

Universidade Federal do Rio de Janeiro

SISTEMA NEURAL DE MONITORAÇÃO NÃO INVASIVA DE CARGA  
ELÉTRICA RESIDENCIAL

Alvaro David Orjuela Cañón

2009



**COPPE/UFRJ**

SISTEMA NEURAL DE MONITORAÇÃO NÃO INVASIVA DE CARGA  
ELÉTRICA RESIDENCIAL

Alvaro David Orjuela Cañón

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientadores: José Manoel de Seixas

Luiz Pereira Calôba

Rio de Janeiro

Outubro/2009

SISTEMA NEURAL DE MONITORAÇÃO NÃO INVASIVA DE CARGA  
ELÉTRICA RESIDENCIAL

Alvaro David Orjuela Cañón

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO  
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA  
(COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE  
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE  
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

---

Prof. José Manoel de Seixas, D.Sc.

---

Prof. Luiz Pereira Calôba, Dr.Ing.

---

Prof. Sandoval Carneiro Júnior, Ph.D.

---

Prof. Moises Vidal Ribeiro, D.Sc.

---

Prof. Charles Bezerra do Prado, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

OUTUBRO DE 2009

Cañón, Alvaro David Orjuela

Sistema Neural de Monitoração Não Invasiva de Carga Elétrica Residencial/Alvaro David Orjuela Cañón.. – Rio de Janeiro: UF RJ/COPPE, 2009.

IX, 102 p.: il.; 29,7 cm.

Orientadores: José Manoel de Seixas

Luiz Pereira Calôba

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2009

Referencias Bibliográficas: p. 83-90.

1. Monitoração de carga. 2. Redes Neurais. I. Seixas, José Manoel, *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica.

III. Título.

*À minha família,  
Meus pais Alvaro e Teresa e meus irmãos  
Jorge, Omar, Núbia, Adriana e Ivan.*

## AGRADECIMENTOS

Primeiro quero agradecer a Deus por sempre me dar uma luz quando mais precisei.

Ao professor Seixas, meu orientador, que sempre esteve aí, por acreditar no meu trabalho, por estar me dando sempre boas indicações para dar direção ao trabalho, e pela paciência para com minhas dúvidas.

Aos meus pais, que ao longo da vida, e desde sempre têm sabido me dar o melhor apoio em todos os meus projetos. A minha família que com mensagens de ânimo sempre torceram quando eu mais precisei. A minha namorada Erika, que sempre me deu força e me apoiou bastante, além de saber entender as dificuldades.

Aos professores que sempre tiveram um tempo para tirar dúvidas, o professor Calôba, José Gabriel, Diniz e aos meus amigos do LPS: Rodrigo, Danilo, Moura, Marcelo, Danton, e a todo o pessoal do laboratório que fez possível este trabalho.

Ao CEPEL, que sem sua ajuda não sei como teria continuado meus estudos. Também ao pessoal do CATE, o engenheiro João, Aroldo, Ana Cláudia, Beth, Norma, Pena, Tyrone, José Carlos, Glauco, Catherine, Amanda e o Diego, quem me deram uma força importante ao final do trabalho.

Ao Brasil, por me receber para poder realizar minhas metas, ao Rio por sempre ter os seus braços abertos.

Aos meus amigos colombianos, que foram como uma família, ao Ivanovich, Cesar, Carlos, Leonardo 1, Leonardo 2, Elkin, Laura, Luz Dary, Lyz, Liliana, Jhon, Hernán, William e um especial agradecimento ao professor Ricardo e sua família: a senhora Luz Marina, Carmen e Elena, que me receberam como se fosse parte da sua família.

Aos funcionários do programa de engenharia elétrica: Mauricio e Daniele, que sempre me ajudaram com a melhor disposição.

Aos meus amigos em casa, cuja energia pude sentir para continuar até o final.

A todos os que faltaram por citar, aqueles que sempre acreditaram em mim, obrigado, obrigado mesmo.

Resumo de Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

SISTEMA NEURAL DE MONITORAÇÃO NÃO INVASIVA DE CARGA  
ELÉTRICA RESIDENCIAL

Alvaro David Orjuela Cañón

Outubro/2009

Orientadores: José Manoel de Seixas  
Luiz Pereira Calôba

Programa: Engenharia Elétrica

Um sistema de monitoração não invasiva de carga elétrica residencial é desenvolvido, visando estudar, de uma maneira aprofundada, o consumo de energia elétrica em residências. Com base nas características da resposta transitória, este sistema utiliza um detector automático de acionamentos e um classificador neural, sendo que, este último determina a classe do transitório detectado. Com esta informação, é possível calcular a quantidade de energia consumida pelos diferentes tipos de eletrodomésticos. Para uma detecção automática dos acionamentos, o 88 % da energia total consumida foi reconstruída corretamente. Os sinais usados correspondem aos equipamentos mais relevantes e foram adquiridos isoladamente em laboratório. A eficiência de classificação foi de 85 %.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements of the degree of Master of Science (M.Sc.)

A NONINTRUSIVE NEURAL ELECTRIC LOAD MONITORING SYSTEM FOR  
HOUSEHOLD APPLIANCES

Alvaro David Orjuela Cañón

October/2009

Advisors: José Manoel de Seixas

Luiz Pereira Calôba

Department: Electrical Engineering

A noninvasive electric load monitoring of household appliances is developed for evaluating the residential energy consumption profile. Based on characteristics of transient response, the developed system employs an automatic event detector and a multi neural classifier, which assigns the detected transient to one of the eleven classes considered. With this information, it is possible to compute the amount of the energy consumed by the different types of appliances. For an automatic event detection, the energy reconstruction efficiency was 88 %. The analysed signals represent the most relevant appliances and were acquired separately in laboratory. The achieved classification efficiency was 85 %.



# Sumário

<b>Capítulo 1</b>	<b>Introdução.....</b>	<b>1</b>
1.1	Motivação .....	3
1.2	Objetivo .....	5
1.3	Organização do documento.....	6
<b>Capítulo 2</b>	<b>Revisão da literatura.....</b>	<b>7</b>
2.1	Sistemas de monitoração não invasivos de cargas residenciais .....	7
2.2	Redes neurais e estimação da carga.....	10
2.3	Sistemas de monitoração não invasivos de carga residencial no Brasil.....	11
<b>Capítulo 3</b>	<b>Materiais .....</b>	<b>13</b>
3.1	Classes de eletrodomésticos.....	14
3.2	Sistema de aquisição de dados .....	21
3.2.1	Aquisição dos sinais no laboratório.....	23
3.2.2	Aquisição no campo.....	25
<b>Capítulo 4</b>	<b>Métodos .....</b>	<b>27</b>
4.1	Detector de transitório .....	28
4.1.1	Detector de patamar simples .....	30
4.1.2	Detector de patamar elaborado.....	34
4.1.3	Detector por correlação.....	38
4.2	Classificação de transitório .....	44
4.2.1	Classificação do transitório por redes neurais.....	45
<b>Capítulo 5</b>	<b>Resultados .....</b>	<b>49</b>
5.1	Resultados para o detector .....	51
5.2	Classificação com recorte manual.....	60
5.3	Classificação com recorte automático .....	67
5.3.1	Classificação com recorte automático para a divisão dos dados por eventos .....	67
5.3.2	Classificação com recorte automático para a divisão dos dados por aquisição .....	73
5.4	Consumo de energia .....	80
<b>Capítulo 6</b>	<b>Conclusões.....</b>	<b>85</b>
6.1	Trabalho futuro.....	87

<b>Referencias Bibliográficas .....</b>	<b>92</b>
<b>Anexo A      Electrodomésticos.....</b>	<b>101</b>

# Capítulo 1

## Introdução

Nos últimos anos, a preocupação em desenvolver programas que ajudem a preservar o planeta Terra tem aumentado consideravelmente. Assim, os diferentes governos fazem esforços pela conscientização das pessoas e das contribuições que cada uma delas pode oferecer na busca de um consumo de energia sustentável.

O Brasil também realiza este tipo de esforço que é representado em diferentes áreas, na busca de melhoras ecológicas. A Eletrobrás [1], que desenvolve planos nesse sentido, é um exemplo disso.

Dentro dos diferentes estudos sobre o consumo de energia elétrica no Brasil [1][2], observa-se o aumento do consumo de energia elétrica residencial, que representa atualmente 22,2 % do consumo total deste tipo de energia. A Figura 1.1 mostra a subdivisão desse consumo, em que o segmento residencial é o segundo colocado em consumo, depois do consumo de tipo industrial que representa 46,7 % do total. Pode-se notar que a energia elétrica usada para tarefas domiciliares representa uma parcela importante, e se encontra em crescimento no Brasil [2]. A terceira parcela importante corresponde ao consumo de tipo comercial/serviços, com 14,2%. Estas informações do ano 2007, mostram que o consumo total de eletricidade foi de 412,1 TWh, crescendo 5,7% em comparação com o consumo no ano de 2006 [2].

Esse crescimento vem acontecendo devido a diversas razões, dentre as quais destacam-se:

1. A expansão da oferta da energia elétrica, para atendimento da crescente demanda por este insumo, que, do ponto de vista técnico, é dada pela expansão dos sistemas de geração, transmissão e pela preocupação permanente da universalização do serviço.

2. Um fator social, dado pela modernização da sociedade e das tarifas favorecidas que o mercado oferece. Além disso, o desenvolvimento do país, que propicia uma renda maior para a população.

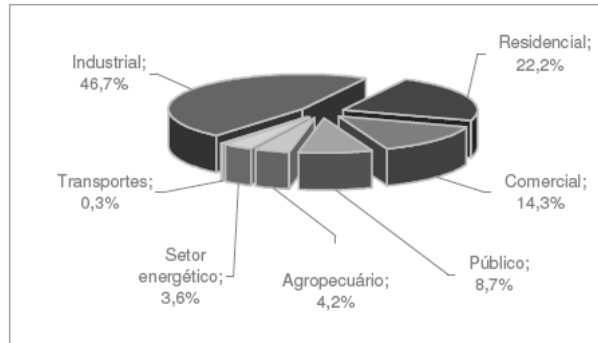


Figura 1.1: Consumo setorial de eletricidade.

Detalhando esse consumo de energia elétrica, em 2003, segundo o Instituto de Desenvolvimento Estratégico do Setor Elétrico (Illumina), o consumo residencial de eletricidade na sociedade brasileira foi, em média, 200 kWh [3]. Em alguns estados do Nordeste, o consumo foi de apenas 90 kWh, o suficiente para uma pequena geladeira e duas lâmpadas incandescentes. Nas residências da cidade do Rio de Janeiro, o consumo mensal das comunidades carentes é de 95,88 kWh, ou seja, tão baixo quanto no Nordeste [3]. Este estudo também revelou que o consumo brasileiro, por habitante, é de 2.000 kWh/ano, valor abaixo da média mundial [3].

A introdução de novos eletrodomésticos nos lares brasileiros muda o consumo domiciliar de energia elétrica. Na última década, isto é dado pela entrada de novos aparelhos que suprem determinadas tarefas que antigamente eram manuais, como máquinas de lavar pratos ou roupas, que facilitam o trabalho no lar, com novas tecnologias. No longo prazo, os estudos de eficiência energética procuram um melhor uso da energia elétrica através de um menor consumo de energia. As mudanças dos hábitos de consumo são incentivadas com propagandas educacionais, para que as pessoas usem melhor este recurso energético, ou com o uso de equipamentos modernos, cujo avanço tecnológico os tornaram mais eficientes.

Do ponto de vista energético, há projetos desenvolvidos pelas fábricas de eletrodomésticos elétricos, onde é procurado um uso mais eficiente da energia por parte dos dispositivos por elas fabricados. Para isto, existe o programa PROCEL (Programa ao Combate ao Desperdício de Energia Elétrica) da Eletrobrás [5], que faz-se presente, qualificando os tipos de aparelhos de acordo com sua eficiência energética.

Dentre os diferentes planos de desenvolvimento das diferentes entidades federais como o Ministério de Minas e Energia ou a Agência Nacional de Energia Elétrica, uma parte importante é aquela relacionada com planejamento energético [4][5][6], a qual, dentro das suas múltiplas tarefas, está a criação de hábitos racionais no uso da eletricidade pelas famílias brasileiras. No último período (2006/2007), estes programas em planejamento energético permitiram economia de 368 Gigawatts/hora/ano (Gwh/ano) e retiraram uma demanda de 138 MW do horário de ponta [6].

Nesse sentido, considerando o apresentado anteriormente, é necessário aprofundar os estudos e análises que permitam uma melhor avaliação da nova dinâmica do mercado de energia elétrica. Assim, é possível estabelecer uma relação desse mercado com o ritmo de crescimento econômico, onde os estudos sobre consumo de energia elétrica são importantes para planos de eficiência energética ao longo prazo, visando, com isto, aproveitar melhor os recursos que se têm no país.

## **1.1 Motivação**

Para estudar os hábitos de consumo de energia elétrica nos lares brasileiros, utilizam-se freqüentemente enquetes e entrevistas [1][2][3]. A Figura 1.2 mostra como é distribuído o consumo, em média, para os eletrodomésticos mais comuns em residências brasileiras [2].

A monitoração do consumo de energia elétrica tem várias vantagens:

1. Permite estudar o consumo de energia elétrica nas residências brasileiras, para saber de que forma esta energia é utilizada pelos usuários.
2. Permite elaborar planos de eficiência energética através de propagandas

educacionais em populações já conhecidas, a partir dessa informação do uso da energia elétrica.

3. Permite levantar perfis de consumo dos usuários, obtendo informação importante dos horários de pico, onde o consumo aumenta e, assim, implementar estratégias que garantam um melhor serviço, por parte das empresas fornecedoras.
4. Baseados nos estudos de monitoração, causas de perda de energia elétrica podem ser revelados, na forma de conexões ilegais à rede elétrica.
5. Permitir obter informação sobre dispositivos utilizados em cada uma das residências para estudos de perfil sócio-econômico, ou para estudos de mercado para empresas fornecedoras de aparelhos eletrônicos.

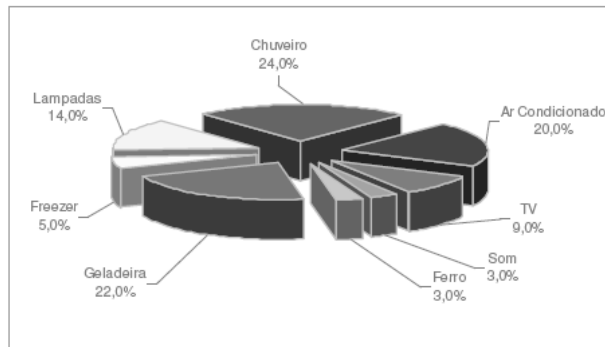


Figura 1.2: Consumo final na carga elétrica residencial no Brasil.

Para realizar esses estudos de consumo de energia elétrica, freqüentemente é feita uma coleta de dados por meio de enquete. A partir dos dados, são feitas análises sobre a informação adquirida. Por sua natureza, esses dados estão expostos aos erros do tipo sistemático, como informação faltante dada por questões sem resposta por parte do usuário, ou devido à má manipulação dos dados, por parte da pessoa que faz a entrevista. Outro erro no levantamento de dados sobre o consumo tem a ver com o fator psicológico que cada consumidor vai ter, ou seja, os habitantes de um prédio podem fornecer informações distintas aos seus hábitos de consumo quando estão sendo questionados na matéria, fazendo com que os dados levantados não sejam representativos, em termos de consumo naquele prédio. Isso também acontece quando as pessoas esquecem alguns hábitos de consumo, como por exemplo, não lembrar quantas vezes ligaram as luzes do banheiro. Um exemplo disso pode ser visto no estudo

realizado em [3], onde a média de consumo mensal obtida via enquete sobre uma comunidade específica é de 338,16 kWh, enquanto que, os dados da Light (empresa distribuidora de energia) indicam um consumo médio mensal de 95,88 kWh para a mesma comunidade.

A partir dos erros gerados pela forma com que são adquiridos os dados, é de suma importância desenvolver uma maneira automática para aquisição da informação, de forma a reduzir os erros sistemáticos. Também é preciso tempos menores de levantamento e processamento dos dados, uma vez que os estudos realizados por meio de enquetes ou entrevistas acabam requerendo um tempo elevado para a divulgação dos resultados.

## **1.2 Objetivo**

O objetivo desse trabalho é desenvolver um sistema de monitoração de cargas elétricas para estudo do perfil de consumo de energia elétrica domiciliar. Este sistema é desenvolvido a partir de um detector, que identifica os transitórios de diferentes equipamentos, quando estes são acionados. Em seguida, redes neurais são usadas como ferramenta fundamental, processando estes transitórios produzidos por cada tipo de eletrodomésticos (motores, resistências, equipamentos eletrônicos, e outros).

Trabalhos anteriores [7][8], onde são tratadas aplicações similares, mostram que o transitório das cargas representa informação suficiente para classificar estes tipos de eletrodomésticos, obtendo taxas de acerto de até 98 % [8]. Baseados nesses resultados, o presente estudo utiliza unicamente informações do regime transitório para fazer a classificação dos tipos de eletrodomésticos mais comuns nas residências brasileiras.

O presente trabalho, também procura validar os resultados obtidos pelo estudo desenvolvido em [2], realizado pela Eletrobrás, no qual foram levantados hábitos de consumo por meio de enquetes e entrevistas. Os resultados desse estudo serão comparados com os resultados obtidos pelo sistema tratado no presente trabalho. Isso será realizado em uma fase posterior do projeto da Eletrobrás, e que aqui, é citada como trabalho futuro.

Como desdobramento do projeto da Eletrobrás, o Cepel (Centro de Pesquisas em Energia Elétrica) desenvolveu um dispositivo de aquisição de dados com os quais se trabalhou no presente trabalho. Este dispositivo, faz uma coleta dos dados, adquirindo de forma contínua, informações importantes da rede elétrica (corrente, potencia ativa, potencia reativa) das residências a ser estudadas. Com estes dados coletados, é desenvolvida uma análise *offline*, que discrimina a parcela de energia elétrica consumida por cada uma das classes de eletrodomésticos definida. Esta análise é o escopo deste trabalho, a qual é desenvolvida através de um detector de transitório, encontrando os acionamentos dos equipamentos, e fazendo-se uma classificação dos mesmos com redes neurais.

### **1.3 Organização do documento**

Este documento está dividido em mais cinco capítulos, que se seguem à esta introdução. Uma revisão bibliográfica será apresentado no capítulo 2, onde são descritos diferentes trabalhos desenvolvidos para a monitoração da cargas elétricas residenciais, e como foram usadas as diferentes técnicas para resolver o problema da classificação destas cargas. Aplicações de redes neurais no setor elétrico são comentadas nesse capítulo.

O capítulo 3 trata a forma como foi realizada a aquisição de dados, os dispositivos utilizados assim como a estrutura do banco de dados usado neste trabalho. Já no capítulo 4 se descreve como foi abordado o problema, dividido em duas partes principais: a detecção do transitório produzida pelo eletrodoméstico, quando este é ligado, e a classificação do transitório detectado. A parte referente ao cálculo de energia consumida pelos eletrodomésticos detectados também é tratada. No capítulo 5, estão discutidos os resultados obtidos neste trabalho com as diferentes técnicas utilizadas no projeto de cada parte do sistema.

Para finalizar, o capítulo 6 encerra o documento com as diferentes conclusões do desenvolvimento e traz propostas para trabalhos futuros.



## **Capítulo 2**

### **Revisão da literatura**

O problema de monitoração de carga elétrica não é um tema novo. Diferentes técnicas e metodologias têm sido desenvolvidas em busca da solução ótima do problema. No presente capítulo são discutidos estes avanços, assim como diferentes técnicas que oferecem de alguma maneira uma orientação para os desenvolvimentos apresentados nos capítulos 3 e 4.

Na seção 2.1 será descrita uma pequena história das técnicas mais conhecidas para a solução do problema de estimação de carga. Posteriormente na seção 2.2 são citados trabalhos na área de engenharia elétrica desenvolvidos com ajuda de redes neurais, e por último, na seção 2.3 são abordados os avanços nesta matéria no Brasil.

#### **2.1 Sistemas de monitoração não invasivos de cargas residenciais**

Diferentes trabalhos foram desenvolvidos até o presente na procura de solucionar a estimação de consumo particular de cada um dos eletrodomésticos existentes nos diferentes lares. Um dos primeiros trabalhos foi o desenvolvido na Universidade de Massachussets na década de 1980, quando o professor Fred Shcweppe e o Dr. George Hart [9] desenvolveram a primeira versão deste tipo de medidores, o qual ainda é uma importante referência.

O trabalho do Dr. Hart apresenta uma análise bastante detalhada e completa, onde trata o problema com soluções que têm a ver com métodos invasivos e suas notáveis diferenças com métodos não invasivos, dando ênfase a estes últimos. Para estes métodos não invasivos, Hart propôs diferentes abordagens. Entre os mais importantes

estão os que se referem aos métodos baseados em modelos *on/off* dos tipos de cargas, em que se trabalha com uma função booleana que diz se a carga está ou não ligada em um determinado intervalo de tempo  $t$ . Outra abordagem é realizada sobre máquinas de estado finitas (FSM, *Finite State Machine*), onde as cargas mais complexas são tratados como uma máquina de estados finita, a qual modela os diferentes possíveis estados em que pode se encontrar a carga, por exemplo, uma máquina de lavar em cada um dos seus ciclos de lavagem é um estado da carga.

Os algoritmos propostos por Hart e sua equipe foram desenvolvidos a partir dos valores da potencia real e reativa de cada uma das cargas em estado estacionário e analisando as variações em intervalos de tempo. Também são apresentadas análises durante o transitório como uma possível solução, mas com resultados que não superavam aqueles obtidos com as técnicas desenvolvidas para regime permanente, tal abordagem não foi aprofundada.

Resumidamente, o algoritmo de Hart trabalha da seguinte maneira:

Passo 1 – O algoritmo detecta mudanças nos níveis constantes da potencia ativa encontrando assim acionamentos ou desligamentos nas cargas da residência;

Passo 2 – Faz-se um mapeamento da informação da potencia ativa junto com a informação da potencia reativa em um plano 2D;

Passo 3 – Valores próximos em potência em pares de acionamento e desligamento são agrupados como pertencentes à mesma carga.

Passo 4 – Os valores não considerados no passo anterior podem representar novas cargas acionadas usando algoritmos de verossimilhança ou simplesmente são descartados.

Passo 5 – Os pares encontrados no passo 3 são associados ao consumo de uma carga específica, obtendo-se assim o estudo de consumo de energia pelas diferentes cargas em uma residência.

Diferentes trabalhos têm sido realizados desde o desenvolvimento inicial do Hart [10][11][12][13][14][15][16][17][18] nos quais, são melhorados os algoritmos de detecção dos transitórios quando as cargas são ligadas. Os algoritmos relativos às atribuições desses transitórios a determinadas cargas e seu agrupamento, também foram melhorados. É importante dizer que os trabalhos desenvolvidos a partir do trabalho de Hart foram realizados baseados em informações de estado permanente das cargas.

Outra abordagem foi investigada por Steven B. Leeb em [19] no Instituto de Tecnologia em Massachussets (MIT, pela sigla em inglês). Leeb analisou informação presente no transitório que a carga produz quando é conectada à rede elétrica. Ele propôs diferentes classes para os tipos de cargas dependendo das suas equações de estado. Assim ele divide as cargas, de acordo com a sua composição física, em três importantes grupos:

- Eletrotérmicas: como as lâmpadas incandescentes, fornos elétricos ou cafeteiras, as quais possuem uma resistência fixa, e na medida em que vai esquentando, aumenta o valor dessa resistência. A característica destas cargas é que a forma do seu transiente é não linear.
- Eletromecânicas: como motores DC (*Direct Current*), motores de indução ou motores síncronos. As primeiras dependem do protocolo que é usado para ligar o motor. No segundo caso, o transitório é representado por uma transição medida em amplitude e tempo. No caso de motores síncronos, o sinal é tão afastado da rede elétrica normal que sua identificação é simples.
- Eletrônicas: como os computadores ou cargas de tipo eletrônico. Seu transitório depende de uma carga eletrotérmica ou eletromecânica, mais uma parte de controle. Têm frequências harmônicas devido à sua natureza física, as quais servem para a sua classificação.

A partir de cada um dos padrões que representam cada uma das classes que ele sugeriu, utiliza-se um filtro transversal ou filtro casado [20]. Este filtro faz uma correlação entre os eventos encontrados com os padrões existentes de cada uma das classes. Assim, o transitório é associado à classe vencedora dentro desses valores de correlação. Trabalhos desenvolvidos a partir das idéias do Leeb têm sido realizados com resultados interessantes [20][21] [22][23][24] [25][26][27].

## 2.2 Redes neurais e estimação da carga

No setor elétrico as redes neurais têm ocupado um espaço importante em diferentes aplicações. Desenvolvimentos com esta poderosa ferramenta têm ajudado na previsão de carga elétrica a ser demandada por uma região de consumidores. Existem assim dois tipos de predição:

1. *Short-Term*: é uma previsão de carga em curtos intervalos de tempo, geralmente em torno de 24 horas.
2. *Long-Term*: é uma previsão de carga em intervalos maiores de tempo, desde um mês até anos na frente.

Trabalhos relacionados ao primeiro tipo (*Short Term*) podem ser vistos em [28][29][30][31][32][33][34], onde a previsão é realizada para permitir economia no consumo e garantir a operação segura do sistema elétrico. As previsões do segundo tipo (*Long Term*) são importantes para fazer planejamento energético no sistema elétrico [35][36][37][38][39][40][41][42].

Outras aplicações interessantes no setor elétrico, tendo como base redes neurais, podem ser encontradas em um amplo número de problemas em diferentes áreas como a predição no preço da eletricidade [43], técnicas de detecção de falhas nas linhas de transmissão da rede elétrica [44][45][46], ou em restauração de sistemas de potência [47]. Estes últimos, depois de ter sofrido *blackouts*, os quais devem ser postos em funcionamento a partir de certos passos. Neste caso, as redes neurais oferecem respostas mais rápidas do que outros métodos oferecidos nesta área.

Quanto aos trabalhos desenvolvidos na área de eficiência energética, as redes neurais também têm diferentes aplicações como estimação de energia [48], predição de produção e consumo de energia [49] e diagnóstico para a conservação de energia baseado em redes neurais [50]. Aplicações em previsão e detecção de descargas atmosféricas em subestações, também podem ser resolvidos com ajuda de redes neurais, [51][52][53][54].

Diferentes trabalhos tratando aplicações com redes neurais no campo do setor elétrico têm sido desenvolvidos e são inumeráveis. Neste trabalho são citados os mais relevantes com relação aos objetivos apresentados neste documento.

## **2.3 Sistemas de monitoração não invasivos de carga residencial no Brasil**

Estudos sobre os hábitos de consumo de energia elétrica no Brasil têm sido realizados há pelo menos uma década [7]. Desta forma, tem sido possível planejar programas educativos e institucionais para fomentar um melhor e mais eficiente consumo da energia elétrica [5].

Informações específicas sobre os hábitos de consumo são importantes para este tipo de planejamentos. Assim, trabalhos em distintas áreas podem ser encaminhados para obter estas informações, por exemplo, controlando o acionamento das cargas em tempo de pico [55], ou com trabalhos onde se propõem importantes ferramentas para o planejamento de programas de conservação [56]. Com este tipo de sistemas é possível contribuir na melhora do consumo de energia elétrica.

Outro exemplo muito importante consiste em saber de que maneira os brasileiros consomem a energia elétrica e em que proporção para cada um dos grupos de eletrodomésticos mais representativos dos lares. Uma previsão de carga também é desenvolvida em diferentes trabalhos [57][58][59][60], onde são utilizadas grandezas do consumo de energia elétrica no Brasil.

Tratando especificamente o tema do monitoramento não invasivo, trabalhos deste tipo foram desenvolvidos pelo CEPEL, os quais abordam o problema com ajuda de redes neurais e processando *online* [7]. Para essa primeira versão, eram necessárias aproximações devido à pouca capacidade em memória dos equipamentos utilizados. Posteriormente foram conseguidos avanços na matéria, com a melhora dos algoritmos e

propondo novas alternativas para os diferentes cenários de implementação. Neste último, podem ser usados vários monitores deste tipo, aproveitando técnicas de multiprocessamento em tempo real [8].

O trabalho atual é baseado nestas duas propostas, mas usando novos dispositivos para a aquisição do sinal. Isto está dado por recentes desenvolvimentos no CEPTEL, com este novo *hardware*, são aproveitadas as vantagens de processamento *offline* que antes eram limitadas, além de novas informações que antes não se tinham.

## Capítulo 3

### Materiais

Pesquisas sobre eletrodomésticos e hábito de consumo vêm sendo realizadas no Brasil [2][3][4] para detalhar o consumo de energia elétrica. Os trabalhos desenvolvidos para este fim [7][8], nos dão informações sobre os eletrodomésticos mais utilizados nos lares brasileiros. Baseados nesses estudos, podemos selecionar um grupo representativo de dispositivos para fazer as respectivas análises no presente trabalho. O anexo A apresenta uma lista dos eletrodomésticos usados neste estudo e que representam os mais usados nas residências do Brasil.

Outro aspecto a definir refere-se ao tipo de informação que deve ser utilizada no sinal de um eletrodoméstico. Alguns trabalhos dão um enfoque às informações de potência ativa e reativa em estado permanente [9][10][12], como foi dito na revisão bibliográfica. Dessa mesma forma, trabalhos sobre o sinal de corrente no regime transitório [19][20][24] nos dão diferentes alternativas para enfrentar o problema.

Como se descreveu na introdução, este trabalho faz parte de um projeto desenvolvido no CEPEL (Centro de Pesquisa em Energia Elétrica), sendo realizadas as aquisições neste centro de pesquisa. Estas aquisições são divididas em dois tipos:

- Uma realizada nos laboratórios de CEPEL, onde são caracterizados os eletrodomésticos mais representativos do consumo residencial brasileiro [2].
- Um outro tipo realizado no campo, ou seja, sinais adquiridos em residências enquanto realizam um consumo real.

Assim, foi construído no CEPEL um dispositivo de aquisição, o qual fornece informações de tensão, corrente, potência ativa e potência reativa em regime transitório e permanente. Neste capítulo, será descrito este dispositivo com o qual foram adquiridos todos os sinais para desenvolver o presente trabalho.

Características das diferentes aquisições são apresentadas nas seções seguintes, onde primeiro são descritas as classes dos eletrodomésticos a tratar, e depois é realizada uma descrição de como foram feitas as aquisições em laboratório e em residências.

### 3.1 Classes de eletrodomésticos

Do capítulo anterior, o trabalho do Leeb [19] faz um agrupamento das cargas quanto às suas características físicas. Para fazer uma monitoração de carga elétrica residencial, é necessário definir estas classes ou tipos de eletrodomésticos, onde de acordo com as características similares que existam entre eles, são agrupados em determinado número de classes. Desta forma, identificar o consumo em função dos tipos de cargas é menos complicado do que fazer isto para cada uma delas, onde as possibilidades de identificar esse consumo são variadas, e depende do número de equipamentos no mercado.

Das informações recolhidas dos sinais adquiridos, existem dois tipos de representações que permitem o agrupamento dos eletrodomésticos em classes de características similares [7]:

- Uma dada pela informação de regime transitório, que geralmente é tomada da forma de onda do sinal de corrente [19].
- Outra dada por informações de regime permanente [9], a qual sugere uma representação dessas informações de regime permanente nos eixos formados pelas potências ativas  $P$ , e reativas  $Q$ , ou ainda sobre um plano formado pela corrente aparente  $I$  e o ângulo de fase ( $\theta$ ).

Para a caracterização das classes a partir das informações de regime transitório, são tomadas as considerações dos trabalhos [7][8] que são os alicerces do presente trabalho. Eles apresentam um número de agrupamentos de eletrodomésticos em seis classes, que serão descritos mais na frente.

Os avanços na implementação do *hardware* do novo dispositivo de aquisição de dados desenvolvido pelo CEPTEL, com relação ao dispositivo utilizado em [7], que dificultava a medição nos eletrodomésticos com corrente abaixo de 1A, propiciaram o aumento da



capacidade de resolução do dispositivo, permitindo a atuação do equipamento em uma faixa de corrente maior. Como resultado, podemos analisar eletrodomésticos com correntes acima de 100 mA, o que aumentou número de classes.

Este aumento de classes, também está dado por essa nova vantagem do *hardware* somado ao fato de poder estudar em mais detalhe sobre o hábito de consumo de energia elétrica específica para algumas classes. Um exemplo disso está relacionado com o tema de iluminação, onde se tem lâmpadas de tipo incandescente, que estão sendo substituídas cada vez mais por lâmpadas de tipo fluorescente [61], de acordo a que estas últimas têm características similares quanto a iluminação, mas apresentam um menor consumo de energia.

Partindo das análises de [7][8] para o agrupamento dos eletrodomésticos, e observando a forma das envoltórias dos transitórios típicos, que chamaremos de transitórios só, as principais características consideradas foram:

1. Pico grande de corrente e estabilização com queda exponencial intermediária (estabilização entre 10 e 60 ciclos de 60Hz) para um valor de  $\pm 11\%$  do valor de pico – características de equipamentos de refrigeração: refrigeradores, *freezers*, condicionadores de ar [7][8] (Figura 3.1).




Figura 3.1: Transitório típico para um compressor.

- Um patamar de corrente estabilizado em nível constante – característico de cargas resistivas para aquecimento, como chuveiros, torradeiras, ferros de passar, cafeteiras, etc [7][8] (Figura 3.2).




Figura 3.2: Transitório típico para um eletrodoméstico resistivo.

- Pico médio de corrente e estabilização com queda exponencial intermediária (estabilização entre 10 e 60 ciclos de 60Hz) para um valor de  $\pm 50\%$  do valor do pico – características de motores universais, como liquidificadores, batedeiras e furadeiras [7][8] (Figura 3.3).




Figura 3.3: Transitório típico para um motor universal.

- Um patamar de corrente com queda lenta (estabilização em mais de 100 ciclos de 60 Hz) em nível constante de pouca amplitude – características de motores de ventilação como circuladores e ventiladores [7][8] (Figura 3.4).




Figura 3.4: Transitório típico para um motor de ventilação.

5. Pico de corrente curto e largo com amplitude muito baixa, e estabilização com queda rápida (estabilização em menos de 10 ciclos de 60 Hz) – equipamentos eletrônicos de diferentes tipos [7][8] (Figura 3.5).




Figura 3.5: Transitório típico para eletrodoméstico eletrônico.

6. Pico curto de corrente e estabilização com queda rápida (estabilização em menos de 10 ciclos de 60 Hz) – característica de lâmpadas incandescentes [7][8] (Figura 3.6).




Figura 3.6: Transitório típico para lâmpada incandescente.

7. Pico de corrente curto e largo, com amplitude baixa e estabilização de queda rápida (estabilização em menos de 10 ciclos de 60 Hz) – característica de lâmpadas fluorescentes de reator eletrônico [62] (Figura 3.7).




Figura 3.7: Transitório típico para lâmpada fluorescente com reator eletrônico.

8. Dois patamares – amplitudes crescentes – características de lâmpadas fluorescentes de reator eletromagnético [63] (Figura 3.8).




Figura 3.8: Transitório típico para uma lâmpada fluorescente com reator eletromagnético

9. Caso especial: máquinas de lavar. Neste caso foi tomado como transitório o sinal de 150 amostras do valor de corrente a partir do acionamento da máquina de lavar no ciclo de lavado. Contudo, não se tem estabilização para o seu regime permanente (Figura 3.9).




Figura 3.9: Transitório típico para uma máquina de lavar roupa.

10. Dois patamares – amplitudes crescentes – características de monitores de tubos de raios catódicos (CRT) (Figura 3.10).




Figura 3.10: Transitório típico para monitor CRT.

11. Um patamar constante – característica de monitores de telas de cristal líquido (LCD) (Figura 3.11).




Figura 3.11: Transitório típico para um monitor LCD.

Dos agrupamentos expostos, é visto que os correspondentes às classes 5, 6 e 7, evidenciam semelhanças entre seus padrões. Para a classificação deles, são aproveitadas características que podem ser usadas na sua representação como, por exemplo, amplitude depois da estabilização, ou proporção do pico com relação ao valor em regime permanente.

Quanto à classe 9 é um caso especial, uma vez que a natureza do eletrodoméstico não permite ter um regime permanente devido a uma comutação no seu circuito elétrico.

Optamos por considerar como transitório o sinal produzido quando este eletrodoméstico é ligado. Resumidamente, as seguintes classes de cargas foram definidas para a identificação:

1. Compressores;
2. Equipamentos resistivos;
3. Equipamentos de agitação, movimento e mistura;
4. Equipamentos de ventilação;
5. Equipamentos eletrônicos;
6. Lâmpadas incandescentes;
7. Lâmpadas fluorescentes de reator eletrônico;
8. Lâmpadas fluorescentes de reator eletromagnético;
9. Máquinas de lavar;
10. Monitores CRT;
11. Monitores LCD.

### **3.2 Sistema de aquisição de dados**


O CEPTEL, nos últimos anos, tem desenvolvido um dispositivo para fazer aquisição de dados de uma maneira não invasiva. Este dispositivo pode ser colocado no poste em que se encontra a linha elétrica que fornece energia elétrica no prédio. A figura 3.12(a) mostra como o medidor pode ser instalado na residência a ser estudada. Os diferentes estágios do medidor também são mostrados (Figura 3.12(b)).

Este dispositivo faz aquisição a cada ciclo da onda da rede elétrica, obtendo 60 amostras com informações de corrente e tensão por cada segundo. Também em cada ciclo, é calculada a potência ativa e reativa das correntes e tensões *rms* (*root mean square*) adquiridas. Trabalhando com uma resolução de 10 bits, é possível adquirir valores mínimos de até 5 mA, no caso da corrente, valor que foi programado previamente no *hardware*.

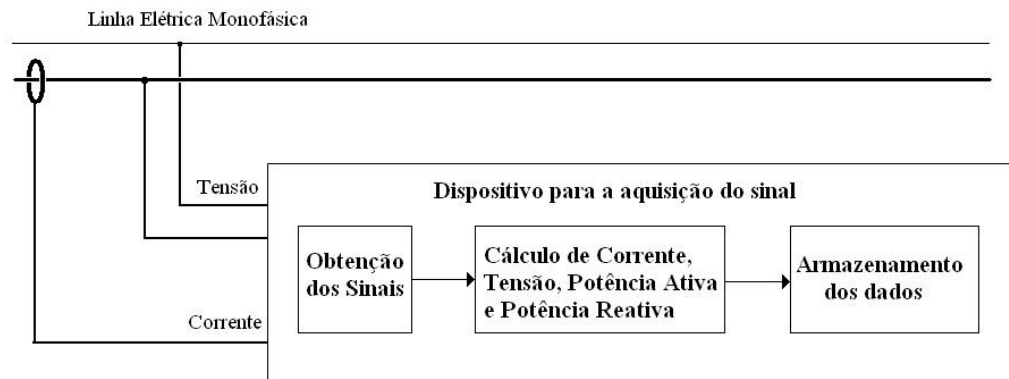
Os dados adquiridos são armazenados, permitindo fazer uma análise *offline* e completa no sinal. Desta forma, podemos obter informações relevantes de regime transitório e do regime permanente, isso ocorre, quando técnicas adequadas são empregadas.

Para a constituição do banco de dados, as aquisições foram realizadas de duas maneiras:

1. Nos laboratórios do CEPEL, onde foram adquiridos sinais dos eletrodomésticos mais representativos no consumo residencial, de maneira isolada.
2. Em campo, onde são adquiridos sinais reais de consumo, ligando e desligando eletrodomésticos de diferentes tipos, em uma dada residência.



(a)



(b)

Figura 3.12: (a) Monitor não invasivo e (b) Forma de conexão.



Destes dois tipos de aquisição para o presente trabalho, a base de dados trabalhada foi a conformada por sinais dos eletrodomésticos isolados (caso 1 acima), propondo também uma aquisição no campo, que foi realizada, mas que não foi avaliada no presente estudo.

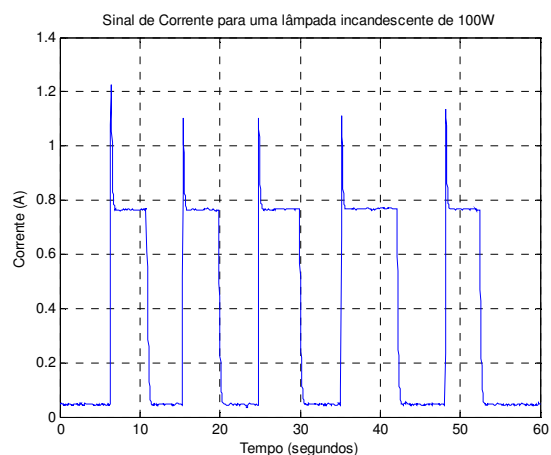
Para tornar o sistema de aquisição robusto, os dados são armazenados periodicamente, com um intervalo de tempo mínimo de um minuto. Com isto, procura-se evitar perda da informação devido às falhas na rede elétrica ou no mesmo dispositivo, salvando assim as informações anteriores ao período anterior à falha. Como intervalo máximo de aquisição, foi fixado um valor de uma hora para os sinais adquiridos.

Como o dispositivo armazena a forma de onda do sinal de corrente elétrica e a de potência, faz-se necessário escolher um destes sinais para realizar a detecção e classificação. Geralmente em sistemas deste tipo [13][15][17], são tomados os sinais de potência para fazer a monitoração. Experimentalmente, foi observado que este sinal apresenta um maior nível de ruído comparado com o sinal de corrente, o qual pode atrapalhar a detecção. Por esta razão, o sinal de corrente foi escolhido. A Figura 3.13 mostra a diferença entre os dois tipos de sinais, onde o sinal de potência apresenta maior nível de ruído na aquisição.

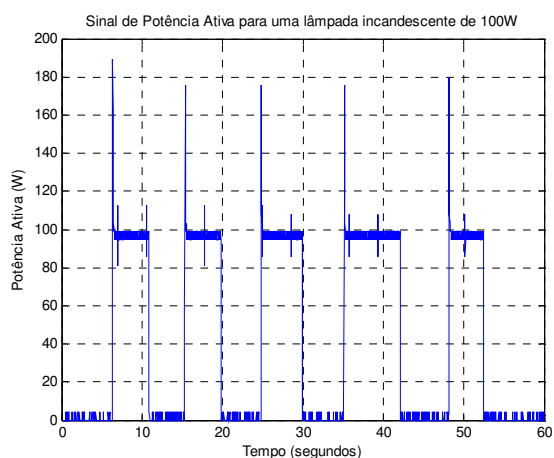
### **3.2.1 Aquisição dos sinais no laboratório**

Esta aquisição, realizada nos laboratórios do CEPEL, consistiu em obter dados dos eletrodomésticos mais representativos, de diferentes marcas, dos lares brasileiros e realizar um determinado número de acionamentos e desligamentos do eletrodoméstico na mesma aquisição.

Como existem eletrodomésticos que precisam de um tempo maior para voltar ao seu estado original, os intervalos completos de aquisição são diferentes para cada eletrodoméstico. Um exemplo disso é uma lâmpada incandescente, onde é necessário esperar que seu filamento esfrie. Uma outra consequência de tempos maiores de aquisição, está refletida da procura de uma boa representação estatística de cada eletrodoméstico, isto para lograr uma melhor generalização no estudo.



(a)



(b)

Figura 3.13: (a) Sinal de corrente para uma aquisição de vários acionamentos de uma lâmpada incandescente, (b) Sinal de potência ativa da mesma aquisição.

A Figura 3.14 apresenta um sinal de aquisição para um refrigerador. Pode-se ver que para este eletrodoméstico foram feitos 6 acionamentos para a aquisição..

Estes tipos de aquisições são realizadas para extrair características importantes do transitório de cada um dos eletrodomésticos visando a detecção e o treinamento das redes neurais, as quais são aplicadas para a classificação.

Quando existirem eletrodomésticos de varias classes envolvidas, ou seja, com diferentes tipos de transitórios, como por exemplo, um ar condicionado, que tem transitórios das

classes de compressores e de motores de ventilação, o equipamento é representado pela classe mais relevante quanto ao seu consumo de energia. Neste caso, o ar condicionado é representado pela classe de compressores.

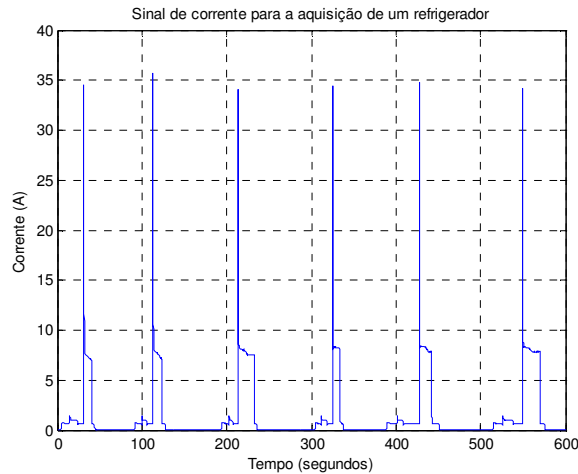


Figura 3.14: Sinal de corrente para uma aquisição de um refrigerador.

### 3.2.2 Aquisição no campo

Um dos objetivos deste trabalho é identificar e classificar o consumo de energia elétrica residencial, mas o consumo real não está dado na forma como foram adquiridos os sinais no laboratório. Esta energia, consumida em média por uma residência [4], é calculada dos acionamentos sucessivos das cargas, sem que necessariamente seja desligado o equipamento que foi ligado primeiro. Assim, os acionamentos contínuos de aparelhos em uma residência provocam o empilhamento dos sinais.

Para este tipo de aquisição, foram usadas duas residências diferentes no Rio de Janeiro. Paralelamente, foram anotados os equipamentos que iam sendo ligados e o tempo aproximado da duração de cada ativação do eletrodoméstico.

Outros sinais foram coletados, mas neste caso nos laboratórios do CEPEL, onde se fez uma simulação de um possível consumo, onde havia eletrodomésticos de diferentes tipos à disposição, para realizar a aquisição. O mesmo procedimento de anotar os tempos foi feito, para comparação com os resultados. A Figura 3.15 mostra um sinal de

consumo real em um período de 4 horas, em uma residência onde se fez a aquisição. Neste caso foi feito o acionamento do compressor de um refrigerador e o acionamento de um chuveiro elétrico.

Este tipo de aquisição foi realizado, mas não foi aprofundado, como foi mencionado anteriormente. O presente trabalho tem como escopo tratar os sinais isolados dos eletrodomésticos para desenvolver as técnicas usadas. Na subseção de trabalho futuro é descrita a maneira como deverá ser avaliada este tipo de aquisição.

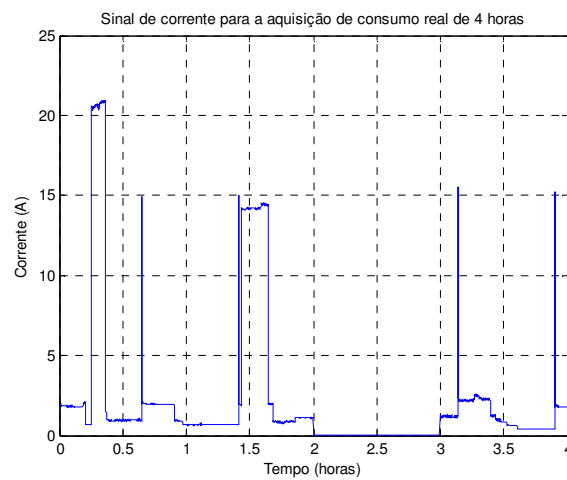


Figura 3.15: Sinal de consumo real em um período de 4 horas em uma residência do Rio de Janeiro

## Capítulo 4

### Métodos

Um dos objetivos mais relevantes do projeto é obter informação do consumo de energia por cada uma das classes que foram apresentadas no capítulo anterior. Para isso são necessárias informações de potência e o intervalo de tempo de consumo para cada uma das classes. Esta tarefa é descrita nesta seção, onde é explicado como são obtidas essas informações.

Partindo dos sinais de corrente armazenados pelo dispositivo descrito no capítulo anterior, o processamento é feito de maneira *offline*, considerando-se as principais aplicações alvo, que consistem na validação dos formulários do PROCEL [1], e a determinação dos perfis de consumo para as residências em estudo.

O processamento de sinais é dividido em duas partes importantes: detecção e segmentação. Na primeira parte, se encontra a detecção dos transitórios visando, sobretudo, identificar o acionamento de um equipamento. Na segunda parte se encontra a classificação dos transitórios obtidos na detecção, para relacionar o transitório com o tipo de eletrodoméstico. Estas duas partes serão explicadas em detalhe no presente capítulo.

Para calcular a eficiência da classificação, é importante saber o consumo de cada uma das classes para desenvolver os objetivos do estudo, que procura achar os tipos de eletrodomésticos que consomem mais energia elétrica. Assim, para cada uma das classes é necessário saber o tempo inicial quando foi ligado o equipamento, tarefa realizada pelo detector, e a classe do eletrodoméstico ligado, trabalho que realiza o classificador. Com estas informações, é estimada a energia consumida a través da expressão:

$$Energia = (t_{final} - t_{inicial}) * Potência_{média} \quad (4.1)$$

em que  $t_{inicial}$  é medido na parte da detecção e  $t_{final}$  é o tempo final de consumo, que no presente estudo, está dado pelo fim do transitório. Isto é feito, assumindo que os eletrodomésticos têm um valor de potência constante em regime permanente, e assim, é calculada a energia consumida por cada classe. Esta estimativa de consumo foi obtida, através da medida da potência sobre as últimas 10 amostras no transitório considerado, que correspondem também à sua representação de regime permanente. Com esta potência é calculada a energia consumida, com tempo de consumo igual a dois segundos e meio, para todas as classes.

O diagrama de blocos do sistema de monitoração de carga elétrica residencial é visualizado na Figura 4.1, onde informações dos detectores de transitório e desligamento, assim como, do classificador do transitório são usados no cálculo da energia. No caso do detector de desligamento, o final do transitório é considerado como foi explicado acima, sem precisar desenvolver uma técnica para este detector. Os dois subsistemas restantes são explicados a seguir.

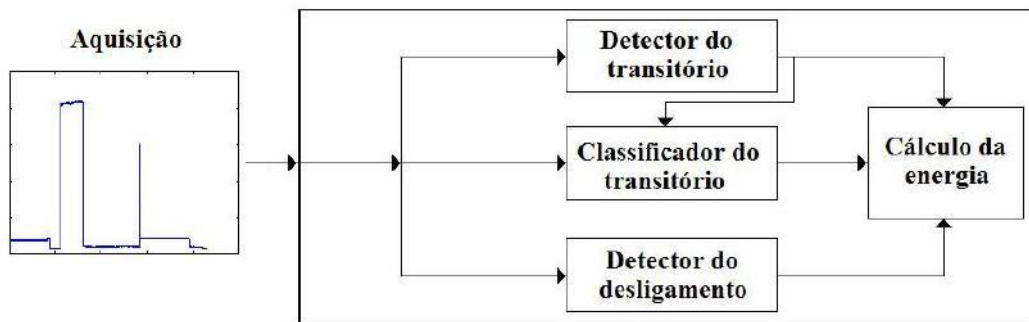


Figura 4.1: Subsistemas para a monitoração não invasiva de cargas residencial.

## 4.1 Detector de transitório

Diferentes trabalhos foram desenvolvidos até o presente na procura de solucionar a estimação particular de consumo dos eletrodomésticos que existem em uma residência.

Um dos primeiros trabalhos foi o desenvolvido na Universidade de Massachussets na década de 1980, quando o professor Fred Shcwepe e o Dr. George Hart [9] desenvolveram a primeira versão deste tipo de medidor, a qual ainda é uma importante referência. Trabalhos mais recentes [7][8] não dão maior relevância ao detector uma vez que o *hardware* de aquisição fazia esta tarefa, o qual se resume a adquirir um sinal que sobrepasse um limiar de corrente.

No presente trabalho, são apresentadas duas propostas para detectar os transitórios dos eletrodomésticos. Assim, são aproveitadas as características desta parte do sinal, que comparado com análises em regime permanente, têm importantes diferenças [9][12]. Estas duas partes dos sinais podem ser extraídas por uma aquisição completa: primeiro é detectado o transitório, que é recortado de maneira que, posteriormente, possa ser classificado no estágio seguinte. As últimas amostras do transitório recortado são consideradas como o começo do regime permanente e, assim, são obtidas as informações pertencentes ao regime permanente.

A primeira proposta de detecção desenvolvida descreve um detector de patamar, que trabalha procurando as mudanças no sinal, característica dos transitórios. Quando o sinal tem uma transição o sinal é recortado. Uma segunda proposta é baseada na anterior, no entanto os critérios para procurar a mudança, e para fazer o recorte, são mais elaborados.

Uma outra proposta para o detector realiza uma aproximação simples do filtro casado determinístico. Para isso, é realizada a correlação de janelas temporais do sinal que está sendo adquirido, com padrões de cada uma das classes de interesse.

Três técnicas propostas foram usadas para detectar o transitório. Para desenvolver as experiências foi necessário construir uma base de dados para o desenvolvimento, escolhendo 80% do total dos dados adquiridos, e deixando os 20% restantes para realizar testes sobre as propostas desenvolvidas, avaliando o desempenho do detector.

### 4.1.1 Detector de patamar simples

Como pode ser visto da Figura 4.2, quando um eletrodoméstico é acionado o sinal de corrente devido à sua composição física [19] sofre uma modificação, que representa uma transição. Aproveitando estas características, o equipamento pode se encaixar em uma das classes descritas no capítulo anterior.

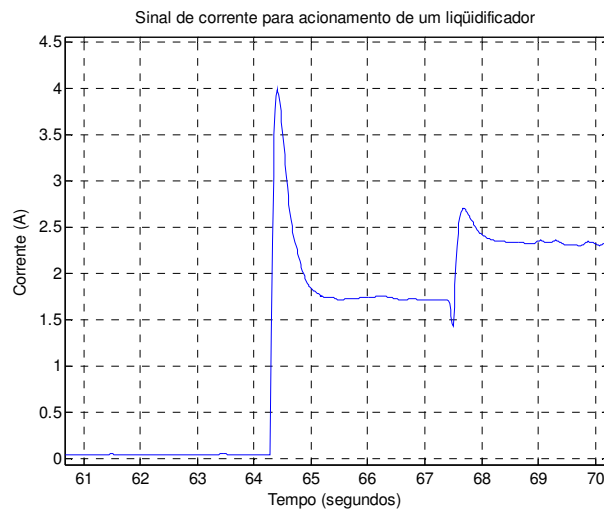


Figura 4.2: Sinal de corrente para o acionamento de um liquidificador.

Estes transitórios podem ser identificados medindo-se as diferenças entre duas amostras consecutivas da maneira:

$$a(n) = x(n+1) - x(n) \quad (4.2)$$

em que  $a(n)$  é o valor da corrente entre duas amostras consecutivas. Assim, quando temos um transitório, as diferenças nos valores de corrente de amostra para amostra é bem diferenciado da parte do sinal que está em regime permanente ou em repouso. Aproveitando esta característica, podemos encontrar a parte do sinal que é de nosso interesse, realizando a subtração sucessiva entre suas amostras.



Neste trabalho, a primeira proposta está baseada em encontrar os transitórios a partir de da subtração em (4.2) que ao superar certo limiar, sugere a existência de um acionamento naquele trecho do sinal.

Para começar, primeiro deve-se limpar o sinal de possíveis ruídos na linha elétrica, motivo pelo qual o sinal deve ser filtrado para retirar aqueles valores de corrente, que correspondem às variações do sinal e que podem atrapalhar a operação da subtração. Esta filtragem é realizada por uma rotina de média móvel, que substitui o valor da amostra pelo valor médio de um determinado número de amostras subsequentes. Para este caso, determinou-se experimentalmente um valor de 10 amostras para a filtragem. Na Figura 4.3 é mostrado o sinal original para um acionamento de um liquidificador e sua correspondente versão filtrada.

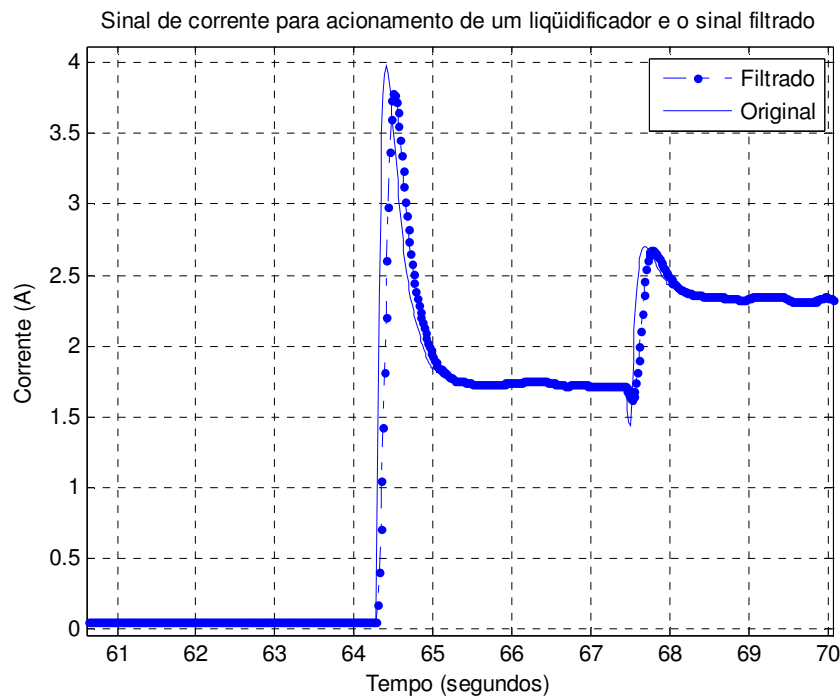


Figura 4.3: Sinal de corrente para o acionamento de um liquidificador e sua versão filtrada.

A partir do sinal filtrado, o detector realiza uma operação de subtração entre amostras sucessivas. Quando esta subtração supera um limiar estabelecido, considera-se aquele trecho de sinal como de interesse.

Uma característica importante do projeto refere aos valores mínimos de corrente a detectar pelo sistema, isto define nosso limiar de operação para a aplicação-alvo. Para o presente trabalho, valores maiores a 15 watts são considerados de maior relevância.

Considerando-se a detecção por corrente, este valor de potência se reflete na expressão:

$$I = S/V \quad (4.3)$$

em que  $S$  é a potência da carga,  $V$  é o valor da tensão e  $I$  é o valor da corrente. Comumente o valor de tensão nominal padrão para residências monofásicas no estado do Rio de Janeiro é de 127V, o qual é considerado neste trabalho. Desta forma, o valor da corrente para as cargas que demandam 15 watts em (4.3) é de  $\sim 118$  mA. Arredondando, trabalhamos com um valor de corrente de 100 mA, que, representaria cargas acima de 12,7 W, cumprindo as especificações da aplicação-alvo.

Tendo definido o limiar para o detector do patamar, o passo seguinte é analisar o sinal para encontrar o instante de tempo em que ocorre essa diferença no sinal, definindo o início do recorte do transitório. O transitório assim encontrado é validado analisando suas últimas amostras, que são consideradas como o começo do sinal de regime permanente do equipamento. Neste caso, foi realizada uma análise da maneira seguinte:

$$b(n) = x(n+150) - x(n) \quad (4.4)$$

em que  $b(n)$  é o valor do aumento da corrente para um intervalo de tamanho de um transitório, o qual foi definido como de 150 amostras.

Se o valor de  $b(n)$  em (4.4) é maior do que o limiar estabelecido, certifica-se a existência de um transitório, isto porque a potência aumentou com o acionamento de uma carga com corrente de pelo menos 100 mA. Neste instante, o sinal já alcançou seu regime permanente.

Depois de encontrar o trecho de sinal de interesse, é necessário fazer um recorte do transitório, conhecendo o início do acionamento. Ao trabalhar sobre o sinal de corrente

filtrado, é extraído do sinal qualquer tipo de flutuação correspondente ao ruído na linha elétrica, ficando assim, as mudanças do sinal que correspondem aos transitórios dos eletrodomésticos. Para o detector de patamar simples, foi definido um pequeno limiar que define o começo do acionamento, que nesse caso, se dá quando a subtração entre duas amostras sucessivas, dado por (4.2), é maior do que 10 mA. Este valor foi determinado a partir da resolução do dispositivo de aquisição, que é 5 mA, considerando assim qualquer variação acima desse valor como o começo de um transitório.

Com as informações da existência do transitório, assim como o ponto inicial do mesmo, é feito o recorte. O detector de patamar simples é resumido em quatro passos:

1. Condição 1: Subtração do valor de corrente da amostra futura para o valor de corrente da amostra atual, como é dado em (4.2).
2. Condição 2: Subtração do valor de corrente da amostra atual mais 150 com o valor de corrente da amostra atual, como é dado em (4.4).
3. Se o valor da condição 1 é maior do que 10 mA, e o valor da condição 2 maior do que 100 mA, é recortado o transitório do sinal original, sem filtrar.
4. Se não ocorre o passo 3, a análise se realiza para amostra futura.

Estes passos são mostrados no fluxograma da Figura 4.4.

O transitório recortado tem um tamanho de 150 amostras, este valor está determinado por estudos dados por Leeb [19], e considerados em trabalhos mais recentes [7][8], onde é mostrado que para a maioria de tipos de cargas, o estado transitório é menor a 120 ciclos de corrente alternada. Do capítulo anterior, na parte de definição de classes, é visto que para este ponto os eletrodomésticos estão no seu regime permanente.

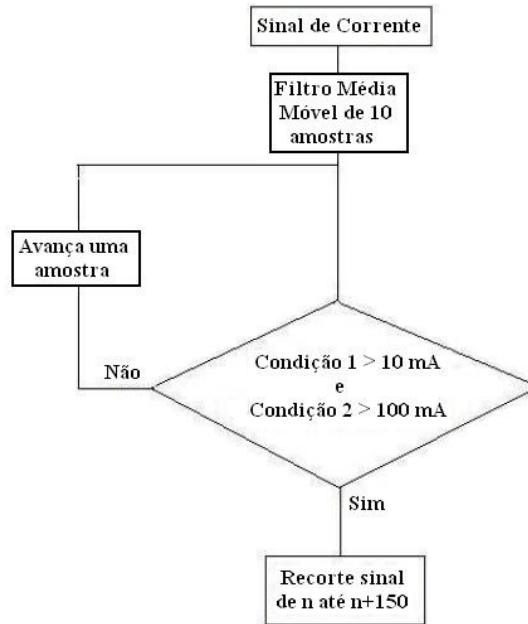


Figura 4.4: Diagrama de fluxo para o detector de patamar simples.

#### 4.1.2 Detector de patamar elaborado

Este detector segue o princípio de funcionamento do detector anterior, mas com critérios mais rigorosos quanto ao recorte do sinal. O limiar para a detecção é o mesmo, foram considerados valores de mudança na corrente de 100 mA, ao ter uma mudança desse tipo, sabemos que existe um transitório naquele trecho do sinal.

Para este recorte, são feitas janelas de 50 amostras no sinal. Esse valor foi escolhido porque para os transitórios analisados no conjunto de desenvolvimento, mais do 95 % desses transitórios alcançam valores de corrente acima de 100 mA. Na Figura 4.5 é mostrado o histograma para as amostras que apresentam o primeiro valor de corrente maior do que 100 mA dos transitórios no conjunto de desenvolvimento.




Figura 4.5: Histograma para as amostras que apresentam o primeiro valor de corrente acima de 100 mA.

Dentro de cada janela faz-se a análise seguinte:

1. Condição 1: Subtração do valor da corrente da última amostra da janela com o valor da corrente da primeira amostra, dada por:

$$c(n) = x(n + 50) - x(n) \quad (4.5)$$

2. Se o valor da condição 1 for maior do que o limiar, temos um possível transitório.
3. Condição 2: Analisamos as subsequentes 150 amostras após a janela, com a expressão:

$$d(n) = x(n + 200) - x(n) \quad (4.6)$$

onde o sinal estará em regime permanente. Isto serve para achar um transitório verdadeiro, e não um pico de sinal com tamanho menor do que um transitório.

4. Se o valor da condição 2 for maior ao limiar temos um transitório.

O passo seguinte ao se achar o transitório, é realizar um recorte de uma janela com tamanho de um transitório, que é de 150 amostras. Esta janela com o transitório do sinal é guardada para que seja classificada no estágio subsequente. Isto é desenvolvido realizando uma outra análise do sinal para achar o momento certo onde começou o transitório.

É importante conhecer o ponto exato onde começa o transitório para que não seja apresentado ao classificador um transitório deslocado temporalmente que pode perder características da classe que ele representa. Além disso, como o classificador é treinado com transitórios recortados manualmente, sem deslocamento, a tarefa de classificação se torna mais complexa no caso de um deslocamento significativo.

Para encontrar o ponto inicial do transitório e recortar o sinal, baseamos a análise considerando que os transitórios dos equipamentos são sinais de corrente crescentes, ou seja, mostram um comportamento de subida em corrente. Foi obtido o histograma (Figura 4.6) que mostra o número de amostra onde os transitórios têm o valor máximo de corrente, e para o conjunto de desenvolvimento é encontrado que o valor máximo do transitório acontece após a amostra 5 para pelo menos 90% dos transitórios.

Com esta informação dos valores máximos, foi desenvolvida uma análise, considerada dentro da janela de 50 amostras, dada por:

$$x(n) < x(n+1) < x(n+2) < x(n+3) < x(n+4) < x(n+5) \quad (4.7)$$

isto é mostrado em uma subida do sinal de 5 amostras sucessivas. Assim, foi marcado o começo do transitório.

Com estes dados temporais que correspondem ao início do transitório, o sinal é recortado do sinal sem filtrar, para se reter toda a informação valiosa para a tarefa de classificação, que é feita sobre o sinal original.

Sabemos que, nesta janela, temos um transitório devido à primeira análise que foi feita e que cumpre com a condição de um aumento de corrente maior a 100 mA, mas algumas vezes a segunda condição acima para o recorte (condição de subida) não é satisfeita. Nesse caso, não devemos desconsiderar que temos um transitório, razão pela qual é feita uma análise adicional. Aqui é realizada uma operação de subtração, e quando é satisfeita a restrição de que a expressão 4.2 seja superior a 10 mA, o sinal é recortado nesse ponto. Se esta última condição não é satisfeita, o sinal é recortado desde o começo da janela de 50 amostras realizada ao princípio da análise.




Figura 4.6: Histograma para as amostras com valor máximo de corrente dos transitórios.

Podemos resumir os passos do detector como:

1. O sinal de corrente é passado através de um filtro média móvel de tamanho 10.
2. Definimos uma janela de 50 amostras do sinal
3. Condição 1: realizamos uma subtração entre o valor de corrente da última amostra com o valor de corrente da primeira amostra, isto é dado pela formula

- 4.5. Se essa diferença é maior do que o limiar definido de 100 mA, dizemos que temos um possível transitório.
4. Condição 2: verificamos se as subseqüentes 150 amostras após da janela, onde o sinal estará em regime permanente, como mostrado na formula 4.6, tem um valor de corrente maior do que 100 mA. Isto serve para achar um transitório verdadeiro, e não um pico de sinal com tamanho menor do que um transitório.
  5. Se a condição de subida dada pela expressão 4.7 é cumprida, é realizado o recorte do transitório.
  6. Se a condição de subida do passo 5 não acontece, procuramos uma condição adicional dada pela fórmula 4.2, onde se o valor de corrente para esta subtração for maior do que 10 mA, é realizado o recorte.
  7. Se as condições 5 ou 6 não ocorrerem, recortamos o sinal a partir do começo da janela de 50 amostras.
  8. Guardamos o transitório recortado.

A Figura 4.7 mostra o diagrama de fluxo para o detector por patamar.

### **4.1.3 Detector por correlação**

Este método é usado para encontrar a parte do regime transitório dos sinais usando correlações com os padrões, a partir de janelas deslizantes de tamanho igual ao número de amostras que temos considerado para os transitórios.

Este tipo de detector se aproxima a um filtro casado determinístico, considerando padrões típicos das classes, retirados do conjunto de desenvolvimento. A amostra de ruído é extraída da parte do sinal onde não há regime transitório. A Figura 4.8 mostra um diagrama do detector por correlação usado para encontrar os transitórios.

No primeiro estágio, trabalhamos sobre o conjunto de desenvolvimento extraíndo os transitórios que são mais representativos para cada uma das classes. O padrão de cada



classe é obtido correlacionando-se todos os eventos de cada classe entre si, escolhendo-se aquele que tem o maior valor de correlação. Uma outra de obter o padrão é calcular a média aritmética para cada classe, aproximando-se ao filtro casado determinístico.

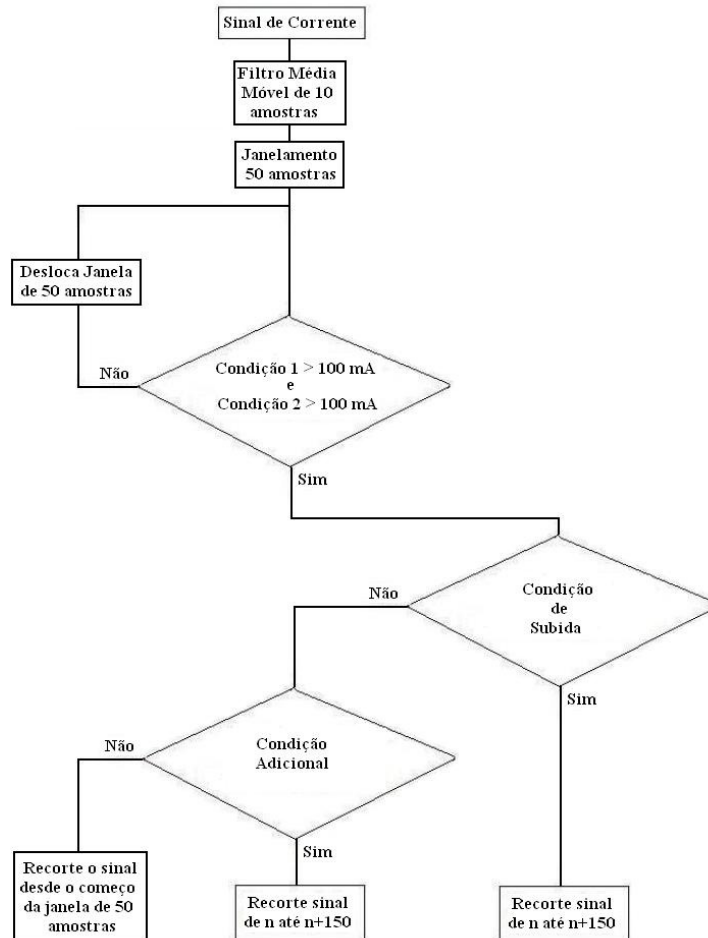


Figura 4.7: Diagrama de fluxo para o detector de patamar.

A correlação é calculada por meio da expressão:

$$\rho = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y} \quad (4.8)$$

Em que  $x$  e  $y$  são vetores de cada uma das classes, a função  $\text{cov}(\cdot)$  é a covariância dos vetores  $x$  e  $y$  e  $\sigma_x$  e  $\sigma_y$  são os desvio padrão para de cada um dos vetores.

Em um segundo estágio, cada sinal é branqueado, para eliminar o efeito de ruído. Para este branqueamento são usadas informações de ruído, extraídas dos trechos do sinal que não contém transitórios. Depois, é realizada uma correlação de cada um destes padrões com uma janela de 150 amostras sobre o sinal a tratar. Esta janela vai se deslocando de amostra a amostra obtendo assim o valor da correlação para cada janela no tempo. Quando o valor da correlação supera um limiar de 0,9, o detector, nos indica que existe uma alta correlação entre a janela tratada e qualquer dos onze padrões armazenados. A partir desse momento é recortado o transitório. As Figuras 4.9 a 4.19 mostram os transitórios padrões para cada uma das classes antes de ser branqueados.

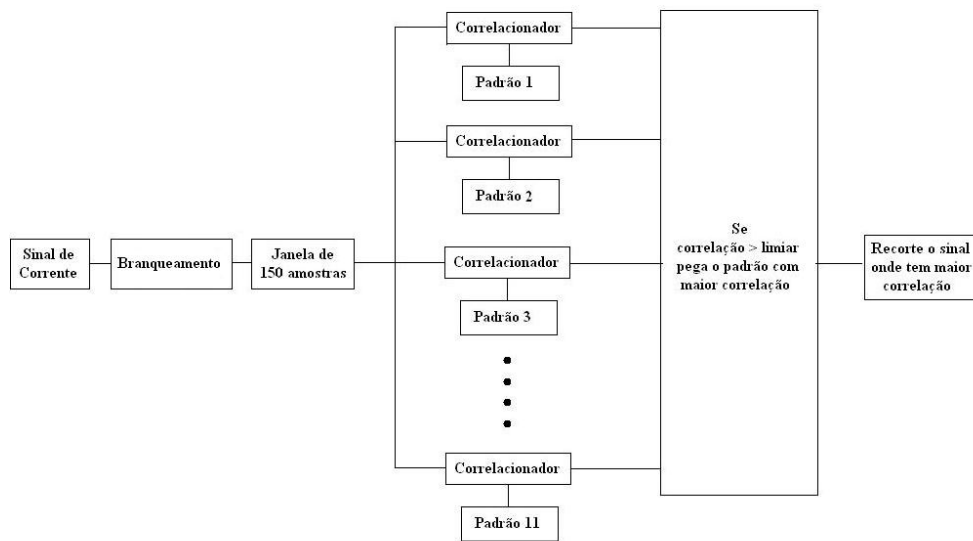


Figura 4.8: Diagrama para o detector por correlação

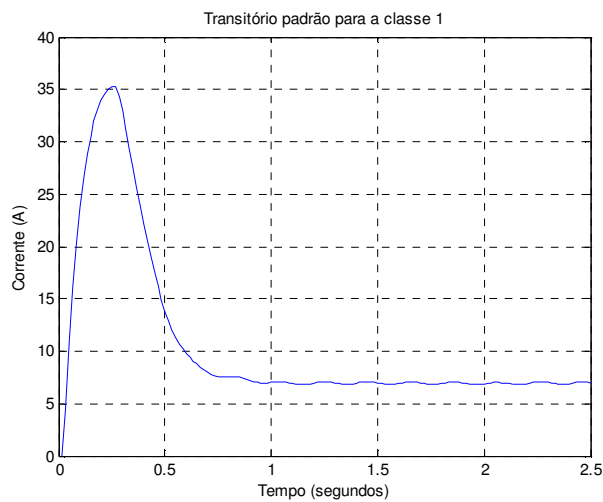


Figura 4.9: Transitório padrão para a classe 1 no detector por correlação




Figura 4.10: Transitório padrão para a classe 2 no detector por correlação




Figura 4.11: Transitório padrão para a classe 3 no detector por correlação

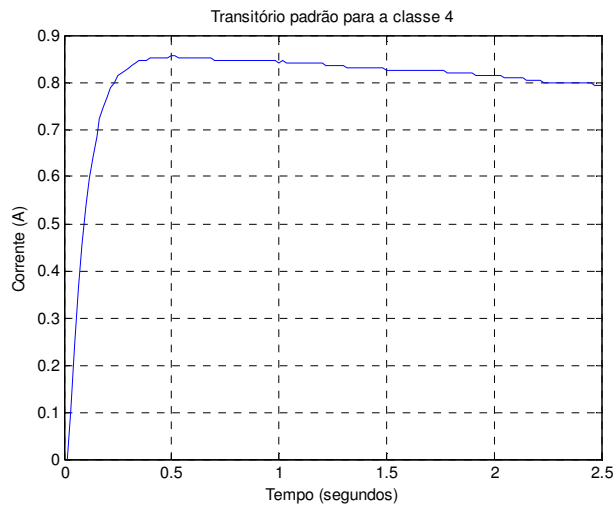


Figura 4.12: Transitório padrão para a classe 4 no detector por correlação

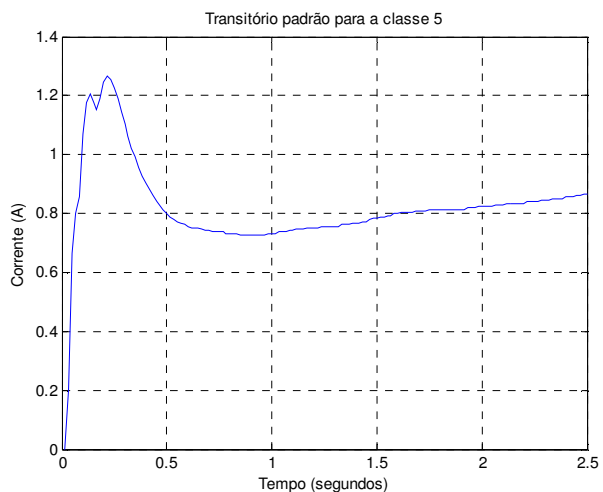


Figura 4.13: Transitório padrão para a classe 5 no detector por correlação




Figura 4.14: Transitório padrão para a classe 6 no detector por correlação




Figura 4.15: Transitório padrão para a classe 7 no detector por correlação




Figura 4.16: Transitório padrão para a classe 8 no detector por correlação




Figura 4.17: Transitório padrão para a classe 9 no detector por correlação




Figura 4.18: Transitório padrão para a classe 10 no detector por correlação




Figura 4.19: Transitório padrão para a classe 11 no detector por correlação

## 4.2 Classificação de transitório

A segunda etapa de processamento do sistema realiza uma classificação automática dos transitórios recortados do sinal original, como foi visto na subseção anterior. Este classificador associa uma classe a cada transitório recortado, considerando-se as onze classes possíveis de acordo com suas características mais relevantes.

Nesta subseção, vamos tratar o tema da classificação e a metodologia usada para realizar este trabalho, sobre resultados obtidos, estes serão apresentados na seção seguinte.

O classificador usado se baseia em redes neurais artificiais pelo seu amplo uso com sucesso neste tipo de tarefas. As redes neurais, se diferenciam de outras técnicas convencionais de reconhecimento de padrões pela potencialidade de mapear o espaço de entrada complexo e não linear em um outro espaço representativo para a classificação e diferenciação dos padrões de entrada.

Com o uso de métodos adequados, pode-se treinar a rede para realizar classificações dos padrões de entrada. Para esse treinamento é apresentado, tanto quanto 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 [64][65][66].

#### **4.2.1 Classificação do transitório por redes neurais**

Da aquisição de dados e da subseção anterior, que detecta os transitórios e os recorta, sabemos que estes transitórios, são formados por 150 amostras retiradas do sinal de corrente.

Utilizamos um conjunto de 1056 transitórios distribuídos em onze classes, descritas já anteriormente. Os transitórios adquiridos de diferentes eletrodomésticos cobrem mais de 95% dos equipamentos usados no setor residencial [1]. Esse conjunto foi construído como explicado no capítulo 3.

A arquitetura escolhida para a rede neural classificadora é um *perceptron* multicamada *feedforward* básico, que é amplamente usado por sua eficiência em problemas de classificação de padrões. Nesta arquitetura utiliza-se apenas uma camada escondida [66], cujo número de neurônios é determinado experimentalmente. O vetor de entradas corresponde às 150 amostras do transitório. A camada de saída possui onze neurônios cada um associado a uma classe [67][68]. A Figura 4.19 mostra a arquitetura de rede neural usada para a classificação.

O conjunto total de dados foi dividido em subconjuntos, deixando 60% dos dados para o treino, 20% para a validação e 20% para o teste. Do conjunto de desenvolvimento utilizado na subseção anterior, que trata da detecção, e o qual é composto por 1056 eventos foi realizada uma subdivisão dos dados para o treinamento da rede neural, dos quais 798 eventos formam o conjunto de treino, e 258 eventos para o conjunto de

validação. Um de 278 eventos foi usado para avaliar o desempenho da rede neural, através do conjunto de teste.




Figura 4.20: Arquitetura da a rede neural classificadora

Para a base de dados, foram feitas 139 aquisições no total, cada uma com diferente número de eventos. Dividiu-se em 78 aquisições para o treino, 29 para validação e 32 para teste, com número equivalente de eventos.

O treinamento utilizado foi o *resilient backpropagation* [69], devido a seu melhor desempenho frente a outros algoritmos da mesma complexidade. Como o treinamento foi realizado por batelada, em cada iteração é apresentado todo o conjunto de exemplos para que a rede faça a atualização dos seus pesos. O conjunto de validação faz com que a rede neural consiga generalização, apresentando eventos que não estão considerados no conjunto de treino.



O critério de parada para o processo de treinamento da rede neural foi realizado com base no número de iterações de treino ou por parada prematura, na qual, o treinamento é interrompido quando o erro nos eventos do conjunto de validação começa a crescer, mostrando que a rede está sendo sobre treinada para os dados de treino e não está obtendo generalização frente a novas entradas.

A eficiência da rede neural é medida sobre o conjunto de teste. Para isto, foi usado um conjunto de 278 eventos de transitórios recortados manualmente da divisão dos dados por aquisição. Fazendo uma divisão dos dados a partir do número de eventos, o conjunto de teste tem 268 eventos. Para a determinação da classe vencedora, foi considerado o neurônio de saída mais ativo, no nosso caso foi aplicada uma função *sign* sobre as saídas da rede neural, definindo como maior do que zero a classe ganhadora. Foi necessário definir também uma não-classe, a qual está dada, quando dois o mais neurônios são maiores do que zero, fazendo com que mais de duas saídas estivessem ativas, para o qual, a classificação não determina nenhuma das classes.

Para treinar o classificador neural, podemos resumir os parâmetros em:

- |  |                                  |
|--|----------------------------------|
| 1. Número de camadas da rede neural:                     | 2                                |
| 2. Numero de entradas                                    | 150                              |
| 3. Numero de neurônios na camada escondida               | 20 - 25                          |
| 4. Numero de neurônios na camada de saída                | 11                               |
| 5. Taxa de aprendizado                                   | 0.9                              |
| 6. Algoritmo para o treinamento                          | <i>resilient backpropagation</i> |
| 7. Valor inicial dos pesos                               | aleatório                        |
| 8. Épocas de treinamento                                 | máximo 5000                      |
| 9. Função de ativação                                    | tangente hiperbólico             |
| 10. Número de passos máximo para o conjunto de validação | 300                              |

O seguinte capítulo mostra em detalhe os resultados para esta classificação da detecção manual. Também, é considerada a classificação da detecção automática a partir das técnicas desenvolvidas na seção anterior. Para esta classificação foram utilizadas as redes neurais treinadas anteriormente, e foram usadas como entradas os transitórios recortados automaticamente dos sinais adquiridos. Neste caso, o critério para a classe, foi atribuído o neurônio ganhador aquele que tem o valor máximo, depois de se encontrar que a taxa de transitórios determinados como de não-classe aumenta.

## Capítulo 5

### Resultados

Esta seção tem como objetivo mostrar os resultados obtidos pelas técnicas descritas no capítulo anterior, onde foram tratados o detector e o classificador do sistema. Em uma primeira parte, serão apresentados os resultados para os três tipos de detectores desenvolvidos. Em seguida, serão apresentados os resultados para o classificador dos transitórios detectados. Ao final são expostas análises gerais juntando os resultados da detecção e da classificação.

Para apresentação dos resultados, é necessário descrever como foi desenvolvida a divisão dos dados. Foram construídos três subconjuntos: treino, validação e teste, cada um com uma proporção de 60 %, 20 % e 20 % aproximadamente.

Uma primeira divisão, chamada de divisão por aquisição, foi feita partindo do número total de aquisições de cada classe. Dependendo do número de eventos de cada aquisição, foram conformados os subconjuntos. A Tabela 5.1 mostra a divisão dos dados feita a partir das aquisições. A motivação para fazer este tipo de divisão, está dada porque possui características similares com as aquisições reais feitas em residências, onde o sistema realiza a detecção e classificação sobre os sinais obtidos do dispositivo de aquisição.

A outra divisão dos dados foi realizada tomando o número total de transitórios a estudar (Tabela 5.2), sem ter em conta as aquisições às quais cada um deles pertence, e dividi-los aleatoriamente, para realizar os subconjuntos de treino, validação e teste.

O presente capítulo, apresenta os resultados diferenciando entre as duas divisões de dados. Primeiro são apresentados os resultados para o detector, onde os resultados dos diferentes tipos de detecção automática descritos no capítulo anterior, são comparados com uma detecção de tipo manual. Depois são apresentados os resultados para a classificação dessa detecção manual, com as que foram treinadas as redes neurais,

seguido pela classificação dos transitórios encontrados pelos detectores de forma automática. Por último, é apresentada a eficiência da classificação, dada pela potência que é possível classificar, a partir da potência consumida originalmente nos sinais.

Tabela 5.1: Divisão dos dados de acordo às aquisições

Classe	Treino		Validação		Teste		TOTAL
	Aquisições	Eventos	Aquisições	Eventos	Aquisições	Eventos	
<b>C_01</b>	6	53	1	16	3	17	<b>86</b>
<b>C_02</b>	15	108	3	36	3	36	<b>180</b>
<b>C_03</b>	5	127	2	42	4	43	<b>212</b>
<b>C_04</b>	6	112	1	36	2	38	<b>186</b>
<b>C_05</b>	10	67	5	22	4	22	<b>111</b>
<b>C_06</b>	8	62	4	19	3	20	<b>101</b>
<b>C_07</b>	15	116	7	38	4	38	<b>192</b>
<b>C_08</b>	3	36	2	12	2	12	<b>60</b>
<b>C_09</b>	2	21	1	6	3	8	<b>35</b>
<b>C_10</b>	5	53	2	18	2	20	<b>91</b>
<b>C_11</b>	3	33	1	13	2	24	<b>70</b>
<b>TOTAL</b>	<b>78</b>	<b>788</b>	<b>29</b>	<b>258</b>	<b>32</b>	<b>278</b>	<b>1324</b>
<b>% DIVISÃO</b>		<b>60</b>		<b>19</b>		<b>21</b>	<b>100</b>

Tabela 5.2: Divisão dos dados de acordo ao número de eventos

Classe	Treino	Validação	Teste	TOTAL
<b>C_01</b>	52	17	17	<b>86</b>
<b>C_02</b>	108	36	36	<b>180</b>
<b>C_03</b>	128	42	42	<b>212</b>
<b>C_04</b>	112	37	37	<b>186</b>
<b>C_05</b>	67	22	22	<b>111</b>
<b>C_06</b>	61	20	20	<b>101</b>
<b>C_07</b>	116	38	38	<b>192</b>
<b>C_08</b>	36	12	12	<b>60</b>
<b>C_09</b>	21	7	7	<b>35</b>
<b>C_10</b>	55	18	18	<b>91</b>
<b>C_11</b>	42	14	14	<b>70</b>
<b>TOTAL</b>	<b>798</b>	<b>263</b>	<b>263</b>	<b>1324</b>
<b>(%) DIVISÃO</b>	<b>60</b>	<b>20</b>	<b>20</b>	<b>100</b>

## 5.1 Resultados para o detector

Para poder comparar os resultados dos detectores, foram recortados manualmente os transitórios correspondentes a cada uma das classes. Algumas aquisições têm eventos com características similares aos transitórios, mas que não foram considerados como tais. Exemplos disso estão dados por eventos que não têm o número de amostras (150) requerido para os transitórios certificados, ou porque estão com algum tipo de erro sistemático na aquisição. Estes eventos são referenciados, pois podem ser também encontrados pelos detectores automáticos desenvolvidos, o que não necessariamente é considerado um erro, uma vez que estes sinais cumprem com a maioria de características que um transitório pode ter. A Figura 5.1 mostra um exemplo deste tipo de transitório, onde o equipamento foi desligado antes de cumprir as 150 amostras.




Figura 5.1: Exemplo de um transitório falso

Do capítulo anterior, é visto que foram desenvolvidas três técnicas para o detector automático. Para cada uma delas é medido o número de eventos detectados em relação ao número total de eventos que foram extraídos na detecção manual, obtendo um desempenho em cada técnica, para o detector por correlação, foram desenvolvidas duas análises: uma com padrões obtidos da correlação intra-classe e outra com padrões calculados da média aritmética de cada classe. A detecção manual é considerada como

ótima e por tanto de referência, desde o ponto de vista em que cada um dos sinais originais foi observado amostra por amostra, encontrando os acionamentos com ajuda de informações da aquisição.

As Tabelas 5.3, 5.4 e 5.5, mostram os resultados para os três detectores automáticos baseados no resultado do detector manual, da divisão dos dados por evento. Para esta divisão de dados, não foi apresentado o número de transitórios falsos, já que os transitórios recortados correspondem a diferentes aquisições de sinal.

Tabela 5.3: Resultados para os detectores no subconjunto de treino dado pela divisão dos dados por evento.

<b>TREINO</b>	<b>MANUAL</b>	<b>PATAMAR SIMPLES</b>	<b>PATAMAR ELABORADO</b>	<b>CORRELAÇÃO (Correlação)</b>	<b>CORRELAÇÃO (Média)</b>
<b>CLASSES</b>	<b>Eventos</b>	<b>Detectados</b>	<b>Detectados</b>	<b>Detectados</b>	<b>Detectados</b>
<b>C_01</b>	52	49	50	45	44
<b>C_02</b>	108	101	106	100	107
<b>C_03</b>	128	109	104	111	120
<b>C_04</b>	112	90	87	98	100
<b>C_05</b>	67	42	46	27	35
<b>C_06</b>	61	54	54	58	58
<b>C_07</b>	116	111	111	67	104
<b>C_08</b>	36	31	36	3	2
<b>C_09</b>	21	18	17	4	0
<b>C_10</b>	55	20	53	20	13
<b>C_11</b>	42	0	34	30	33
<b>TOTAL</b>	<b>798</b>	<b>625</b>	<b>698</b>	<b>563</b>	<b>616</b>
<b>(%) EFICIÊNCIA</b>	<b>100</b>	<b>78</b>	<b>87</b>	<b>71</b>	<b>77</b>

Pode ser visto que para este caso o melhor desempenho está dado pelo detector por patamar elaborado, que tem uma taxa de acerto para os eventos de 90 %. O segundo melhor desempenho é para o detector de patamar simples com 83 % de eventos detectados, e finalmente o detector de menor desempenho é o desenvolvido pela técnica de correlação. Também pode ser visto que nesta última técnica, que ao utilizar os padrões calculados da média aritmética melhora a detecção dos transitórios, mas na classe 9 não foi possível detectar acionamentos.

Como pode ser visto, o detector de patamar simples não detecta transitórios da classe onze, isto é explicado pela forma do transitório para esta classe (Figura 3.11), onde o

sinal de corrente no começo do transitório, apresenta uma variação menor do que o limiar 10 mA estabelecido para este detector, o que faz difícil sua detecção. O detector por correlação tem um baixo desempenho notável na classe oito e a classe nove para ambas as duas técnicas para o cálculo dos padrões.

Tabela 5.4: Resultados para os detectores no subconjunto de validação dado pela divisão dos dados por evento.

<b>VALIDAÇÃO</b>	<b>MANUAL</b>	<b>PATAMAR SIMPLES</b>	<b>PATAMAR ELABORADO</b>	<b>CORRELAÇÃO (Correlação)</b>	<b>CORRELAÇÃO (Média)</b>
<b>CLASSES</b>	<b>Eventos</b>	<b>Detectados</b>	<b>Detectados</b>	<b>Detectados</b>	<b>Detectados</b>
<b>C_01</b>	17	16	17	13	13
<b>C_02</b>	36	35	35	32	36
<b>C_03</b>	42	36	37	36	42
<b>C_04</b>	37	32	31	31	32
<b>C_05</b>	22	12	13	7	9
<b>C_06</b>	20	19	18	19	19
<b>C_07</b>	38	36	37	18	34
<b>C_08</b>	12	9	11	0	0
<b>C_09</b>	7	7	6	2	0
<b>C_10</b>	18	6	18	9	3
<b>C_11</b>	14	0	11	10	13
<b>TOTAL</b>	<b>263</b>	<b>208</b>	<b>234</b>	<b>177</b>	<b>201</b>
<b>(%) EFICIÊNCIA</b>	<b>100</b>	<b>79</b>	<b>90</b>	<b>67</b>	<b>76</b>

Tabela 5.5: Resultados para os detectores no subconjunto de teste dado pela divisão dos dados por evento.

<b>TESTE</b>	<b>MANUAL</b>	<b>PATAMAR SIMPLES</b>	<b>PATAMAR ELABORADO</b>	<b>CORRELAÇÃO (Correlação)</b>	<b>CORRELAÇÃO (Média)</b>
<b>CLASSES</b>	<b>Eventos</b>	<b>Detectados</b>	<b>Detectados</b>	<b>Detectados</b>	<b>Detectados</b>
<b>C_01</b>	17	15	17	14	14
<b>C_02</b>	36	33	36	35	36
<b>C_03</b>	42	38	35	39	41
<b>C_04</b>	37	33	30	30	31
<b>C_05</b>	22	20	21	10	9
<b>C_06</b>	20	17	16	17	17
<b>C_07</b>	38	37	35	23	31
<b>C_08</b>	12	10	11	1	1
<b>C_09</b>	7	7	6	4	0
<b>C_10</b>	18	8	18	10	9
<b>C_11</b>	14	0	13	9	7
<b>TOTAL</b>	<b>263</b>	<b>218</b>	<b>238</b>	<b>192</b>	<b>196</b>
<b>(%) EFICIÊNCIA</b>	<b>100</b>	<b>83</b>	<b>91</b>	<b>73</b>	<b>75</b>

Nas Tabelas 5.6, 5.7 e 5.8, se encontram os resultados para o desempenho baseado na detecção manual, considerando-se o resultado do treinamento sobre aquisição. A coluna de “Falsos” têm os transitórios descritos anteriormente, que têm características similares aos transitórios considerados, mas que não são usados para a classificação.

Nota-se que, dos três detectores projetados, o de melhor resultado é o detector de patamar elaborado, o qual tem a melhor taxa de acerto, ou seja, encontra o maior número de transitórios certificados, e também obtém o menor número de transitórios falsos. O segundo melhor desempenho se obtém para o detector de patamar simples, que tem o procedimento mais simples das três técnicas. Também, para este detector, a classe 11 não teve transitórios detectados, fazendo com que seu desempenho seja reduzido.

Tabela 5.6: Resultados para os detectores no subconjunto de treino dado pela divisão dos dados por aquisição.

TREINO	MANUAL		PATAMAR SIMPLES		PATAMAR ELABORADO		CORRELAÇÃO			
	Eventos	Falsos	Detec.	Falsos	Detec.	Falsos	Correlação		Média	
Classes							Detec.	Falsos	Detec.	Falsos
C_01	53	40	50	34	52	35	45	93	44	107
C_02	108	22	104	26	105	26	103	95	108	94
C_03	127	11	105	17	103	18	124	61	127	70
C_04	112	2	88	12	84	14	90	78	91	89
C_05	67	6	46	6	52	8	25	134	31	147
C_06	62	7	60	7	59	7	61	28	61	14
C_07	116	2	112	1	109	4	70	79	103	37
C_08	36	0	33	5	35	7	2	57	0	61
C_09	21	6	19	223	19	186	7	271	0	28
C_10	53	4	27	25	52	2	19	96	13	146
C_11	33	2	0	22	27	5	23	25	18	31
<b>TOTAL</b>	<b>788</b>	<b>102</b>	<b>644</b>	<b>378</b>	<b>697</b>	<b>312</b>	<b>569</b>	<b>1017</b>	<b>596</b>	<b>824</b>
(%) EFIC.	<b>100</b>		<b>82</b>		<b>89</b>		<b>72</b>		<b>75</b>	

Pode-se ver, que o melhor resultado nos casos de treino, validação e teste, é o detector do patamar elaborado, que, para o subconjunto de teste, apresenta um desempenho de 88 % de acerto no número de eventos corretamente detectados. O detector de pior desempenho é o detector por correlação que apresenta uma taxa de 67 % de acerto. Quanto ao número de falsos transitórios, o de melhor resultado é o detector de patamar simples. Esta última característica, pode ser determinante na hora de escolher um dos detectores, isto porque o sistema detectaria um número considerável de eventos que não



são transitórios certificados, levando à complicar a classificação que vem seguida da detecção. Estes transitórios falsos são estudados a seguir.

Tabela 5.7: Resultados para os detectores no subconjunto de validação dado pela divisão dos dados por aquisição.

VALIDAÇÃO	MANUAL		PATAMAR SIMPLES		PATAMAR ELABORADO		CORRELAÇÃO			
	Eventos	Falsos	Detec.	Falsos	Detec.	Falsos	Correlação		Média	
Classes							Detec.	Falsos	Detec.	Falsos
<b>C_01</b>	16	0	16	0	16	0	16	0	16	1
<b>C_02</b>	36	0	31	3	36	0	32	14	36	11
<b>C_03</b>	42	57	40	6	39	8	33	63	31	79
<b>C_04</b>	36	0	36	0	34	2	32	12	36	12
<b>C_05</b>	22	8	11	10	12	18	13	85	17	90
<b>C_06</b>	19	0	15	0	15	0	17	11	17	5
<b>C_07</b>	38	0	35	3	36	2	16	34	29	19
<b>C_08</b>	12	0	5	7	10	2	0	17	0	16
<b>C_09</b>	6	1	6	5	3	8	0	6	0	7
<b>C_10</b>	18	2	0	18	18	0	11	35	6	70
<b>C_11</b>	13	1	0	12	8	5	12	6	13	6
<b>TOTAL</b>	<b>258</b>	<b>69</b>	<b>195</b>	<b>64</b>	<b>227</b>	<b>45</b>	<b>185</b>	<b>283</b>	<b>201</b>	<b>316</b>
<b>(%) EFIC.</b>	<b>100</b>		<b>76</b>		<b>88</b>		<b>71</b>		<b>78</b>	

Tabela 5.8: Resultados para os detectores no subconjunto de teste dado pela divisão dos dados por aquisição

TESTE	MANUAL		PATAMAR SIMPLES		PATAMAR ELABORADO		CORRELAÇÃO			
	Eventos	Falsos	Detec.	Falsos	Detec.	Falsos	Correlação		Média	
Classes							Detec.	Falsos	Detec.	Falsos
<b>C_01</b>	17	61	14	45	16	49	11	98	11	100
<b>C_02</b>	36	0	34	1	36	0	34	13	36	12
<b>C_03</b>	43	85	38	48	34	62	33	121	40	108
<b>C_04</b>	38	15	31	15	30	15	35	32	35	33
<b>C_05</b>	22	29	17	40	16	70	8	107	8	104
<b>C_06</b>	20	0	14	0	13	1	15	13	15	10
<b>C_07</b>	38	5	37	1	38	0	22	35	36	12
<b>C_08</b>	12	0	11	1	12	0	0	17	1	18
<b>C_09</b>	8	39	7	275	7	314	3	242	0	82
<b>C_10</b>	20	2	6	13	19	1	9	33	4	53
<b>C_11</b>	24	3	0	14	23	2	17	18	11	21
<b>TOTAL</b>	<b>278</b>	<b>239</b>	<b>209</b>	<b>453</b>	<b>244</b>	<b>514</b>	<b>187</b>	<b>729</b>	<b>197</b>	<b>553</b>
<b>(%) EFIC.</b>	<b>100</b>		<b>75</b>		<b>88</b>		<b>67</b>		<b>71</b>	

Como é possível ver nos resultados anteriores no detector desenvolvido pela técnica de correlação, o de melhor desempenho está dado quando os padrões são obtidos com o cálculo da média aritmética, razão pela qual os resultados mostrados no restante deste documento, e para este tipo de detector, são referenciados aos padrões obtidos por esta técnica.

As Tabelas 5.9, 5.10 e 5.11, mostram em detalhe, os falsos transitórios achados nos três detectores automáticos. Cada detector, tem o número de falsos transitórios, o número de transitórios que foram encontrados pelo detector e que foram achados na detecção manual, e também a porcentagem destes últimos no conjunto total de falsos transitórios. Pode-se ver que estas porcentagens são baixas, mostrando que os falsos transitórios achados pelos detectores não correspondem, na sua maioria, aos transitórios não certificados do detector manual. Para os dois detectores de patamar, é observado o mesmo comportamento frente aos transitórios não certificados, dado pela reduzida diferença nos resultados. Isto último é explicado pela similaridade do algoritmo, onde o segundo detector, que é mais elaborado, procura um recorte mais exato dos transitórios, mas baseado no detector simples.

Tabela 5.9: Resultados do subconjunto de treino para os falsos transitórios detectados

TREINO	MANUAL	PATAMAR SIMPLES		PATAMAR ELABORADO		CORRELAÇÃO	
	Falsos Manual	Falsos Detectados	Manual	Falsos Detectados	Manual	Falsos Detectados	Manual
C_01	40	34	28	35	29	107	13
C_02	22	26	22	26	21	94	14
C_03	11	17	4	18	3	70	7
C_04	2	12	1	14	1	89	0
C_05	6	6	0	8	0	147	5
C_06	7	7	5	7	5	14	3
C_07	2	1	1	4	1	37	2
C_08	0	5	0	7	0	61	0
C_09	6	223	4	186	5	28	3
C_10	4	25	1	2	1	146	4
C_11	2	22	0	5	0	31	1
<b>TOTAL</b>	<b>102</b>	<b>378</b>	<b>66</b>	<b>312</b>	<b>66</b>	<b>824</b>	<b>52</b>
<b>% Falsos Manual</b>			<b>17</b>		<b>21</b>		<b>6</b>

Tabela 5.10: Resultados do subconjunto de validação para os falsos transitórios detectados

VALIDAÇÃO	MANUAL	PATAMAR SIMPLES		PATAMAR ELABORADO		CORRELAÇÃO	
		Falsos Manual	Falsos Detectados	Manual	Falsos Detectados	Manual	Falsos Detectados
C_01	0	0	0	0	0	1	0
C_02	0	3	0	0	0	11	0
C_03	57	6	5	8	3	79	8
C_04	0	0	0	2	0	12	0
C_05	8	10	0	18	0	90	8
C_06	0	0	0	0	0	5	0
C_07	0	3	0	2	0	19	0
C_08	0	7	0	2	0	16	0
C_09	1	5	0	8	0	7	1
C_10	2	18	0	0	0	70	1
C_11	1	12	0	5	0	6	0
<b>TOTAL</b>	<b>69</b>	<b>64</b>	<b>5</b>	<b>45</b>	<b>3</b>	<b>316</b>	<b>18</b>
% Falsos Manual			<b>8</b>		<b>7</b>		<b>6</b>

Tabela 5.11: Resultados do subconjunto de teste para os falsos transitórios detectados

TESTE	MANUAL	PATAMAR 1		PATAMAR 2		CORRELAÇÃO	
		Falsos Manual	Falsos Detectados	Manual	Falsos Detectados	Manual	Falsos Detectados
C_01	61	45	42	49	46	100	46
C_02	0	1	0	0	0	12	0
C_03	85	48	45	62	41	108	19
C_04	15	15	13	15	13	33	15
C_05	29	40	2	70	1	104	2
C_06	0	0	0	1	0	10	0
C_07	5	1	0	0	0	12	0
C_08	0	1	0	0	0	18	0
C_09	39	275	28	314	30	82	30
C_10	2	13	0	1	0	53	2
C_11	3	14	0	2	1	21	2
<b>TOTAL</b>	<b>239</b>	<b>453</b>	<b>130</b>	<b>514</b>	<b>132</b>	<b>553</b>	<b>116</b>
% Falsos Manual			<b>29</b>		<b>26</b>		<b>21</b>

Nota-se também, que a classe que apresenta maior número de falsos transitórios é a classe 9, que corresponde à máquina de lavar, isto é dado pela forma de onda de corrente quando equipamentos desta classe estão em funcionamento. No seu ciclo de

lavagem, é feita uma inversão de giro do motor que faz parte da máquina de lavar, que produz um sinal oscilatório de corrente no dispositivo de aquisição. Isto causa um aumento dos falsos transitórios detectados nessa classe transitórios.

O número alto de transitórios falsos, encontrados pelo detector por correlação, é produzido porque cada janela é correlacionada com os onze padrões existentes. Assim, uma janela que não possui um transitório certificado, pode ter uma correlação alta com um padrão diferente a esta classe, fazendo que o detector recorte um transitório onde a detecção manual desconsiderou a existência de um acionamento. Maior desenvolvimento sobre este tipo de detector deve ser feito para considerar se na janela há um transitório certificado. Como o alvo do detector é encontrar o transitório, não foram realizados maiores desenvolvimentos, isto porque a maioria destas técnicas, como filtros casados, fazem ao mesmo tempo uma classificação. Para a presente aplicação, esta tarefa é realizada em uma outra parte do sistema.

Uma proposta a implementar, é a combinação de dois ou mais tipos de detectores. Para isso, são mostradas as Figuras 5.2, 5.3 e 5.4, que mostram os eventos do detector manual contra os eventos detectados por cada uma das técnicas. Os pontos sobre a reta inclinada, mostram os eventos que foram detectados. Os outros pontos sobre a reta horizontal são os eventos que o detector não conseguiu encontrar, e as retas verticais e horizontais encerram cada uma das classes. É fácil ver que alguns eventos foram detectados por uma técnica de detecção, mas por outra não foi possível detectá-los. Fazendo uma análise sobre o detector de patamar elaborado, que tem o melhor desempenho, pode-se melhorar sua eficiência. Para isso, é possível juntar esta técnica com a do detector de patamar simples. Isto funciona no caso da classe 2, onde os primeiros eventos são detectados pelo detector simples, enquanto o detector de patamar elaborado não consegue. Assim, é melhorada a eficiência do sistema neste caso.

Para a classe 4, podem ser juntadas as técnicas das detecções de patamar elaborado e a do patamar por correlação, onde é possível observar que os primeiros eventos não são detectados pelo detector de patamar elaborado, enquanto o detector por correlação encontra estes transitórios.




Figura 5.2: Gráfico dos eventos detectados pelo detector de patamar simples vs. eventos da detecção manual




Figura 5.3: Gráfico dos eventos detectados pelo detector de patamar elaborado vs. eventos da detecção manual




Figura 5.4: Gráfico dos eventos detectados pelo detector de patamar por correlação vs. eventos da detecção manual

## 5.2 Classificação com recorte manual

Para a classificação, como foi explicado no capítulo anterior, foi desenvolvida uma rede neural multicamada do tipo *feedforward*, que foi treinada com os eventos do subconjunto de treino. Para obter boa generalização, um subconjunto de validação foi utilizado para a parada prematura, de tal modo que a etapa de treinamento fosse encerrada quando o erro de validação começa a aumentar. O subconjunto de teste foi usado para avaliar o desempenho da rede, pois contém eventos que não foram usados no procedimento do treino.

Duas redes neurais foram treinadas, uma para cada divisão dos dados. Primeiro são mostrados os resultados para o treinamento feito sobre a base de dados dividida pelo número de eventos. Depois são mostrados os resultados para a rede treinada com os eventos da divisão de dados por aquisição.

Para os dados obtidos pela divisão por eventos, redes neurais foram treinadas com 5, 10, 15, 20, 25 e 30 neurônios na camada escondida, com algoritmo *resilient backpropagation*, e os parâmetros expostos no capítulo anterior. A Figura 5.5 mostra a curva do erro quadrático médio dos subconjuntos de treino e validação durante o treinamento. A melhor taxa de acerto foi encontrada com uma rede de 25 neurônios na camada escondida. A Tabela 5.12 mostra as contingências desta rede para o subconjunto de teste. As Tabelas 5.13, 5.14 e 5.15, mostram os resultados da classificação para os subconjuntos de treino, validação e teste. A coluna de acertos tem o número de transitórios classificados corretamente pela rede neural. Como descrito no capítulo anterior, foram definidas saídas de não classe, o que significa que a rede não consegue determinar uma classe dentre as onze existentes. A coluna de erros mostra os eventos que a rede classificou de forma errada.




Figura 5.5: Curva do erro quadrático médio durante o treinamento da rede 150 x 25 x 11 para os subconjuntos da divisão por eventos

É possível ver, que para a classe 5, a rede apresenta uma baixa taxa acerto, isto se dá pela diferença nas formas de onda dos seus transitórios. Como esta classe encerra

dispositivos eletrônicos, é difícil achar o padrão característico para desenvolver uma boa classificação. Embora a taxa de acerto pequena para esta classe, a taxa de erro não aumentou, determinando uma grande parcela como dados de não-classe, e não como erros da rede. As classes 6 e 7 também apresentam taxas de acerto reduzidas, devido à sua similaridade entre os seus padrões. Ainda assim, foi conseguida uma taxa de acerto maior do que 70 % para cada uma delas.

Tabela 5.12: Tabela de contingências para as saídas da rede com o subconjunto de teste da divisão por eventos

CLASSE	C_01	C_02	C_03	C_04	C_05	C_06	C_07	C_08	C_09	C_10	C_11	Não Classe
C_01	16	0	0	0	0	0	0	0	0	0	0	1
C_02	0	34	0	2	0	0	0	0	0	0	0	0
C_03	0	0	42	0	0	0	0	0	0	0	0	0
C_04	0	0	0	36	0	0	0	0	0	0	0	1
C_05	0	0	2	0	7	0	1	0	0	0	0	12
C_06	0	0	0	0	0	15	2	0	0	0	0	3
C_07	0	0	0	1	0	1	27	0	0	0	0	9
C_08	0	0	0	0	0	0	0	11	0	1	0	0
C_09	0	0	1	0	0	0	0	0	6	0	0	0
C_10	0	0	0	0	0	0	0	0	0	16	0	2
C_11	0	0	0	0	0	0	0	0	0	0	14	0

Tabela 5.13: Resultados para a classificação no subconjunto de treino dado pela divisão dos dados por evento.

TREINO		MANUAL		
CLASSES	Eventos	Acertos	Não Classe	Erros
C_01	52	51	1	0
C_02	108	101	4	3
C_03	128	126	2	0
C_04	112	110	2	0
C_05	67	40	24	3
C_06	61	50	7	4
C_07	116	85	20	11
C_08	36	36	0	0
C_09	21	21	0	0
C_10	55	48	7	0
C_11	42	42	0	0
<b>TOTAL</b>	<b>798</b>	<b>710</b>	<b>67</b>	<b>21</b>
(%) <b>DESEM.</b>	<b>100</b>	<b>89</b>	<b>8</b>	<b>2</b>



Tabela 5.14: Resultados para a classificação no subconjunto de validação dado pela divisão dos dados por evento.

VALIDAÇÃO		MANUAL		
CLASSES	Eventos	Acertos	Não Classe	Erros
C_01	17	15	2	0
C_02	36	34	1	1
C_03	42	41	1	0
C_04	37	35	2	0
C_05	22	11	7	4
C_06	20	16	4	0
C_07	38	32	5	1
C_08	12	11	0	1
C_09	7	6	0	1
C_10	18	15	2	1
C_11	14	14	0	0
<b>TOTAL</b>	<b>263</b>	<b>230</b>	<b>24</b>	<b>9</b>
(%) <b>DESEM.</b>	<b>100</b>	<b>88</b>	<b>9</b>	<b>3</b>

Tabela 5.15: Resultados para a classificação no subconjunto de teste dado pela divisão dos dados por evento.

TESTE		MANUAL		
CLASSES	Eventos	Acertos	Não Classe	Erros
C_01	17	16	1	0
C_02	36	34	0	2
C_03	42	42	0	0
C_04	37	36	1	0
C_05	22	7	12	3
C_06	20	15	3	2
C_07	38	27	9	2
C_08	12	11	0	1
C_09	7	6	0	1
C_10	18	16	2	0
C_11	14	14	0	0
<b>TOTAL</b>	<b>263</b>	<b>224</b>	<b>28</b>	<b>11</b>
(%) <b>DESEM.</b>	<b>100</b>	<b>85</b>	<b>11</b>	<b>4</b>

Para os subconjuntos obtidos pela divisão por aquisição, foi treinada uma rede neural com o algoritmo de treinamento *resilient backpropagation*, e com número máximo de iterações de 3000. Para esta divisão dos dados, o melhor desempenho da rede foi obtido com 20 neurônios na camada escondida. A Figura 5.6 mostra a curva do erro médio

quadrático dos subconjuntos de treino e validação durante o treinamento da rede, e a Tabela 5.16 mostra as contingências para o subconjunto de teste. Neste caso, o número de transitórios considerados nestes subconjuntos é diferente da divisão dos dados por aquisição para a divisão por eventos, pela razão que foi explicada no começo do capítulo.

As Tabelas 5.17, 5.18 e 5.19 mostram os resultados da rede para os subconjuntos de treino, validação e teste. A taxa de acerto é mantida acima do 72 % para os três casos. As classes com pior desempenho são a 5, 6 e 8, com taxas de acerto embaixo dos 50 %. Como foi explicado no caso anterior, a classe 5 é a que maior dissimilaridade tem entre os padrões da sua mesma classe, o qual faz difícil obter taxas com resultados altos, ainda assim, o erro é baixo, encaixando os seus eventos em não-classe. No caso da classe 6, têm-se padrões parecidos à classe 7, que pode ser observado na tabela de contingências (Tabela 5.16), onde o 45 % dos seus eventos são classificados como de classe 7, também o número de eventos determinados como de não-classe, contém uma parcela grande dos eventos com um 35 %. Para a classe 8, acontece a mesma situação, onde 50 % dos seus eventos são classificados como de classe 10, pela sua similaridade entre os padrões.




Figura 5.6: Curva do erro quadrático médio durante o treinamento da rede 150 x 20 x 11 para a divisão dos dados por aquisição

Tabela 5.16: Tabela de contingências para as saídas da rede com o subconjunto de teste da divisão por aquisição

CLASSE	C_01	C_02	C_03	C_04	C_05	C_06	C_07	C_08	C_09	C_10	C_11	Não Classe
C_01	12	0	5	0	0	0	0	0	0	0	0	0
C_02	0	36	0	0	0	0	0	0	0	0	0	0
C_03	0	1	42	0	0	0	0	0	0	0	0	0
C_04	0	0	0	36	0	0	0	0	0	0	0	2
C_05	0	0	1	1	4	0	1	0	0	0	0	15
C_06	0	0	0	0	1	3	9	0	0	0	0	7
C_07	0	0	0	3	0	0	27	0	0	0	0	8
C_08	0	0	0	0	0	0	0	2	0	6	0	4
C_09	0	0	0	0	0	0	0	0	7	0	0	1
C_10	0	0	0	4	0	0	0	0	0	11	0	5
C_11	0	0	0	0	0	0	0	0	0	0	24	0

Tabela 5.17: Resultados para a classificação no subconjunto de treino dado pela divisão dos dados por aquisição.

TREINO		MANUAL		
CLASSES	Eventos	Acertos	Não Classe	Erros
C_01	53	50	3	0
C_02	108	97	6	5
C_03	127	109	12	6
C_04	112	101	8	3
C_05	67	24	36	7
C_06	62	18	13	30
C_07	116	76	32	8
C_08	36	30	6	0
C_09	21	21	0	0
C_10	53	41	12	0
C_11	33	33	0	0
<b>TOTAL</b>	<b>788</b>	600	128	59
(%) <b>DESEM.</b>	<b>100</b>	<b>76</b>	<b>16</b>	<b>8</b>

Tabela 5.18: Resultados para a classificação no subconjunto de validação dado pela divisão dos dados por aquisição

VALIDAÇÃO		MANUAL		
CLASSES	Eventos	Acertos	Não Classe	Erros
C_01	16	16	0	0
C_02	36	36	0	0
C_03	42	42	0	0
C_04	36	35	1	0
C_05	22	0	19	3
C_06	19	8	5	7
C_07	38	21	14	3
C_08	12	4	5	3
C_09	6	6	0	0
C_10	18	17	1	0
C_11	13	13	0	0
<b>TOTAL</b>	<b>258</b>	<b>198</b>	<b>45</b>	<b>16</b>
(%) <b>DESEM.</b>	<b>100</b>	<b>77</b>	<b>17</b>	<b>6</b>

Tabela 5.19: Resultados para a classificação no subconjunto de teste dado pela divisão dos dados por aquisição.

TESTE		MANUAL		
CLASSES	Eventos	Acertos	Não Classe	Erros
C_01	17	12	0	5
C_02	36	36	0	0
C_03	43	42	0	1
C_04	38	36	2	0
C_05	22	4	15	3
C_06	20	3	7	10
C_07	38	27	8	3
C_08	12	2	4	6
C_09	8	7	1	0
C_10	20	11	5	4
C_11	24	24	0	0
<b>TOTAL</b>	<b>278</b>	<b>204</b>	<b>42</b>	<b>32</b>
(%) <b>DESEM.</b>	<b>100</b>	<b>73</b>	<b>15</b>	<b>12</b>

Ao comparar os resultados da divisão dos dados por aquisição com os resultados da divisão dos dados por eventos, o desempenho da rede treinada com os subconjuntos desta última divisão é melhor. Enquanto a taxa de acertos na classificação para a divisão por aquisição é de 73 % para o subconjunto de teste, a taxa de acerto para a divisão por

eventos é de 85 %, isso quer dizer que a taxa de acerto cai cerca de 12 pontos percentuais. Isto é explicado porque nos subconjuntos de dados construídos a partir da divisão por aquisição, a estatística muda de aquisição para aquisição, fazendo que a rede aprenda sobre eventos pertencentes à mesma aquisição, mas sem generalizar frente a outros eventos fora dos sinais considerados.

### **5.3 Classificação com recorte automático**

Na primeira seção deste capítulo foram mostrados os resultados para as três técnicas de detecção, mostrando que o detector de patamar elaborado apresenta o maior número de eventos detectados. Na seção anterior, foram apresentados os resultados para a classificação dos transitórios da detecção manual. Baseados nas redes neurais anteriores, são classificados os transitórios detectados pelas três técnicas apresentadas.

A classificação com recorte automático utiliza os transitórios detectados em cada uma das técnicas expostas e, faz uma classificação a partir das redes treinadas com os eventos da detecção manual.

Para apresentar os resultados na presente seção, são feitas duas subseções, onde a primeira são expostos as três técnicas de detecção e o classificador neural, obtidos para a divisão os dados por eventos. Em seguida, são apresentados os resultados para a divisão feita a partir das aquisições dos sinais. Desta forma, fica de maneira mais clara na hora de comparação dos resultados.

#### **5.3.1 Classificação com recorte automático para a divisão dos dados por eventos**

Dentre as três técnicas para a detecção, primeiro são mostrados os desempenhos para os transitórios obtidos pelo detector de patamar simples. A Tabela 5.20 mostra os resultados para a classificação destes transitórios, onde a primeira coluna, tem o número de eventos encontrados pelo detector para cada uma das classes. As colunas restantes apresentam os acertos, os eventos de não classe e erros.

Tabela 5.20: Resultados para a classificação do recorte automático realizado pelo detector de patamar simples, para a divisão por eventos.

<b>TREINO</b>	<b>DETECTOR</b>	<b>CLASSIFICADOR</b>		
<b>CLASSES</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Não Classe</b>	<b>Erros</b>
C_01	49	47	2	0
C_02	101	94	4	3
C_03	109	94	13	2
C_04	90	83	7	0
C_05	42	15	23	4
C_06	54	35	13	6
C_07	111	69	25	17
C_08	31	22	7	2
C_09	18	15	2	1
C_10	20	11	8	1
C_11	0	0	0	0
<b>TOTAL</b>	<b>625</b>	<b>485</b>	<b>104</b>	<b>36</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>77</b>	<b>16</b>	<b>7</b>
<b>VALIDAÇÃO</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Não Classe</b>	<b>Erros</b>
C_01	16	12	4	0
C_02	35	33	0	2
C_03	36	30	5	1
C_04	32	29	3	0
C_05	12	4	6	2
C_06	19	13	6	0
C_07	36	26	9	1
C_08	9	8	0	1
C_09	7	5	0	2
C_10	6	3	2	1
C_11	0	0	0	0
<b>TOTAL</b>	<b>208</b>	<b>163</b>	<b>35</b>	<b>10</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>78</b>	<b>16</b>	<b>6</b>
<b>TESTE</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Não Classe</b>	<b>Erros</b>
C_01	15	13	2	0
C_02	33	31	0	2
C_03	38	33	4	1
C_04	33	31	2	0
C_05	20	3	13	4
C_06	17	10	6	1
C_07	37	22	13	2
C_08	10	7	2	1
C_09	7	5	0	2
C_10	8	5	3	0
C_11	0	0	0	0
<b>TOTAL</b>	<b>218</b>	<b>160</b>	<b>45</b>	<b>13</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>73</b>	<b>20</b>	<b>8</b>

A taxa de acerto cai em 12 pontos percentuais, comparada com os resultados para a classificação dos eventos do detector manual. A taxa de eventos determinados pela rede

como de não-classe, atinge a quinta parte da classificação no subconjunto de teste. Como foi mostrado no capítulo anterior, para a classificação sobre as transitórios detectados automaticamente, foi utilizado outro critério para o neurônio ganhador das saídas da rede neural. Isto muda a representação dos dados após a classificação desses transitórios, desde o ponto de em que a rede não tem saídas de não-classe. Depois de fazer esta nova avaliação dos neurônios da camada de saída, foram obtidos melhores resultados na taxa de acerto. Pode-se observar que as saídas de não-classe, são divididas entre os acertos e os erros, aumentando a taxa de acertos em 7 pontos percentuais para o subconjunto de teste.

Analisando o subconjunto de teste, que avalia a generalização do detector de patamar simples, quanto a classificação, é possível ver que a rede não consegue classificar os eventos pertencentes à classe 5 e 7 na sua totalidade. Da seção anterior, onde foram mostrados os resultados para a classificação do detector manual, foi explicada uma das causas da pouca taxa de acerto na classe 5, que tem a ver com a dissimilaridade dos transitórios dessa mesma classe. Nas classes 6 e 7, os padrões tem semelhanças na sua forma de onda, o qual explica, o alto número de erros na classificação destas classes. A classe 11, não pôde ser avaliada porque não foram detectados transitórios deste tipo. Também foi visto que, para a classe 4, todos os eventos foram classificados corretamente.

A Tabela 5.22 mostra os resultados para os eventos detectados pelo detector de patamar elaborado, onde a taxa de acerto do subconjunto de teste, aumentou em 2 pontos percentuais comparado com o detector de patamar simples. É claro ver também, que com este detector o número de eventos achados é maior, onde temos 20 eventos a mais no detector de patamar elaborado. As classes 5 e 7 apresentam altas taxa de erro, como visto anteriormente, sendo a classe 5 a de maior taxa de erro, e que, como já foi mencionado, deve-se às dissimilaríeis dentro desta classe, fazendo com que a rede não encontre um padrão que consiga representar os eventos. Outras classes, como a 4 e 11 conseguem ser classificadas corretamente para todos os eventos do subconjunto de teste.

Depois de ver a classificação para os eventos do detector de patamar elaborado, também são apresentados os resultados para os eventos encontrados pelo detector por correlação (Tabela 5.23).

Tabela 5.21: Resultados para a classificação do recorte automático realizado pelo detector de patamar simples, para a divisão por eventos, e usando o novo critério para o neurônio ganhador das saídas.

<b>TREINO</b>	<b>DETECTOR</b>	<b>CLASSIFICADOR</b>	
<b>CLASSES</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	49	48	1
C_02	101	94	7
C_03	109	100	9
C_04	90	85	5
C_05	42	18	24
C_06	54	40	14
C_07	111	83	28
C_08	31	24	7
C_09	18	15	3
C_10	20	12	8
C_11	0	0	0
<b>TOTAL</b>	<b>625</b>	<b>519</b>	<b>106</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>83</b>	<b>17</b>
<b>VALIDAÇÃO</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	16	13	3
C_02	35	33	2
C_03	36	31	5
C_04	32	31	1
C_05	12	5	7
C_06	19	16	3
C_07	36	30	6
C_08	9	8	1
C_09	7	5	2
C_10	6	3	3
C_11	0	0	0
<b>TOTAL</b>	<b>208</b>	<b>175</b>	<b>33</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>84</b>	<b>16</b>
<b>TESTE</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	15	13	2
C_02	33	31	2
C_03	38	35	3
C_04	33	33	0
C_05	20	4	16
C_06	17	12	5
C_07	37	27	10
C_08	10	8	2
C_09	7	5	2
C_10	8	7	1
C_11	0	0	0
<b>TOTAL</b>	<b>218</b>	<b>175</b>	<b>43</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>80</b>	<b>20</b>



Tabela 5.22: Resultados para a classificação do recorte automático realizado pelo detector de patamar elaborado, para a divisão por eventos, e usando o novo critério para o neurônio ganhador das saídas.

<b>TREINO</b>	<b>DETECTOR</b>	<b>CLASSIFICADOR</b>	
<b>CLASSES</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	50	49	1
C_02	106	99	7
C_03	104	96	8
C_04	87	82	5
C_05	46	18	28
C_06	54	39	15
C_07	111	82	29
C_08	36	31	5
C_09	17	12	5
C_10	53	45	8
C_11	34	34	0
<b>TOTAL</b>	<b>698</b>	<b>587</b>	<b>111</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>84</b>	<b>16</b>
<b>VALIDAÇÃO</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	17	14	3
C_02	35	33	2
C_03	37	33	4
C_04	31	30	1
C_05	13	5	8
C_06	18	16	2
C_07	37	30	7
C_08	11	10	1
C_09	6	4	2
C_10	18	14	4
C_11	11	11	0
<b>TOTAL</b>	<b>234</b>	<b>200</b>	<b>34</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>85</b>	<b>15</b>
<b>TESTE</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	17	15	2
C_02	36	34	2
C_03	35	33	2
C_04	30	30	0
C_05	21	4	17
C_06	16	11	5
C_07	35	26	9
C_08	11	9	2
C_09	6	4	2
C_10	18	17	1
C_11	13	13	0
<b>TOTAL</b>	<b>238</b>	<b>196</b>	<b>42</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>82</b>	<b>18</b>

Tabela 5.23: Resultados para a classificação do recorte automático realizado pelo detector por correlação, para a divisão por eventos, e usando o novo critério para o neurônio ganhador das saídas.

TREINO	DETECTOR	CLASSIFICADOR	
CLASSES	Eventos	Acertos	Erros
C_01	44	44	0
C_02	107	96	11
C_03	120	101	19
C_04	100	96	4
C_05	35	10	25
C_06	58	50	8
C_07	104	70	34
C_08	2	2	0
C_09	0	0	0
C_10	13	13	0
C_11	33	26	7
<b>TOTAL</b>	<b>616</b>	<b>508</b>	<b>108</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>0,82</b>	<b>0,18</b>
VALIDAÇÃO	Eventos	Acertos	Erros
C_01	13	11	2
C_02	36	33	3
C_03	42	35	7
C_04	32	32	0
C_05	9	3	6
C_06	19	16	3
C_07	34	25	9
C_08	0	0	0
C_09	0	0	0
C_10	3	3	0
C_11	13	8	5
<b>TOTAL</b>	<b>201</b>	<b>166</b>	<b>35</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>0,83</b>	<b>0,17</b>
TESTE	Eventos	Acertos	Erros
C_01	14	14	0
C_02	36	34	2
C_03	41	38	3
C_04	31	30	1
C_05	9	1	8
C_06	17	15	2
C_07	31	23	8
C_08	1	0	1
C_09	0	0	0
C_10	9	7	2
C_11	7	6	1
<b>TOTAL</b>	<b>196</b>	<b>168</b>	<b>28</b>
<b>(%) EFIC.</b>	<b>100</b>	<b>86</b>	<b>14</b>

A classificação aumenta para 86 %, mantendo a taxa de classificação para os três detectores. Da mesma forma que nas outras duas classificações automáticas, a classe 5 também mostra uma alta taxa de erros. Ainda assim, a taxa de acertos para a classificação do número de eventos detectados é mantida. A classe 1 classificou todos os eventos corretamente, entanto que as classes 8 e 9 no tiveram eventos para ser classificados

Em geral, as taxas de acerto na classificação, para as três técnicas de detecção, é no mínimo 80 % de acerto, o qual mostra que o classificador mantém seu desempenho para qualquer dos detectores usados, quando a divisão dos dados por eventos é realizada. Quanto às taxas de erros, estão nas classes 5, 6 e 7, como explicado em cada técnica. Nos três detectores, todos os eventos da classe 4 são classificados corretamente.

### **5.3.2 Classificação com recorte automático para a divisão dos dados por aquisição**

Nesta subseção, são tomados os transitórios encontrados pelas três técnicas de detecção, para os subconjuntos de treino, validação e teste, e que foram obtidos pela divisão feita por aquisição, e são apresentados à rede neural treinada com os transitórios da detecção manual.

Primeiro são apresentados (Tabela 5.24) os dados para a classificação dos eventos detectados pela técnica de patamar simples. Para a classe 11, não foram encontrados eventos por este detector, como foi explicado na primeira subseção do presente capítulo, desta forma, não foi possível avaliar a classificação desta classe. As classes 1, 2, 3, 4, 7 e 9 têm desempenho com taxa de acerto acima do 70 %, para as outras classes (5, 6, 8, e 10) apresentam taxas de acerto embaixo do 50 %, isto é devido às semelhanças entre as classes 5 e 6, e as classes 8 e 10, como foi tratado anteriormente.

Quando são apresentados os transitórios detectados pela técnica de patamar elaborado (Tabela 5.25), a classificação apresenta um desempenho similar subindo em dois pontos percentuais só.

Tabela 5.24: Resultados para a classificação do recorte automático realizado pelo detector de patamar simples, para a divisão por aquisição, e usando o novo critério para o neurônio ganhador das saídas.

TREINO	DETECTOR	CLASSIFICADOR	
CLASSES	Eventos	Acertos	Erros
C_01	50	48	2
C_02	104	92	12
C_03	105	97	8
C_04	88	88	0
C_05	46	13	33
C_06	60	15	45
C_07	112	84	28
C_08	33	29	4
C_09	19	16	3
C_10	27	16	11
C_11	0	0	0
<b>TOTAL</b>	<b>644</b>	<b>498</b>	<b>146</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>77</b>	<b>23</b>
VALIDAÇÃO	Eventos	Acertos	Erros
C_01	16	16	0
C_02	31	31	0
C_03	40	38	2
C_04	36	36	0
C_05	11	1	10
C_06	15	8	7
C_07	35	22	13
C_08	5	3	2
C_09	6	6	0
C_10	0	0	0
C_11	0	0	0
<b>TOTAL</b>	<b>195</b>	<b>161</b>	<b>34</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>83</b>	<b>17</b>
TESTE	Eventos	Acertos	Erros
C_01	14	10	4
C_02	34	34	0
C_03	38	36	2
C_04	31	31	0
C_05	17	1	16
C_06	14	5	9
C_07	37	29	8
C_08	11	4	7
C_09	7	6	1
C_10	6	0	6
C_11	0	0	0
<b>TOTAL</b>	<b>209</b>	<b>156</b>	<b>53</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>75</b>	<b>25</b>

Tabela 5.25: Resultados para a classificação do recorte automático realizado pelo detector de patamar elaborado, para a divisão por aquisição, e usando o novo critério para o neurônio ganhador das saídas.

TREINO	DETECTOR	CLASSIFICADOR	
CLASSES	Eventos	Acertos	Erros
C_01	52	50	2
C_02	105	93	12
C_03	103	97	6
C_04	84	84	0
C_05	52	13	39
C_06	59	14	45
C_07	109	80	29
C_08	35	29	6
C_09	19	15	4
C_10	52	41	11
C_11	27	26	1
<b>TOTAL</b>	<b>697</b>	<b>542</b>	<b>155</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>78</b>	<b>22</b>
VALIDAÇÃO	Eventos	Acertos	Erros
C_01	16	16	0
C_02	36	36	0
C_03	39	36	3
C_04	34	34	0
C_05	12	1	11
C_06	15	8	7
C_07	36	23	13
C_08	10	3	7
C_09	3	3	0
C_10	18	18	0
C_11	8	8	0
<b>TOTAL</b>	<b>227</b>	<b>186</b>	<b>41</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>82</b>	<b>18</b>
TESTE	Eventos	Acertos	Erros
C_01	16	12	4
C_02	36	36	0
C_03	34	32	2
C_04	30	30	0
C_05	16	1	15
C_06	13	5	8
C_07	38	30	8
C_08	12	4	8
C_09	7	5	2
C_10	19	11	8
C_11	23	22	1
<b>TOTAL</b>	<b>244</b>	<b>188</b>	<b>56</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>77</b>	<b>23</b>

Da mesma maneira, as classes com melhor taxa de acerto são a 1, 2, 3, 4, 7, 9 e a classe 11, a qual para este caso tem eventos que avaliaram a classificação. Os mesmos problemas para as classes 5, 6, 8 e 10 são produzidos pela rede, de acordo ao explicado anteriormente.

Para o detector por correlação, a Tabela 5.26 apresenta os resultados da classificação para os transitórios achados por esta técnica. Para a taxa de acerto geral, teve-se um aumento para o 83 %, sobre um número de eventos menor que nos casos anteriores. O comportamento das classes 1, 2, 3, 4, 7, 10 e 11 é taxas de acerto acima do 70 %, como nos casos anteriores. Para as classes 8 e 9 não foi possível testar a classificação, devido a que o detector encontrou só um transitório da classe 8 e nenhum evento da classe 9. Isto último, está refletido na taxa de acerto da classe 10, onde, a causa de não ter eventos que semelhantes, como os eventos da classe 8, todos são classificados corretamente. As classes 5 e 6 apresentam as taxas de acerto mais baixas, dado pelos motivos de tratados em todo o capítulo.

Comparando os resultados dos dois tipos de divisão de dados, os subconjuntos com melhor desempenho são os obtidos da divisão por eventos, onde a estatística é maior. Assim, a generalização na detecção tanto na classificação é possível. Devido à pouca estatística aportada pela divisão dos dados por aquisição, a classificação tem uma queda de 5 pontos percentuais nas classificações dos detectores de patamar simples e elaborado. Uma queda de 3 pontos percentuais na classificação dos eventos do detector por correlação, é vista neste tipo de divisão. Esta última, pode ser explicada pela queda do número de eventos detectado por esta técnica, onde o detector com menor número de eventos, das três técnicas, é o dado por correlação.

Por último, à rede treinada com transitórios da divisão dos dados por aquisição, são apresentados os eventos correspondentes aos falsos transitórios encontrados na detecção manual, e que foram descritos ao começo desta seção. A Figura 5.7 mostra como ficaram distribuídos esses transitórios entre as onze classes que discrimina a rede neural. Pode ser visto que 95 % dos falsos transitórios são classificados pela rede neural como dos tipos 1, 2 e 3, sendo a maior parcela da classe 2. Isto acontece, pela facilidade com que o padrão representativo desta classe pode ser confundido com patamares de corrente similares, ocasionados por flutuações do sinal.

Tabela 5.26: Resultados para a classificação do recorte automático realizado pelo detector por correlação, para a divisão por aquisição, e usando o novo critério para o neurônio ganhador das saídas.

<b>TREINO</b>	<b>DETECTOR</b>	<b>CLASSIFICADOR</b>	
<b>CLASSES</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	44	44	0
C_02	108	86	22
C_03	127	106	21
C_04	91	88	3
C_05	31	0	31
C_06	61	19	42
C_07	103	84	19
C_08	0	0	0
C_09	0	0	0
C_10	13	13	0
C_11	18	18	0
<b>TOTAL</b>	<b>596</b>	<b>458</b>	<b>138</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>77</b>	<b>23</b>
<b>VALIDAÇÃO</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	16	16	0
C_02	36	36	0
C_03	31	31	0
C_04	36	36	0
C_05	17	2	15
C_06	17	10	7
C_07	29	23	6
C_08	0	0	0
C_09	0	0	0
C_10	6	6	0
C_11	13	13	0
<b>TOTAL</b>	<b>201</b>	<b>173</b>	<b>28</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>86</b>	<b>14</b>
<b>TESTE</b>	<b>Eventos</b>	<b>Acertos</b>	<b>Erros</b>
C_01	11	11	0
C_02	36	36	0
C_03	40	30	10
C_04	35	35	0
C_05	8	0	8
C_06	15	5	10
C_07	36	30	6
C_08	1	1	0
C_09	0	0	0
C_10	4	4	0
C_11	11	11	0
<b>TOTAL</b>	<b>197</b>	<b>163</b>	<b>34</b>
<b>(%) DESEM.</b>	<b>100</b>	<b>83</b>	<b>17</b>




Figura 5.7: Classificação dos falsos transitórios obtidos do recorte manual para o subconjunto de teste.

Para fazer uma comparação dos falsos transitórios classificados da detecção manual, são apresentados os eventos detectados por cada uma das técnicas desenvolvidas à mesma rede neural. As Figuras 5.8 – 5.10 mostram histogramas destes eventos. Pode-se observar, para os detectores por patamar, que a maior parcela corresponde à classe 9, onde como foi tratado anteriormente, existe o maior número de eventos deste tipo.




Figura 5.8: Classificação dos falsos transitórios obtidos do recorte automático pelo detector de patamar simples para o subconjunto de teste.






Figura 5.9: Classificação dos falsos transitórios obtidos do recorte automático pelo detector de patamar elaborado para o subconjunto de teste.




Figura 5.10: Classificação dos falsos transitórios obtidos do recorte automático pelo detector por correlação para o subconjunto de teste.

Para o detector por correlação, a maioria de falsos transitórios são determinados como da classe 11, onde a causa de seu padrão, a rede classifica patamares de corrente como dessa classe. A classe 9 não apresenta nenhum evento devido a que o detector não obtém transitórios desta classe.

## 5.4 Consumo de energia

Um dos principais objetivos do sistema de monitoração, é discriminar a energia consumida por cada uma das classes existentes, e comparar com o estudo sobre hábitos de consumo [2]. Desta maneira, é realizada uma análise deste tipo, onde primeira é calculada a energia dos transitórios considerados recortados manualmente, e em uma outra etapa, é utilizada para comparar com a quantidade de energia que tem sido detectada e classificada automaticamente de forma correta. Assim, foi obtida uma medida da eficiência baseada na energia consumida pelas classes.

Para os subconjuntos de treino, validação e teste, é calculada a energia de cada transitório dado por (4.1), como foi explicado no capítulo anterior. Estas energias são apresentadas em watts-hora (Wh), e representam uma estimativa de energia para avaliar o sistema automático de detecção e classificação em conjunto. A energia é calculada sobre os transitórios recortados e classificados corretamente, considerando as 150 amostras de 2,5 segundos de duração. Fazendo uma comparação para o caso prático, o final do transitório representa o tempo final de consumo de energia, este estaria dado com um detector de desligamento no caso real, medindo a energia consumida pela residência.

Seguindo a ordem apresentada no trabalho, primeiro são apresentados os resultados para a divisão por eventos, onde a Tabela 5.27 resume, em termos de energia, os resultados para as três técnicas de detecção. Na primeira coluna, encontra-se os valores de energia calculado sobre os transitórios detectados manualmente, estes valores representam a porcentagem de energia que é necessário discriminar. A segunda coluna, contém os valores da energia, que é possível classificar por meio da rede neural treinada, sobre os transitórios da detecção manual. Pode-se ver, que para o subconjunto de teste, a rede consegue classificar 95 % da energia total consumida, isto é explicado, de acordo à alta taxa de acerto das classes com maior energia, como são a classe 1 e 2, fazendo com que seja discriminada uma alta parcela de energia.

Tabela 5.27: Resultados para energia para a divisão dos dados por eventos.

Classes Treino	Energia (Wh)	MANUAL	PATAMAR S.	PATAMAR E.	CORRELAÇÃO
		Energia Detecções Corretas	Energia Detecções Corretas	Energia Detecções Corretas	Energia Detecções Corretas
C_01	814	810	719	719	639
C_02	3220	3205	2976	3168	3099
C_03	859	851	613	596	611
C_04	260	254	191	189	187
C_05	80	35	20	21	3
C_06	120	107	87	84	102
C_07	87	74	60	60	48
C_08	67	67	47	57	5
C_09	139	139	123	122	0
C_10	108	96	23	85	22
C_11	31	31	0	21	13
<b>TOTAL</b>	<b>5785</b>	<b>5669</b>	<b>4859</b>	<b>5122</b>	<b>4729</b>
(%) DESEM.	<b>100</b>	<b>98</b>	<b>84</b>	<b>89</b>	<b>82</b>
Classes Validação	Energia (Wh)	MANUAL	PATAMAR 1	PATAMAR 2	CORRELAÇÃO
		Energia Detecções Corretas	Energia Detecções Corretas	Energia Detecções Corretas	Energia Detecções Corretas
C_01	198	160	150	154	143
C_02	1158	1153	1108	1108	1132
C_03	240	240	175	181	168
C_04	87	83	61	60	60
C_05	26	10	6	6	2
C_06	46	43	39	39	40
C_07	30	26	22	22	17
C_08	21	19	16	17	0
C_09	34	34	29	29	0
C_10	35	30	5	26	5
C_11	11	11	0	7	4
<b>TOTAL</b>	<b>1886</b>	<b>1809</b>	<b>1611</b>	<b>1649</b>	<b>1571</b>
(%) DESEM.	<b>100</b>	<b>96</b>	<b>85</b>	<b>87</b>	<b>83</b>
Classes Teste	Energia (Wh)	MANUAL	PATAMAR 1	PATAMAR 2	CORRELAÇÃO
		Energia Detecções Corretas	Energia Detecções Corretas	Energia Detecções Corretas	Energia Detecções Corretas
C_01	258	223	198	212	180
C_02	1142	1137	1058	1136	1136
C_03	221	221	159	151	149
C_04	86	85	71	65	69
C_05	45	8	4	4	1
C_06	32	29	23	22	30
C_07	34	29	25	24	16
C_08	23	22	16	18	0
C_09	23	22	6	5	0
C_10	34	32	12	31	12
C_11	10	10	0	7	2
<b>TOTAL</b>	<b>1908</b>	<b>1818</b>	<b>1572</b>	<b>1675</b>	<b>1595</b>
(%) DESEM.	<b>100</b>	<b>95</b>	<b>82</b>	<b>88</b>	<b>84</b>

Baseados nesta energia classificada corretamente pela rede neural sobre os dados da detecção manual, são medidas as eficiências da classificação sobre cada uma das três técnicas de detecção. Primeiro, pode ser vista a eficiência do detector de patamar simples, que consegue classificar corretamente um 82 % da energia da detecção manual.

Na detecção por patamar elaborado, a eficiência atinge os 88 %, que como vem sendo tratado neste documento, é a detecção de melhores características quanto a detecção e classificação. Para o detector por correlação, esta eficiência cai a 84 %, a causa da baixa taxa de detecção de eventos, embora tenha uma taxa de classificação comparável com as outras técnicas. É possível também observar, que as três técnicas automáticas de detecção e classificação não são muito diferentes quanto a ponderação por energia.

Desde este ponto de vista, o detector por patamar elaborado, possui a melhor opção dentre as três técnicas, já que apresenta a taxa de eficiência mais alta de classificação ponderada pela energia total consumida.

Para os subconjuntos divididos a partir de aquisições, a Tabela 5.28 mostra os resultados de maneira igual do que na divisão por eventos. Nesta tabela há também, uma coluna com a energia calculada sobre os falsos transitórios encontrados por cada detector. No caso da classificação para a detecção manual, uma eficiência de 85 % é vista, caindo em 10 pontos percentuais frente à classificação na divisão dos dados por eventos. Isto, como tratado, deve-se à pouca generalização quando foram construídos os subconjuntos a partir das aquisições do sinal.

Partindo dessa energia classificada pela rede neural sobre os eventos de detecção manual, são calculadas as eficiências das três técnicas automáticas. Para o detector de patamar simples, é calculada uma eficiência de 74 %, já para o detector de patamar elaborado, esta eficiência sobe para um 77 %, e por último, o detector por correlação cai para o 72 %.

Em geral, pode-se observar uma queda em 11 pontos percentuais da divisão dos dados por eventos à divisão por aquisição, mantendo taxas de eficiência similares para as três técnicas. Esta queda é consequência da flutuação estatística de aquisição para aquisição, como foi mostrado na classificação automática anteriormente.

Tabela 5.28: Resultados para energia para a divisão dos dados por aquisição.

Classes Treino	Energia (Wh)	MANUAL		PATAMAR 1		PATAMAR 2		CORRE	
		Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas
C_01	723	712	12	661	177	646	172	531	394
C_02	3261	3237	13	3100	693	3134	686	2985	2157
C_03	879	751	86	617	44	588	79	606	234
C_04	241	220	18	172	2	166	10	155	93
C_05	105	24	76	14	6	14	7	0	81
C_06	120	55	18	43	9	40	12	58	27
C_07	89	50	32	38	0	37	2	53	28
C_08	69	61	8	49	6	47	9	0	63
C_09	159	159	0	123	604	122	739	0	71
C_10	99	78	22	28	39	73	1	22	13
C_11	24	24	0	0	14	15	3	10	13
<b>TOTAL</b>	<b>5769</b>	<b>5371</b>	<b>285</b>	<b>4845</b>	<b>1594</b>	<b>4882</b>	<b>1720</b>	<b>4420</b>	<b>3174</b>
(%) DESEM.	100	93		84		85		76	
Classes Validação	Energia (Wh)	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas
C_01	235	235	0	205	0	205	0	229	14
C_02	1190	1190	0	1004	107	1190	0	1161	285
C_03	91	91	0	69	1	70	11	50	209
C_04	60	58	2	58	0	55	3	52	17
C_05	23	0	19	0	9	0	13	0	35
C_06	44	25	12	19	0	19	0	32	4
C_07	36	18	16	13	3	13	1	20	14
C_08	14	5	6	2	4	2	2	0	10
C_09	2	2	0	1	0	0	1	0	0
C_10	35	33	2	0	29	29	0	11	4
C_11	10	10	0	0	6	5	3	8	4
<b>TOTAL</b>	<b>1740</b>	<b>1667</b>	<b>57</b>	<b>1371</b>	<b>159</b>	<b>1588</b>	<b>34</b>	<b>1563</b>	<b>596</b>
(%) DESEM.	100	96		79		91		90	
Classes Teste	Energia (Wh)	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas	Energia Detecções Corretas	Energia Detecções Falsas
C_01	311	137	565	111	457	125	455	101	540
C_02	1069	1069	0	1019	28	1069	0	1076	251
C_03	350	332	132	238	114	243	158	141	520
C_04	133	125	55	88	37	84	37	115	79
C_05	23	2	4	1	10	1	13	0	56
C_06	34	9	0	16	0	9	2	16	19
C_07	26	20	0	21	0	17	0	19	24
C_08	29	6	0	12	1	3	0	2	22
C_09	35	24	577	19	341	19	338	0	1211
C_10	43	23	0	0	23	18	2	7	14
C_11	18	18	0	0	9	13	1	5	8
<b>TOTAL</b>	<b>2071</b>	<b>1765</b>	<b>1333</b>	<b>1525</b>	<b>1020</b>	<b>1601</b>	<b>1006</b>	<b>1482</b>	<b>2744</b>
(%) DESEM.	100	85		74		77		72	

Deste modo, o detector por patamar elaborado, continua sendo uma alternativa para obter a melhor eficiência na classificação ponderada pela energia. Desde o ponto de vista de menor energia detectada dada por falsos transitórios, também se encontra o detector de patamar elaborado como a melhor alternativa, este consegue detectar a mais baixa das energias para os três tipos de detectores, superando inclusive ao detector por patamar simples, que apresenta poucos falsos transitórios na detecção. O pior detector é obtido com a técnica da correlação, onde tem pouca eficiência na detecção de transitórios certificados, como foi explicado na primeira seção deste capítulo. Além disso, este detector, apresenta uma alta energia na detecção de falsos transitórios, superando incluso, à energia dos transitórios certificados.

## Capítulo 6

### Conclusões

O problema da monitoração não invasiva de carga elétrica foi tratado no presente trabalho, como um sistema de detecção automática de transitórios e uma classificação de tipo neural.

Como descrito anteriormente, este trabalho é uma extensão dos desenvolvimentos em [7][8], nos quais uma solução é procurada para o problema da monitoração. Nesses trabalhos, o sistema de aquisição foi realizado de uma maneira distinta, onde não se dava maior relevância ao tema da detecção. A diferença para o presente estudo reside no sistema de detecção, que identifica quando ocorre um acionamento que represente uma carga a monitorar. Outro diferencial do presente trabalho está no tratamento da classificação; no primeiro momento, era procurada uma elevada taxa de acerto para a classificação dos transitórios, enquanto que, para o caso atual também é procurado identificar eficientemente o consumo. Neste trabalho foi possível identificar 95 % da energia consumida, a partir da energia classificada corretamente do recorte manual dos sinais.

Os três métodos desenvolvidos para o detector dão enfoques diferentes na hora da sua aplicação, por exemplo, foi visto no capítulo anterior que nem todos têm a mesma eficiência na hora de detectar os transitórios para todas as classes, assim, pode-se dar uma ênfase maior para algumas classes no caso que seja requerida uma classe com maior relevância frente às outras. A partir dos resultados obtidos, o de melhor desempenho é o dado pela técnica de patamar elaborado, onde uma mudança maior de 100mA na corrente, e somado a outras características, é válido como um transitório. Esta técnica apresenta boa eficiência na hora de encontrar os transitórios das onze classes. Para o detector de patamar simples, a classe onze parece ter problemas para ser detectada, isto porque a forma do seu transitório, que tem amostras com valores pequenos de corrente, faz com que o detector não consiga encontrá-los. Já para o

detector por correlação, a eficiência é mantida para as onze classes, mas com uma queda geral frente aos resultados dos outros dois detectores.

Outro fator importante na hora de escolher um detector são os falsos transitórios, cuja identificação pode se tornar complexa dependendo da situação. Isto resulta em um consumo de energia maior do que a efetivamente esta sendo utilizada, além de poder fazer com que a classificação perca eficiência. Deste ponto de vista, é necessário trabalhar com um detector que mostre um número baixo de detecção em transitórios falsos. O detector que melhor oferece esta possibilidade é o detector desenvolvido pela técnica de patamar simples. O detector por correlação apresenta o maior número de falsos transitórios detectados. A classe que mais dificulta a detecção deste ponto de vista é a classe 9, que corresponde ao padrão para máquinas de lavar, a qual, devido à forma do seu transitório, faz com que os detectores de patamar encontrem transitórios de consumo inexistentes.

Para a classificação, é notável ver a influência do tipo de divisão dos dados. Enquanto para os subconjuntos de treino, validação e teste obtidos a partir de uma divisão tendo em conta a aquisição, uma rede 150-20-11 apresenta a melhor taxa de classificação com um 85 % sobre a energia total. Para os subconjuntos divididos a partir do número total de eventos, uma rede de 150-25-11 apresenta o melhor desempenho com uma taxa de acerto do 95 % da energia total consumida. É clara a influencia da divisão dos dados na generalização da classificação, causada pela flutuação estatística de aquisição para aquisição no primeiro caso.

O trabalho desenvolvido oferece ainda uma série de possibilidades para análises futuras que possam ajudar no incremento da eficiência do sistema. Dentre essas possibilidades estão:

- Foi verificado que a flutuação de aquisição para aquisição, ao dividir os dados a partir destas, apresenta uma diminuição na eficiência da classificação frente à divisão dos dados a partir do número total de transitórios. Isto sugere a idéia de aumentar o número de aquisições para evitar a influência estatística deste tipo. Assim, é possível conseguir uma melhora na generalização da classificação dos transitórios.



- Desenvolver o detector por correlação a partir de um filtro casado estocástico, onde se pode aumentar a eficiência na detecção que está diretamente associada à classificação dos transitórios.
- É desejável aumentar o número de eventos nas classes que têm pouca representação, como nas classes 8 e 9 que correspondem às lâmpadas fluorescentes de reator eletromagnético e às máquinas de lavar.
- Realizar uma combinação de detectores para aumentar a taxa de eventos detectados corretamente, já que como mostrado, em algumas classes existem transitórios que não são obtidos por uma técnica de detecção, mas por outro tipo de detector podem ser encontrados
- O uso dos padrões na detecção por correlação, sugere a idéia de fazer uma pré-classificação associando a janela à classe do padrão apresentado. Isto pode ser desenvolvido a partir de um filtro casado determinístico de igual número de classes.
- Métodos de ICA podem ser aplicados nas aquisições de residências como sistemas especialistas por classe. Assim, poder calcular a energia de cada classe baseado neste tipo de sistemas.

## 6.1 Trabalho futuro

Como trabalho futuro, é apresentada uma proposta baseada em informações de regime estacionário, que podem complementar às informações de regime transitório que foram tratadas anteriormente.

Para a caracterização em regime permanente, em [7][8] foi feito um mapeamento no plano  $I \times \theta$  (Figura 6.1), onde  $I$  é a corrente aparente e  $\theta$  é o ângulo de fase entre as

potências ativa e reativa. Nessa figura, os quadriláteros de 1 a 7 definem regiões ocupadas por eletrodomésticos de características semelhantes de regime permanente.

Os agrupamentos obtidos, de acordo com o mapeamento  $I \times \theta$  (ver Figura 3.16), 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
6. Equipamentos eletrônicos (vídeocassetes, televisões, etc.) e lâmpadas fluorescentes
7. Condicionadores de ar.

Esta representação pode ser usada como sistema de apoio para os agrupamentos por transitório, onde as classes 5, 6, 8 e 10 apresentam formas de onda similares. Os agrupamentos através de informação de regime estacionário são descritos como uma possível ferramenta em caso de ser necessário um apoio deste tipo.

Foi verificado que a caracterização das cargas elétricas domésticas por meio dos transitórios, permite uma definição de 11 classes, dadas pelas agrupações com as quais é relevante trabalhar. Para as características de regime permanente, de [7][8], 7 classes deveriam ser criadas para completa caracterização destas cargas.

Para este mapeamento do plano  $I \times \theta$  das informações do regime permanente, existem regiões superpostas o que dificulta a identificação dos grupos, razão pela qual também não é usada no presente trabalho. Este mapeamento pode ser aproveitado nas classes não superpostas como a 3 e a 7 da Figura 6.1, que correspondem às classes 6 e 7 do presente trabalho, as quais apresentam baixas taxas de classificação pelo transitório. Estas informações podem ser um apoio na etapa de classificação.




Figura 6.1: Mapeamento dos Eletrodomésticos no plano  $I \times \theta$ .

Em algumas aplicações, o espaço de entrada é composto por informações de natureza diversa. Para estes casos, uma possível técnica de implementação seria a utilização de redes neurais especialistas para o conjunto de informações que compõem o espaço de entrada. O objetivo é, sub-redes neurais especializadas em informações distintas no nosso caso, no transitório e no regime permanente (ângulo de fase e corrente aparente). Cada uma dessas sub-redes especialistas funciona como um extrator de características relevantes. A Figura 6.2 mostra a topologia de uma rede neural composta de sub-redes neurais especialistas para as informações do transitório e do regime permanente.

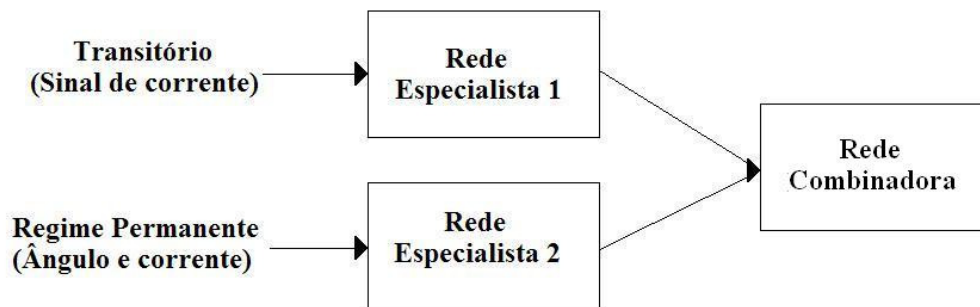


Figura 6.2: Topologia para o processamento neural baseado em sub-redes neurais especialistas para informações do transitório e do regime permanente.

Cada sub-rede neural especialista será treinada de modo a se obter a máxima eficiência de classificação, para a classe na qual se pretende especializar a rede. Para se combinar os resultados obtidos por cada rede treinada, existem diferentes maneiras [7][8] maneiras. Uma possibilidade é combinar as saídas das sub-redes especialistas, ou as informações extraídas no sub-espaço das camadas intermediárias de cada uma delas.

A rede especialista no regime permanente deve ser treinada apenas com informação da amplitude de corrente e o ângulo de fase entre as potências ativa e reativa. Para isso, o valor médio da corrente nas suas últimas dez amostras, que corresponde praticamente, ao começo do regime permanente. Para o ângulo, como foi visto no capítulo três, o dispositivo de aquisição obtém informações das potências ativas e reativas. Com estas informações o ângulo é obtido da equação:

$$\theta = \text{Tan}^{-1}\left(\frac{Q}{P}\right) \quad (6.1)$$

onde  $Q$  é a potencia reativa e  $P$  é a potencia ativa. Estes valores são calculados das últimas 10 amostras dos sinais de potencia ativa e reativa do transitório encontrado. Para esta rede neural, é proposta uma arquitetura com duas entradas, que correspondem à corrente e ao ângulo. Uma camada escondida com o numero de neurônios a ser determinado e uma camada de saída com os onze neurônios correspondentes às classes que estamos trabalhando completam a arquitetura da rede especialista no regime permanente. A Figura 6.3 mostra a arquitetura desta rede neural para informações de regime permanente.

Quando são obtidos os melhores resultados para esta rede, é desenvolvida uma terceira rede combinadora, que junta as sub-redes de regime transitório e regime permanente, como mostrado na Figura 6.2.




Figura 6.3: Arquitetura para a rede neural treinada com informações de regime permanente

## Referencias Bibliográficas

- [1] ELETROBRÁS, *Relatório Analítico – mercado de energia elétrica*. Reporte Ministério de Minas e Energia, 2003.
- [2] ELETROBRAS, *Avaliação do Mercado de Eficiência Energética no Brasil – Pesquisa de pose de equipamentos e hábitos de uso - Ano Base 2007 – Classe Residencial Relatório Brasil*.
- [3] SILVA, T., *Estimativa De Padrão De Consumo Energético De Comunidades Carentes, Estudo De Caso – Complexo Da Maré*. Dissertação de Mestrado, UFRJ, 2003.
- [4] MINISTÉRIO DE MINAS E ENERGIA & EMPRESA DE PESQUISA ENERGÉTICA, *Relatório Plano Decenal de Expansão 2008-2017 Capítulo II*. 2008.
- [5] VILLA VERDE, V. S., *A Conservação de Energia Elétrica no Novo Modelo Institucional do Setor Elétrico Brasileiro*. Dissertação de Mestrado, UFRJ, 2000.
- [6] AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL, *Relatório ANEEL 2006*.
- [7] AGUIAR, J., *Identificação Não Invasiva de Cargas Elétricas Residências Utilizando Redes Neurais*. Dissertação de Mestrado, UFRJ, 1996.
- [8] PRADO, C. B., *Sistema De Monitoração de Carga Elétrica Residencial com Implementação Para Diferentes Cenários de Aplicação*. Tese de Doutorado, UFRJ, 2006.
- [9] HART, G. V., “Nonintrusive appliance load monitoring”, *Proc. of the IEEE*, v. 80, pp. 1870 – 1891, Dec. 1992.

- [10] SULTANEM, F., "Using Appliances Signatures for Monitoring Residential Loads at Meter Panel", *IEEE Trans. On Power Delivery*, v. 6. pp. 1380 -1385, Oct. 1991.
- [11] 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.
- [12] DRENKER, S., KADER, A., "Nonintrusive Monitoring of Electrical Loads", *IEEE Computer Applications in Power*, v. 12, pp. 47-51, Oct. 1999.
- [13] PIHALA, H. "Non-intrusive Appliance Load Monitoring System Based on a Modern KWh-meter", Thesis of Licentiate in Technology in Espoo, May 1998, Technical Research Centre of Finland ESPOO 1998.
- [14] 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.
- [15] LAUGHMAN, C., LEE, K., COX, R., *et al.*, "Power Signature Analysis", *IEEE Power and Energy*, v. 1, pp. 56-63, 2003.
- [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] MARCEU, 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.
- [18] NORTH, G., "Electricity consumption and load control possibilities: Residential energy monitoring in Sweden". *ECEE*, 2001.

- [19] LEEB, S., B., “A Conjoint Pattern Recognition Approach to Nonintrusive Load Monitoring”, PhD Thesis, MIT,
- [20] 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.
- [21] 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.
- [22] SHAW, S. R., “System Identification Techniques and Modelling for Nonintrusive Load Diagnostics”, PhD Thesis, MIT, February 2000.
- [23] COX, R., LEEB, S. B., SHAW, S. R., NORFORD, L., K., “Transient Event Detection for Nonintrusive Load Monitoring and Demand Side Management Using Voltage Distortion” pp. 1751-1757, 2006.
- [24] 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.
- [25] 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. 56-64, 1996.
- [26] NORFORD, L. K., LEEB, S. B., LUO, D., SHAW, S. R., “Advanced Electrical Load Monitoring: A Wealth of Information at Low Cost”. MIT, pp. 1-10,
- [27] SHAW, S. R., NORFORD L. K., LEEB, S. B. LUO, D., “Detection and Diagnosis of HVAC Faults via Electrical Load Monitoring” HPCBS # E5P22T3b *et al.*, California Energy Commission, Public Interest Energy Research Program.



- [28] CARPINTERO, 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.
- [29] CARPINTERO, O. A. S., SILVA, A. P. A. D., “ A Hierarchical Self-Organizing Map Model in Short-Term Load Forecasting”. In: *Proceedings of the 5<sup>th</sup> International Conference on Engineering Applications of Neural Networks*, pp. 775-780, Torun, Poland, 2001.
- [30] KANG, H., JANG, W. S., LEE, S. M., LEE, H. M., “A development of the Short Term Electrical Prediction System Based on Fuzzy System and the Evolutionary Algorithm”. In: *Proceedings of the SICE-ICASE International Joint Conference*, pp. 5232-5235, Bexco, Busan, Korea, 2006.
- [31] LI, X., ZHANG, Y., CAI, L., “Electrical Load Forecasting Based on Fuzzy Wavelet Neural Networks”. In: *Proceedings of the International Seminar on Future BioMedical Information Engineering*, pp. 122-125, IEEE, 2008.
- [32] HIPPERT, H. S., PEDREIRA, C. E., SOUZA, R. C., “Neural Networks for Short-Term Load Forecasting: A Review and Evaluation”. In: *IEEE Trans. on Power Systems*, v. 16, n. 1, pp. 44-55, 2001.
- [33] HUANG, S. J., SHIN, K. R., “Short Term Load Forecasting via ARMA Model Identification Including Non-Gaussian Process Considerations”, *IEEE Trans. On Power Systems*, v. 18, n. 2, pp. 673-679, May 2003.
- [34] SAINI, L.M.; SONI, M.K.; “Artificial Neural Network-Based Peak Load Forecasting Using Conjugate Gradient Methods”, *IEEE Transactions on Power Systems*, v.17, n.3, pp. 907-912, Aug. 2002.
- [35] SATISH, B.; SWARUP, K.S.; SRINIVAS, S.; RAO, A.H.; “Effect of Temperature on Short Term Load Forecasting Using a Integrated ANN”, *Electric Power Systems Research*, v.72, n.1, pp. 95-101, Nov. 2004.

- [36] RINWOOD, 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.
- [37] KERSHMANSHASHI, H. I., "Up to year 2020 load forecasting using neural nets", *International Journal of Electrical Power and Energy Systems*, pp. 789-797, November 2002.
- [38] KANDIL, M. S., DEBEIKY, S., HASANIEN, N. E., "Long-term load forecasting for fast developing utility using a knowledge-based expert system", *IEEE Transactions on Power Systems*, v. 17, n. 2, pp. 491-496, 2002.
- [39] PASILA, F., "Multivariate inputs for electrical load forecasting on hybrid neuro-fuzzy and fuzzy C-Means forecaster". In: *IEEE World Congress on Computational Intelligence*, pp. 2307-2312, IEEE, Hong Kong, 2008.
- [40] TAYLOR, J. W., BUIZZA, R., "Neural Network Load Forecasting with Weather Ensemble Predictions". In: *IEEE Trans. on Power Systems*, v. 17, pp. 626-632, 2002
- [41] GHANBARI, A., NAGHAVI, A., GHADERI, S.F., SABAGHIAN, M., "Artificial Neural Networks and Regression Approaches Comparison for Forecasting Iran's Annual Electricity Load". In: *Power Engineering, Energy and Electrical Drives, POWERENG International Conference*, pp. 675-679, March 2009.
- [42] CHEN, B.-J.; CHANG, M.-W.; LIN, C.-J; "Load Forecasting Using Support Vector Machines: A Study on EUNITE Competition 2001", *IEEE Transactions on Power Systems*, v.19, n.4, pp. 1821-1830, Nov. 2004.
- [43] LIN, Z., GAO, L., ZHANG, D., "Predictions of System Marginal Price of Electricity Using Recurrent Neural Network". In: *Proceedings of the 6<sup>th</sup> World Congress on Intelligent Control and Automation*, pp. 7592-7595, Dalian, China, 2006

- [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, 2000.
- [45] 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.
- [46] 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.
- [47] BRETAS, A. S., PHADKE, A., “Artificial Neural Networks in Power System Restoration”, *IEEE Trans. on Power Delivery*, v. 18, n. 4, pp. 1181-1186, October 2003.
- [48] MABEL, M. C., FERNANDEZ, E., “Estimation of Energy Yield From Wind Farms Using Artificial Neural Networks”. In: *Trans on Energy Conversion*, v. 24, n. 2, pp. 459-464, June 2009.
- [49] WEI, L., YUMIN, S., “Prediction of Energy Production and Energy Consumption based on BP Neural Networks”. In: *IEEE International Symposium on Knowledge Acquisition and Modeling Workshop*, pp. 176-179, December 2008.
- [50] TSAI, L. F., KU, Y. T., CHANG, Y. C., CHUNG, H. L., “Energy Conservation Diagnosis Based on Neural Network and Statistical Computing”. In: *International Conference on Computer Engineering and Technology*, pp. 548-551, Singapore, January 2009.
- [51] SERT, S. B., KALENDERI, O., “Determination of source voltage from audible corona noise by neural networks”. In: *IEEE Trans. On Dielectrics and Electrical Insulation*, v. 16, pp. 224-231, February 2009.

- [52] FOTIS, G. P., EKONOMU, L., MARIS, T. I., LIATSI, P., “Development of an artificial neural network software tool for the assessment of the electromagnetic field radiating by electrostatic discharges”. In: *IET Science, Measures and Technology*, v. 1, pp. 261-269, September 2007.
- [53] GUOHA, H., DOGMEI, X., SHUGING S., “Medium-Long Term Prediction on Monthly Discharge at Yangtze Three Georges Based on Neural Network”, In: *IFITA 2009, International Forum Information Technology and Applications*, v. 3, pp. 197-199, Chengdu, China., May 2009.
- [54] GUOHA, H., HEHUA, S., XING, Y., “Medium-Long Term Prediction on Monthly Discharge at Xiangjiang River Based on Neural Networks”, In: *ISA 2009, International Workshop in Intelligent Systems and Applications*, p. 1-4, Wuhan, May 2009.
- [55] TEIVE, R. C. G., VILVERT, S. H., “Demand side management for residential consumers by using direct control on the loads”. In: *Fifth International Conference on Power System Management and Control*, pp. 233-237, April 2002.
- [56] AMENDOLA, A., “Energy Conservation Strategies Applied to Demand Management”. In: *14<sup>th</sup> International Conference and Exhibition on Electricity Distribution*, v. 15, pp. 1-5, IEE, June 1997.
- [57] ALVES DA SILVA, A.P; MOULIN, L.; “Confidence Intervals for Neural Network Based Short-term Load Forecasting”, *IEEE Transactions on Power Systems*, v.15, n.4, pp. 1191-1196, Nov. 2000.
- [58] ALVES DA SILVA, A.P.; RODRIGUES, U.P.; REIS, A.J.R.; MOULIN, L.S.; “Oráculo – Uma ferramenta para Previsão de Carga”, *XVI SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica*, GOP/012, Campinas, São Paulo, Brasil, 21-26 de Outubro de 2001.

- [59] REIS, A.J.R.; ALVES DA SILVA, A.P.. “Feature Extraction Via Multi Resolution Analysis for Short-Term Load Forecasting”, *IEEE Transactions on Power Systems*, v.20, n.1, pp. 189-198, Feb. 2005.
- [60] FERREIRA, V. H., *Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga*. Tese de Doutorado, UFRJ, 2008.
- [61] WATSON, N. R., SCOTT, T. L., HIRSCH, S. J. J., “Implications for Distribution Networks of High Penetration of Compact Fluorescent Lamps”. In: *IEEE Trans. on Power Delivery*, v. 24, n. 3, pp. 1521-1528, July, 2009.
- [62] SOLA, J. C., SALICHS, M., “Study and Characterization of Waveforms From Low-Watt (<25W) Compact Fluorescent Lamps With Electronic Ballasts”. In: *IEEE Transactions on Power Delivery*. v. 22, n. 4, pp. 2305-2311, October 2007.
- [63] YAAKOV, S. B., PERETZ, M. M., PARRA, J. M. S., PARRA, J. M. J., “Self-Oscillating Constat-Current Fluorescent Lamp Driver: Theory and Application”. In: *IEEE Trans. on Power Delivery*, pp. 3093-3099, Israel, 2007.
- [64] HAYKIN, S., *NEURAL NETWORKS A Comprehensive Foundation*. 1 ed. New York, 1994.
- [65] HERTZ, J., KROGH, A., PALMER, R. G., *Introduction to the Theory of Neural Computation*. Addison – Wesley, 1991
- [66] WASSERMAN, P., *Neural computing Theory and Practice*. 1 ed. New York, 1989.
- [67] CĂLOBA, L., *Notas de Aula Redes Neurais*, COPPE/UFRJ, 2007.
- [68] BISHOP, J. M., MITCHELL, R. J., “Neural Networks – an introduction”. In: *IEEE Colloquium on Neural Networks for Systems*. PP. 1/1 -1/3, 1991.

[69] RIEDMILLER, M., BRAUN, H., “A direct adaptive method for faster backpropagation learning: the RPROP algorithm”. In: *IEEE International Conference on Neural Networks*, v. 1, pp. 586-591, 1993.

[70] HANSELMAN, D. C., LITTLEFIELD, B. C., *Matlab 6 Curso Completo*. Prentice Hall, 2003.

## Anexo A

### Eletrodomésticos

As tabelas A.1 e A.2 apresentam uma lista dos eletrodomésticos usados no presente estudo.

Tabela A.1: Lista de eletrodomésticos utilizados da classe 1 à 4

<b>ELETRODOMÉSTICOS POR CLASSE</b>	<b>NÚMERO DE EQUIPAMENTOS</b>
<b>COMPRESSORES</b>	<b>10</b>
Ar condicionado	4
Bebedouro	1
Geladeira	5
<b>RESISTIVOS</b>	<b>28</b>
Aquecedor de água	2
Cafeteira	2
Churrasqueira elétrica	1
Chuveiro	2
Espremedor de frutas	1
Ferro de passar	5
Ferro de solda	1
Forno elétrico	5
Máquina de vapor	1
Sanducheira	3
Secador de cabelo	4
Torradeira	1
<b>MOTORES UNIVERSAIS</b>	<b>13</b>
Aspirador de pó	2
Batedeira	2
Enceradeira	1
Furadeira	2
Liquidificador	5
Processador de alimentos	1
<b>MOTORES DE VENTILAÇÃO</b>	<b>10</b>
Ventilador	5
Circulador	5

Tabela A.2: Lista de eletrodomésticos utilizados da classe 5 à 11.

<b>ELETRODOMÉSTICOS POR CLASSE</b>	<b>NÚMERO DE EQUIPAMENTOS</b>
<b>ELETRÔNICOS</b>	<b>23</b>
CD player	1
PC Desktop	3
DVD	1
Equipo de som	1
Impressora	1
Laptop	2
Receiver AM/FM	1
Televisor CRT 14 polegadas	3
Televisor CRT 20 polegadas	3
Televisor CRT 29 polegadas	2
Videocassete	5
<b>LÂMPADAS INCANDESCENTES</b>	<b>13</b>
<b>LÂMPADAS FLUORESCENTES DE REATOR ELETRÔNICO</b>	<b>19</b>
<b>LÂMPADAS FLUORESCENTES DE REATOR ELETROMAGNETICO</b>	<b>4</b>
<b>MÁQUINAS DE LAVAR</b>	<b>2</b>
<b>MONITORES CRT</b>	<b>4</b>
<b>MONITORES LCD</b>	<b>3</b>