas residenciais que vem sendo desenvolvido pelo CEPEL. O DAQM apresenta algumas vantagens, citadas abaixo:

- É uma unidade de aquisição que fica externo à residência, caracterizando um sistema de aquisição não-invasivo.
- Por ser portátil, permite realizar a aquisição em campo de diferentes casas.

- A aquisição dos dados pode ser realizada em condições mais próximas às do uso real dos equipamentos e em seu ambiente de uso, diferentemente do que ocorre em aquisições feita em laboratório.

As vantagens que citamos acima foram as razões que nos fizeram realizar essa aquisição de dados. Para o CEPEL, que foi nosso parceiro nesse processo de aquisição, a principal motivação foi a de que eles poderiam vir a integrar nesse equipamento uma rede neural classificadora, que projetamos neste trabalho.

A análise até então feita pelo CEPEL para reconhecimento de padrões de cargas residenciais baseava-se em algumas características do transitório do sinal, tais como o tempo de decaimento do transitório, o nível de corrente nas primeiras e últimas amostras do transitório e considerações sobre subidas e descidas na forma de onda do transitório. Essa análise apresentava muitas falhas no reconhecimento para testes em residências, a eficiência para esses casos ficava em torno de 50%. Por esse resultado obtido, o CEPEL se interessou em migrar essa análise para o classificador neural que projetaremos.

Este protótipo difere do sistema de aquisição apresentado na seção 3.1 nos seguintes pontos:

- Aquisição do transitório - Foram adquiridos 160 amostras de corrente, sendo essas amostras os picos de corrente. O sistema utilizado detectava, por *hardware*, o valor máximo de corrente entre dois cruzamentos por zero.
- Sistema de aquisição - O sistema é composto, basicamente, de dois elementos: um conversor A/D para retenção da amostras de corrente e um microcontrolador 8031 que tinha a função de controlar essa aquisição e enviar os dados adquiridos para um computador externo para análise posterior.
- Por ser um protótipo, o equipamento ainda não suportava a aquisição de equipamentos com partidas do transitório em níveis abaixo de 1A, o que impossibilitou a aquisição de equipamentos eletrônicos (classe 5).

Para fins de definição das classes de eletrodomésticos, agrupamos, inicialmente, a classe 2 (Equipamentos Resistivos) e a classe 4 (Equipamentos de ventilação).

Esse agrupamento já era feito pelo CEPEL em sua análise, de forma que para compararmos a implementação atual do CEPEL com um sistema neural, necessariamente esse agrupamento teve que ser considerado.

Abaixo, temos as classes de eletrodomésticos identificadas nessa nova aquisição:

1. Classe 1: Equipamentos de refrigeração
2. Classe 2: Equipamentos resistivos e de ventilação
3. Classe 3: Equipamentos de agitação, movimento e mistura
4. Classe 4: Lâmpadas incandescentes
5. Classe 5: Lâmpadas fluorescentes
6. Classe 6: Microondas

Pudemos observar, também, nessa nova aquisição de dados o surgimento de uma nova classe de eletrodomésticos: os microondas. Esta classe apresentou um comportamento totalmente diferenciado das demais classes com relação à forma do transitório de partida, e por isso mereceu um novo agrupamento. As Figuras 3.18, 3.19 e 3.20 mostram a forma de onda de alguns transitórios.

Para aquisição dos transitórios, 6 residências foram utilizadas, num total de 186 equipamentos eletrodomésticos.

Projetamos, então, um discriminador neural com 4 neurônios na camada intermediária, que representam as componentes principais de discriminação, e os 3 neurônios de saída codificados binariamente. Para treinamento, utilizamos um conjunto de treinamento com 123 transitórios de eletrodomésticos, representando 75% do conjunto total de amostras. As amostras restantes foram utilizadas para teste da rede neural. Obtivemos sobre esse conjunto de dados uma taxa de acerto global de 90% [78].

Concluimos que a utilização de um sistema inteligente, usando rede neurais, nos permitiu obter um sistema mais eficiente e robusto do que aquele que o CEPEL vinha utilizando para discriminação de eletrodomésticos.

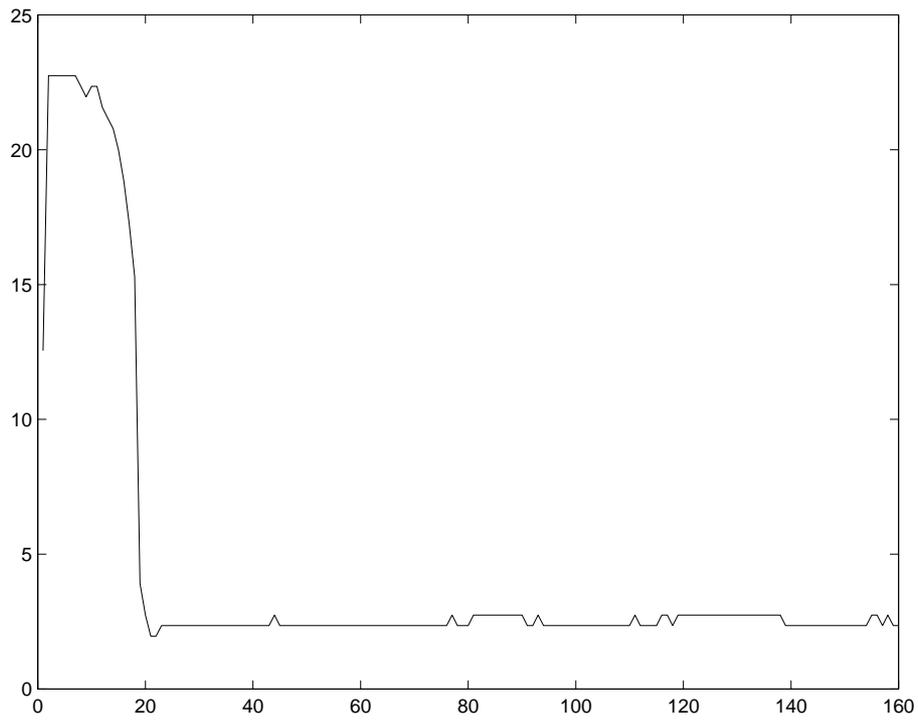


Figura 3.18: Transitório típico de um refrigerador.

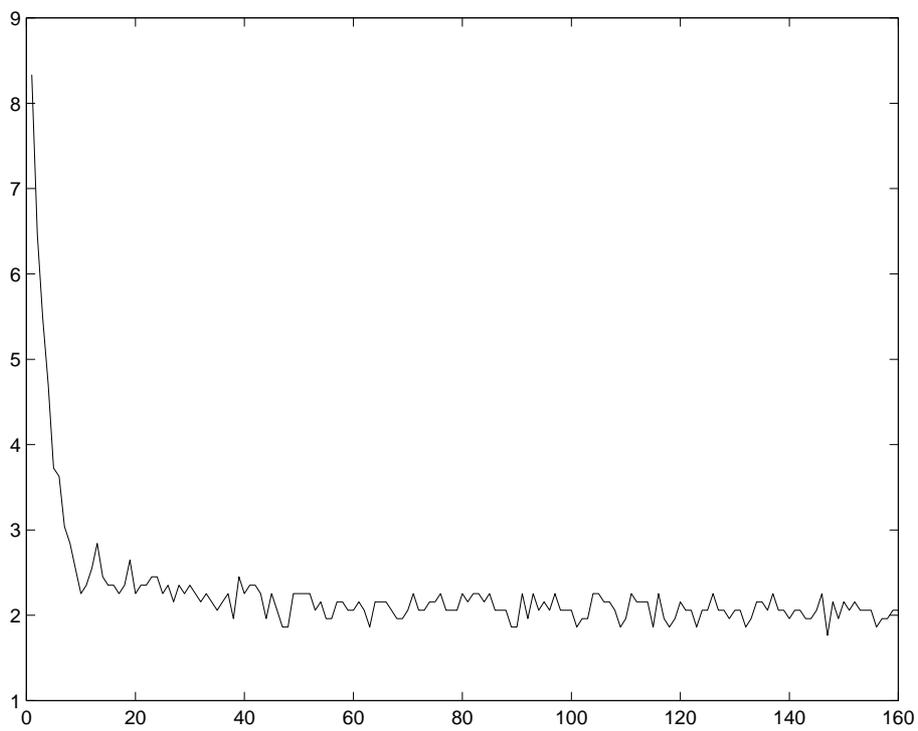


Figura 3.19: Transitório típico de um aspirador de pó

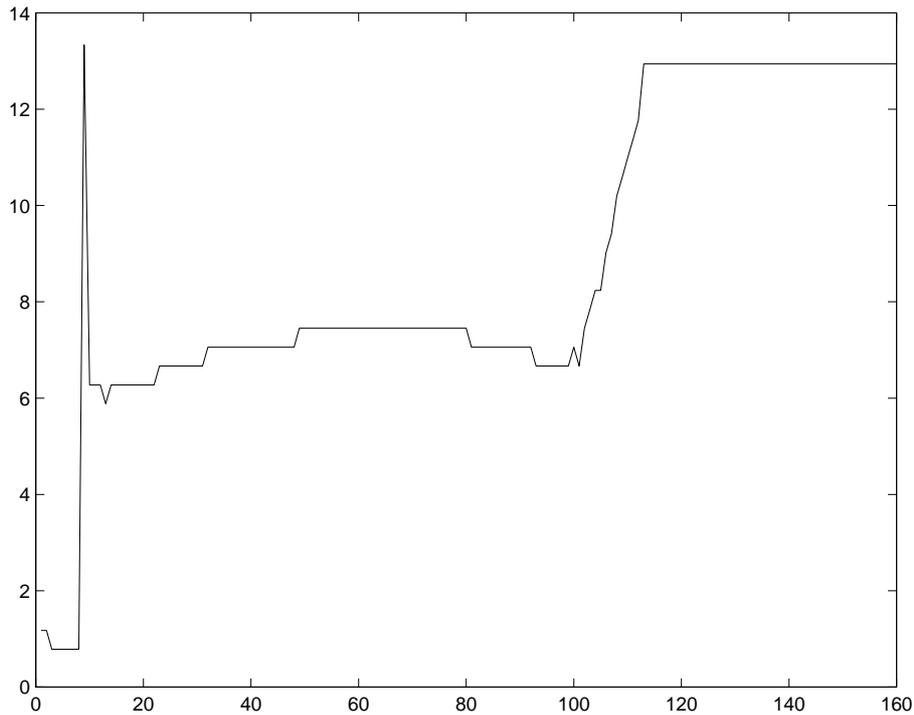


Figura 3.20: Transitório de típico de um microondas

3.6 DAQxDAQM - Estudo de Correlação

O modelo que adotamos para o projeto da rede neural utiliza a análise de componentes principais de discriminação como ferramenta, importante na obtenção de um classificador compacto e eficiente. Aplicamos esse modelo aos dados obtidos em duas aquisições diferentes. Para o DAQ, como descrito na seção 3.1, foi necessário utilizar equipamentos como osciloscópio digital e multímetro digital para adquirir amostras do transiente e do regime permanente (corrente e fase), usando uma taxa de amostragem para aquisição do transiente de 512 amostras/segundo (obtendo-se, após pré-processamento, 200 amostras). Uma outra aquisição foi feita utilizando o DAQM um protótipo feito pelo CEPEL com características mais próximas das de um equipamento de aquisição em campo. Para este sistema (visto na seção 3.5) as amostras do transiente são adquiridas retendo-se os picos de corrente diretamente do sinal amostrado por um conversor A/D de 8 bits, armazenando-se 160 amostras do transiente.

Essas diferenças entre DAQ e DAQM nos motivaram a verificar a correlação entre os dados adquiridos por eles. Para tal, utilizamos a PCA, sobre os transientes

Tabela 3.8: Ângulos entre as direções PCA de DAQ e DAQM

direção PCA-DAQ	direção PCA-DAQM	ângulo(em graus - aproximadamente)
1	1	43
2	2	42
3	3	80

dessas aquisições, porque sobre esse novo espaço de dados teríamos os transitórios projetados nas direções, decrescentemente a partir da primeira PC, de maior energia. A correlação dos dados poderá ser analisada pelos ângulos entre as direções principais encontradas sobre DAQ e DAQM. Quanto menor ângulo (ou quanto mais próximo de zero), maior será a correlação dos dados; o inverso representará uma menor correlação. A Tabela 3.8 mostra os ângulos obtidos entre as três direções principais de maior energia.

A Tabela 3.8 mostra que para as duas direções principais de maior energia para DAQ e DAQM um ângulo de 42 graus entre elas pode representar, ainda que não fortemente (o que seria para ângulos próximo de 0 graus), uma correlação entre essas direções. Para a terceira direção, um ângulo de 80 graus já mostra direções pouco correlacionadas.

As duas PCs para DAQ representam mais de 80% da energia acumulada do espaço de entradas e para DAQM, representam mais de 90%. Essa alta concentração de energia nas duas primeiras PCs significa que poderíamos representar o espaço de entradas nas suas projeções considerando somente essas duas componentes. E podemos, dado o resultado visto na Tabela 3.8, agrupar os conjuntos de dados de DAQ e DAQM.

Como o DAQM representa uma aquisição mais próxima de um dispositivo real, optamos por modificar os dados de DAQ (200 amostras) para se tornarem compatíveis com os dados de DAQM (160 amostras). Essa modificação foi feita descartando-se as últimas 40 amostras de DAQ; isso pode ser feito pelo fato de os transitórios por ele adquiridos terem nessas últimas amostras um nível constante de corrente (nível DC), não caracterizando as variações decorrentes do transitório do

sinal.

Projetamos uma rede neural, considerando esse novo conjunto de dados (DAQ + DAQM). Utilizamos novamente a análise PCD para compactação e classificação das classes de eletrodomésticos, e a saída da rede codificada binariamente. Obtivemos uma eficiência global de 80% ao final do treinamento, e 4 PCDs foram extraídas. A classe 2 e 7 tiveram 75% de acertos (os piores resultados), e a classe 6 teve o maior acerto, 88%.

O nosso objetivo, neste estudo de correlação, não é propor uma utilização conjunta dos dados de DAQ e DAQM, uma vez que DAQ não representa um módulo de aquisição que pode ser usado em campo. Mas, como realizamos análises considerando esses dois conjuntos de dados, esse estudo nos indicou que o modelo que adotamos para projeto de um classificador neural através da PCD é um modelo flexível e robusto às alterações na forma de aquisição do transitório vistos em DAQ e DAQM.

3.7 Análise de Componentes Principais de Discriminação - Considerações

Quando desenvolvemos uma pesquisa que utiliza redes neurais em sua implementação um dos grandes questionamentos que se faz é o que a rede neural está “enxergando” no espaço de entradas para realizar o processamento desejado (reconhecimento, agrupamento, detecção, etc) e se obter resultados ótimos. Sabemos que a projeção do espaço de entradas na camada intermediária, o que traz uma nova representação dos dados que capacita a rede neural diferenciá-los corretamente. Entretanto, é muito complexo, e às vezes impossível associar essa nova representação dos dados com características originais desses dados, e por isso muitas das vezes a rede neural é vista como uma caixa preta. Ao utilizarmos a análise de componentes principais de discriminação no projeto das redes neurais deste trabalho, também se pode questionar que direções são essas que permitiram a rede neural obter uma máxima eficiência de discriminação das classes de eletrodomésticos ? Ou ainda, é possível descrever o que a rede neural projetada com a análise PCD “enxerga” no espaço de entradas original para diferenciar essas classes ? Na seção 3.3 introduzimos o concei-

to da análise de componentes principais de discriminação, que procura direções nas quais os vetores de entrada são projetados com fins de se obter um espaço de dados mais representativo para discriminação de classes, como no caso dessa tese. Para a rede neural 200-2-3, discutida na seção 3.4.3, somente duas componentes principais foram necessárias para se obter uma eficiência de 98%, o que representou o maior percentual de acerto dentre as redes neurais anteriormente projetadas. Mas, que informações são essas que a análise PCD extraiu dos sinais originais que determinou uma alta taxa de acertos? Propusemos, então, uma análise também utilizando redes neurais que nos permitisse pelo menos tentar responder esse questionamento.

Propusemos a utilização de uma rede neural para se obter a inversa de cada componente de discriminação extraídas, que no caso da rede neural 200-2-3 foram duas PCDs. Como a projeção de um vetor de amostras do espaço original em uma PCD é uma operação linear, propusemos uma topologia como um neurônio de entrada, representando as projeções das entradas na PCD e uma camada com 200 neurônios lineares de saída; não utilizamos camada intermediária. Treinamos a rede neural para que, a partir das amostras de um transitório projetadas em uma PCD, se obtenha nos 200 neurônios de saída as amostras do espaço original. Assim, ao final do treinamento teremos os sinais dos transitórios dos eletrodomésticos reconstruídos através daquela PCD. Esses sinais reconstruídos representam o que a rede neural está “enxergando” dos sinais de entrada.

As Figuras 3.21, 3.22 e 3.23 representam a reconstrução de um transitório típico das classes 1, 3 e 7 a partir das duas PCD que foram extraídas para se obter a rede neural 200-2-3. Essas reconstruções apontam para uma característica comum entre elas, que é uma modificação do gráfico a partir da amostra 60. Uma outra observação é que a segunda PCD não representa uma compensação da primeira componente para se obter uma reconstrução do transitório do sinal original, o que indica que a análise PCD encontrou direções importantes para classificação, mas irrelevantes para reconstrução do sinal original. As Figuras 3.24, 3.25 e 3.26 representam a reconstrução do sinal original de transitórios considerando as duas primeiras componentes principais (obtidas com PCA) que apontam para as direções de maior energia.

As Figuras 3.24,3.25,3.26 mostram que a reconstrução dos sinais a partir

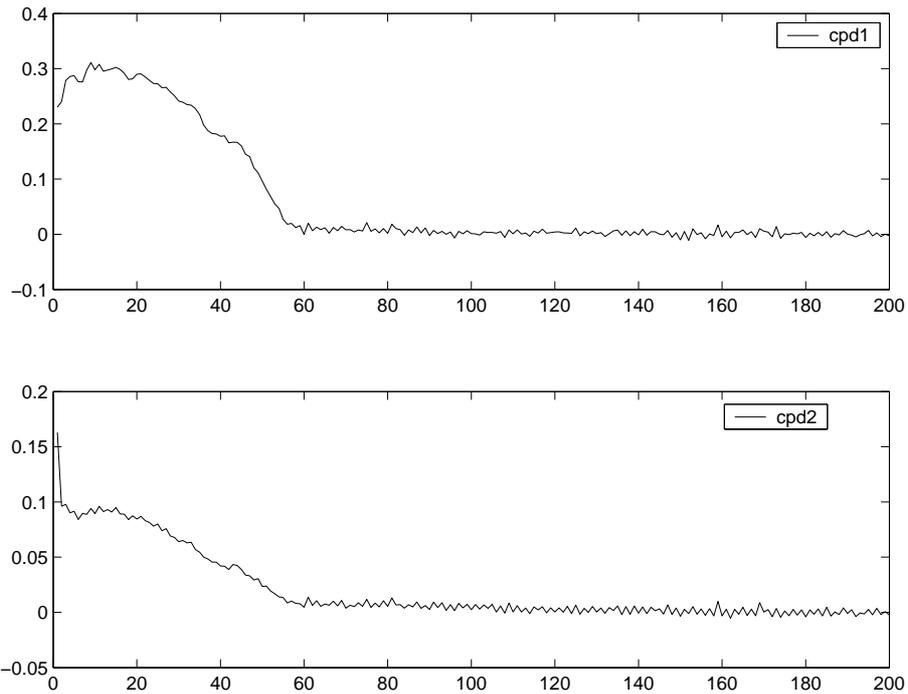


Figura 3.21: Reconstrução Transitório da Classe 1 - Acima Primeira PCD - Abaixo Segunda PCD

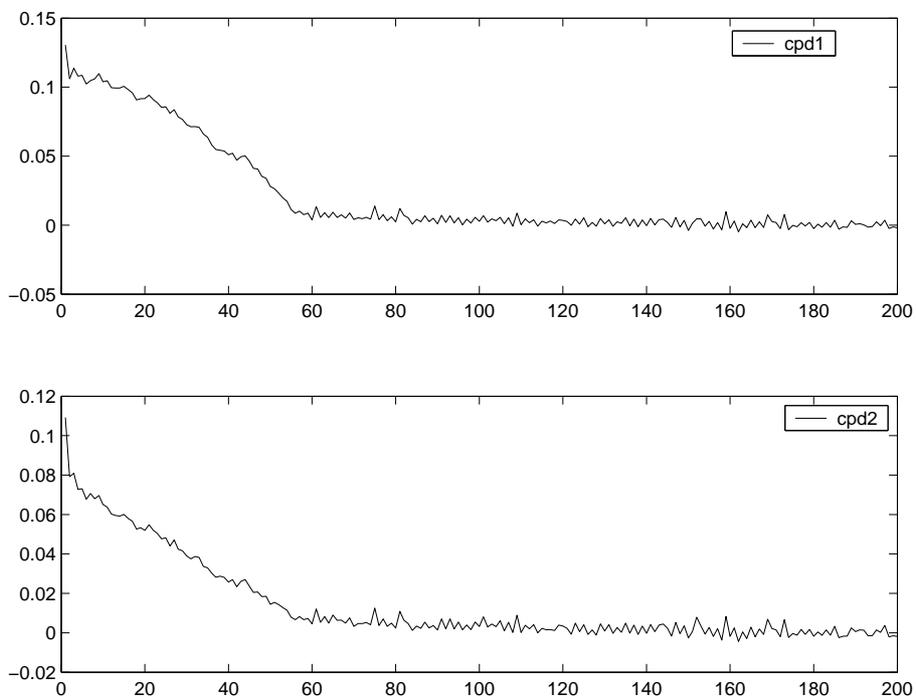


Figura 3.22: Reconstrução Transitório da Classe 3 - Acima Primeira PCD - Abaixo Segunda PCD

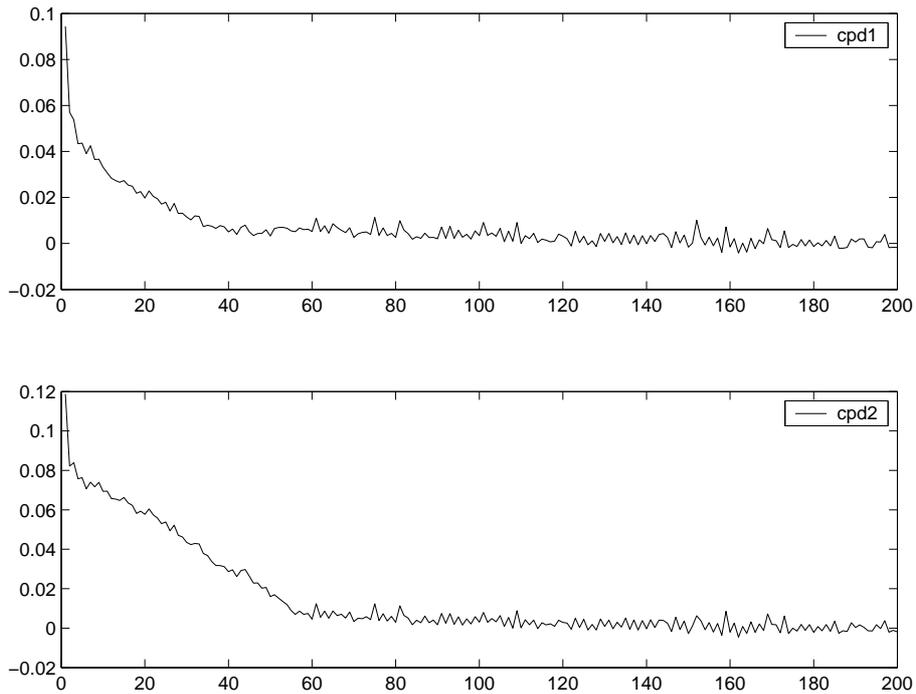


Figura 3.23: Reconstrução Transitório da Classe 7 - Acima Primeira PCD - Abaixo Segunda PCD

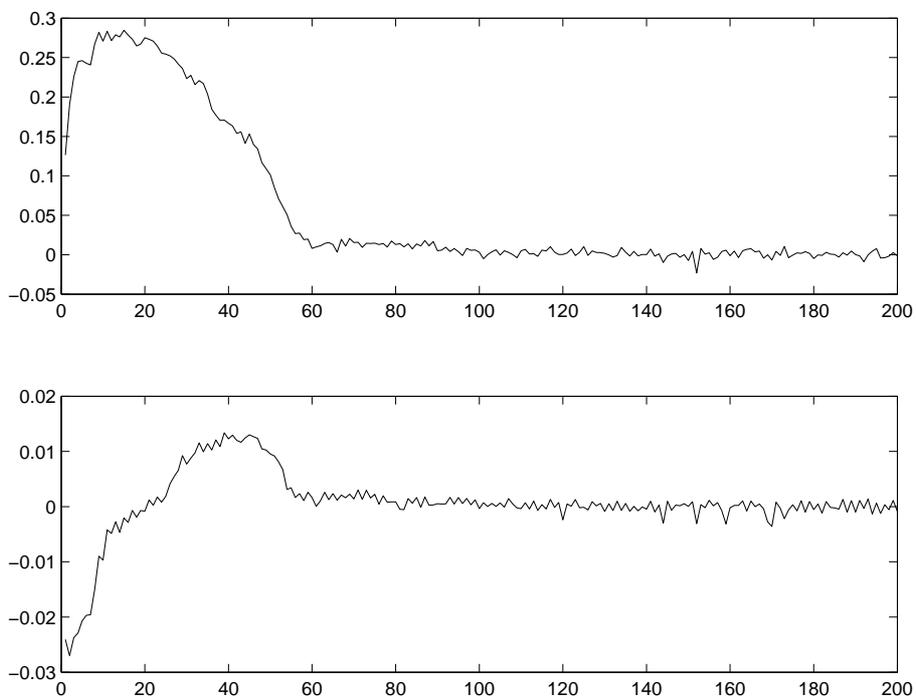


Figura 3.24: Reconstrução Transitório da Classe 1 - Acima Primeira PCA - Abaixo Segunda PCA

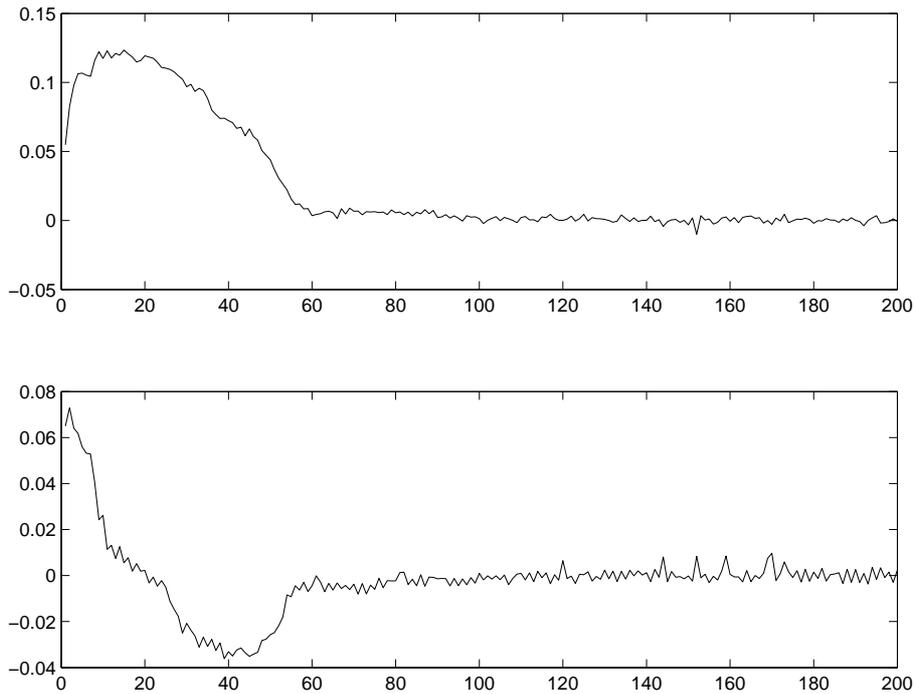


Figura 3.25: Reconstrução Transitório da Classe 3 - Acima Primeira PCA - Abaixo Segunda PCA

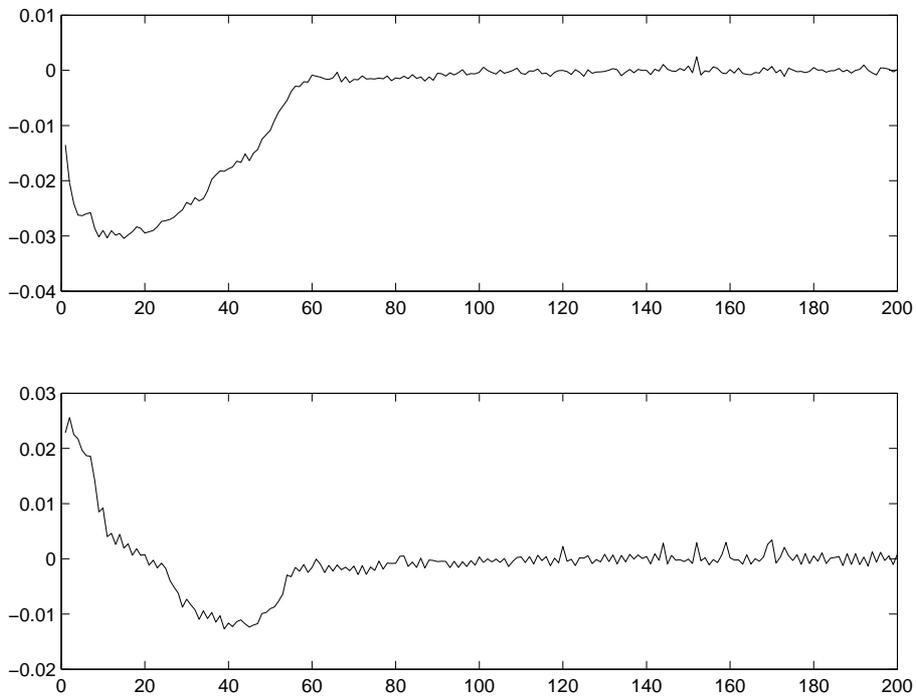


Figura 3.26: Reconstrução Transitório da Classe 7 - Acima Primeira PCA - Abaixo Segunda PCA

Tabela 3.9: Coeficientes de correlação e ângulos entre as direções PCD e PCA

PCD	PCA	coef. correlação	ângulo(em graus - aproximadamente)
1	1	-0,2178	100
1	2	0,0064	89
2	1	0,0086	92
2	2	-0,0072	90

da segunda PCA extraída é diferente da reconstrução considerando-se a segunda PCD extraída. O que pode nos levar a concluir que as direções PCAs e PCDs encontradas são direções pouco correlacionadas. Para formalizarmos os resultado expressos graficamente, descrevemos na Tabela 3.9 os coeficientes de correlação entre as direções PCD e as direções PCA, mostrando também os ângulos entre os vetores que representam esses dois espaços de dados.

A Tabela 3.9 nos dá um resultado quantitativo daquilo que visualmente observamos nos gráficos anteriores, que as componentes PCDs representam direções não correlacionadas (ou pouco correlacionadas) com as direções apontadas pelas PCAs.

Um outro resultado muito expressivo foi encontrado quando projetamos os eventos de cada classe de eletrodomésticos nas duas direções PCD. A Figura 3.27 mostra a combinação das projeções na primeira e segunda componentes principais de discriminação. Verificamos a tendência das classes serem agrupadas em regiões distintas, com pouquíssimas superposição de classes. Observamos uma superposição de um evento da classe 6 com a de um evento da classe 7, e um evento da classe 2 distante dos demais eventos dessa classe. Isso nos mostra uma potencialidade que as componentes principais de discriminação apresentaram que é de agrupar eventos de uma mesma classe de eletrodoméstico (formando “clusters”). Já a Figura 3.28, que representa a combinação das projeções da primeira e segunda PCAs, não mostra nenhuma separação nítida das classes, inclusive nos mostra uma região com superposições das classes 2, 3, 4 e 6 .

Quanto à pergunta : “Que informações do sinal original as PCDs “enxergam” ?” esta não pode ser totalmente respondida. No entanto, as reconstruções dos

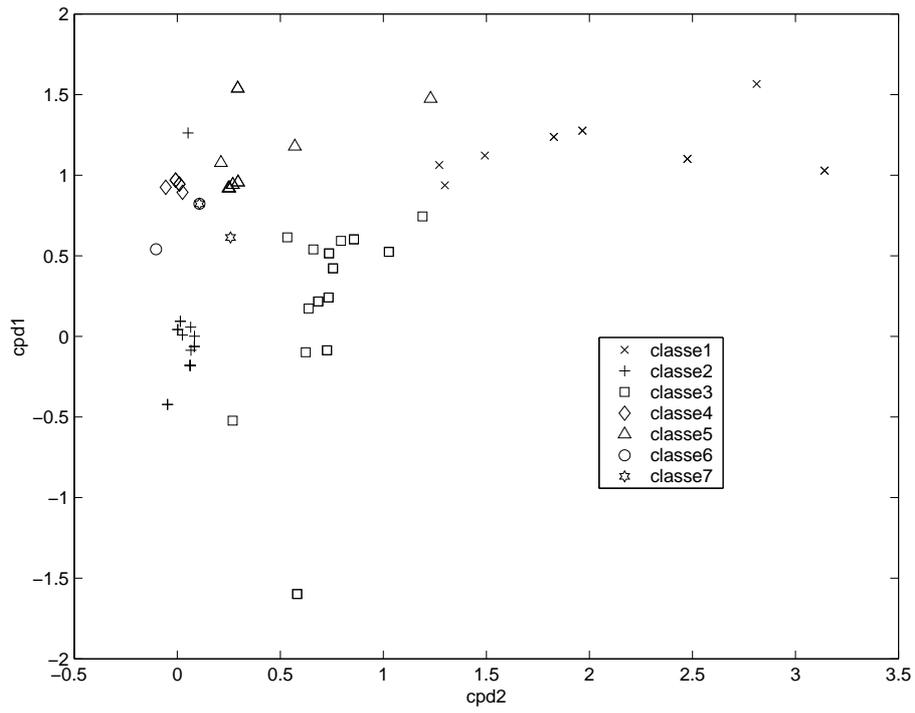


Figura 3.27: Projeções das entradas nas 2 PCDs

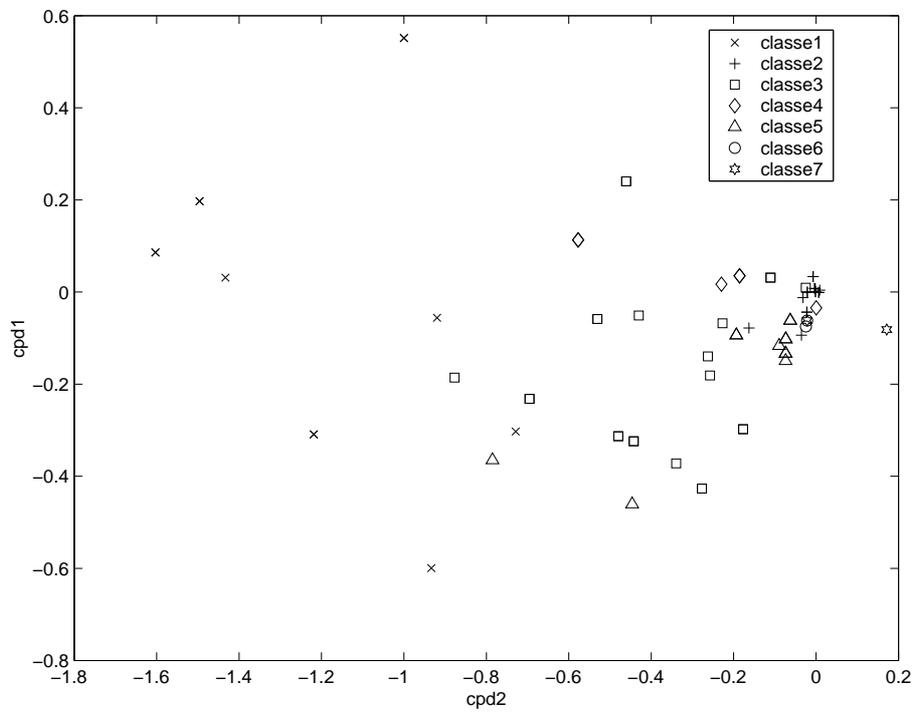


Figura 3.28: Projeções das entradas nas 2 PCAs

Tabela 3.10: Tabela de contingências - rede neural 60-2-3

4
.	5
.	.	7
.	.	.	2	.	.	.
.	.	.	.	4	.	.
.	2	.
.	1	1

sinais a partir das projeções PCDs revelaram sinais com decaimento até a amostra 60 do transitório, indicando que estas amostras seriam suficientes para se identificar os eletrodomésticos. Essa conclusão nos levou a realizar o projeto de um discriminador neural, usando análise PCD, considerando os transitórios com somente as 60 primeiras amostras.

3.7.1 Rede Neural com 60 amostras de entrada

Verificaremos nesta seção a afirmação que fizemos com base nas reconstruções dos transitórios a partir das projeções PCDs, de que as 60 primeiras amostras do transitório são suficientes para se ter um classificador neural tão eficiente quanto o encontrado considerando todas as 200 amostras do transitório (topologia 200-2-3).

A topologia da rede neural que iremos construir será de 60 amostras de entrada + PCDs extraídas + 3 neurônios (codificados binariamente). Configuramos a taxa de aprendizado com valor de 0,1, com taxa de decaimento de 0,999995 a cada passo de treinamento, que no total resultou em 200.000 passos para um erro médio quadrático ao final de 0,0003 e uma taxa de acerto global de 98%. A Tabela de contingência 3.10 mostra os erros de classificação cometidos pela rede neural, a diagonal principal para erro zero é : 4,5,7,2,4,2,2.

A rede neural errou para um evento de teste da classe 7 (Tabela 3.10) e durante o conjunto de treinamento também um evento dessa classe foi classificado errado. Esse resultado prova o que concluímos na seção anterior, de que somente as 60 primeiras amostras eram necessárias para fins de discriminação, e surpreendente-

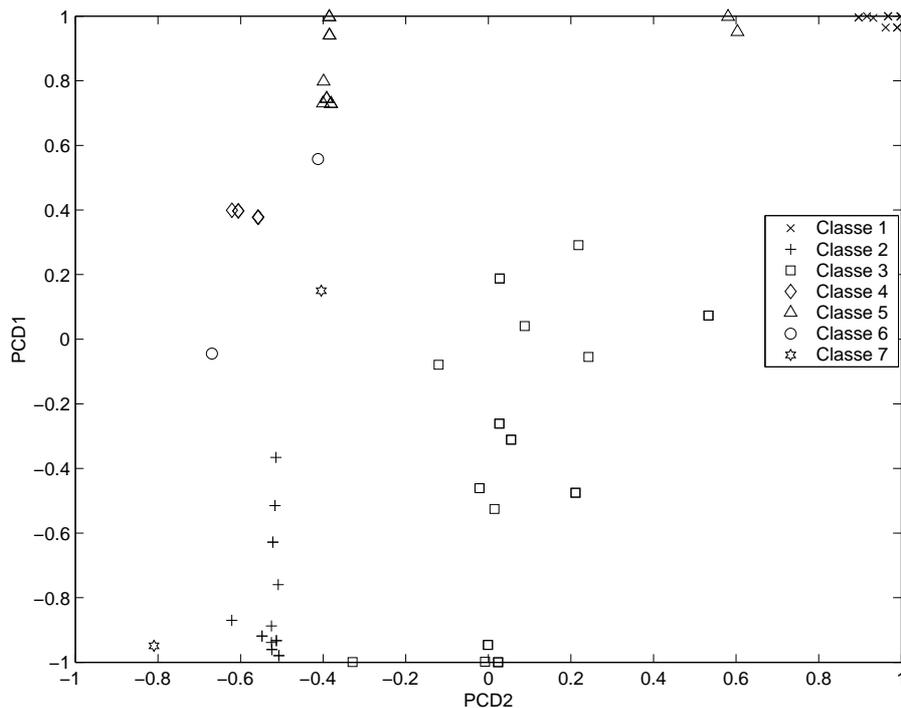


Figura 3.29: Projeções das entradas nas 2 PCDs

mente nos apresentou um resultado tão bom quanto a rede neural considerando as 200 amostras do transitórios. A Figura 3.29 mostra as projeções dos transitórios nas 2 direções PCDs encontradas, e pode-se notar mais uma vez a análise PCD sendo agrupador dos diferentes padrões de entrada.

A proposta de tentarmos entender o que as PCDs “enxergaram” como importante do espaço original nos levou a um resultado muito importante, uma vez que obtivemos ao final desse estudo um classificador mais compacto, o que dentro dos objetivos desse trabalho é muito expressivo, uma vez que desejamos obter implementações com o menor grau de complexidade possível, relacionando o custo dessa implementação com a quantidade de residências a serem monitoradas.

3.8 Superposição de transitórios

As superposições de transitórios de corrente podem ocorrer durante as aquisições, no entanto, a probabilidade de ocorrerem tais situações é bem pequena. De acordo com os levantamentos já realizados, referidos na seção 2.1, verificou-se que ocorrem cerca de 300 eventos transitórios por dia em residências típicas, o que impli-

ca um intervalo médio entre os transitórios em torno de 5 minutos. Se considerarmos que em uma aquisição precisamos de 60 amostras do transitórios (resultado obtido na seção anterior), esse período de tempo representará 0,5 segundo. Então podemos considerar a superposição de um ou mais eventos muito remota, o que pouco afetaria no desempenho global da rede neural. Ressaltamos que esta afirmativa é válida para o cenário de aquisição em que cada residência é monitorada de forma independente, que consideramos para esta análise; para um cenário de várias residências sendo monitoradas por um único sistema de monitoração, as superposições ocorrerão em maior frequência, podendo, neste caso, afetar o desempenho da rede neural.

Propomos um estudo para verificarmos o comportamento da rede neural quando a ela são apresentados eventos superpostos. Nessa análise consideraremos a topologia da rede neural discutida na seção anterior, que foi 60-2-3. Consideramos três condições de superposição, deslocando o início da superposição por espaçamento de 20 amostras. Abaixo, temos a descrição de cada caso:

1. Superposição ocorrendo de forma completa, isto é, todas amostras foram superpostas;
2. O início da superposição de um transitório começando pela amostra 20, isto é, a partir dessa amostra um outro transitório foi acionado, até a amostra 60. Assim, 40 amostras foram superpostas;
3. Superposição começando da amostra 40 indo até a amostra 60, num total de 20 amostras superpostas.

Geramos os dados superpostos, conforme as condições acima, fazendo o cruzamento entre os eventos de duas classes de eletrodomésticos distintas, para as sete classes de eletrodomésticos. Esses sinais superpostos foram apresentados à rede neural e seus resultados computados para verificação do comportamento da mesma.

Para as superposições completas (sobre as 60 amostras), a rede neural discriminou 80% desses eventos como sendo uma das classes que foram superpostas. Para os outros casos de superposição, a rede neural classificou, em mais de 95% dos casos, que a classe vencedora foi uma que não aquelas que estavam superpostas. O resultado indica que quanto mais para o final de um transitório ocorrer uma superposição,

pior será o desempenho da rede neural. Podemos concluir que a rede neural apresenta um resultado caótico quando lhe são apresentados transitórios superpostos, principalmente para as superposições que ocorrem ao final do transitório, neste caso estamos cortando do sinal original uma informação praticamente estado-estacionária para acrescentar amostras iniciais de um outro transitório.

As Figuras 3.31 e 3.30 mostram as projeções dos eventos originais, sem superposição (eventos da classe1 à classe7) e os eventos superpostos, que nos gráficos estão citados como classe8, nas duas direções PCDs.

Verificamos na Figura 3.30 e na Figura 3.31 que as projeções dos eventos superpostos (classe 8) apresentaram uma dispersão na sua distribuição, nestes dois casos as superposições iniciaram a partir da amostra 20 e 60 respectivamente. A Figura 3.30 representa as projeções dos eventos superpostos, consideramos que os eventos da classe 1 foram superpostos por eventos da classe 5 desde o início da aquisição dos transitórios (superposição das 60 amostras), para este caso os eventos superpostos ficaram agrupados sobre a área que representa as projeções dos eventos da classe 1 sem superposição.

Concluimos que em situações de superposição de eventos a rede neural apresentará resultados incoerentes, no entanto, como introduzimos nesta seção esses eventos serão raros de acontecer, afetando de forma insignificante o desempenho global da rede neural.

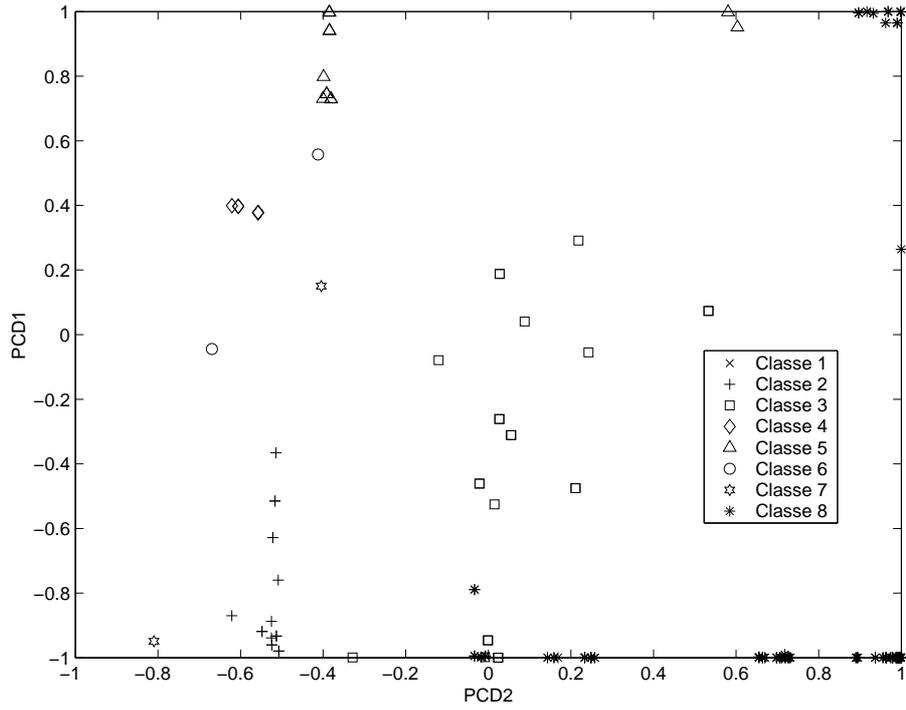


Figura 3.30: Superposição da classe 1 com eventos da classe 5, iniciando da amostra 40

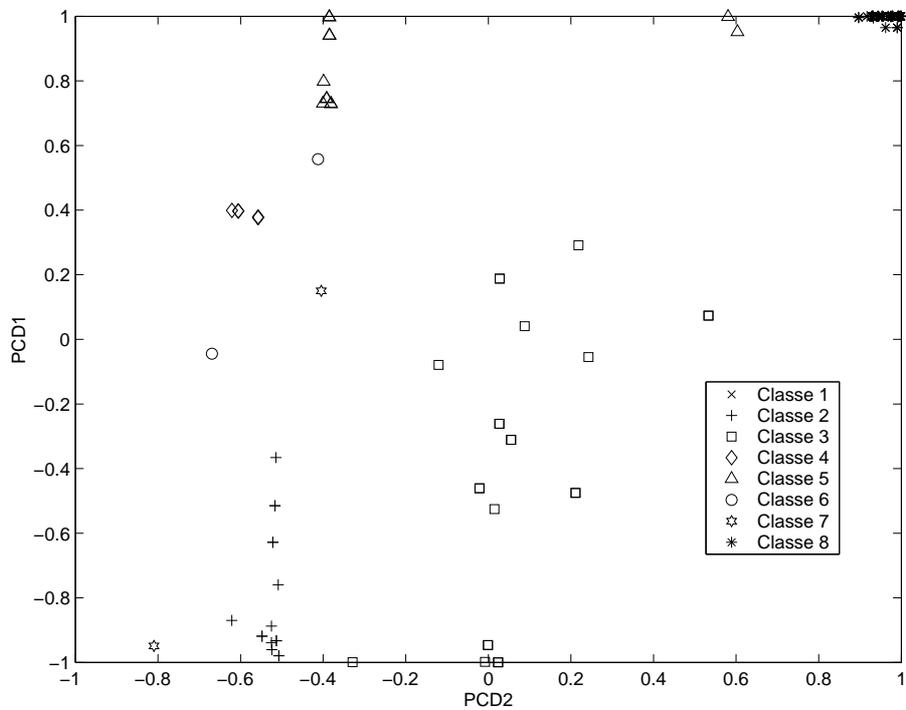


Figura 3.31: Superposição completa (60 amostras) da classe 1 com eventos da classe 5

Capítulo 4

Cenários de Implementação

Neste capítulo, discutiremos a implementação do sistema neural não-invasivo de monitoração de cargas elétricas residenciais considerando três cenários diferentes de aplicação, conforme já introduzido no primeiro capítulo. Numa aplicação prática, a escolha do cenário efetivo de realização leva em conta duas variáveis: o custo de implementação e a quantidade de residências a serem monitoradas. Para uma implementação na qual o baixo custo é prioritário (Cenário 1), escolhemos uma unidade de processamento baseada em microcontrolador. Já para implementações em que ocorrerá uma monitoração de blocos residências, estaremos utilizando DSPs (processadores digitais de sinais), uma tecnologia que apresenta um custo maior do que a de microcontroladores, mas também capaz de realizar um processamento mais veloz, nos permitindo ainda realizar multiprocessamento. Esse enfoque será visto para os cenários 2 e 3. Para o cenário 3, que exige o processamento de uma massa considerável de dados, implementaremos o sistema por meio de processamento paralelo, usando uma plataforma com 4 DSPs integrados. Para esta implementação específica, apresentaremos ainda alguns direcionamentos para se obter a melhor arquitetura de paralelismo. Como uma alternativa de implementação para o cenário 3, desenvolveremos um sistema de monitoração em uma máquina paralela, que fornece 16 nós de processamento.

4.1 Cenário 1

Este cenário foi definido considerando-se que a implementação seria a de menor custo possível, e a sua granularidade consistindo da monitoração individual de residências. Como o baixo custo de implementação é prioritário, a monitoração a ser feita deve abranger uma quantidade razoável de residências sem que o custo total se torne proibitivo. Assim, este sistema se adapta aos seguintes fins de uso:

- O baixo custo aqui proposto permite a monitoração de regiões de interesse, com a instalação do sistema nas residências por interesse tanto da concessionária, do cliente que se utiliza da energia elétrica, como do próprio governo;
- Interesse da concessionária - Para a concessionária, a utilização deste sistema permitiria monitorar áreas de interesse para fins de análise de dados que pudessem indicar o uso e o perfil do consumo e também a possível utilização da energia elétrica de forma fraudulenta, e também para fins de oferecimento de serviços e produtos;
- Utilização pelo usuário - Já para o cliente, este poderia solicitar a instalação desse sistema para se ter uma auditoria que indicasse o seu perfil de consumo energético. Para este caso, esse equipamento estaria de posse de um órgão de auditoria, de forma a possibilitar ao cliente questionar o consumo faturado pela concessionária de energia elétrica;
- Uso pelos órgãos governamentais - Para o governo, o interesse principal poderia ser a aquisição de dados que seriam indicativos para possíveis investimentos no fornecimento e para planejamentos futuros para atender a um crescimento neste consumo energético.

Propusemos, então, um sistema de monitoração utilizando um microcontrolador. A escolha leva em conta que este dispositivo eletrônico é de baixo custo e possui uma tecnologia de larga abrangência, já bastante consolidada. Optamos em realizar a implementação deste cenário em um ambiente simulado, uma vez que a transposição desta implementação para um dispositivo real não implicaria em dificuldades.

4.1.1 Implementação usando o Microcontrolador HCS08

O HCS08 é um microcontrolador da Motorola de alto desempenho da família HC08 [79]. É um microcontrolador de 8 bits com baixo consumo de energia e com 20MHz de velocidade de processamento. A Figura 4.1 mostra a arquitetura interna deste microcontrolador. Nesta figura, podemos verificar alguns dispositivos internos comuns ao microcontroladores: CPU, ALU, RAM. O HCS08 também inclui um conversor A/D de 10bits, uma entrada/saída serial para comunicação com dispositivos externos, espaço de 64Kbytes de memória flash para armazenamento do código da aplicação. Verificamos, na Figura 4.1, um módulo chamado DBG (“Debug Module”) que permite analisar, passo a passo, um código de implementação, acessando as funcionalidades internas do HCS08, antes do mesmo ser gravado no microcontrolador.

Para emularmos a implementação neste microcontrolador, usamos o software de desenvolvimento da própria Motorola, chamado *Metrowerks HCS08 CodeWarrior Development Tools* [80]. Este emulador, cuja linguagem de programação é ANSI C, nos permitiu realizar os teste de compilação e simulação do funcionamento do sistema. Neste ambiente, conforme pode ser visto na Figura 4.2, é possível verificarmos os valores dos registradores a cada passo de execução, das variáveis e também o número de ciclos de clocks necessários para se executar uma determinada instrução.

Utilizamos, para implementação, o discriminador neural obtido sobre os dados adquiridos por DAQM, na qual a topologia de rede era 160-4-3. Para este discriminador neural, obtivemos um tempo de processamento de 250ms.

4.1.2 Considerações sobre o resultado

Ao escolhermos um dispositivo de processamento como um microcontrolador, assumimos inicialmente que o nosso maior enfoque seria obter um tempo de processamento que permitisse processar um evento de entrada em um tempo menor do que a duração média dos transitórios, pois sabemos que esses dispositivos são extremamente úteis para controles de sistema e não para se realizar as operações mais típicas do processamento digital de sinais, como produto interno. O seu maior atrativo é a facilidade de implementação e o baixo custo.

O microcontrolador HCS08, embora nos permita escrever os códigos de imple-

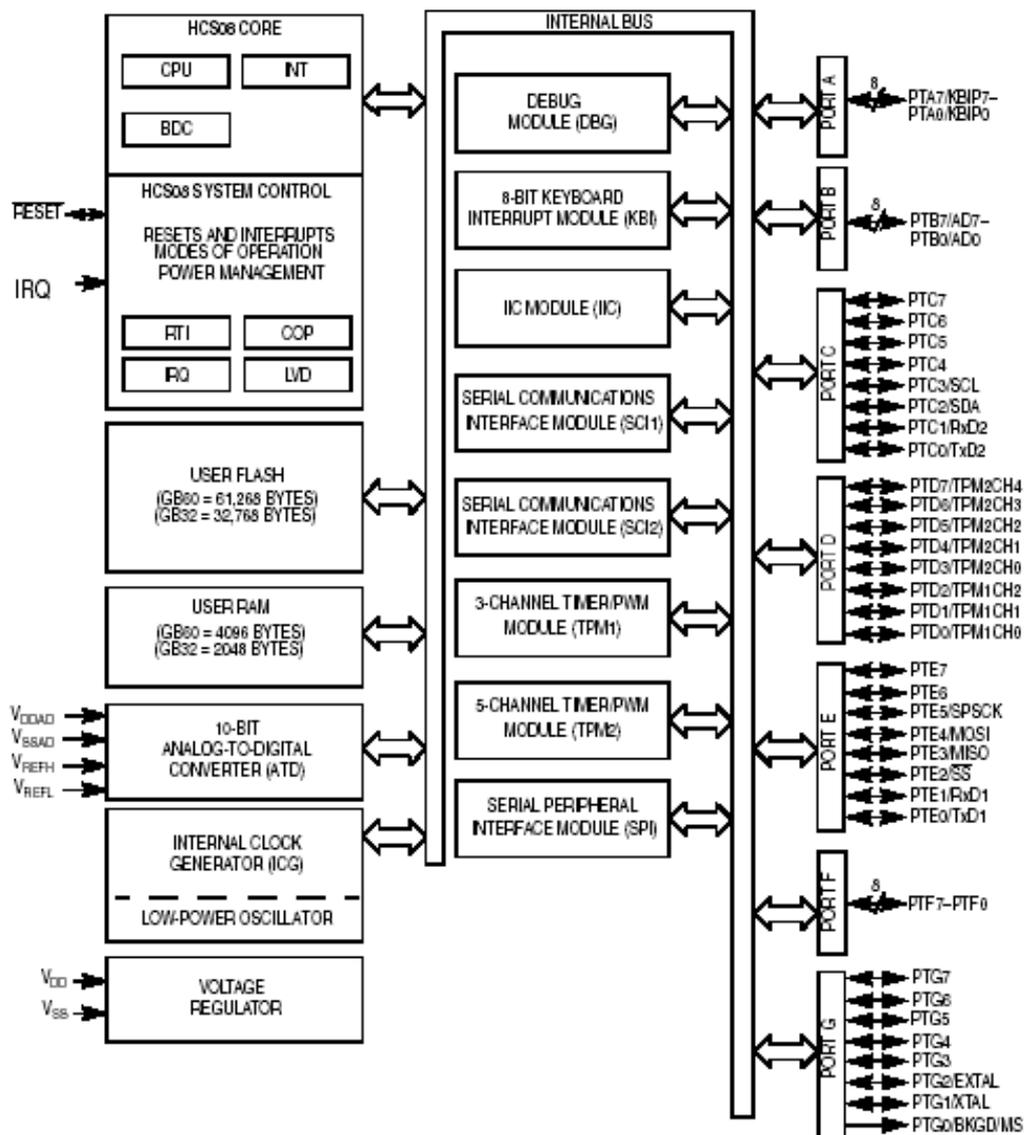


Figura 4.1: arquitetura Interna do microcontrolador HCS08

mentação como se estivéssemos em uma plataforma 32-bits (plataforma Windows), realiza cada operação através de instruções de 8 bits, o que implica num maior tempo de processamento, uma vez que uma simples soma ou multiplicação de dois números de 32-bits (dois “floats” por exemplo) será executada após diversas manipulações internas destes valores, representando mais ciclos de clocks numa plataforma de 8-bits.

O tempo de processamento obtido de 250ms, quando se considera que uma única residência estará sendo monitorada, é mais do que suficiente para se processar

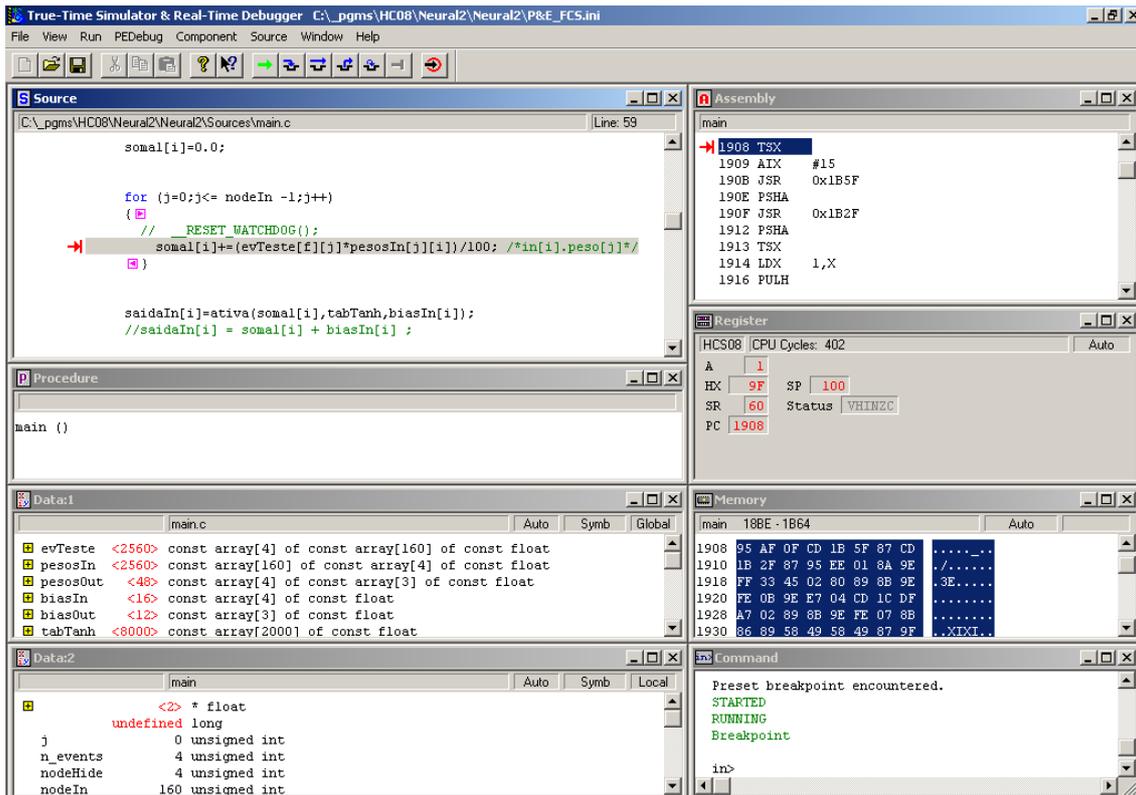


Figura 4.2: Ambiente de programação e simulação - HCS08

um evento de transitório. A janela de aquisição de um transitório é da ordem 2 segundos (se considerarmos a rede 200-2-3, visto na seção 3.4.3), então um processamento deste evento adquirido em 250ms representaria um tempo de processamento quase 10 vezes mais rápido do que a aquisição. Para o sistema de aquisição móvel proposto pelo CEPEL, e que foi apresentado no capítulo anterior, poderíamos ter o microcontrolador HCS08 sendo o “core” de todo o sistema. Este dispositivo poderia realizar a aquisição do transitório (visto que ele possui internamente um conversor A/D de 10bits), o processamento para se reter os picos de corrente e o processamento neural para identificação deste transitório.

O próprio microcontrolador do sistema de aquisição móvel, que é o microcontrolador 8031, poderia ser utilizado para implementar um classificador neural. Esta é, inclusive, a proposta atual do CEPEL, de integrar o nosso classificador neural ao seu sistema atual. Mas para fins de pesquisa, optamos por desenvolver o classificador neural em um microcontrolador mais recente e com mais recursos internos, já projetando um sistema com maior capacidade de processamento e mais integrado.

4.2 Cenário 2

A característica determinante do cenário 2 de implementação é que, para cada bloco de residências, existe uma unidade de processamento central que é alimentada pelos dados adquiridos (transitórios de corrente) de cada uma das unidades residenciais componentes. A quantidade de dados a ser processada, neste cenário aumenta consideravelmente, o que justifica termos uma unidade de processamento mais complexa, embora com um maior custo, e que possibilite o processamento de uma massa considerável de dados.

Definir blocos de residências (ou regiões) que podem ser monitorados, pode trazer algumas vantagens:

- A concessionária de energia elétrica poderia monitorar o consumo de energia elétrica de blocos de residências e assim projetar um planejamento de energia mais eficiente para aquela região, uma vez que esses dados lhe forneceriam o perfil do consumo médio daquela região;
- Para o governo, a monitoração de regiões de interesse poderia lhe conceder o conhecimento de como o crescimento e o uso de energia elétrica tem se dado para aquela região. Resultados desta monitoração poderia servir de base para que o governo cobrasse das concessionária um melhor fornecimento de energia, se assim for necessário, e esses dados também lhe indicariam, de um forma não-invasiva, o perfil sócio-econômico daquela região.

Implementaremos este cenário em um DSP (*Digital Signal Processors*), que é um dispositivo de processamento de sinais que nos permitirá atender aos requisitos mais exigentes de processamento deste cenário. Em particular, usaremos a família SHARC de processadores.

4.2.1 ADSP-21160M

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 desempenho e baixo consumo, mas a implementação de sistemas complexos 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 [81]. Suas principais características são:

- **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.
- **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 que simplifica o desenvolvimento do código. Além disso, a integração destes controladores reduz o número de componentes do sistema, reduzindo, conseqüentemente, as dimensões e a complexidade do mesmo.

Para a implementação do sistema proposto, optou-se por utilizar o processador ADSP-21160M da *Analog Devices*. Este processador é um DSP de 32 bits

com *clock* de 80 MHz que forma um sistema de processamento completo *on-chip*. A Figura 4.3 mostra internamente esse dispositivo. 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*) [82, 83, 84], permitindo que a mesma instrução seja realizada sobre dois dados distintos. Desta maneira, em certas ocasiões, como operações de produto interno, consegue-se dobrar o número efetivo de operações por ciclo, aumentando consideravelmente a eficiência de processamento, sem a necessidade de aumentar o *clock* do processador.

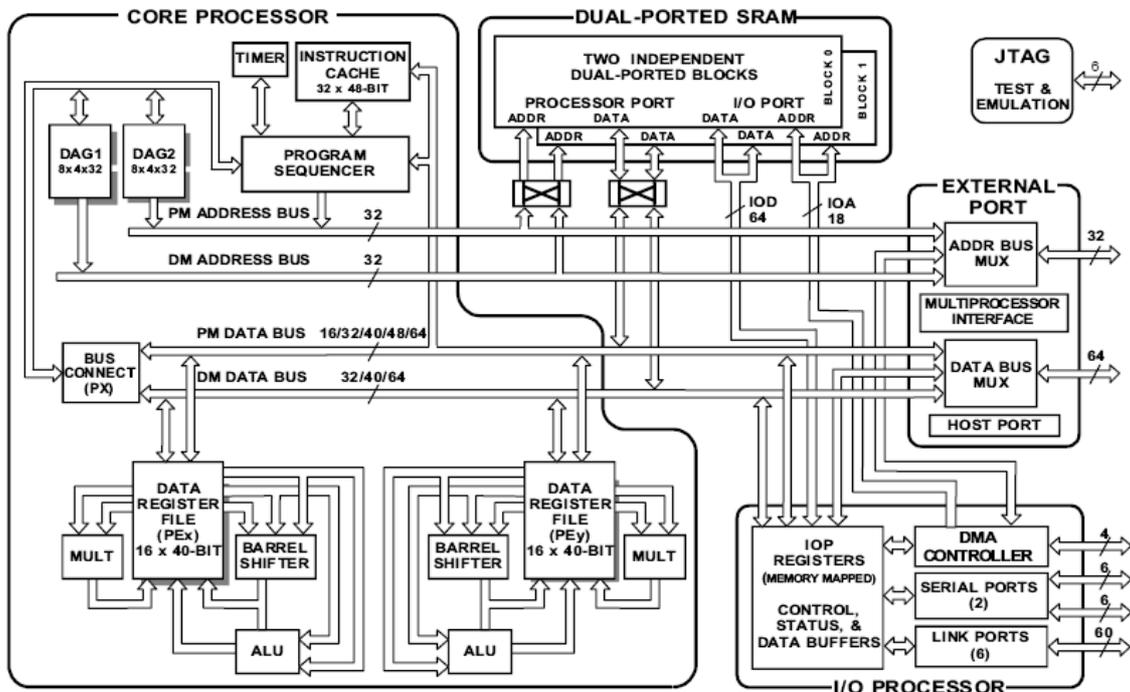


Figura 4.3: Arquitetura Interna do ADSP-21160M - extraído de [82]

4.2.2 Implementação e Resultados

Para desenvolvermos uma aplicação no ADSP-21160M utilizamos o ambiente de programação da *Analog Devices* que é o VisualDSP++. Nesta plataforma, podemos escrever o código da implementação em C ou C++. Este ambiente de programação fornece a facilidade de realizarmos o “debug” da aplicação antes de efetivamente carregá-la no DSP. Assim, é possível eliminarmos todos os erros de

Tabela 4.1: Tempo de processamento - ADSP 21160M

	Tempo (em μs)
SIMD desabilitado	116
SIMD habilitado	52
SIMD habilitado (iteração dos “loops” por hardware)	21

programação antes de realmente executá-la no DSP e ainda é possível termos uma estimativa muito próxima do tempo de processamento da aplicação.

A Tabela 4.1 mostra os tempos de processamento obtidos, considerando a realização de uma rede neural com a topologia de 160-4-3. O primeiro tempo de processamento obtido representa o ADSP-21160M com suporte SIMD desabilitado, enquanto o segundo tempo de processamento com este suporte habilitado. Como em nossa aplicação o maior tempo de processamento ocorre nos produtos internos, ao habilitarmos o suporte SIMD configuramos o DSP para que, em único ciclo de *clock*, se efetue o produto interno sobre dois dados distintos.

Observa-se na Tabela 4.1 que o tempo de processamento com SIMD é menor que a metade do tempo sem SIMD. Ao habilitarmos a compilação do código com esse suporte, o compilador realiza uma otimização de código específica, melhorando ainda mais o desempenho com multiprocessamento.

O menor tempo obtido ($21\mu s$) foi conseguido ao escrevermos as operações de soma e produto em linguagem *Assembling*, o que também nos permitiu habilitar a iteração dos “loops” através de hardware [82], otimizando-se mais ainda o código.

Os tempos de processamento obtidos indicam que uma solução como esta, em que se utiliza um DSP, pode ser apropriada para se monitorar blocos de residências. Ao habilitarmos o suporte SIMD desenvolvemos um plataforma que permite operar sobre uma grande quantidade de dados. Neste caso, o sistema com DSP seria utilizado para receber os diversos transitórios, adquiridos previamente por um outro sistema, e processá-los localmente.

4.3 Cenário 3 - Implementação usando arquitetura paralela de processamento

O cenário 3 representa uma extensão do cenário 2, no qual a preocupação era monitorar blocos de residências. Neste novo cenário, o foco principal é a monitoração de vários blocos de residências, ou mesmo uma sub-estação. Este cenário, comparativamente com os dois cenários anteriores, é o que tem a maior quantidade de dados para monitoração, e, conseqüentemente, se torna o cenário com o maior custo de implementação.

Este cenário apresenta algumas características importantes:

- Ao se monitorar áreas relativamente grandes de residências, estamos levantando indiretamente o perfil de consumo daquela região. Pode ser bastante interessante para campanhas publicitárias;
- Para o governo, o maior interesse seria gerenciamento, fiscalização e planejamento de fornecimento de energia;

Para desenvolvermos este cenário, escolhemos uma plataforma de processamento paralelo. Utilizaremos uma placa de desenvolvimento contendo 4 DSP's (ADSP-21060) e um sistema de computação paralela com 16 nós de processamento baseado no ADSP-21020, que vem a ser o núcleo central do ADSP-21060..

4.3.1 Multiprocessamento usando ADSP 21060

O ADSP-21060 é um DSP da *Analog Devices* com 32-bits de processamento com *clock* de 40Mhz, possuindo memória SRAM, porta serial, controlador DMA, etc. [85]. Suporta multiprocessamento, aonde até 6 processadores podem ser interligados, sendo um desses o processador *host*, aquele que se comunicará com a aplicação externa. Uma outra especificação bem interessante é que o processador “host” pode acessar a memória interna de todos os outros processadores e também os seus registros internos. Na Figura 4.4, verificamos que existem áreas de memória de cada processador compartilhada e que podem ser acessadas pelo processador *host*. É como se fossem áreas de memórias internas do processador *host*.

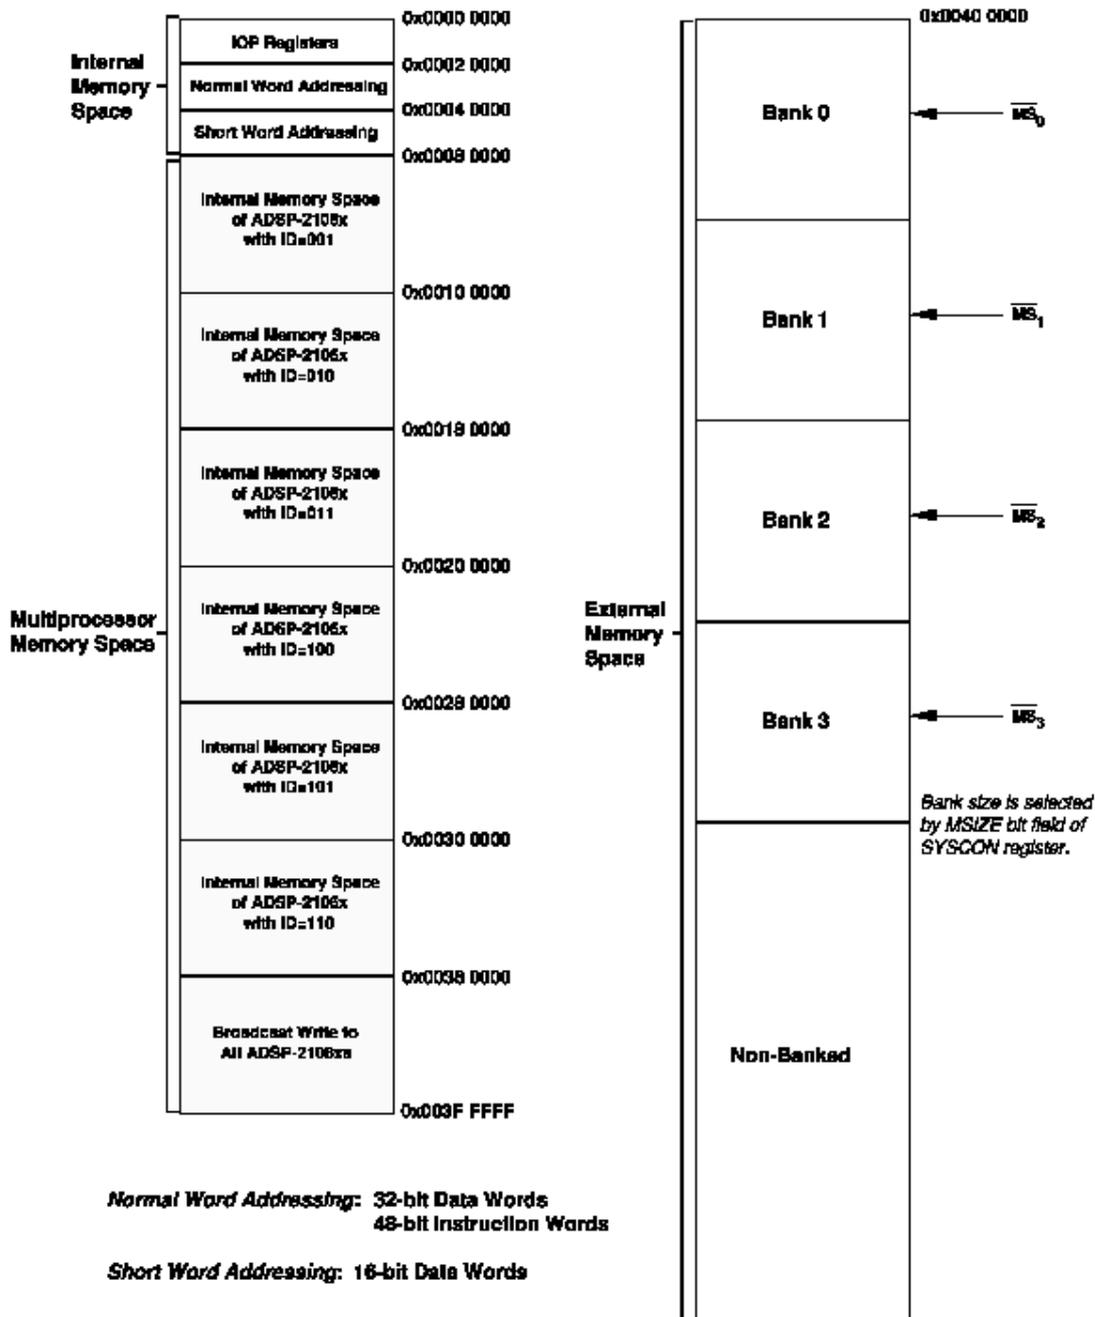


Figura 4.4: Memória Compartilhada do ADSP-21060 - extraído de [85]

Para a nossa aplicação utilizaremos uma estrutura paralela com 4 DSP's, com um processador atuando como o *host*, enviando os dados aos demais processadores para o processamento neural. A estrutura de processamento paralelo definida para a implementação é o paralelismo de dados, em que cada nó de processamento executa a mesma tarefa sobre diferentes dados.

Usamos a propriedade da arquitetura em que a aplicação *host* pode ter acesso

Tabela 4.2: Tempo de processamento - DSP 21060

Configuração	Tempo (em μs)
1 processador	208
1(host) + 2 processadores	109
1(host) + 3 processadores	76

à memória interna de cada processador para escrever os dados a serem processados (transitórios de corrente) e para ler os resultados do processamento. Esse acesso direto à memória permite que o processamento se torne mais eficiente e rápido, uma vez que o tempo gasto para escrever e ler um dado na memória é bem inferior do que o envio dos dados através de um canal de comunicação.

A Tabela 4.2 nos mostra os resultados das diferentes implementações realizadas: na primeira, a aplicação está rodando em único processador; na segunda situação temos um processador *host* responsável por enviar os dados e 2 processadores que realizam o processamento sobre os dados; e na terceira, utilizamos o paralelismo de dados. O tempo de processamento é computado como sendo o tempo gasto para se processar um evento.

Verificamos que o tempo de processamento diminui conforme aumentamos o número de processadores. No entanto, verificamos que esse tempo é sempre maior do que o tempo obtido usando-se um único processador (208 μs) dividido pelo número de processadores que efetivamente realizam o processamento neural. Este tempo a mais decorre do tempo de escrita dos dados a serem processados e leitura das respostas do processamento neural por parte da aplicação “host”.

4.3.2 Considerações sobre os resultados

Os resultados apresentados na Tabela 4.2 mostram que a realização nesta plataforma de processamento é viável. Embora os tempos de processamento sejam maiores do que aqueles obtidos pelo ADSP-21160M, a velocidade de processamento permite um processamento sustentado de uma massa considerável de dados.

Empregamos em nossa análise o paralelismo de dados por ser esta técnica a mais eficiente para os casos em que o processamento é o mesmo sobre diferentes

dados. No apêndice B apresentamos os conceitos relativos não só ao paralelismo de dados, como de outras técnicas de paralelismo.

Uma dificuldade no processamento paralelo é a determinação do número ótimo de processadores. Para os casos apresentados neste trabalho, tivemos a formulação mais simples de paralelismo, com cada nó de processamento realizando a mesma tarefa (o processamento neural) sobre dados distintos. Em casos como este, para se determinar o número ótimo de processadores, utilizamos a fórmula 4.1, onde $T(1)$ representa o tempo para se processar um evento (processamento neural) em um único processador e T_{comm} é o tempo de comunicação entre a aplicação *host* e as unidades de processamento.

$$N \geq \left(\frac{T(1)}{T_{comm}} + 1 \right) \quad (4.1)$$

A equação nos mostra que quanto maior o tempo gasto em comunicação entre os processadores menor será o número de nós de processamento realizando tarefas em paralelo. Supondo que $T_{comm} = T(1)$, só precisaríamos de 1 nó de processamento, visto que o tempo gasto para se transmitir os dados seria igual ao tempo de processamento desses dados. Logo, não teríamos nenhum ganho na eficiência se aumentássemos o número de processadores. As arquiteturas paralelas eficientes tendem a ter estruturas internas de alta velocidade para realizar a intercomunicação dos processadores.

A equação 4.1 só é válida se os nós de processamento realizarem as mesmas tarefas. Para casos em que isto não ocorre, isto é, cada nó de processamento pode realizar tarefas diferentes, a formulação de uma arquitetura paralela se torna mais complexa. Em [86] propusemos um estudo para resolver essas situações. Esse artigo aplica o conceito de SER (*Scheduling by Edge Reversal*) que permite sincronizar processos originalmente assíncronos e uma vez resolvido o assincronismo inerente da aplicação podemos, então, transportar a estrutura encontrada para uma plataforma paralela.

4.4 Implementação usando uma máquina paralela

Se imaginarmos que a quantidade de dados a serem processadas cresça a um ponto tal que a arquitetura com 4 DSPs, utilizada na seção anterior, não seria suficiente para atender a essa demanda de dados, uma solução seria utilizar máquinas com alta capacidade de processamento, normalmente compostos por vários nós de processamento. Em particular, utilizamos uma máquina paralela, Sistema TN310 [87], para implementação do sistema de monitoração de cargas elétrica residenciais que demandasse o processamento de uma grande massa de dados. O sistema TN-310 se classifica com uma máquina M.I.M.D (Multiple Instruction Multiple Data), conforme a definição de Flynn [88], sendo uma arquitetura de memória distribuída, o que significa que cada nó de processamento possui uma memória local. A rede de conexões entre os diversos processadores é do tipo pseudodinâmica, isto é, a topologia da rede de conexões pode ser modificada antes da execução de uma dada aplicação. Esse sistema possui 16 nós de processamento, os quais podem se comunicar entre si através de uma rede assíncrona de chaves, formada pelos dispositivos STC104.

Cada nó de processamento desse sistema contém um *transputer* (INMOS T9000) para gerenciar a comunicação, um banco de memória RAM privada de 8Mbytes, um processador digital de sinais (ADSP-21020) e um *buffer* de comunicação entre o transputer e o ADSP de 256Kbytes.

Presente em cada nó de processamento, o DSP se encontra disponível para otimizar as aplicações em processamento de sinais. O ADSP-21020 pode ser programado a partir de rotinas de bibliotecas em C [89, 90]. O sistema TN310 possui duas placas interconectadas, cada qual composta de oito nós de processamento (Figura 4.5).

O transputer T9000 (ver Figura 4.6) é um microprocessador CMOS 32 bits projetado para facilitar a comunicação entre processos. Seu clock é de 20Mhz e ele integra em si uma unidade de ponto flutuante (FPU), realizando operações de ponto flutuante a taxas de 15Mflops. Possui 16Kbytes de memória *cache*, que pode ser utilizada em três diferentes configurações: toda em *cache*, metade *cache*/metade memória de acesso rápido ou totalmente configurada como memória de acesso rápido. Contém uma unidade de memória programável que tem 4Gbytes de espaço de endereços físicos. Esta arquitetura permite a criação e programação de qualquer número

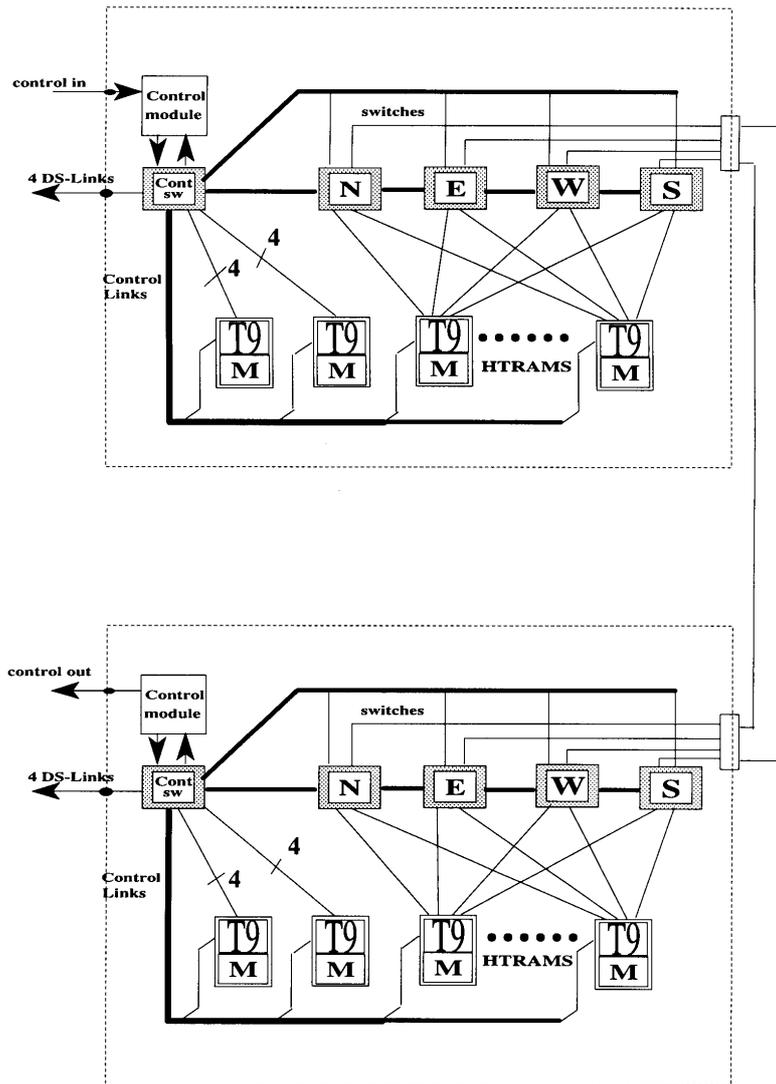


Figura 4.5: Arquitetura do Sistema TN-310 e interconexões entre as duas placas de processadores.

de processos concorrentes [89].

A comunicação entre os T9000 é feita através dos canais de comunicação implementados em baixo nível (*hardware*). A mesma instrução de máquina é usada para comunicação entre processos do mesmo transputer, bem como para a comunicação entre processos de diferentes transputers. A comunicação entre processos de diferentes transputers (T9000) é feita através dos canais virtuais. Esses canais virtuais são multiplexados nos canais físicos por um Processador de Canais Virtuais (VCP) em 4 *DS-Links*, que ficam internos ao T9000.

A idéia básica do procedimento de comunicação é simples. Quando uma

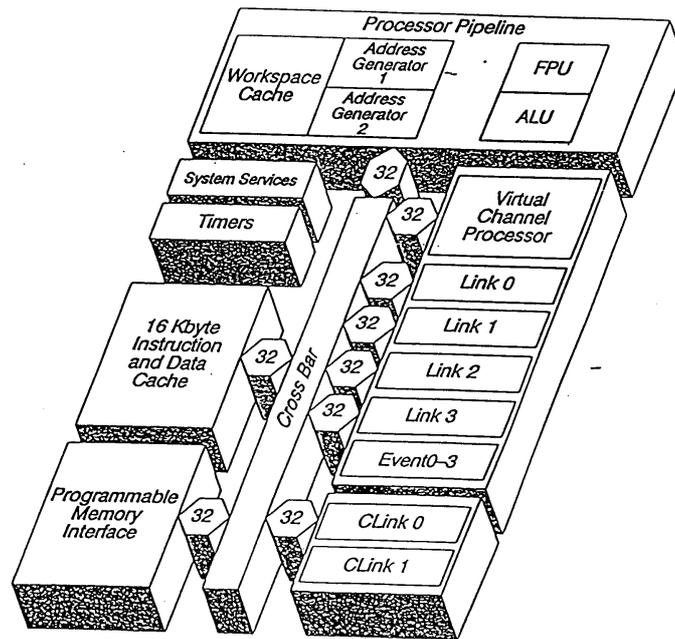


Figura 4.6: Arquitetura Interna do Transputer T9000

informação está para ser transmitida, o processo que deseja transmitir envia uma mensagem para o seu VCP, indicando o endereço do receptor (T9000 destinatário) e o tamanho da informação a ser enviada. O VCP divide o dado a ser transmitido em pacotes de tamanho fixo (32 bytes). Cada pacote carrega um cabeçalho indicando o endereço do receptor e o roteamento necessário, através da rede de dispositivos C104s. O pacote é enviado para a primeira chave no roteamento pré-definido, a qual interpreta (e remove) a primeira parte do cabeçalho e envia o pacote para o próximo nó. No destino final, cada pacote é reconhecido e a transmissão de um novo pacote é permitida. A Figura 4.7 ilustra esse esquema.

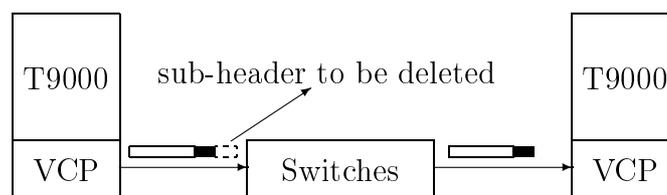


Figura 4.7: Roteamento dos Pacotes.

O ADSP-21020 (ver Figura 4.8) é um processador com 32/40-bits ponto flutuante, capaz de realizar uma instrução a cada 40ns. A arquitetura básica desse

DSP inclui três unidades computacionais independentes: ALU, multiplicador com acumulador ponto-fixe e deslocador (shifter). Essas unidades são conectadas em paralelo, de forma que uma instrução de produto interno e busca dos operandos da próxima multiplicação possa ser executada em um ciclo de clock.

A comunicação entre o DSP e o T9000 de um nó de processamento é feita através de um *buffer* comum de 256Kbytes. Esta comunicação permite que o T9000 divida as suas tarefas de processamento com o DSP. Para a nossa aplicação, o processamento de sinais (processamento neural) foi feito no DSP, enquanto o restante do processamento no T9000. Desta maneira obtivemos um tempo menor no processamento global.

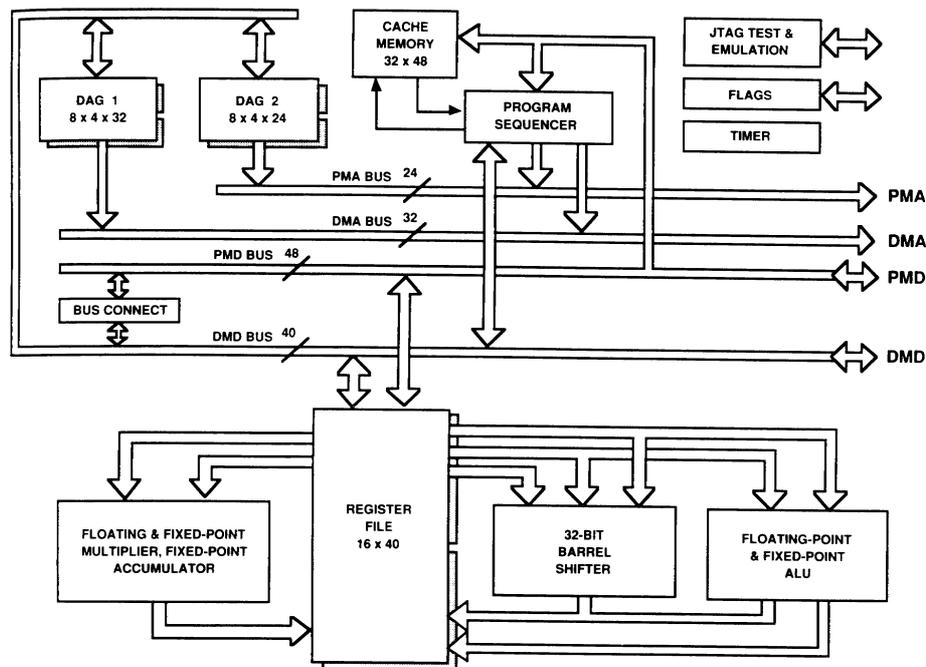


Figura 4.8: Arquitetura Interna do ADSP 21020.

As conexões entre os nós de processamento deste sistema são feitas através de chaves, baseadas no circuito integrado C104. Essas chaves são capazes de conectar 64 canais de comunicação seriais entre si, formando até 32 *links* de comunicação entre os diversos processadores. Esses “links” são capazes de operar concorrentemente na transferência de 32 pacotes de dados sem que haja interferência entre eles. Cada nó pode acessar a rede de comunicação através de 4 links seriais de alta velocidade.

de (100Mbits/segundo), os quais são usados para acessar os dados residentes em qualquer outro nó de processamento.

4.4.1 Programação no Sistema TN-310

A programação no Sistema TN-310 pode ser realizada em três diferentes ambientes (ou níveis) de programação de flexibilidade crescente. O primeiro ambiente, ou nível mais baixo de programação, é o *InMos C Toolset*. Neste nível de programação, o usuário tem acesso a um conjunto de ferramentas que permite a configuração dos parâmetros de *hardware* da arquitetura e de um conjunto de bibliotecas que o permite programar utilizando uma linguagem ANSI-C concorrente. Por ser um ambiente de programação em baixo nível, se exige do usuário um maior conhecimento da estruturação em hardware do sistema em contrapartida, se ganha em velocidade de processamento.

No segundo nível de programação, um pequeno sistema operacional atua nos diversos nós de processamento do sistema. Este sistema operacional é chamado de *RUBIS*, sendo este sistema um *micro Kernel*, programado em ANSI C, adaptado para máquinas paralelas. Neste ambiente, a programação se torna mais fácil; no entanto, se perde em velocidade de processamento.

O terceiro ambiente de programação do sistema TN-310 inclui ferramentas de programação em *PVM*. O ambiente de programação em *PVM* é um ambiente de paralelismo virtual que permite uma padronização entre rotinas de comunicação de diferentes ambientes computacionais. As aplicações que rodam nesta camada se tornam mais lentas em relação às duas camadas anteriores. A Figura 4.9 mostra os níveis de programação e como se altera a velocidade de processamento e flexibilidade em cada nível. Pode-se observar, também, que o nível mais baixo de programação é o *Assembler*, no entanto este ambiente de programação não se encontra disponível à aplicação em questão.

Descreveremos, a seguir, com maiores detalhes o ambiente de programação *InMos C Toolset*, uma vez que este projeto foi completamente desenvolvido neste ambiente de programação.

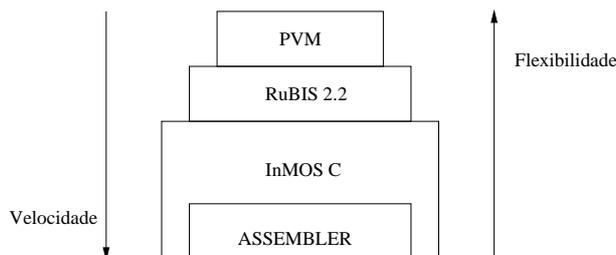


Figura 4.9: As diversas camadas de programação disponíveis no Sistema TN-310.

4.4.1.1 Ambiente CTOOLSET

O sistema TN-310 não se apóia sobre nenhum sistema operacional. Os processos existentes em seus processadores executam programas (executáveis) montados em uma máquina externa ¹ com Sistema Operacional próprio (DOS, UNIX, WINDOWS). Especificamente, neste projeto, utilizou-se um computador pessoal IBM, rodando Windows, e funcionando como sistema hospedeiro da máquina paralela.

A linguagem C utilizada é o ANSI-C (padrão) com suporte de bibliotecas especiais que permitem a concorrência e paralelismo entre os processos. Identificamos, abaixo, algumas dessas bibliotecas e suas funções.

- `process.h` - nesta biblioteca são definidas as funções de inicialização de processos e controle dos mesmos.
- `channel.h` - biblioteca que contém as funções utilizadas na definição de canais de comunicação e a transmissão de dados por esses canais.
- `fnload.h` - esta biblioteca define as funções para utilização de códigos dinâmicos.

As bibliotecas permitem que a descrição da rede seja feita em *software*. Para descrevermos o comportamento da rede em baixo nível, é necessário escrevermos um arquivo no padrão NDL (*Network Description Language*). Neste arquivo são configurados quaisquer parâmetros dos componentes da rede de processadores e chaves. Neste arquivo são definidos, por exemplo, a configuração da memória *cache*, as instruções de inicialização e ponteiros para área de memória dos processadores, e também as conexões (rede de chaveamento) entre os diversos nós de processamento.

¹Também chamada de máquina hospedeira - Host

Como foi visto na seção anterior, para a comunicação entre processos que rodam em processadores diferentes é necessário se utilizar o Processador de Canais Virtuais, de forma a se possibilitar a interconexão de todos os 16 nós de processamento. A forma como a arquitetura de processamento paralelo será implementada na máquina é descrita através de um arquivo de configuração (arquivo texto comum .CFS). Neste arquivo é definido o número de processadores a serem utilizados, a alocação dos mesmos (o número do processador de 0 até 15), as suas interconexões e a definição de qual processador estará ligado ao Host e a memória disponível para cada tarefa. Este arquivo de configuração nos traz um benefício enorme, pois não é preciso lidar diretamente com o arquivo NDL, pois neste arquivo há uma linha que descreve a configuração da rede a ser utilizada já definida a priori.

Para se compilar um código em C, utilizam-se compiladores e *linker* especiais (**icc** e **ilink**) que fazem parte do InMos C Toolset. A união dos arquivos para formar uma aplicação é feita através de aplicativos específicos, o **inconf** e o **icollect**. A Figura 4.10 nos mostra, para a aplicação mestre e escravo, como foi construído o arquivo executável, o arquivo **teste.btl**.

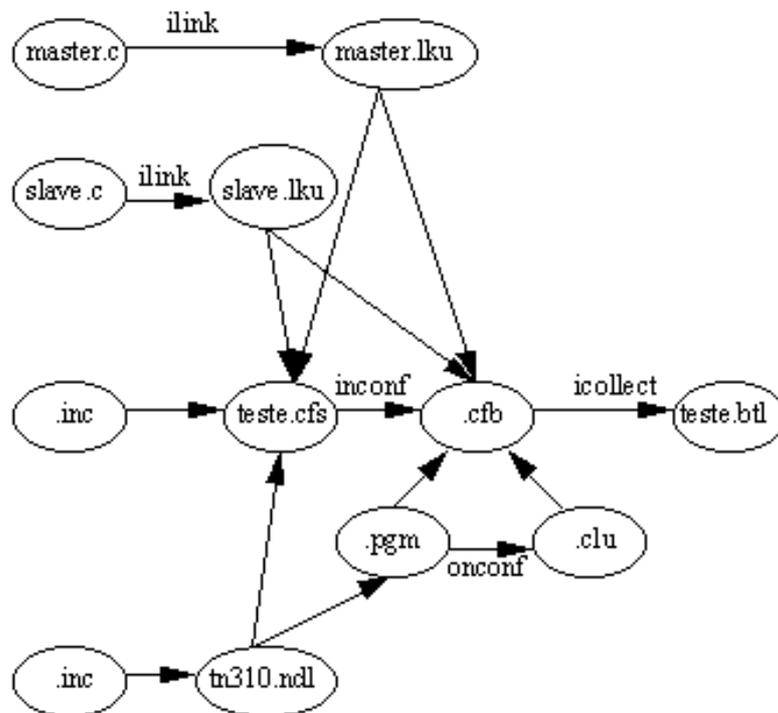


Figura 4.10: Montagem de um código executável

4.4.2 Implementação em 1 processador

O sistema de monitoração de cargas elétricas residenciais foi implementado no sistema TN-310 utilizando-se, primeiramente, uma programação seqüencial. Utilizamos um dos 16 nós de processamento do sistema TN310 e para este processador codificamos, em linguagem C, as operações matemáticas das rede neurais vistas nas seções 3.4.1, 3.4.2, 3.4.3.

O paralelismo que estaremos implementando e analisando na seção seguinte se refere unicamente ao processamento em paralelo da rede neuronal, isto porque o pré-processamento não contém paralelismo inerente em seu conteúdo. Ao compararmos os tempos de processamento seqüencial e paralelo estaremos nos referindo, somente, ao processamento da rede neuronal.

O tempo de processamento da rede neuronal está diretamente ligado ao número de multiplicações e somas necessário para que se obtenha a saída correspondente a um determinado padrão de entrada. Como o tempo de processamento de uma soma ou de uma multiplicação, no DSP, é determinado pelo paralelismo interno da CPU, este tempo é fixo. No entanto, a função de transferência de um neurônio em nossa estrutura é uma função não linear, no caso a função tangente hiperbólica. Na biblioteca *math.h* encontramos a função $\tanh(x)$ que retorna o valor da tangente hiperbólica de x através da chamada de uma subrotina que realiza esta operação.

Observando que a tangente hiperbólica para valores que estejam acima de 10 ou para valores abaixo de -10 apresentam valores praticamente saturados em +1 e -1 respectivamente, optamos por construir uma tabela (LUT - *look-up table*) com 20.000 valores entre -10 e +10 com resolução de 0,001. Esta tabela foi, então, carregada na memória. Para obtermos o valor da tangente hiperbólica de um determinado número, associamos tal número a um ponteiro que retornava o conteúdo do endereço apontado por ele. A Figura 4.11 mostra melhor essa idéia.

Preferimos não utilizar a função $\tanh(x)$ do ANSI-C, pois o número de instruções associado à leitura de uma dado na memória é menor que o número de instruções associado à chamada de uma subrotina, no caso a função $\tanh(x)$, e de execução dessa mesma subrotina.

Os tempos de processamento para cada rede neural implementada podem ser

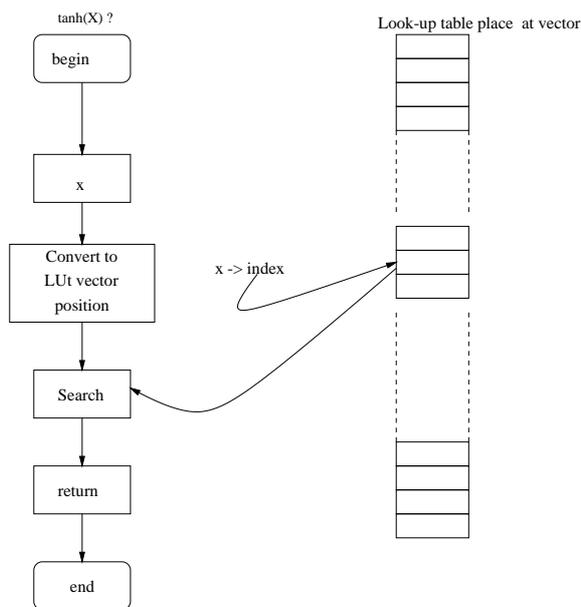


Figura 4.11: Exemplo de uma look-up table

observados na Tabela 4.3. Para simplificação, daqui em diante, estaremos utilizando a seguinte nomenclatura:

- Rede 1 - rede neural com configuração 18-7-7. (Seção 3.4.1)
- Rede 2 - rede neural, codificada, com configuração 200-2-3. (Seção 3.4.3)
- Rede 3 - rede neural obtida de rede neuronais especialistas nas amostras do transiente e do estado estacionário. A rede global, responsável por conectar os resultados de ambas redes especialistas, foi implementada com a configuração 8-4-7. (Seção 3.4.2)

A análise de discriminação principal foi utilizada nos casos das redes 2 e 3. Para a rede 2, os nós de saída da rede neural foram codificados binariamente.

Tabela 4.3: Tempos de processamento seqüencial para cada tipo de rede neural implementada

Rede	Tempo de processamento
Rede 1	357 μ s
Rede 2	838 μ s
Rede 3	331 μ s

4.4.3 Implementação Paralela

Para a implementação paralela do sistema de monitoração de cargas elétricas optamos por utilizar o paralelismo de dados. Esta escolha foi feita para que a contribuição do tempo de comunicação entre os processadores no tempo global de processamento fosse minimizado.

Utilizamos uma configuração *mestre-escravo*, conforme ilustra a Figura 4.12. Um nó de processamento, dentre os dezesseis disponíveis na máquina, foi escolhido para atuar como mestre. Este nó ficou designado para carregar os eventos recebidos do sistema hospedeiro (PC) e repassá-los para cada um dos escravos. Cada um desses escravos ficou responsável por processar um desses eventos através da rede neural e enviar as saídas da rede neural para o processador mestre.

O mestre também ficou responsável por outras funções, tais como: ler e escrever dados no arquivo, carregar inicialmente os parâmetros da rede neuronal (pesos e níveis de thresholds) e a tabela contendo os valores da tangente hiperbólica nos processadores escravos.

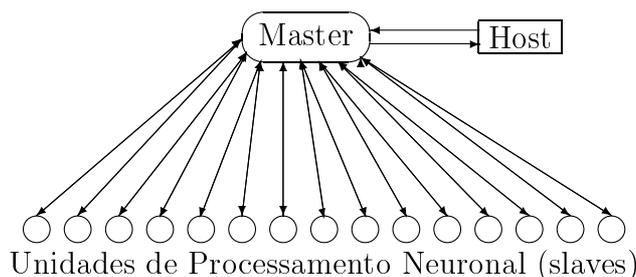


Figura 4.12: Estrutura Básica mestre-escravo da Implementação do Sistema de Monitoração.

Implementamos os códigos em C para o nó funcionando como mestre e para os escravos, sendo que os escravos rodavam o mesmo programa sobre diferentes dados. Definimos, também, um arquivo de configuração que detalhava a alocação de cada processo, bem como as comunicações entre eles. A Tabela 4.4 mostra os tempos de processamento, com arquitetura paralela, para cada rede neuronal implementada.

Tabela 4.4: Tempos de processamento para cada rede neuronal implementada, utilizando arquitetura da Figura 4.12

Rede implementada	Tempo de processamento em paralelo
Rede 1	$38\mu s$
Rede 2	$100\mu s$
Rede 3	$38\mu s$

Podemos dizer que o tempo de processamento em uma aplicação paralela que utilize o paralelismo de dados está limitado pelo tempo de comunicação entre os processadores (“overhead” de comunicação). Este tempo de comunicação entre os processadores é definido pelas conexões entre eles e pela taxa de transmissão de dados de cada um desses nós de processamento. No Sistema TN310, uma alocação mal condicionada dos processos nos diversos nós de processamento redundará em um tempo maior de processamento, já que as conexões entre processadores são feitas através das chaves STC104. O número de chaves que interliga esses processadores entre si pode variar de 1 até 4 chaves, o que resulta em atrasos diferentes na transmissão de dados entre eles. A Figura 4.13 mostra com mais detalhes as interligações (nós de processamento) através das chaves STC104.

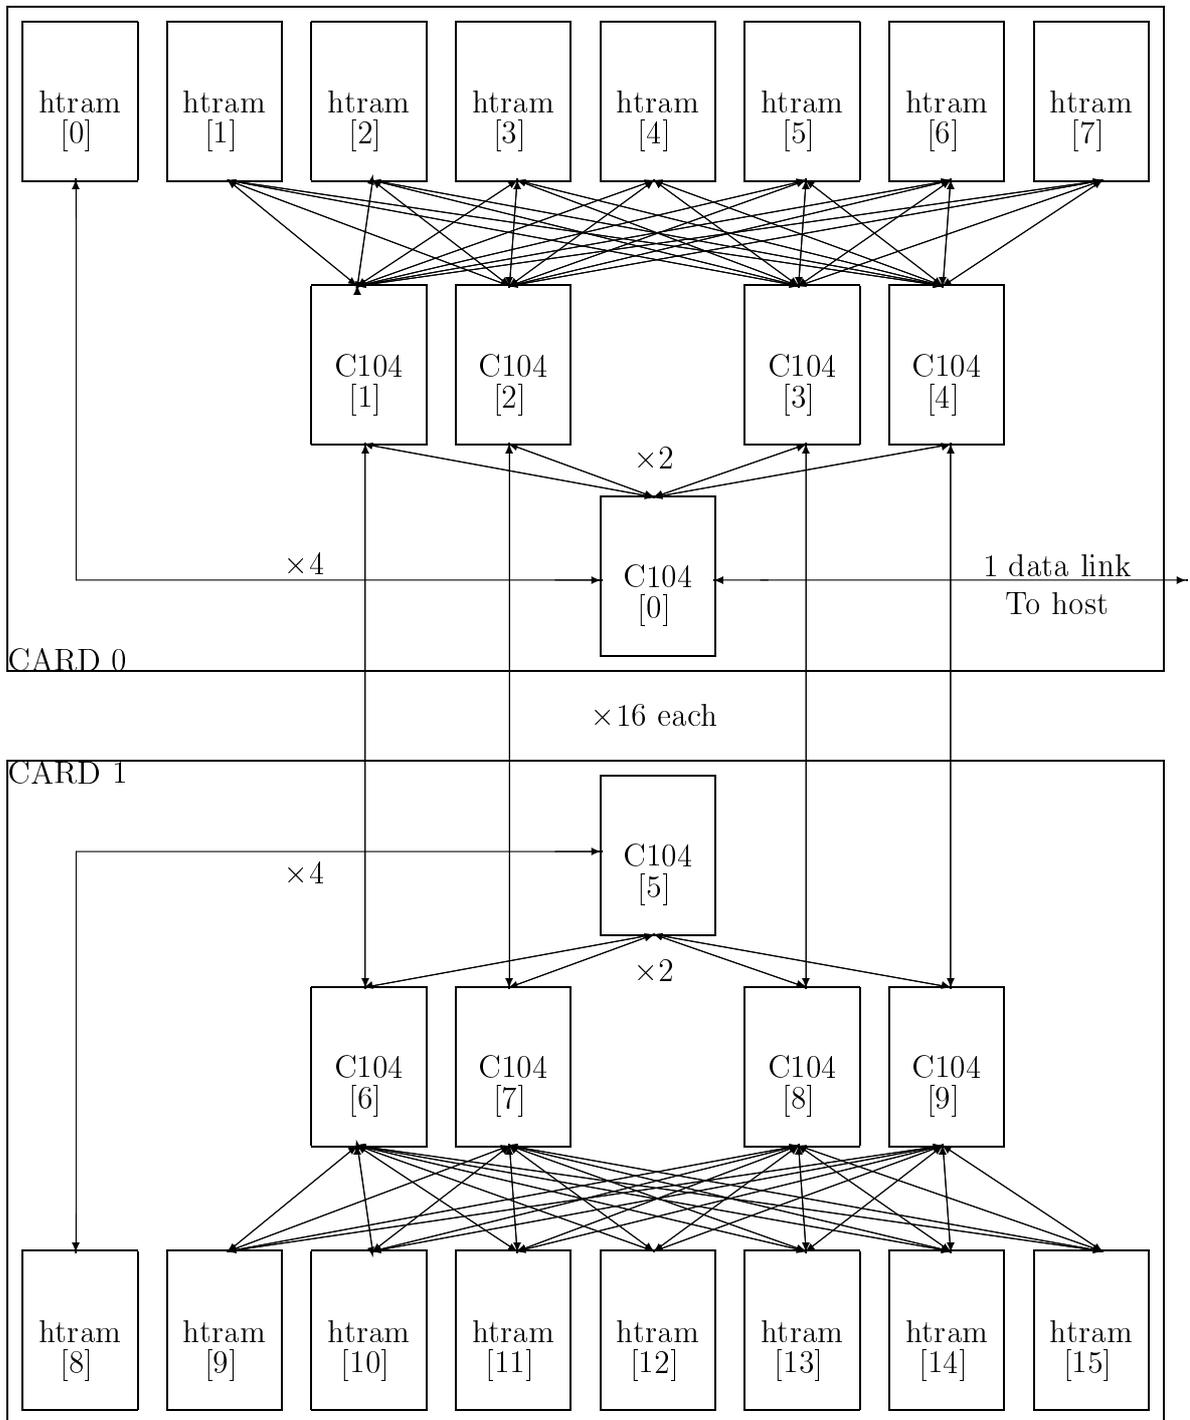


Figura 4.13: TN-310 - Conexões dos diversos nós de HTRAM

Podemos observar na Figura 4.13 que, dependendo da alocação de dois processos comunicantes, haverá, no mínimo, uma chave entre eles e até quatro chaves interligando os processos. Essas possíveis variações no número de chaves envolvidas na comunicação entre dois processos influenciam no tempo de comunicação, já que cada chave representa um atraso de aproximadamente $1,7\mu s$. Uma alocação ótima dos processos é aquela que procura colocar processadores com maior intensidade de

Tabela 4.5: Tempo de transmissão (μs) de pacotes de 32 bytes em função do número de chaves.

Bytes	Pacotes	1	2	3	4
1 - 32	1	10,2	12,1	13,8	15,5
33 - 64	2	16,9	20,6	24,0	27,6
65 - 96	3	23,5	28,9	34,2	39,5
100	4	30,2	37,5	44,6	51,8
250	8	57,2	71,4	85,4	99,5
1000	32	217	274	331	387
10000	313	2120	2670	3200	3760

comunicação próximos entre si, utilizando, assim, um menor número de chaves para interligação.

A Tabela 4.5 mostra o tempo requerido (em μs) para a transmissão de pacotes de 32 bytes de tamanho através de 1 a 4 chaves de conexão. Pode-se observar que o tempo de transmissão varia com o tamanho do pacote e com o número de chaves envolvidas na transmissão destes pacotes.

Para a arquitetura implementada, utilizando todos os processadores da máquina, verificamos que existirão comunicações utilizando de uma até quatro chaves. No entanto, pela Figura 4.13, percebemos que a melhor escolha seria alocarmos o processador mestre nos nós de processamento entre 1-7 ou entre 9-15, o que permitiria a utilização mais frequente de uma e duas chaves e, com menos frequência a utilização de três chaves, na comunicação, evitando-se ainda a utilização de quatro chaves.

Vamos considerar, a princípio, que os tempos de comunicação envolvidos na estrutura mestre-escravo se enquadra na configuração de transmissões de pacotes que envolvem uma chave. Para a estrutura da rede neuronal implementada, considerando o caso da rede 1, o mestre envia as 18 amostras de entrada da rede neuronal que representam 18 números reais ou 72 bytes (1 número real=4 bytes), e recebe dos escravos 7 amostras de saída que representam 7 números reais ou 28 bytes. Ao consultarmos a Tabela 4.5, verificamos que, para o mestre enviar 72 bytes, o tempo de transmissão seria de, aproximadamente, 23,5 μs e o tempo para os escravos

enviarem 28 bytes seria de $10,2 \mu s$, totalizando um tempo de transmissão de $33,7 \mu s$. Ao compararmos este tempo total de $33,7 \mu s$ com o tempo de processamento paralelo de $38 \mu s$, verificamos que estes tempos são bem próximos o que caracteriza para a estrutura implementada que não é possível se obter um tempo de processamento menor que o tempo de comunicação.

Para determinarmos o número ótimo de processadores, basta utilizarmos a equação (4.1), considerando o tempo de processamento em único processador igual a $357 \mu s$ (tempo de processamento para a rede 1 - Tabela 4.3) e o tempo de comunicação igual a $34 \mu s$, o que resulta em 10 processadores. A topologia final foi de um mestre e dez escravos.

Para o caso da rede 2, realizando a mesma análise de tempo de transmissão de pacotes entre chaves feita para a rede 1, e aplicando a equação (4.1) para determinarmos o número de processadores, teremos uma topologia final de um mestre e cinco escravos. Para o caso da rede 3, conclui-se que a estrutura otimizada é aquela composta de um mestres e dez escravos.

Nos três tipos de rede implementados, o tempo de processamento de um evento foi o mesmo obtido utilizando-se a estrutura com o dezesseis processadores, no entanto com um menor número de processadores da máquina paralela.

Concluimos que uma arquitetura paralela pode ser utilizada para implementações dos cenários 3 e 4, em situações de aquisição de uma grande massa de dados. Verificamos que o paralelismo de dados, no qual temos diversos nós de processamento realizando a mesma tarefa, permitiu que obtivéssemos estrutura otimizadas, reduzindo-se o número total de processadores (no caso do sistema TN310 são 16) para um número útil de processadores sempre menor que o total de 16 processadores.

Capítulo 5

Conclusões

Um sistema de monitoração de carga elétrica residencial foi implementado considerando quatro cenários de implementação. O uso da análise de componentes principais de discriminação (PCD) se mostrou uma ferramenta poderosa na implementação de tais cenários, uma vez que possibilitou projetarmos sistemas compactos e com alta eficiência, atingindo para o melhor caso, de 98% para sete classes de eletrodomésticos. Adicionalmente, esta técnica permite que o projeto dos classificadores sejam integrados com a compactação do espaço de entrada, isto é, ao mesmo tempo que se retirava as PCDs, constrói-se um classificador neural.

Diferentemente dos trabalhos que só utilizam a informação do regime permanente [8, 10, 11] para reconhecimento de cargas elétricas e do proposto em [56], que utiliza além desses dados a informação do transitório, o trabalho aqui desenvolvido mostrou que somente a informação do transitório foi necessária para se obter um sistema robusto e eficiente. Utilizar só o transitório significa ter uma resposta mais rápida a um evento que represente o acionamento de um eletrodomésticos. Para a melhor estrutura que obtivemos, rede 60-2-3, só precisaríamos adquirir as 60 primeiras amostras do transitório, o que dá algo em torno de 0,6 segundos, para classificar esse evento. Nos trabalhos que se têm baseado em [8], é necessário armazenar as informações de potência ativa e reativa ao se ligar um equipamento, e esperar um determinado período de tempo (de fração de segundos até minutos), até que esse equipamento seja desligado para novamente armazenar as potências ativa e reativa para, com esse par de dados, realizar a classificação do equipamento (discutido na seção 2.1). Para o trabalho realizado em [56], é necessário se adquirir ângulo

de fase e corrente aparente, informações essas que só podem ser adquiridas após o transitório, que dura em média 2 segundos.

Desenvolvemos, neste trabalho, arquiteturas de implementação que atendessem às especificações de cada um dos quatro cenários propostos. Utilizamos um microcontrolador, uma arquitetura de baixo custo, e vimos ser essa uma implementação viável para um sistema em que a menor granularidade é uma residência (cenário 1); neste caso, como os eventos acontecem em média a cada 3 minutos, o tempo de processamento obtido (da ordem de 250ms) é mais do que suficiente para se classificar um evento apresentado à rede neural. Esse estudo foi feito considerando-se a rede 160-4-3, que foi projetada considerando os dados obtidos por um dispositivo de aquisição móvel. Para uma estrutura que monitorasse um bloco de residências ou bloco de apartamentos, propusemos a utilização de um DSP com capacidade de paralelismo interno, o ADSP-21160M, e verificamos que foi possível obter uma estrutura altamente otimizada (utilizando linguagem Assembly), que explorou toda a potencialidade de processamento desse dispositivo. Para um cenário que demandasse um alto nível de processamento, devido à grande massa de dados, desenvolvemos o sistema de monitoração considerando um arquitetura com 4DSPs e uma outra considerando o sistema TN310 (máquina paralela com 16 nós de processamento); verificamos a aplicabilidade de nosso classificador nessas duas plataformas, caracterizando assim os cenários 3 e 4.

Embora tenhamos obtido uma eficiência de 98% para a rede 60-2-3, por exemplo, esse resultado não elimina a necessidade de se obter um número maior de transitórios, principalmente para a classe 6 (lâmpadas incandescentes) e a classe 7 (lâmpadas fluorescentes) em que para o conjunto de teste só foi possível separar 2 eventos para cada classe.

Este trabalho não se encerra nas conclusões acima ou naquelas que discutimos nos capítulos anteriores, mas abre um caminho de possibilidades e análises que podem se seguir a partir deste trabalho, como citamos abaixo:

- Verificamos que o classificador neural apresenta respostas erradas para entradas superpostas. Mesmo sendo situações pouco prováveis de ocorrer, pode ser interessante desenvolver técnicas que permitam classificar corretamente tais situações. A análise de componentes independentes (ICA) [91] poderia ser um

caminho, uma vez que essa análise é bastante útil em problemas de mistura de sinais, que é o caso da superposição de transitórios.

- Desenvolver um classificador neural que possa aprender localmente e, assim, agregar novos eletrodomésticos, sem a necessidade de se adquirirem novos dados.
- Para aquisições de transitório em um prédio de apartamentos, por exemplo, deve-se verificar se a monitoração de uma determinada residência pode sofrer interferência devido ao acionamento de equipamentos de uma outra residência, uma vez que os cabeamentos AC passam pela mesma tubulação.
- Ampliar a capacidade desse sistema para monitoração de carga de outros setores de consumo, como o comércio e a indústria.
- Realizar aquisições em um bairro, por exemplo, e comparar os resultados com resultados obtidos através da pesquisa de hábitos e posse de eletrodomésticos.

Referências Bibliográficas

- [1] ELETROBRÁS, *Relatório Analítico - mercado de energia elétrica*, Report, Ministério de Minas e Energia, 2003.
- [2] ANEEL, *Projeto de Inovação Tecnologia Energética: Recomendação para uma estratégia regulatória nacional de combate ao desperdício de eletricidade no Brasil*, Report, Ministério de Minas e Energia, Agosto 2000.
- [3] ELETROBRÁS, *Relatório Analítico - mercado de energia elétrica*, Report, Ministério de Minas e Energia, 2001.
- [4] COELBA, *Programa de Eficiência Energética - Ciclo 2003/2004*, Report, Coelba, 2004.
- [5] LIGHT/COPPE-UFRJ/PUC-RIO, *Pesquisa de Posse de Equipamentos e Hábitos de Consumo*, Report, Light, Rio de Janeiro, Brasil, 2006.
- [6] PUC-RJ/PROCEL, *Pesquisa de Posse de Eletrodomésticos e Hábitos de Consumo*, Report, Eletrobrás, 1999.
- [7] COELBA, *Pesquisa de Posse de Eletrodomésticos e Hábitos de Consumo*, Report, Coelba/Procel, Porto Segura e Vitória da Conquista, Bahia, Brasil, 2000.
- [8] HART, G. W., “Nonintrusive appliance load monitoring”, *Proc. of the IEEE*, v. 80, pp. 1870–1891, Dec 1992.
- [9] ELETROBRÁS, *Informe de Mercado*, Report, Ministério de Minas e Energia, 2004.
- [10] SULTANEM, F., “Using Appliance Signatures for Monitoring Residential Loads at Meter Panel Level”, *IEEE Trans. Power Delivery*, v. 6, pp. 1380–1385, Oct 1991.

- [11] COLE, A. I., ALBICKI, A., “Algorithm for Non-Intrusive Identification of Residential Appliances”, *IEEE International Symposium on Circuits and Systems*, v. 3, pp. 338–342, 1998.
- [12] LEE, W. K., FUNG, G. S. K., LAM, H. Y., *et al.*, “Exploration on Load Signatures”. *International Conference on Electrical Engineering*, 725, Sapporo, Japan, July 2004.
- [13] DRENKER, S., KADER, A., “Nonintrusive Monitoring of Electrical Loads”, *IEEE Computer Application in Power*, v. 12, pp. 47–51, Oct. 1999.
- [14] LAUGHNMAN, C., LEE, K., COX, R., *et al.*, “Power Signatures Analysis”, *IEEE Power and Energy*, v. 1, pp. 56–63, 2003.
- [15] MARCEAU, M. L., ZMEUREANU, R., “Nonintrusive load disaggregation computer program to estimate the energy consumption of major end uses in residential buildings”, *Energy Conv. and Manag.*, v. 41, pp. 1389–1403, 2000.
- [16] ROSS, I. G., LANE, I. E., BOTHA, E. C., *et al.*, “Using Neural Networks for non-intrusive monitoring of industrial electrical loads”. In: *Proceedings of the Instrumentation and Measurement Technology Conferences*, v. 3, pp. 1115–1118, Hamamatsu, Japan, May 1994.
- [17] NORTH, G., “Electricity consumption and load control possibilities: Residential energy monitoring in Sweden”. *ECEE*, 2001.
- [18] LEEB, S. B., JUNIOR, J. L. K., VAN, M. S. L., *et al.*, “Development and Validation of a Transient Event Detector”, *AMP Journal of Technology*, v. 3, pp. 69–74, Nov 1993.
- [19] LEEB, S. B., SHAW, S. R., JUNIOR, J. L. K., “Transient Event Detection in Spectral Envelope Estimates for Nonintrusive Load Monitoring”, *IEEE Trans. Power Delivery*, v. 10, n. 3, pp. 1200–1210, July 1995.
- [20] LAUGHMAN, C., LEE, D., COX, R., *et al.*, “Advanced Nonintrusive Monitoring of Electric Loads”, *IEEE Power and Energy*, v. 1, n. 2, pp. 56–63, March 2003.

- [21] NORFORD, L. K., LEEB, S. B., “Non-intrusive electrical load monitoring in commercial buildings based on steady-state and transient load-detection algorithms”, *Energy and Buildings*, v. 24, n. 1, pp. 51–64, 1996.
- [22] FLORES, C. D., *Fundamentos dos Sistemas Especialistas*. Bookman, 2003.
- [23] CUENCA, W. M., LEVY, A. F., SEIXAS, J. M., “Sistema Caracterizador Híbrido para Identificar Descargas Parciais em Transformadores de Potência”. In: *V Congresso Brasileiro de Redes Neurais*, v. 1, pp. 169–174, Rio de Janeiro, 2001.
- [24] LOFTY, Z. A., “Intelligent Systems and Their Applications”, *IEEE*, , 1994.
- [25] LI, H., LOVE, P. E. D., “Combining rule-based expert systems and artificial neural networks for mark-up estimation”, *Construction Management & Economics*, v. 17, pp. 169–176, 1999.
- [26] TSOUKALAS, L., JIMENEZ, J., “A Hybrid expert system-neural networks methodology for anticipatory control in a process environment”. In: *Proceedings of the International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems*, v. 2, pp. 1045–1053, South Carolina, USA, 1990.
- [27] PALAU, A., VELO, E., PUIGJANER, L., “Use of Neural Networks and Expert Systems to Control a Gas/Solid Sorption Chilling Machine”, *International Journal of Refrigeration*, v. 22, n. 1, pp. 59–68, January 1999.
- [28] LACHER, R. C., MRUSKA, S. I., KUNCIKY, D. C., “Back-propagation learning in expert networks”, *IEEE Transactions on Neural Networks*, v. 3, pp. 63–72, 1992.
- [29] FIGUEIREDO, K., PACHECO, M. A., OLIVEIRA, F., *et al.*, “Intelligent Solution to Energy Conservation Problem”, , 2002.
- [30] EUGÊNIO, S., RODRIGUES, J. R., THOMÉ, A. C. G., “Extração de Características para o Reconhecimento de Letras Manuscritas”. *V Simpósio Brasileiro de Automação Inteligente*, 2001.

- [31] MORI, H., “Fuzzy Neural Network Applications to Power System”. In: *Proceedings of the Power Engineering Society Winter Meeting*, v. 1, pp. 1284–1288, IEEE, 2000.
- [32] HELL, M., SECCO, L., JUNIOR, P. C., “Redes Neurais e Neuro-Fuzzy aplicadas a Modelagem Térmica de Transformadores de Potência”. *V Congresso Brasileiro de Redes Neurais*.
- [33] BARBERA, H. M., SKARMETA, A. G., IZQUIERDO, M. . Z., *et al.*, “Neural networks for sonar and infrared sensors fusion”. *Information Fusion*, 2000.
- [34] BARSHAN, B., AYRULU, B., UTETE, S. E., “Neural network-based target differentiation using sonar for robotics applications”, *IEEE Transactions on Robotics and Automation*, v. 16, n. 4, pp. 435–442, 2000.
- [35] DROR, I. E., ZAGAESKI, M., MOSS, C. F., “Three-Dimensional Target Recognition via Sonar: A Neural Network Model”, *Neural Networks - Elsevier Science*, v. 8, n. 1, pp. 149–160, 1995.
- [36] LEWIS, T. W., POWERS, D. M. W., “Audio-visual speech recognition using red exclusion and neural networks”, *In: Australasian conference on Computer Science*, v. 24, pp. 149–156, January 2002.
- [37] OLIVEIRA, A. R., OLIVEIRA, L. W., “Redes Neurais Artificiais Aplicadas na Detecção e Classificação de Defeitos em Linhas de Transmissão”. In: *Book of Abstracts and Proceedings of the VI Congresso Latino Americano de Geração de Eletricidade e Transmissão de Energia*, Mar Del Plata, Argentina, 2005.
- [38] R. GIOVANINI, D. V. C., “Localização de Falhas em Linhas de Transmissão de Energia Elétrica Utilizando Reconhecimento de Padrões”. In: *Anais do IV Congresso Brasileiro de Redes Neurais*, pp. 281–286, São José dos Campos, São Paulo, Brasil, Julho 1999.
- [39] M. M. S. LIRA, M. A. C. J., AQUINO, R. R. B., VALENÇA, M. J. S., *et al.*, “Classificação de Distúrbios Elétricos Utilizando Wavelets, Componentes Principais e Redes Neurais Artificiais”. In: *Anais do VII Congresso Brasileiro de*

Redes Neurais, v. CD-Rom, pp. 1–6, Natal, Rio Grande do Norte, Brasil, October 2005.

- [40] AL-DABBAGH, M., AL-DABBAGH, L., “Neural Networks Based Algorithm for Detecting High Impedance Faults on Power Distribution Lines”. In: *Proceedings of the International Joint Conference on Neural Networks*, v. 5, pp. 10–16, Washington-DC, USA, 1999.
- [41] OLESKOVICZ, M., COURY, D. V., AGGARWAL, R. K., “Redes Neurais Artificiais na Detecção, Classificação e Localização de Faltas em Linhas de Transmissão”, *SBA Controle e Automação*, v. 14, n. 2, pp. 138–150, 2003.
- [42] MAHANTY, R. N., GUPTA, P. B., “Application of RBF Neural Network to Fault Classification and Location in Transmission Line”. In: *Generation, Transmission and Distribution*, v. 151, pp. 201–212, IEE, March 2004.
- [43] CARPINTEIRO, O. A. S., SILVA, A. P. A. D., FEICHAS, C. H. L., “A Hierarchical Hybrid Neural Model in Short-Term Load Forecasting”. In: *Proceedings of the International Joint Conference on Neural Networks*, v. 6, pp. 241–246, Piscataway, NJ, USA, 2000.
- [44] LI, K. K., LAI, L. L., DAVID, A. K., “Application of Artificial Neural Network in Fault Location Technique”. In: *Proceedings of the International Conference on Electric Utility Deregulation and Restructuring and Power*, pp. 226–231, IEEE, London, April 2000.
- [45] KUNG, C. M., MUANG, C. M., DEVANEY, M. J., “An Adaptive Power System Load Forecasting Scheme using a Generic Algorithm Embedded Neural Network”. In: *Proceedings of the Instrumentation on Measurement Technology Conference*, v. 1, pp. 308–311, IEEE, St. Paul, Minnesota, USA, May 1998.
- [46] CARPINTEIRO, O. A. S., SILVA, A. P. A. D., “A Hierarchical Self-Organizing Map Model in Short-Term Load Forecasting”. In: *Proceedings of the 5th International Conference on Engineering Applications of Neural Networks*, pp. 775–780, Torun, Poland, 2001.

- [47] CAMASTRA, F., COLLA, A. M., “Short-Term Load Forecasting Based on Correlation Dimension Estimation and Neural Nets”. In: *Proceedings of the International Joint Conference on Neural Networks*, v. 1327, pp. 1035–1040, Lausanne, Switzerland, October 1997.
- [48] MOHAMED, O., PARK, D., MERCHANT, R., *et al.*, “Practical Experiences with an Adaptive Neural Network Short-Term Load Forecasting System”, *IEEE Trans Power Systems*, pp. 1062–1068, May 1994.
- [49] BRETAS, A. S., PHADKE, A., “Artificial Neural Networks in Power System Restoration”, *IEEE Trans in Power Delivery*, v. 18, n. 4, pp. 1181–1186, October 2003.
- [50] RINGWOOD, J. V., BOFELLI, D., MURRAY, F. T., “Forecasting Electricity Demand on Short, Medium and Long Time Scales Using Neural Networks”, *Journal of Intelligent and Robotic Systems*, v. 31, n. 1-3, pp. 129–147, May 2001.
- [51] KERSHMANSHASHI, “Neural network for forecasting next 10 years loads of nine Japanese utilities”, *Neurocomputing*, v. 23, n. 1-3, pp. 125–133, December 1998.
- [52] KERSHMANSHASHI, H., I., “Load forecasting using neural nets”, *International Journal of Electrical Power and Energy Systems*, pp. 789–797, November 2002.
- [53] PARLOS, A. G., OUFIL, E., MUTHUSAMI, J., *et al.*, “Development of an intelligent long-term electric load forecastingsystem”. In: *Proceedings of the International Conference on Applications to Power Systems*, v. 1, pp. 288–292, Orlando, USA, 1996.
- [54] KANDIL, M. S., DEBEIKY, S., HASANIEN, N. E., “Long-term load forecasting for fast developong utility using a knowledge-based expter system”, *IEEE Transactions on Power Systems*, v. 17, n. 2, pp. 491–496, 2002.

- [55] PENG, M. T., HUBELE, N. F., KARADY, N. F., “An Adaptive Neural Network Approach to One-Week Ahead Load Forecasting”, *IEEE Transactions on Power Systems*, v. 8, n. 3, pp. 1195–1203, 1993.
- [56] AGUIAR, J., *Identificação Não-invasiva de Cargas Elétricas Residenciais Utilizando Redes Neurais*. M.Sc. dissertation, UFRJ, 1996.
- [57] JACKSON, L., *Digital Filters and Signal Processing: with MATLAB Exercises*. 3 ed. Kluwer Academic Publishers, 1996.
- [58] JOLLIFE, L., *Principal Component Analysis*. Springer, 2002.
- [59] FIORI, S. C. A. S., “Image Compression using Principal Component Neural Networks”, *Image and Vision Computing*, v. 19, pp. 649–668, 2000.
- [60] OJA, E., “A Simplified Model as a Principal Component Analyzer”, *J. Math. Biol.*, v. 15, pp. 267–273, 1982.
- [61] PAPOULIS, A., *Probability, Random Variables, and Stochastic*. McGraw-Hill, 1991.
- [62] PEEBLES, P., *Probability, Random Variables, and Random Signal Principles*. McGraw-Hill, 1993.
- [63] CALOBA, L., SEIXAS, J. M., PEREIRA, F. S., “Neural Discriminating Analysis for a Second-Level Trigger System”. *Computing in High Energy Physics*, Rio de Janeiro, 1997.
- [64] SEIXAS, J. M., CALOBA, L. P., PRADO, C. B., *et al.*, “Neural Discriminating Analysis for a Nonintrusive Electrical Load Monitoring System”. In: *IX Simpósio Brasileiro de Arquitetura de Computadores - Computação de Alto Desempenho (SBAC - PAD)*, pp. 201–210, Campos de Jordão, São Paulo, Brasil, 1997.
- [65] CUENCA, W. M., LEVY, A. F., SEIXAS, J. M., “Análise de Componentes Principais para Identificar Descargas Parciais em Transformadores de Potência”. *VI Brazilian Symposium on Neural Networks*, Rio de Janeiro, 2000.

- [66] DAMAZIO, D. O., SOARES, A. C., SEIXAS, J. M., “Um Classificador Neuronal Compacto e Eficiente com Capacidade de Identificar Contaminação em Dados Experimentais”, *Revista Controle & Automação*, v. 14, n. 4, pp. 359–367, 2003.
- [67] HAYKIN, S., *NEURAL NETWORKS A Comprehensive Foundation*. 1 ed. New York, 1994.
- [68] HERTZ, J., KROGH, A., PALMER, R. G., *Introduction to the Theory of Neural Computation*. Addison - Wesley, 1991.
- [69] WASSERMAN, P., *Neural computing Theory and Practice*. 1 ed. New York, 1989.
- [70] PERHINSCHI, M., CAMPA, G., NAPOLITANO, M., *et al.*, “A Simulation Tool for On-Line Real Time Parameter Identification”. *AIAA Modeling and Simulation Technologies Conference and Exhibit*, Monterey-California, Aug 2002.
- [71] WUNSCH, P., WINKLER, S., HIRZINGER, G., “Real-Time Pose Estimation of 3-D Objects from Camera Images Using Neural Networks”. In: *Proceedings of the International Conference on Robotics and Automation*, v. 4, pp. 3232–3234, IEEE, Albuquerque, USA, 1997.
- [72] M.C., D., C., S. N., “Real time wave forecasting using neural networks”, *Ocean Engineering*, v. 26, n. 3, pp. 191–203, August 1998.
- [73] CICHOCKI, A., LOBOS, T., “Artificial neural networks for real-time estimation and basic waveforms of voltage and currents”. In: *Proceedings of the Power Industry Computer Application Conference*, pp. 357–363, IEEE, Scottsdale, AZ, USA, May 1993.
- [74] ZHAO, L., PINGALI, G., CARLBOM, I., “Real-Time ahead orientation estimation using neural networks”. In: *Proceedings of the International Conference on Image Processing*, pp. 297–300, Rochester, New York, USA, 2002.
- [75] LONNBALD, L., PETERSON, C., ROGNVALDSSON, T., *Pattern Recognition in High Energy Physics with Artificial Neural Networks -JETNET 2.0*. Department of Theoretical Physics, University of Lund, Sweden, 1991. Manual.

- [76] SEIXAS, J. M. ., PRADO, C. B., CALOBA, L. . P. ., *et al.*, “A Neural Nonintrusive Electrical Load Identification Using a Parallel Machine”. In: *Proceedings of the Third International Conference Engineering Applications Neural Networks*, v. 1, pp. 277–280, Sweden, 1997.
- [77] SEIXAS, J. M., PRADO, C. B., CALOBA, L. P., *et al.*, “An Electric Load Monitoring System Based on Expert Neural Networks and Parallel Processing”. In: *Proceedings of the International Conference on Intelligent System Application to Power System*, v. 1, pp. 197–201, Rio de Janeiro, 1999.
- [78] PRADO, C. B., SEIXAS, J. M., TORRES, R. C., “Um cenário de implementação de um sistema neural não-invasivo de identificação de cargas elétricas”. In: *Anais do VII Congresso Brasileiro de Redes Neurais*, v. CD-Rom, pp. 1–5, Natal, Rio Grande do Norte, Brasil, Outubro 2005.
- [79] FLASH DEVICES - USER’S MANUAL, *Debugger/Programmer for freescale HCS08 family*, 2005.
- [80] METROWERKS, *Metrowerks HCS08 CodeWarrior Development Tools*, 2005.
- [81] ACKENHUSEN, J. G., *Real-Time Signal Processing*. Prentice Hall, 1999.
- [82] ANALOG DEVICES, INC, *ADSP-21160: SHARC DSP Hardware Reference*, 2002.
- [83] LORENZ, M., KOFFMAN, D., BASHFORD, S., *et al.*, “Optimized address assignment for DSPs with SIMD memory accesses”. In: *Asia South Pacific design automation*, pp. 415–420, Yokohama, Japan, 2001.
- [84] KALAVADE, A., LEE, E. A., “A Hardware-Software Codesign Methodology for DSP Applications”, *IEE Design & Test archive*, v. 10, n. 3, pp. 16–28, July 1993.
- [85] ANALOG DEVICE, INC, *ADSP-2106X SHARC User’s Manual*, 1997.
- [86] PRADO, C. B., DINIZ, P. S. R., FRANÇA, F. M. G., “Implementation of overlapped block filtering using scheduling by edge reversal”, In: *Proceedings of*

the IEEE International Symposium on Circuits and Systems, v. 5, pp. 97–100, May 2000.

- [87] TELMAT MULTINODE, *TN 310 System Manual and Training Set*. França, 1995.
- [88] AMORIM, C. L., BARBOSA, V. C., FERNANDES, E. S. T., *Uma Introdução à Computação Paralela e Distribuída*. Campinas-SP, Unicamp, IMECC, 1998.
- [89] TELMAT MULTINODE, *T9000 ANSI C Toolset User Guide Analog*. França, 1995.
- [90] TELMAT MULTINODE, *T9000 ANSI C Toolset Language and Libraries Reference Manual Analog Devices*. França, 1995.
- [91] LEE, T. W., *Independent Component Analysis*. Kluwer Academic, 1998.

Apêndice A

Eletrodomésticos

A tabela A.1 mostra os eletrodomésticos mais utilizados em uma residência típica. Esse levantamento foi obtido em [6].

Tabela A.1: Eletrodomésticos

Aparelhos Elétricos	Potência Média Watts
ABRIDOR/AFIADOR	135
AFIADOR DE FACAS	20
APARELHO DE SOM 3 EM 1	80
APARELHO DE SOM PEQUENO	20
AQUECEDOR DE AMBIENTE	1550
AQUECEDOR DE MAMADEIRA	100
AR-CONDICIONADO 7.500 BTU	1000
AR-CONDICIONADO 10.000 BTU	1350
AR-CONDICIONADO 12.000 BTU	1450
AR-CONDICIONADO 15.000 BTU	2000
AR-CONDICIONADO 18.000 BTU	2100
ASPIRADOR DE PÓ	100
BARBEADOR/DEPILADOR/MASSAGEADOR	10
BATEDEIRA	120
BOILER 50 e 60 L	1500
BOILER 100 L	2030
BOILER 200 a 500 L	3000
BOMBA D'ÁGUA 1/4 CV	335
BOMBA D'ÁGUA 1/2 CV	613
BOMBA D'ÁGUA 3/4 CV	849
BOMBA D'ÁGUA 1 CV	1051
BOMBA AQUÁRIO GRANDE	10
BOMBA AQUÁRIO PEQUENO	5
CAFETEIRA ELÉTRICA	600

Tabela A.2: Eletrodomésticos - continuação

Aparelhos Elétricos	Potência Média Watts
CHURRASQUEIRA	3800
CHUVEIRO ELÉTRICO	3500
CIRCULADOR AR GRANDE	200
CIRCULADOR AR PEQUENO/MÉDIO	90
COMPUTADOR/IMPRESSORA/ESTABILIZADOR	180
CORTADOR DE GRAMA GRANDE	114
CORTADOR DE GRAMA PEQUENO	500
ENCERADEIRA	500
ESCOVA DE DENTES ELÉTRICA	50
ESPREMEDOR DE FRUTAS	65
EXAUSTOR FOGÃO	170
EXAUSTOR PAREDE	110
FACA ELÉTRICA	220
FERRO ELÉTRICO AUTOMÁTICO	100
FOGÃO COMUM	60
FOGÃO ELÉTRICO 4 CHAPAS	9120
FORNO À RESISTÊNCIA GRANDE	1500
FORNO À RESISTÊNCIA PEQUENO	800
FORNO MICROONDAS	120
FREEZERVERTICAL/HORIZONTAL	130
FRIGOBAR	70
FRITADEIRA ELÉTRICA	1000
GELADEIRA 1 PORTA	90
GELADEIRA 2 PORTAS	130
GRILL	900
IOGURTEIRA	26
LÂMPADA FLUORESCENTE COMPACTA - 11W	11
LÂMPADA FLUORESCENTE COMPACTA - 15 W	15
LÂMPADA FLUORESCENTE COMPACTA - 23 W	23

Tabela A.3: Eletrodomésticos - continuação

Aparelhos Elétricos	Potência Média Watts
LÂMPADA INCANDESCENTE - 40 W	40
LÂMPADA INCANDESCENTE - 60 W	60
LÂMPADA INCANDESCENTE -100 W	100
LAVADORA DE LOUÇAS	1500
LAVADORA DE ROUPAS	500
LIQUIDIFICADOR	300
MÁQUINA DE COSTURA	100
MÁQUINA DE FURAR	350
MICROCOMPUTADOR	120
MOEDOR DE CARNES	320
MULTIPROCESSADOR	42
NEBULIZADOR	40
OZONIZADOR	100
PANELA ELÉTRICA	1100
PIPOQUEIRA	1100
RÁDIO ELÉTRICO GRANDE	45
RÁDIO ELÉTRICO PEQUENO	10
RÁDIO RELÓGIO	5
SAUNA	5000
SECADOR DE CABELO GRANDE	1400
SECADOR DE CABELOS PEQUENO	600
SECADORA DE ROUPA GRANDE	3500
SECADORA DE ROUPA PEQUENA	1000
SECRETÁRIA ELETRÔNICA	20
SORVETEIRA	15

Tabela A.4: Eletrodomésticos - continuação

Aparelhos Elétricos	Potência Média Watts
TORNEIRA ELÉTRICA	3500
TORRADEIRA	800
TV EM CORES - 14"	60
TV EM CORES - 18"	70
TV EM CORES - 20"	90
TV EM CORES - 29"	110
TV EM PRETO E BRANCO	40
TV PORTÁTIL	40
VENTILADOR DE TETO	120
VENTILADOR PEQUENO	65
VÍDEOCASSETE	10
VÍDEOGAME	15

Apêndice B

Paralelismo

B.1 Paralelismo de Controle

Esta técnica de paralelismo é utilizada em aplicações que são compostas por processos (ou blocos de instruções) totalmente independentes entre si. Em muitos casos reais, uma possível dependência ocorre quando um determinado processo só pode executar o seu conjunto de instruções após a liberação de um resultado do bloco anterior.

Na fig. B.1 podemos verificar um exemplo em que os processos apresentam dependências entre si. Os processos estão representados pelos blocos numerados de 1 a 5.

Para aplicações que tenham relações de dependência entre os blocos de instruções, o tempo de execução final será dado segundo o tempo de execução de cada bloco e as relações de dependência entre eles. Caso os blocos sejam totalmente independentes, o tempo de processamento será igual ao tempo de execução do maior dos blocos.

Para a situação em que todas as tarefas¹ são independentes entre si e o tempo de processamento dessas tarefas igual, quando o número de processadores do computador paralelo for igual ou maior que o número de tarefas referentes à aplicação, cada tarefa poderá ser executada em um único processador. Dessa maneira, quando estiverem distribuídas em N processadores as N independentes ações serão executadas em um tempo N vezes menor que o tempo necessário para o processamento

¹tarefa - conjunto de instruções executadas por um determinado processador

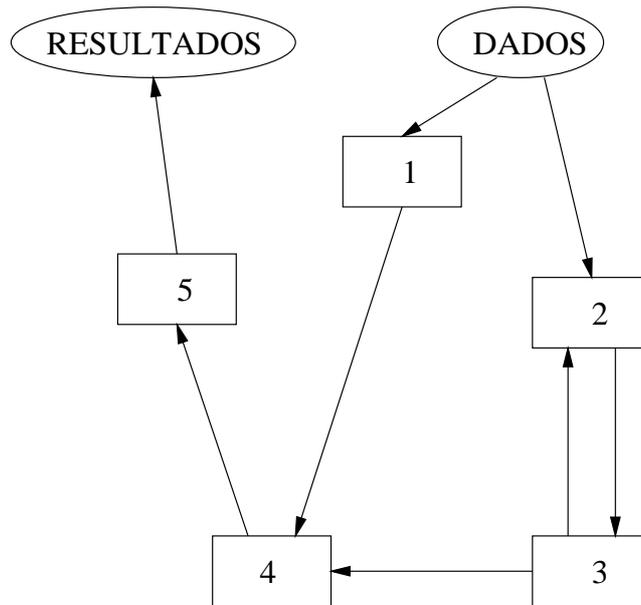


Figura B.1: Paralelismo de Controle

seqüencial em um único processador.

B.2 Paralelismo de Dados

Esta técnica de paralelismo é usada em aplicações que executam uma única tarefa várias vezes sobre dados ou informações diferentes. Podemos citar como exemplo aplicações que usam vetores e matrizes operando sobre dados a serem processados, e o processamento a ser executado é o mesmo sobre cada vetor ou matriz. A Figura B.2 exemplifica essa técnica, mostrando que os diversos processadores realizam as mesmas instruções, contudo sobre dados diferentes.

O paralelismo de dados visa a replicar o algoritmo de processamento dos dados em N processadores de maneira a obtermos um tempo de processamento global N vezes menor quando comparado com o tempo de processamento obtido ao se utilizar um único processador.

Esta técnica possui uma hierarquia inerente às aplicações. Isto se dá pelo fato de que os dados são passados aos processadores que realizam a mesma tarefa sobre os dados, normalmente chamados de escravos (*slaves*), através de uma unidade controladora da aplicação, chamada de unidade mestre (*master*). Esta relação entre *master* e *slaves* cria uma “seqüencialização” da aplicação, pois deve-se passar os

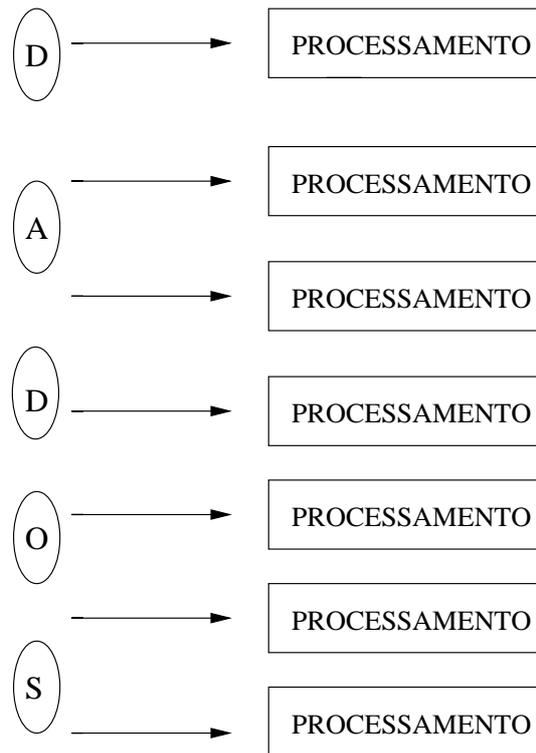


Figura B.2: Paralelismo de Dados

dados da aplicação *master* para as aplicações *slaves*.

B.3 Paralelismo de Fluxo

A terceira técnica de paralelismo é referente a algumas aplicações baseadas no modelo *pipeline*. Nessas aplicações cada tarefa é executada logo após a anterior. Por exemplo, podemos citar uma linha de construção de carro ou uma linha de fabricação de pizzas. A Figura B.3 mostra os diversos processos (blocos retangulares) realizando suas tarefas logo após a execução das tarefas do processo anterior, exemplificando esta técnica de paralelismo.

Imaginemos que na fabricação de 100 pizzas os seguintes processos sejam observados: no primeiro processo é preparada a massa, no segunda etapa é colocado sobre a pizza o molho, no terceiro e último processo a pizza é embalada. Assim que o primeiro processo tenha sido executado, o segundo processo poderá iniciar o seu processamento e o primeiro processo poderá iniciar a preparação da massa seguinte. Quando o último processo estiver agindo na pizza 98, o segundo processo estará

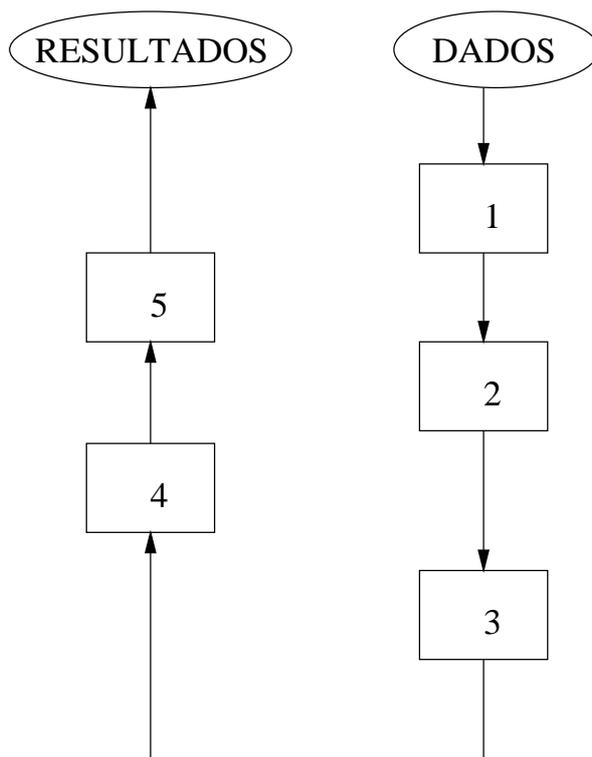


Figura B.3: Paralelismo de Fluxo

atuando na pizza 99 e o primeiro, processo preparando a centésima pizza. Desta forma, pode-se reduzir o tempo de processamento global.

Esta técnica de paralelização, que forma uma espécie de “linha de montagem”, é chamada de paralelismo de fluxo. Para um bom desempenho desta técnica de paralelismo é extremamente importante que cada tarefa seja executada sempre ao mesmo tempo. Se uma determinada tarefa demora mais do que as outras, isto implicará num atraso geral da execução das outras tarefas, aumentando o tempo de processamento final.

B.3.1 Alguns fatores que reduzem a exploração do paralelismo

É muito difícil encontrar-se uma aplicação que possa ser caracterizada por uma das três técnicas de paralelismo apresentadas anteriormente. Em muitos casos a utilização de todas as técnicas se faz necessária para se atingir o menor tempo de processamento.

Para definir a técnica exata a ser utilizada, deve-se levar em conta alguns

fatores importantes que tendem a reduzir a exploração do paralelismo:

- Paralelismo de Controle
 1. A dependência entre as diversas tarefas do processo.
 2. Sequencialização devido a falta de recursos (processadores).
- Paralelismo de Dados
 1. Tamanho dos dados (quando comparados à memória disponível)
 2. Dados escalares
- Paralelismo de Fluxo
 1. Estado Transitório (o tempo que demora até o *pipe* começar a operar).

B.4 Arquiteturas paralelas

De acordo com a classificação de Flynn, existem quatro tipos de arquiteturas computacionais. A classificação feita por Flynn (1966) é baseada na multiplicidade de instruções e no fluxo de dados do sistema computacional. As 4 categorias definidas são:

- S.I.S.D. *Single Instruction Single Data* ou Instrução Única para Dados Únicos;
- S.I.M.D. *Single Instruction Multiple Data* ou Instrução Única para Dados Múltiplos;
- M.I.S.D. *Multiple Instruction Single Data* ou Instrução Múltipla para Dados Únicos;
- M.I.M.D. *Multiple Instruction Multiple Data* ou Instrução Múltipla para Dados Múltiplos.

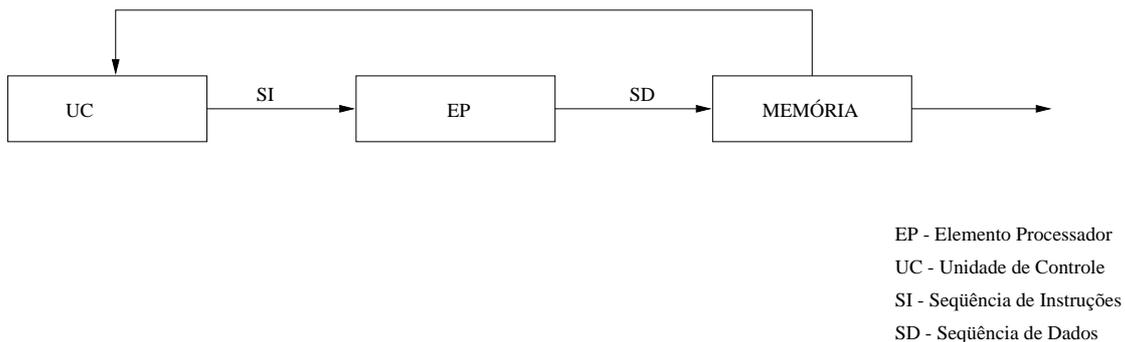


Figura B.4: Computador S.I.S.D

A arquitetura computacional S.I.S.D. (ver Figura B.4) corresponde aos computadores seqüenciais convencionais, nos quais só existe uma única unidade de controle que decodifica seqüencialmente instruções que serão executadas pelo processador sobre um conjunto de dados.

Na arquitetura S.I.M.D (Figura B.5), todos os Elementos de Processamento recebem a mesma instrução difundida pela Unidade de Controle, porém cada processador opera sobre dados distintos. Uma rede de interconexões é usada entre os bancos de memória e os processadores. Nessa arquitetura, um possível subsistema de memória compartilhada pode conter múltiplos módulos, chamados bancos de

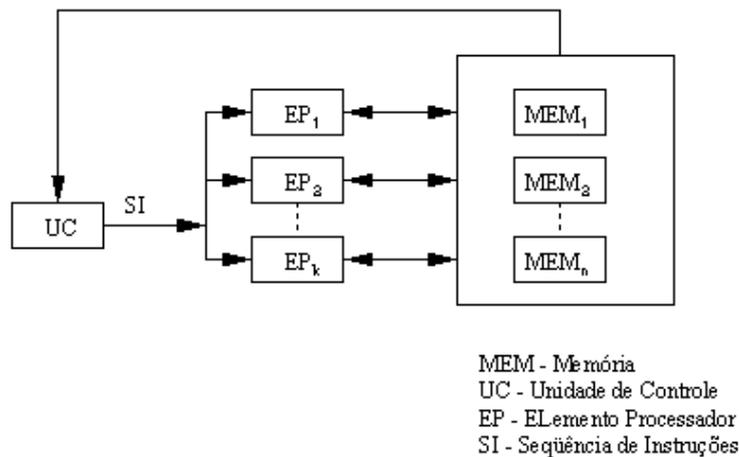


Figura B.5: Computador S.I.M.D

memória, e cada um deles pode ser acessado de forma concorrente. Nesta arquitetura, o acesso ao mesmo endereço por mais de um processador é possível, podendo causar um “gargalo” no processamento. Essas arquiteturas também são chamadas de máquinas vetoriais.

Nas arquiteturas M.I.S.D. (Figura. B.7), um mesmo dado é processado segundo várias instruções, caracterizando um *pipeline* de dados. Quase não existem equipamentos com esta arquitetura.

Na arquitetura M.I.M.D. (Figura B.6) um sistema de memória global é composto por muitos bancos, e cada um dos processadores pode operar sobre diferentes instruções. Uma outra possível arquitetura M.I.M.D. é composta por unidades de processamento que possuem memórias locais (também chamada de memória distribuída). Nesse tipo de estrutura é possível ter-se um grande número de processadores. Uma desvantagem dessa arquitetura pode ser observada quanto ao acesso aos dados em memória não-local, que pode gerar um aumento considerável no tempo de processamento.

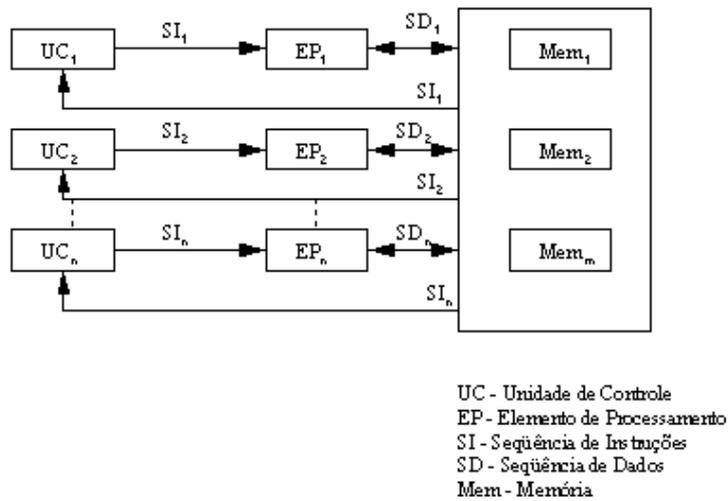


Figura B.6: Computador M.I.M.D

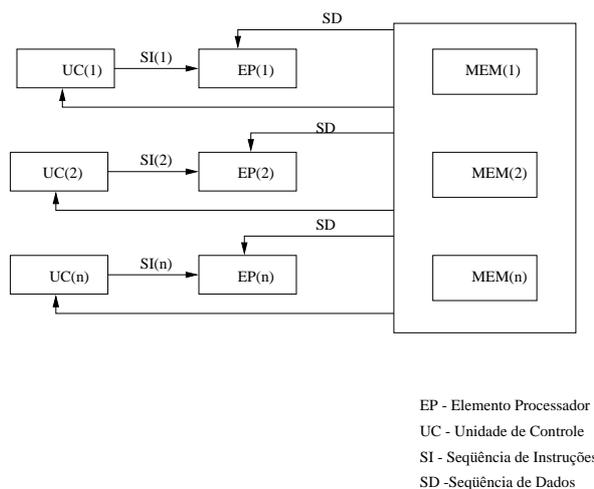


Figura B.7: Computador M.I.S.D

B.5 Interconexões

Em uma aplicação de processamento paralelo, procuramos determinar tarefas que possam ser executadas nos diversos processadores de uma dada arquitetura. Na maioria dos casos existe a necessidade de se passar informações de um processador para outro, sendo essa troca de dados realizada através de uma rede de interconexões que permita que mensagens sejam transmitidas e recebidas entre os processadores.

Uma aplicação paralela pode ser caracterizada por:

- Um conjunto de processos (tarefas, ação).
- Pela relação entre os processos.
 - Cooperação através de troca de mensagens via comunicação.
 - Competitividade de acesso aos dados em uma área compartilhada.

Em sistemas com memória distribuída, a relação entre os processadores ocorre através de trocas de mensagem (fig. B.8) (cooperação). As informações são roteadas de um processador-fonte para o processador-alvo (ou destino) através de uma rede de conexões que interliga os diversos processadores. Essas conexões normalmente são feitas através de chaves muito rápidas. A utilização de chaves pode ser feita de forma complexa ou simples, dependendo do número de processadores do sistema e da velocidade de processamento requerida do sistema.

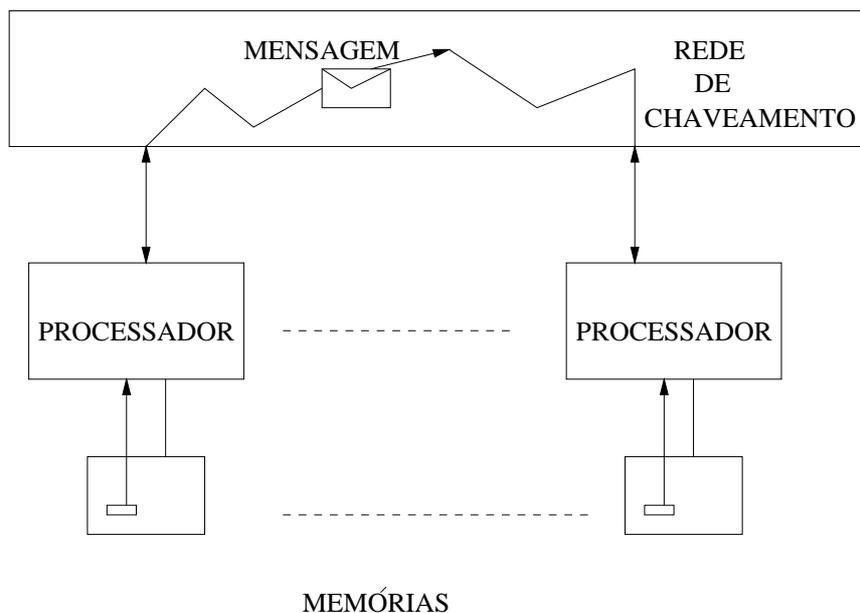


Figura B.8: Troca de mensagens entre processadores através de uma rede chaveamento

Em sistemas com memória compartilhada (global), as trocas de dados são efetuadas através de uma rede de conexões, a qual interliga os diversos processadores aos bancos de memória (Figura B.9). A troca de mensagens é feita escrevendo-se e lendo-se informações em um mesmo endereço. Neste tipo de rede, o caminho de

acesso ao dado é modificado de acordo com o banco de memória no qual o dado se encontra armazenado.

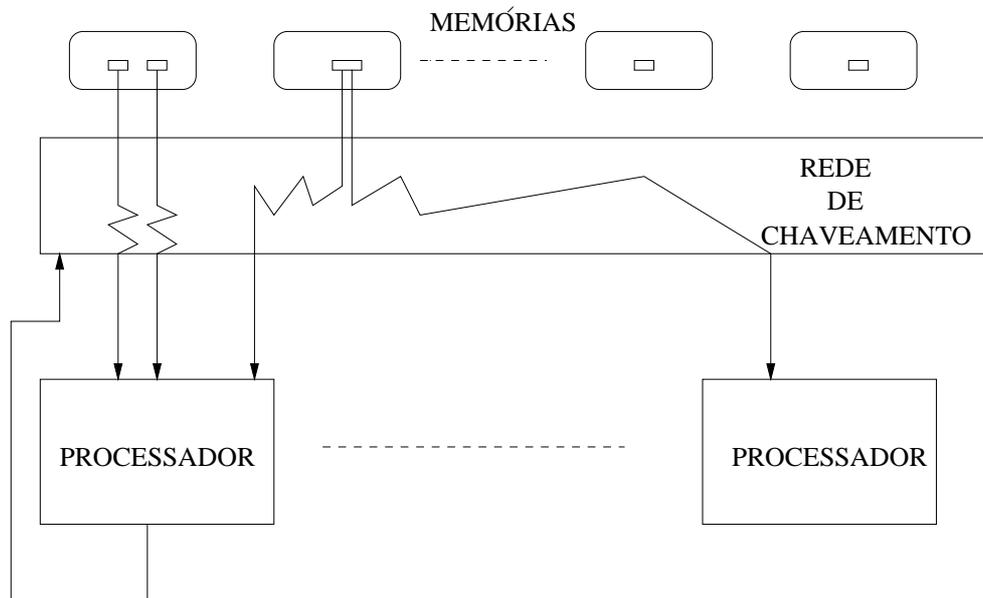


Figura B.9: Sistema de memória compartilhada

Em sistemas que se utilizam da cooperação entre os processos, existem duas formas de comunicação:

- **Comunicação Síncrona** - nesse caso, o processador que envia a mensagem fica suspenso até que a mensagem seja recebida pelo outro processador. Quando o processador-destino recebe a mensagem, este envia uma mensagem ao processador-fonte confirmando o recebimento da mensagem. Podemos dizer, então, que a comunicação entre os processadores é bloqueante.
- **Comunicação Assíncrona** - nesse tipo de comunicação, o processador que envia a mensagem pode prosseguir em seu processamento sem esperar uma confirmação de recebimento da mensagem vinda do processador destino. Este tipo de comunicação entre os processadores é dito não-bloqueante.

Existe, ainda, um outro tipo de classificação com relação aos tipos de redes de conexões, no que diz respeito ao seu dinamismo:

- redes estáticas - a topologia da rede de conexões não pode ser modificada.

- redes pseudodinâmicas - a topologia da rede de conexões pode ser modificada logo antes da execução de um processamento.
- dinâmicas - a topologia da rede de conexões pode ser alterada durante a execução de um processamento.

B.6 Eficiência e “speed-up” de um processamento paralelo

Quando se utiliza um processamento paralelo, é fundamental caracterizar sua eficiência com relação ao tempo de processamento utilizando a respectiva arquitetura paralela, em comparação com o tempo de processamento utilizando um único processador (processamento seqüencial).

$$E = \frac{T(1)}{N.T(N)} \quad (\text{B.1})$$

Na eq. (B.1) E é a eficiência, $T(1)$ representa o tempo de processamento utilizando um único processador (processamento seqüencial), $T(N)$ é o tempo do processamento paralelo utilizando N processadores.

Podemos reescrever a eq. (B.1) em função do tempo de comunicação associado à rede de conexões que interliga os diversos processadores de um determinado computador paralelo. Então, teríamos:

$$E = \frac{T(1)}{N.[T_p(N) + T_{comm}]} \quad (\text{B.2})$$

Na eq. B.2 $T_p(N)$ é o tempo de processamento paralelo utilizando-se N processadores (sem considerar o tempo de comunicação) e T_{comm} é o tempo de comunicação entre os processadores computado durante o processamento. Percebemos que melhor será a eficiência quanto menor for o tempo de comunicação entre os processadores.

O “speed-up” dado pela eq. (B.3) representa o fator de redução no tempo de processamento ao se utilizar um processamento paralelo ($T(N)$) em comparação com o tempo gasto utilizando-se um processamento seqüencial ($T(1)$).

$$\text{speed} - up = \frac{T(1)}{T(N)} \tag{B.3}$$