



**Universidade Estadual de Campinas**  
Faculdade de Engenharia Elétrica e Computação  
Departamento de Engenharia de Sistemas



# **Sistema de Suporte à Decisão para Análise e Previsão de Carga por Barramento**

*Autor:* **Ricardo Menezes Salgado**

*Orientador:* Prof Dr. Takaaki Ohishi

*Co-Orientador(a):* Prof(a). Dr(a). Rosangela Ballini

Tese de Doutorado submetida à Faculdade de Engenharia Elétrica e de Computação como parte dos requisitos para obtenção do título de **Doutor** em Engenharia Elétrica. Área de concentração: Engenharia de Computação.

## **Banca Examinadora:**

Prof. Dr. Takaaki Ohishi (FEEC/UNICAMP).

Prof. Dr. Marcos Trevisan Vasconcellos (PUC Minas).

Dr. Evandro Luiz Mendes (DPP/GMC/ONS).

Prof. Dr. Secundino Soares Filho (FEEC/UNICAMP).

Prof. Dr. Romis R. De Faissol Attux (FEEC/UNICAMP).

**Campinas - SP** 26 de Fevereiro de 2009.

FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

Salgado, Ricardo Menezes

Sa32s Sistema de suporte à decisão para análise e previsão de carga por barramento / Ricardo Menezes Salgado. – Campinas, SP: [s.n.], 2009.

Orientadores: Takaaki Ohishi, Rosangela Ballini.

Tese de Doutorado - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Sistemas de suporte à decisão. 2. Sistemas de energia elétrica - Distribuição de carga. 3. Inteligência artificial. 4. Análise de *cluster*. 5. Análise de séries temporais. I. Ohishi, Takaaki. II. Ballini, Rosangela. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Título em Inglês:	Decision support system to the analysis and bus load forecasting
Palavras-chave em Inglês:	Decision support systems, Electric power systems - Load dispotching, Artificial intelligence, Cluster analysis, Time series analysis
Área de concentração:	Engenharia de Computação
Titulação:	Doutor em Engenharia Elétrica
Banca Examinadora:	Marcos Trevisan Vasconcellos, Evandro Luiz Mendes, Secundino Soares Filho, Romis R. De Faissol Attux
Data da defesa:	26/02/2009
Programa de Pós Graduação:	Engenharia Elétrica

## COMISSÃO JULGADORA - TESE DE DOUTORADO

**Candidato:** Ricardo Menezes Salgado

**Data da Defesa:** 26 de fevereiro de 2009

**Título da Tese:** "Sistema de Suporte a Decisão para Análise e Previsão de Carga por Barramento"

Prof. Dr. Takaaki Ohishi (Presidente): Takaaki Ohishi

Prof. Dr. Marcos Trevisan Vasconcelos: Marcos Vasconcelos

Dr. Evandro Luiz Mendes: Evandro Luiz Mendes

Prof. Dr. Romis Ribeiro de Faissol Attux: Romis

Prof. Dr. Secundino Soares Filho: Secundino Soares F



# Resumo

Na operação de um sistema elétrico de potência (SEP) existem diversas variáveis que influenciam as rotinas de planejamento, operação e controle. O monitoramento destas variáveis é importante para auxiliar os processos responsáveis pela operação segura e confiável no sistema. Dentre estas variáveis pode-se destacar o nível de carga elétrica por barramento como uma variável de grande impacto na operação do SEP. Informações precisas sobre o nível de carga em cada barramento da rede elétrica proporcionam um melhor controle no fluxo de potência, na análise de estabilidade e segurança, no despacho econômico, no planejamento e na programação da operação.

Visando atender estas necessidades, este trabalho apresenta duas contribuições na análise de séries temporais de carga por barramento. A primeira contribuição é o desenvolvimento de uma metodologia de previsão de carga por barramento rápida e efetiva. A segunda contribuição é um sistema computacional denominado *SysPrev - Sistema de Suporte para Análise e Previsão de Carga por barramento* desenvolvido para facilitar o processo de cálculo das previsões por barramento.

O modelo de previsão de carga por barramento é composto por duas etapas: Na primeira, os barramentos são agrupados de acordo com a similaridade do perfil de carga diária. Na segunda etapa, aplica-se um modelo de previsão de carga em cada grupo, e a partir destas previsões por grupo são obtidas as previsões em cada barramento.

O *SysPrev* é um *software* composto por um subsistema gerenciador de dados, um subsistema de modelos e um subsistema de interfaces. O subsistema administrador de dados é composto de um banco de dados que armazena as séries temporais entre outras informações relevantes. O subsistema de modelos é composto por aplicativos que auxiliarão no processo de análise de dados e previsões. Para facilitar a interação do usuário com o sistema, o subsistema de interfaces conta com pacotes de janelas gráficas que proporcionam um ambiente computacional amigável e eficiente, facilitando a interação do *SysPrev* e seus usuários.

Um diferencial do *SysPrev* é a sua construção modularizada baseada em componentes *plug-and-play* que possibilita a inserção de novas funcionalidades. Com esta arquitetura, cada componente é produzido de maneira independente, podendo ser inserido no *software* sem a necessidade de alterações no sistema principal. Este fator é importante, pois fornece ao usuário a opção de personalizar e criar novas ferramentas de análise, facilitando a atualização e manutenção no sistema.

Neste trabalho, o *SysPrev* foi utilizado para analisar um conjunto de dados formado por 73 barramentos. A praticidade e facilidade em criar múltiplos cenários possibilitou o rápido entendimento dos dados gerando bons resultados nas previsões, possibilitando maior precisão na etapa de operação do sistema em geral.

**Palavras Chaves:** Sistema de Suporte à Decisão, Sistemas de Energia Elétrica - Distribuição de Carga, Inteligencia Artificial, Análise de *Cluster*, Análise de Séries Temporais.

# Abstract

In a power operation system there are many variables that can influence the execution of the control routines. The attendance of these variables is very important to aid the processes in the safe operation of the system. In the electric system the bus load level is an important variable in the operation planning step. Accurate information on the load level in each bus provide a better control in the power flow, safe and security analysis, operation programming, planning and others.

Thus, this work presents two contributions to the bus load forecasting area. The first contribution is the development of a bus load forecast methodology that executes and provides the forecast results for several buses in an aggregate way. The second contribution is a computational system for bus load forecasting named *SysPrev - Support System for Bus Load Analysis and Forecasting* - developed to facilitate the bus load forecasting process.

The aggregate bus load forecasting model is composed by two steps: In the first phase a clustering algorithm is used to identify buses clusters with similar daily load profile and in the second phase is proposed an aggregate structure for to foresee each bus using a conventional prediction model.

The *SysPrev* is a software composed of a data manager subsystem, a model subsystem and a graphical interfaces subsystem. The data manager subsystem is composed of a database that contains bus load time series and other relevant information. The model subsystem is composed of forecasting and clustering techniques. To facilitate the user's interaction, the graphical interface has packages of graphic windows that provide a friendly environment facilitating the integration of the *SysPrev* and their users.

An excellent characteristic of the *SysPrev* is its construction based on components plug-and-play that allows the insert of new functionalities. With this architecture, each component is produced on an independent way, could be inserted in the software without alterations in the main system. This factor is important, because it supplies the user with the option of customizing and cre-

ating new analysis tools, facilitating the updating and the maintenance of the system.

The *SysPrev* was applied to a real power system data composed of 73 buses. The easiness of creating multiple sceneries made possible the fast understanding of the data providing good results in the forecasts, making possible larger precision on the power system operation step.

**Keywords:** Decision Support Systems, Electric Power Systems - Load Dispotching, Artificial Intelligence, Cluster Analysis, Time Series Analysis.

*Dedico este trabalho a quatro pessoas especiais em minha vida:  
minha esposa **Juliana**, meu pais **José** e **Enaide** e meu irmão **Marcelo**.*

*Este projeto contou com o suporte financeiro da Fundação de Amparo à Pesquisa do Estado de São Paulo - FAPESP.*

# Agradecimentos

Não tenho palavras para agradecer a bondade do Senhor Deus em minha vida, que por sua excelente vontade, proporcionou os meios necessários para que esta pesquisa pudesse ser realizada.

Agradeço à meus pais José e Enaíde que são co-autores de todas as minhas conquistas e sempre estarão presentes em minha vida. Agradeço também ao meu irmão Marcelo que em momentos difíceis foi um ponto de apoio fundamental.

Expresso a minha profunda gratidão à minha esposa, Juliana, que com todo o seu carinho e amor, esteve presente em todas as horas me confortando e sempre me auxiliando. À família Russano pelos momentos alegres e pelas orações.

Aos professores orientadores Takaaki Ohishi e Rosangela Ballini pela amizade, paciência e orientação na execução e no desenvolvimento desta pesquisa. Aos amigos do COSE aos quais não poderia esquecer de mencionar alguns nomes especiais: Prof. Secundino Soares, Aníbal, André (Manolo), Adriano, Elma, Joaquim, Makoto, Marquito da Gaita, Leonardo, Oderson, Mônica, Thaís, Maiana. A todos vocês expresso minha profunda gratidão pelos momentos descontraídos e alegres. A Engl. Maria da Conceição Guedes Alcoforado (ONS/NE) pela concessão do banco de dados utilizado nesta pesquisa. Agradeço também as pessoas que de alguma forma contribuíram com a concretização deste sonho.

À FAPESP pelo suporte financeiro e o apoio fundamental ao desenvolvimento deste projeto.

**... Muito obrigado a todos!!!**

*“É o SENHOR quem dá sabedoria; a sabedoria  
e o entendimento vêm dele. **Prouvérbios 2:6***

# Sumário

<b>Resumo</b>	p. v
<b>Abstract</b>	p. vii
<b>Sumário</b>	p. xiii
<b>Lista de Tabelas</b>	p. xix
<b>Lista de Figuras</b>	p. xxi
<b>Notação</b>	p. xxvii
<b>1 Enfoque e Motivação</b>	p. 29
1.1 Sistema Elétrico Brasileiro . . . . .	p. 30
1.2 O Processo Previsão de Carga . . . . .	p. 31
1.3 Ferramentas de Auxílio à Previsão de Carga . . . . .	p. 33
1.4 Sistema Computacional de Previsão de Carga por Barramento . .	p. 37
1.5 Objetivos Principais . . . . .	p. 38
1.6 Organização da Tese . . . . .	p. 39

<b>2 Carga Por Barramento: Previsão e Características</b>	p. 43
2.1 Descrição do Problema . . . . .	p. 44
2.2 Revisão Bibliográfica . . . . .	p. 49
2.3 Carga Elétrica Por Barramento . . . . .	p. 55
2.3.1 Alterações nas Características da Carga dos Barramentos .	p. 57
2.4 Análise de Agrupamentos . . . . .	p. 58
2.4.1 Exemplo de Aplicação . . . . .	p. 59
<b>3 Metodologia de Previsão de Carga por Barramento</b>	p. 63
3.1 Motivação . . . . .	p. 64
3.2 Modelo Agregado - Simples Ilustração . . . . .	p. 64
3.2.1 Exemplo: Previsão Individual . . . . .	p. 66
3.2.2 Exemplo: Previsão Agregada . . . . .	p. 68
3.2.2.1 Caso Elementar - Previsão Agregada . . . . .	p. 70
3.3 Generalização do Modelo . . . . .	p. 72
3.3.1 Procedimento Geral . . . . .	p. 73
3.3.1.1 Estrutura Individual . . . . .	p. 75
3.3.1.2 Estrutura Agregada . . . . .	p. 76
3.3.2 Dimensionalidade da Estrutura Agregada . . . . .	p. 78
3.4 Processo de Compressão de Informação . . . . .	p. 79
3.4.1 Importância da redução da dimensionalidade . . . . .	p. 80
3.4.2 Análise de Componentes Principais - PCA . . . . .	p. 80
3.4.3 Algoritmo PCA . . . . .	p. 83
3.4.4 Redução de Dimensionalidade nos Barramentos via PCA .	p. 85

<b>4 Sistema de Suporte - <i>SysPrev</i></b>	p. 87
4.1 Descrição Introdutória . . . . .	p. 88
4.1.1 Sistemas de Suporte . . . . .	p. 88
4.2 Previsão de Carga - <i>SysPrev</i> . . . . .	p. 91
4.2.1 Exemplo: Processo de Previsão - <i>SysPrev</i> . . . . .	p. 91
4.2.1.1 Carregamento e Preparação dos Dados . . . . .	p. 92
4.2.1.2 Agrupamento . . . . .	p. 98
4.2.1.3 Previsão e Análise de Resultados . . . . .	p. 99
<b>5 Sistema Computacional - <i>SysPrev</i></b>	p. 103
5.1 Estratégia de Desenvolvimento . . . . .	p. 104
5.1.1 Características Técnicas . . . . .	p. 105
5.2 Sistema <i>SysPrev</i> . . . . .	p. 107
5.2.1 Modelo de Interface Gráfica . . . . .	p. 108
5.3 Descrição das Funcionalidades . . . . .	p. 111
5.3.1 Inicialização do Sistema . . . . .	p. 112
5.3.2 Gerenciadores de Acesso . . . . .	p. 113
5.3.3 Controle de Execução . . . . .	p. 114
5.3.4 Controle de Dados . . . . .	p. 116
5.3.4.1 Visualização de Resultados - Controle de Dados . .	p. 119
5.3.5 Controle de Estudos . . . . .	p. 123
5.3.5.1 Estudos de Agrupamento . . . . .	p. 127
5.3.5.2 Estudos de Previsão Individual (PI) . . . . .	p. 130
5.3.5.3 Estudos de Previsão Agregada . . . . .	p. 134
5.4 <b>Ferramentas - <i>SysPrev</i></b> . . . . .	p. 136

5.4.0.1	Pacote Gráfico - <i>SysPrev</i> . . . . .	p. 138
5.4.0.2	Pacote Matricial - <i>SysPrev</i> . . . . .	p. 139
<b>6</b>	<b>Sistema Baseado em Componentes</b>	p. 141
6.1	Motivação . . . . .	p. 142
6.2	Componentes <i>Plug-and-Play</i> . . . . .	p. 143
6.2.1	Desenvolvimento de <i>Plugins</i> . . . . .	p. 144
6.2.2	<i>Interfaces</i> . . . . .	p. 145
6.2.2.1	<i>Interfaces</i> para Modelos de Previsão . . . . .	p. 146
6.2.2.2	<i>Interfaces</i> em Modelos de Agrupamento . . . . .	p. 148
6.2.3	Exemplos - Componentes Implementados . . . . .	p. 150
6.2.4	Exemplo - Acesso a Métodos com Polimorfismo . . . . .	p. 151
6.3	Inserção, Atualização e Remoção de Componentes . . . . .	p. 154
6.3.1	Gerenciador de Componentes . . . . .	p. 155
<b>7</b>	<b>Estudo de Casos</b>	p. 157
7.1	Descrição . . . . .	p. 158
7.1.1	Informações Relevantes no Processo de Previsão . . . . .	p. 160
7.1.1.1	Agrupamentos . . . . .	p. 160
7.1.1.2	Rede Neural Artificial . . . . .	p. 161
7.2	Resultados Numéricos - Caso Geral . . . . .	p. 161
7.2.1	Previsão: Dia Específico. . . . .	p. 162
7.2.1.1	Comentários - Metodologia Agregada . . . . .	p. 171
7.2.2	Previsão: 7 dias Consecutivos . . . . .	p. 173
7.3	Análise de Sensibilidade . . . . .	p. 175

7.3.1	Resultados: Diferentes Conjuntos de Entrada . . . . .	p. 176
7.3.2	Resultados: Mudanças nos Agrupamentos . . . . .	p. 179
7.3.3	Resultados: Processo de Redução de Dimensionalidade . .	p. 183
7.3.4	Resultados: Alteração no Período de Previsão . . . . .	p. 188
<b>8</b>	<b>Conclusões, Comentários e Contribuições</b>	p. 195
8.1	Conclusões e Contribuições . . . . .	p. 195
8.2	Comentários e Trabalhos Futuros . . . . .	p. 197
	<b>Referências</b>	p. 199
	<b>Apêndice A – Consumo de Energia e Previsão de Carga</b>	p. 207
A.1	Consumo de Energia . . . . .	p. 207
A.2	O Problema de Previsão de Carga . . . . .	p. 211
A.2.1	Série de Potência Elétrica . . . . .	p. 212
A.2.1.1	Fatores que Influenciam a Carga . . . . .	p. 214
A.2.2	Modelos Previsão de Carga . . . . .	p. 215
A.2.2.1	Horizontes de Previsão de Carga . . . . .	p. 217
	<b>Apêndice B – Modelagem - Banco de Dados SysPrev</b>	p. 219
B.1	Análise Metodológica . . . . .	p. 219
B.1.1	Arquitetura de Banco de Dados . . . . .	p. 219
B.1.2	Sistemas Gerenciadores de Banco de Dados . . . . .	p. 220
B.1.2.1	<i>MySQL</i> . . . . .	p. 222
B.2	Projeto de Banco de Dados . . . . .	p. 223
B.2.1	Modelagem Proposta . . . . .	p. 224

B.2.1.1	Modelo Conceitual . . . . .	p. 225
B.2.1.2	Modelo Lógico . . . . .	p. 226
B.2.1.3	Tabelas e Relacionamentos . . . . .	p. 228
B.2.1.4	Avaliação - Base de Dados . . . . .	p. 235
B.3	Comentários . . . . .	p. 238

# Lista de Tabelas

2.1	Informações Estatísticas. . . . .	p.56
2.2	Análise de Agrupamentos. . . . .	p.61
3.1	Exemplo: Dimensão dos Barramentos. . . . .	p.79
5.1	Ícones: Conexão e Acesso - <i>SysPrev</i> . . . . .	p.112
5.2	Ícones: Gerenciamento de Dados - <i>SysPrev</i> . . . . .	p.115
7.1	Comparativo MAPE: Individual $\times$ Agregado. . . . .	p.163
7.2	MAPE: Grupo #14. . . . .	p.164
7.3	MAPE: Grupo #13. . . . .	p.165
7.4	MAPE Horário - 25/09/2001   Barramento #47. . . . .	p.171
7.5	Esforço Computacional - Metodologia de Previsão. . . . .	p.172
7.6	MAPE: Dias Consecutivos - 20 a 26/9/2001. . . . .	p.174
7.7	Comparativo: Tempo de Processamento Computacional. . . . .	p.175
7.8	MAPE: Influência das Entradas   14 Grupos. . . . .	p.179
7.9	MAPE: 7 dias Consecutivos - 20 a 26/9/2001. . . . .	p.181
7.10	Exemplo: Redução de Dimensionalidade - PCA. . . . .	p.185
7.11	MAPE: Dias Consecutivos - 20 a 26/9/2001. . . . .	p.186
7.12	MAPE: Dias Consecutivos - 27/09 a 03/10/2001. . . . .	p.189

7.13 MAPE: Individual × Agregado   02/10/2001. . . . .	p. 190
B.1 Exemplo: Tabela <i>SIN_Regional</i> . . . . .	p. 229
B.2 Exemplo: Tabela <i>Sist_Transmissao</i> . . . . .	p. 230
B.3 Exemplo: Tabela <i>BARRAMENTOS</i> . . . . .	p. 231
B.4 Exemplo: Tabela <i>CARGA</i> . . . . .	p. 233
B.5 Exemplo: Tabela <i>DATAS</i> . . . . .	p. 233
B.6 Exemplo: Tabela <i>CLIMATICA</i> . . . . .	p. 234

# Lista de Figuras

1.1	Exemplo: Visão Parcial do Sistema Interligado Norte/Nordeste. . . . .	p. 31
1.2	Tela de Abertura - <i>SysPrev</i> . . . . .	p. 38
1.3	Modelagem - Sistema Computacional Proposto. . . . .	p. 39
2.1	Perfil de Consumo - Barramento #47. . . . .	p. 45
2.2	Perfil de Consumo - Barramento #59. . . . .	p. 46
2.3	Exemplo: Rede Elétrica Simples. . . . .	p. 47
2.4	Curva Estimada - Barramentos. . . . .	p. 47
2.5	Motivação para Normalização de Barramentos. . . . .	p. 57
2.6	Mudança no perfil diário - Barramento #46. . . . .	p. 58
2.7	Exemplo: Grupos com 2 ou mais Barramentos. . . . .	p. 61
2.8	Exemplo: Grupos com Barramentos Individuais. . . . .	p. 62
3.1	Carga 16h - Barramento #40. . . . .	p. 66
3.2	Exemplo: Modelo de Previsão para o Barramento #40. . . . .	p. 67
3.3	Exemplo: Modelo de Previsão para o Barramento #33. . . . .	p. 67
3.4	Diagrama de Estrutura Agregada. . . . .	p. 69
3.5	Esquema: Topologia Neural - (Caso Agregado). . . . .	p. 70
3.6	Fluxograma - Metodologia Agregada. . . . .	p. 74

3.7	Exemplo: Sistema de Eixos - PCA. . . . .	p. 82
4.1	Esquema Funcional - <i>SysPrev.</i> . . . . .	p. 90
4.2	Exemplo: Inserção e Controle de Dados - <i>SysPrev.</i> . . . . .	p. 93
4.3	Exemplo: Inserção de Dados - <i>SysPrev.</i> . . . . .	p. 94
4.4	Exemplo: Importador de Dados (Tela 1) - <i>SysPrev.</i> . . . . .	p. 94
4.5	Exemplo: Importador de Dados (Tela 2) - <i>SysPrev.</i> . . . . .	p. 95
4.6	Exemplo: Funções de Normalização - <i>SysPrev.</i> . . . . .	p. 95
4.7	Exemplo: Normalização   Função Máximo - <i>SysPrev.</i> . . . . .	p. 96
4.8	Exemplo: Normalização   Função Primeira Diferença - <i>SysPrev.</i> . . . . .	p. 96
4.9	Exemplo: Apresentação de Dados - <i>SysPrev.</i> . . . . .	p. 97
4.10	Exemplo: Gráfico de Correlograma. . . . .	p. 98
4.11	Exemplo: Configurações - Agrupamento. . . . .	p. 99
4.12	Exemplo: Resultados - Agrupamento. . . . .	p. 100
4.13	Exemplo: Configuração - Previsão Agregada. . . . .	p. 100
4.14	Exemplo: Resultados - Previsão Agregada. . . . .	p. 101
5.1	<i>Layout</i> da Interface Gráfica com o Usuário. . . . .	p. 109
5.2	Ambiente de Estudos e Análise - <i>SysPrev.</i> . . . . .	p. 110
5.3	Tela de Principal - <i>SysPrev.</i> . . . . .	p. 111
5.4	Menus e Barra de Ferramentas - Tela Inicial <i>SysPrev.</i> . . . . .	p. 112
5.5	Tela Login - <i>SysPrev.</i> . . . . .	p. 114
5.6	Tela Principal - Usuário Ativo: ricardo. . . . .	p. 114
5.7	Tela Controles - <i>SysPrev.</i> . . . . .	p. 115
5.8	Abas de Manipulação - Controle de Dados. . . . .	p. 117
5.9	Exemplo: Abas de Carregadas - Controle de Dados. . . . .	p. 118

5.10	Exemplo: Menu Flutuante - Abas   <i>SysPrev</i> . . . . .	p. 119
5.11	Exemplo: Normalização de Dados   <i>SysPrev</i> . . . . .	p. 120
5.12	Visualização Gráfica I - <i>SysPrev</i> . . . . .	p. 120
5.13	Visualização Gráfica II - <i>SysPrev</i> . . . . .	p. 121
5.14	Visualização Gráfica III - <i>SysPrev</i> . . . . .	p. 122
5.15	Visualização Gráfica IV - <i>SysPrev</i> . . . . .	p. 123
5.16	Ambiente de Navegação - Controle de Estudos. . . . .	p. 124
5.17	Tela Principal - Criação de Estudos. . . . .	p. 126
5.18	Navegação em Árvores - Controle de Estudos. . . . .	p. 126
5.19	Configurações - Estudo Agrupamento. . . . .	p. 128
5.20	Tela de Escolha de Dados - Estudo Agrupamento. . . . .	p. 129
5.21	Parâmetros de Configurações - Técnicas de Agrupamento. . . . .	p. 129
5.22	Tela de Resultados - Estudo Agrupamento. . . . .	p. 130
5.23	Configuração - Previsão Individual. . . . .	p. 131
5.24	Escolha de Dados - Modelo de Previsão. . . . .	p. 132
5.25	Seleção de Entradas - Modelo de Previsão. . . . .	p. 132
5.26	Configuração Avançada - Previsores. . . . .	p. 133
5.27	Tela de Resultados - Previsão Individual. . . . .	p. 134
5.28	Tela de Configuração - Previsão Agregada. . . . .	p. 135
5.29	Tela de Resultados - Previsão Agregada. . . . .	p. 136
5.30	Tela de Principal - <i>SysPrev</i>   ( <i>en_US</i> ). . . . .	p. 137
6.1	Modelo Intuitivo - <i>Interface</i> × Componentes. . . . .	p. 145
6.2	Modelo <i>Interfaces</i> : Previsor. . . . .	p. 150
6.3	Modelo <i>Interfaces</i> : Agrupamento. . . . .	p. 152

6.4	Método <b>getJPanelConfiguracoes()</b> - Previsão. . . . .	p. 153
6.5	Método <b>getJPanelConfiguracoes()</b> - Agrupamento. . . . .	p. 153
6.6	Diretório de Ferramentas. . . . .	p. 155
7.1	Conjunto Entradas (PAF) - Barramento #40   Hora 16. . . . .	p. 162
7.2	MAPE - Grupo #9. . . . .	p. 166
7.3	MAPE - Grupo #11. . . . .	p. 166
7.4	Curva: Prevista × Verificada - Barramento #59   25/09/2001. . .	p. 167
7.5	MAPE - Barramento #59   25/09/2001. . . . .	p. 168
7.6	Erro de Previsão - Barramento #59   25/09/2001. . . . .	p. 169
7.7	Curva: Prevista × Verificada - Barramento #47   25/09/2001. . .	p. 169
7.8	Erro Horário - Barramento #47   25/09/2001. . . . .	p. 170
7.9	Conjunto Entradas (DA) - Barramento #40   Hora 16. . . . .	p. 177
7.10	Curva: Prevista × Verificada - Barramento #47   25/09/2001. . .	p. 178
7.11	Curva: Prevista × Verificada - Barramento #59   25/09/2001. . .	p. 178
7.12	Curva: Prevista × Verificada - Barramento #47   25/09/2001. . .	p. 183
7.13	Curva: Prevista × Verificada - Barramento #59   25/09/2001. . .	p. 184
7.14	MAPE: Abordagem PCA x Convencional   Grupo de Barramentos	p. 187
7.15	Curva: Prevista × Verificada - Barramento #47   25/09/2001. . .	p. 187
7.16	Curva: Prevista × Verificada - Barramento #59   25/09/2001. . .	p. 188
7.17	Curva: Prevista × Verificada - Barramento #47   02/10/2001. . .	p. 191
7.18	Curva: Prevista × Verificada - Barramento #59   02/10/2001. . .	p. 191
7.19	Erro Horário - Barramento #47   02/10/2001. . . . .	p. 192
7.20	Erro Horário - Barramento #59   02/10/2001. . . . .	p. 193
A.1	Formação da Série de Potência Elétrica. . . . .	p. 213

A.2	Modelo de Previsão Simples. . . . .	p.215
B.1	Modelo Conceitual - Banco de Dados. . . . .	p.226
B.2	Modelo Lógico - Banco de Dados. . . . .	p.227
B.3	Tabela Sistema Regional - Banco de Dados. . . . .	p.228
B.4	Tabela Sistema Transmissão - Banco de Dados. . . . .	p.229
B.5	Tabela Barramentos - Banco de Dados. . . . .	p.230
B.6	Tabela Cargas - Banco de Dados. . . . .	p.232
B.7	Tabela Datas - Banco de Dados. . . . .	p.233
B.8	Tabela Climática - Banco de Dados. . . . .	p.234
B.9	Exemplo: Select - SIN_Regional . . . . .	p.236
B.10	Exemplo: Select - DATAS . . . . .	p.237
B.11	Exemplo: Select - BARRAMENTOS . . . . .	p.238



# Notação

- ▷ **SysPrev**: Sistema de Suporte para Análise e Previsão de Carga por Barramento;
- ▷ **SEP**: Sistema Elétrico de Potência;
- ▷ **SEB**: Sistema Elétrico Brasileiro;
- ▷ **SIN**: Sistema Interligado Nacional;
- ▷ **CEPEL**: Centro de Pesquisas de Energia Elétrica;
- ▷ **SNPTEE**: Seminário Nacional de Produção e Transmissão de Energia Elétrica;
- ▷ **CPFL**: Companhia Paulista de Força e Luz;
- ▷ **CESP**: Cia Energética de São Paulo;
- ▷ **CELPA**: Centrais Elétricas do Pará;
- ▷ **INPE**: Instituto Nacional de Pesquisas Espaciais;
- ▷ **PA**: Metodologia de previsão Agregada;
- ▷ **PI**: Metodologia de Previsão Individual;
- ▷ **Ind\_RLM**: Metodologia individual com Regressão Linear Múltipla;
- ▷ **Ind\_RNA**: Metodologia Individual com Redes Neurais Artificiais MLP;
- ▷ **Agg\_RLM**: Metodologia agregada com Regressão Linear Múltipla;
- ▷ **Agg\_RNA**: Metodologia agregada com Redes Neurais Artificiais MLP;
- ▷ *MAPE*: Erro Percentual Médio Absoluto;
- ▷ *ME*: Erro Médio;
- ▷ *DSS*: *Decision Support Systems*;
- ▷ *IDE*: *Integrated Development Environment*;

- ▷ *MVC: Model View Controller;*
- ▷ *UML: Unified Modeling Language;*
- ▷ *GUI: Graphical User Interface;*
- ▷ *FCM: Fuzzy C-Means Model;*
- ▷ *PSOM: Pruning Technique Kohonen Self-Organizing Feature Map Model;*
- ▷ *SOM: Kohonen Self-Organizing Feature Map Model;*
- ▷ *SC: Subtractive Clustering Model.*
- ▷ *PCA: Principal Components Analysis;*

## Enfoque e Motivação

A tomada de decisão, em qualquer setor e nos mais diversos níveis, constitui geralmente um processo complexo principalmente em função do nível de incerteza em relação ao futuro. A disponibilidade de informações sobre cenários futuros é um fator importante para possibilitar uma decisão eficaz e com maior grau de confiabilidade. No setor elétrico esta lógica se mantém principalmente devido ao número de variáveis que devem ser consideradas no processo de planejamento e operação do sistema em geral (Sullivan, 1977). Desta forma, informações precisas são essenciais para possibilitar segurança no processo de tomada de decisões e execução de tarefas.

Em um sistema elétrico de potência (SEP), o acompanhamento da carga é uma exigência básica nos processos de operação e planejamento. Para fornecer energia elétrica com boa qualidade, de maneira segura e econômica, uma empresa precisa dispor de mecanismos que possibilitem a resolução de vários problemas de nível técnico e operacional. Com o propósito de obter melhorias no planejamento e controle do sistema, novas ferramentas têm sido desenvolvidas e aplicadas, produzindo resultados relevantes na redução de custos operativos nas empresas de geração, transmissão e distribuição de energia.

Em um sistema de potência, a produção de energia é transmitida e distribuída através da rede elétrica. Esta rede é composta de nós no qual se interligam as linhas de transmissão, transformadores e consumidores. Estes

nós são denominados barramentos ou simplesmente barras. Um barramento pode ser enxergado como um nó supridor de energia elétrica a um dado conjunto de consumidores. Associado a esse conjunto de consumidores é possível levantar um histórico de consumo, e através deste histórico realizar previsão do consumo nas próximas demandas. Para avaliar o impacto do carregamento no sistema de transmissão, é essencial que se conheça a distribuição da carga ao longo da rede, pois os carregamentos nas linhas de transmissão e nos transformadores dependem da demanda de carga em cada barramento. Dentre as aplicações de previsão de carga pode-se citar: *fluxo de potência ótimo, análise de estabilidade e segurança, despacho econômico, planejamento da produção, controle e operação de redes de transmissão/distribuição*, entre outras.

Uma maneira de fazer a previsão de carga por barramento é realizar a previsão aplicando um tratamento individual, ou seja, ajustando-se um modelo de previsão para cada série de carga. Este procedimento é viável quando trabalha-se em um sistema com poucos barramentos; entretanto, em um sistema com um número elevado de barramentos o tratamento individual não é conveniente, pois o custo computacional de se ajustar um modelo de previsão para cada barramento seria alto, dificultando a utilização dos resultados nas etapas de programação da operação diária e na operação em tempo real do sistema.

## **1.1 Sistema Elétrico Brasileiro**

O sistema elétrico brasileiro de transmissão é formado por mais de 4000 barramentos, compostos por várias tensões e perfis de consumo. Esta quantidade de barramentos faz com que o problema de previsão tenha um alto grau de dificuldade, pois necessita-se de um modelo capaz de enxergar as distinções nos barramentos e realizar a previsão de acordo com o perfil de cada região consumidora atendida.

A Figura 1.1 mostra uma visão parcial de uma rede de transmissão na área Norte/Nordeste. Observando esta figura, é possível perceber diversos barramentos que atendem diversas regiões consumidoras. As redes elétricas não são estáticas, pois estão sujeitas a expansão e desligamentos em equipamentos

bem como rotinas de desvio de cargas. Neste processo, um conjunto de consumidores pode ser transferido de um barramento para outro, e esta transferência pode modificar significativamente o comportamento do consumo em determinados barramentos.

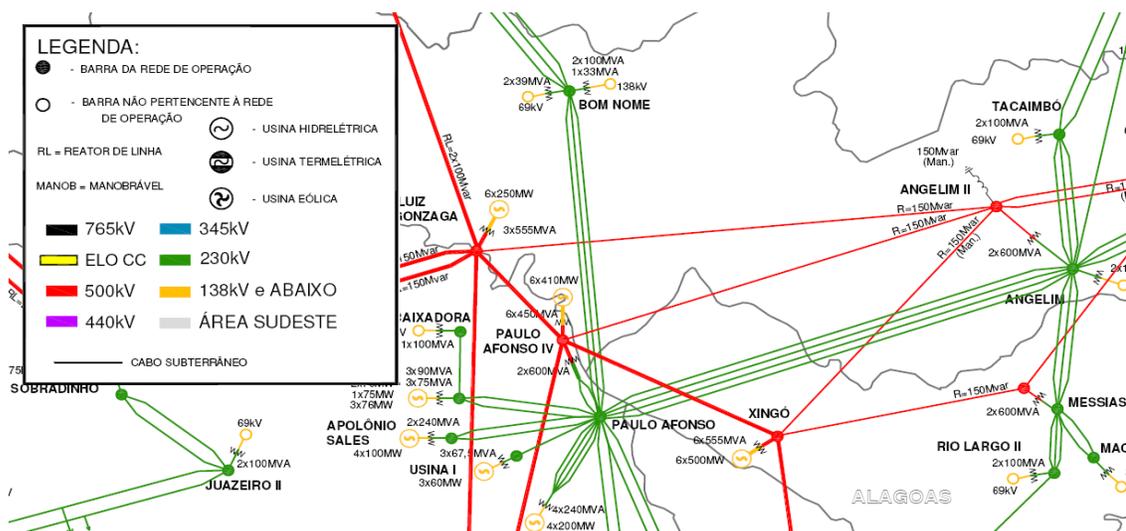


Figura 1.1: Exemplo: Visão Parcial do Sistema Interligado Norte/Nordeste<sup>1</sup>.

De uma maneira geral, tanto o problema de previsão de carga global quanto o problema de previsão de carga por barramento são complexos devido à influência de vários fatores, entre os quais pode-se citar a não-linearidade presente nas séries e as variáveis exógenas (temperatura, dias do calendário, dados econômicos, entre outros). No caso da previsão por barramento o problema é ainda maior, dada a dificuldade de encontrar um modelo que se adapte bem aos diversos tipos de barramentos do sistema elétrico, lembrando que os barramentos podem ter padrões de consumo completamente distintos, tornando o problema mais complexo e trabalhoso.

## 1.2 O Processo Previsão de Carga

Embora nas últimas décadas tenham ocorrido avanços na área de previsão, ainda não é possível determinar, *a priori*, qual é a melhor metodologia para

<sup>1</sup>Fonte: Mapas do SIN - Operador Nacional do Sistema (2009).

a previsão de uma série temporal. Ainda hoje, o processo de previsão de carga é feito por tentativa e erro, devendo o analista testar e escolher os parâmetros da previsão com base em sua experiência e intuição. Na prática, a etapa de análise da série de carga geralmente é um processo “artesanal”, pois todos os passos do processo necessitam da intervenção e das informações do operador. Quando se pensa em analisar somente uma única série, o procedimento manual de análise e escolha dos parâmetros do previsor é factível mesmo demandando um certo tempo para determinar a melhor configuração. No caso do problema de previsão de carga por barramento, o procedimento manual de ajuste do previsor é complexo, pois seria muito custoso analisar aproximadamente 4000 séries temporais em um curto espaço de tempo.

O processo anteriormente descrito diz respeito somente ao processo do desenvolvimento do modelo. Na realidade, há uma etapa de análise de dados, quando vários aspectos devem ser levados em consideração, tais como a consistência dos dados, a identificação dos “*outliers*”<sup>2</sup> e o levantamento de características estatísticas. Esta é uma etapa fundamental, pois a qualidade dos dados reflete diretamente no resultado da previsão e, devido à quantidade de dados existentes no problema de previsão por barramento, esse processo pode exigir grande esforço e tempo de processamento. Neste sentido, é essencial a utilização de um sistema computacional que possibilite a manipulação, visualização e levantamento estatístico de dados de forma simples e direta. Desta forma, é fundamental a disponibilidade de um sistema em que se possa realizar a visualização dos resultados, comparações e estudos com várias configurações de *dados* × *modelos*. Estas facilidades em recursos de manipulação, visualização e configuração de parâmetros são importantes no desenvolvimento de um modelo de previsão de carga efetivo, seja ele global ou por barramento.

---

<sup>2</sup>O termo *outlier* representa um dado ou medição foge ao padrão usual de comportamento da série.

## 1.3 Ferramentas de Auxílio à Previsão de Carga

Na bibliografia, não é comum encontrar ferramentas computacionais que tratem especificamente o problema de previsão de carga por barramento. Em linhas gerais, pode-se afirmar que a grande maioria dos *softwares* existentes preocupam-se apenas em realizar a previsão de carga global do sistema, não executando a análise da carga por barramento. Ao longo desta seção, será apresentado um comentário sobre alguns sistemas computacionais que realizam previsão de carga elétrica em níveis empresariais e acadêmicos.

No SEB existem alguns programas computacionais que são utilizados para fornecer as previsões de carga a curto e médio prazo. Entre os programas utilizados destacam-se o *PrevCar* e o *CaHora*, ambos desenvolvidos pelo CEPEL (Centro de Pesquisas de Energia Elétrica). O *PrevCar* (Cepel, 2000) é utilizado para fazer a previsão da carga global mensal num período de até 12 meses à frente e o *CaHora* (Suarez-Farinas et al., 2004) é aplicado para fornecer a previsão de carga a curto prazo em base horária ou de meia hora. Uma descrição detalhada de ambas as abordagens pode ser encontrada no trabalho de (Azevedo-Filho, 2000). Em linhas gerais, os sistemas (*PrevCar* e *CaHora*) trabalham com um conjunto de modelos que contém desde técnicas estatísticas até modelos baseados em lógica *fuzzy*.

O sistema desenvolvido pela empresa *ETAP Enterprise Solution* apresenta uma proposta para o problema de previsão de carga por barramento. Segundo a descrição encontrada nos informes técnicos do *software* (ETAP, 2009), o sistema faz a previsão de carga global e por barramento levando em consideração fatores climáticos e proporcionando diversas visualizações dos dados históricos. Infelizmente, devido à propriedade intelectual, as informações sobre o sistema desenvolvido não são suficientemente claras para tecer uma análise sobre o programa.

*Energy Forecasting* é uma ferramenta desenvolvida e comercializada pela *Itron*, que tem como proposta principal o fornecimento de ferramentas para análise de dados e previsão de carga. De acordo com as informações disponibilizadas (Itron, 2009), o sistema proporciona funcionalidades para auxiliar a

operação diária do sistema, planos de marketing e análise de risco. Este sistema não detalha as previsões a nível do barramento, não sendo contemplada esta análise neste pacote computacional.

Por meio da ramificação *Advantica Eletric*, a corporação *Advantica Inc.* tem uma proposta interessante através do sistema computacional *SynerGEE Electric*. Segundo as informações técnicas (Advantica, 2009), este sistema é capaz de realizar a previsão e modelagem da carga, sendo ideal para análise de sistemas de potência. Como este *software* é proprietário, o acesso a informações detalhadas é limitado, não sendo possível avaliá-lo de forma completa. Nas descrições do pacote de funcionalidades, o *SynerGEE Electric* não é mencionada a previsão de carga por barramento. Neste sentido, pelas informações disponíveis, este *software*, apesar de possuir várias facilidades não é capaz de realizar a previsão da carga em cada nó do sistema elétrico.

A *NewFound Energy Ltd* desenvolve o aplicativo (*hardware e software*) *ATLAS Load Control* para controlar o pico de carga, medir e realizar as previsões (*ATLAS 2000*). Este conjunto proporciona o controle e o monitoramento através de um sistema computacional. A descrição técnica do sistema (NewFound, 2009) não menciona nenhuma estrutura específica para o problema de previsão de carga por barramento, sendo comentada apenas a possibilidade da previsão de carga individual.

O sistema *Energy Control Systems (ECS)*, comercializado pela *SNC-Lavalin*, possui, entre as suas funcionalidades, um pacote para realizar a previsão de carga (SNC-Lavalin, 2009). Por se tratar de um sistema comercial, as informações detalhadas sobre como a previsão é realizada não estão acessíveis, não sendo possível definir se o sistema possui ou não um processo dedicado para a previsão de carga por barramento.

A empresa *EFACEC Sistemas de Electronica* comercializa o sistema *SCADA EMS* responsável por realizar a análise e o monitoramento de um sistema elétrico (EFACEC, 2009). Juntamente com outras funcionalidades, este sistema dispõe de um pacote específico para realizar a previsão de carga a curto prazo. De maneira similar aos casos anteriores, as informações técnicas não

estão disponíveis; logo não é possível, comentar como o processo da previsão de carga é realizado. Com relação ao problema de previsão de carga por barramento, pode-se inferir somente que esta funcionalidade não está listada nos pacotes disponíveis neste aplicativo.

Outra abordagem de previsão é disponibilizada pela *Toshiba Corporation - Power Systems & Services Company* que comercializa uma ferramenta de controle e monitoramento denominada Toscan-3500 - (Toshiba EMS/SCADA/DAS Network) (Toshiba, 2009). Neste sistema, de acordo com a descrição técnica, há uma implementação uma ferramenta de previsão de carga global e por barramento. Entretanto, não foram encontrados detalhes sobre a forma com que estas previsões são executadas nem como é feito o acesso às funcionalidades existentes neste aplicativo, inviabilizando uma análise detalhada e completa no sistema.

Em termos acadêmicos é possível encontrar nos artigos científicos alguns sistemas computacionais especializados em realizar a previsão de carga. No trabalho de (Silva, R., Reis e Moulin, 2001) é apresentado um sistema computacional de previsão de carga denominado *NeuroDem - (Neural Demand)*. Este sistema foi desenvolvido e é aplicado para realizar a previsão de curtíssimo prazo (15 minutos a frente) em regiões de consumo no Brasil. Apesar do sistema *NeuroDem* possuir um excelente conjunto de funções bem como processos de comunicação com outros sistemas de aquisição de dados, ele não trata especificamente o problema de previsão de carga por barramento com um modelo específico.

O mesmo grupo de pesquisa que desenvolveu o sistema *NeuroDem* também propôs em um trabalho apresentado no XIV SNPTEE<sup>3</sup>, na cidade de Campinas, SP, a ferramenta de previsão de carga *Oráculo - Uma Ferramenta para Previsão de Carga* (Silva, R., Reis, Moulin e Neto, 2001). Este trabalho foi realizado em parceria com a empresa FURNAS/SE, onde o sistema foi aplicado. Em linhas gerais, o programa *Oráculo* realiza previsões de carga de forma automática com discretização de 15 minutos. O mesmo inconveniente encontrado no *NeuroDem* é replicado ao sistema *Oráculo* se levado em consideração o quesito previsão de carga por barramento, no qual os dois sistemas não possuem funcionalidades específicas.

---

<sup>3</sup>Seminário Nacional de Produção e Transmissão de Energia Elétrica.

No trabalho de (Vieira et al., 2001), é apresentado um sistema computacional para realizar o dimensionamento da carga de ponta no estado de São Paulo. Este programa foi submetido a diversos testes de previsões de demanda nas diversas empresas do estado de São Paulo<sup>4</sup>, tendo, segundo os autores, resultados satisfatórios. Novamente, não há a disponibilidade de ferramentas específicas para realizar previsões de carga por barramento, ficando, em aberto, esta funcionalidade neste sistema.

Um sistema de suporte à decisão para predição de cargas é proposto no trabalho de (Rocha et al., 2006). Este artigo apresenta um sistema para predição de cargas baseado em métodos de séries temporais, com a finalidade de definir qual é o consumo em dada região. O sistema também possibilita o estabelecimento de correlações de grandezas utilizando redes *Bayesianas*. As simulações foram realizadas utilizando uma base de dados fornecidos pela Concessionária de Energia do Estado do Pará (CELPA), juntamente com informações climáticas do Instituto Nacional de Pesquisas Espaciais (INPE) e os dados sócio-econômicos pertencentes ao Governo do Estado do Pará. Segundo os autores, os resultados do sistema se mostraram satisfatórios. Entretanto, este *software* não possui ferramentas de previsão de carga por barramento, não sendo indicado para resolver este tipo de problema.

(Barbosa et al., 2007) apresentam uma ferramenta desenvolvida, no âmbito da pesquisa, para automatizar parte das previsões e auxiliar na realização de estudos para a empresa *Tractebel Energia S.A.*. O sistema desenvolvido neste trabalho atende especificamente às características da empresa contratante, não tendo suporte à previsão de carga por barramento. Segundo os autores, para a previsão de carga global, o sistema desenvolvido mostrou-se eficiente auxiliando a obtenção de resultados com bons níveis de precisão.

Em linhas gerais, pelas descrições anteriores, observa-se que somente alguns sistemas computacionais anteriormente comentados realizam a previsão de carga em cada barramento. Entretanto, infelizmente não foi possível analisar profundamente estes *softwares* devido à falta de informações técnicas sobre os procedimentos adotados na realização das previsões.

---

<sup>4</sup>CPFL, CESP, ELETROPAULO, e pequenas empresas.

## 1.4 Sistema Computacional de Previsão de Carga por Barramento

Conforme visto nas seções anteriores, para realizar a previsão em cada barramento do sistema de forma rápida e direta existe a necessidade da utilização de uma ferramenta específica que resolva o problema com métodos desenvolvidos para tratar os diversos perfis de carga existentes nos barramentos da malha elétrica. Nas soluções computacionais encontradas, poucas ferramentas tratavam o problema de previsão por barramento e, mesmo quando este pacote estava disponibilizado no sistema, não era possível encontrar informações suficientes para avaliar o sistema, ou até mesmo realizar uma simulação numérica para comprovar a sua eficiência.

Devido à importância do tema de previsão de carga por barramento em sistemas elétricos de potência, a motivação principal no desenvolvimento deste trabalho de doutorado foi a construção de um sistema de suporte para análise e previsão de carga elétrica à curto prazo por barramento. O sistema proposto foi desenvolvido com base nos modelos de engenharia de *software* e é composto de três módulos: **dados**, **modelos** e um **sistema de interfaces** (*Graphical User Interfaces - GUIs*) para auxiliar a configuração do sistema. Além da construção do sistema, esta pesquisa também objetivou o desenvolvimento de uma metodologia efetiva para a previsão de carga por barramento, capaz de realizar uma previsão com boa qualidade em um menor tempo de processamento.

O aplicativo de previsão desenvolvido apresenta facilidades tanto em termos de janelas gráficas como também na estrutura, visualização e utilização dos modelos. O sistema de janelas gráficas é responsável por controlar todas as estruturas existentes nos dados e modelos. Desta forma, através de comandos acionados graficamente pelos usuários, é possível fazer a integração entre as informações de carga e os modelos, apresentando os resultados de maneira amigável e simples. A Figura 1.2 apresenta a tela de abertura do programa proposto, que foi batizado de *SysPrev - Sistema de Suporte para Análise e Previsão de Carga por Barramento*.

Outro diferencial implementado no *SysPrev* foi a construção dos mode-

los (técnicas de previsão e agrupamento) com base na arquitetura dirigida a componentes modulares ou *Plug-and-Play*. Com esta abordagem, todos os modelos utilizados no sistema deixam de fazer parte do programa principal, sendo apenas blocos adicionais que podem ser inseridos a qualquer tempo sem a necessidade de reprogramação ou compilação do programa principal. Esta característica facilita as atualizações e inserções de novas ferramentas, possibilitando que o banco de modelos do sistema esteja sempre atualizado com as novas metodologias de previsão desenvolvidas na literatura.



Figura 1.2: Tela de Abertura - *SysPrev*.

A idéia expressa na Figura 1.3 mostra os relacionamentos existentes entre os módulos que compõem o sistema proposto. Observando esta figura, nota-se que a interface gráfica é responsável pelo controle de fluxo entre dados × modelos no sistema. Assim, ao acessar qualquer tipo de dado e/ou modelos, o usuário deverá especificar o tipo de comando que deseja executar para que seja feita a comunicação entre os módulos e, conseqüentemente, o resultado seja impresso na tela principal do sistema.

## 1.5 Objetivos Principais

Como comentado previamente, o objetivo principal deste trabalho é o desenvolvimento de um sistema computacional de suporte para análise e previsão de carga por barramento. Juntamente com o sistema computacional, foi desenvolvida uma técnica que possibilita a análise de vários barramentos simul-

tâneos com excelente resultado e baixo custo computacional. Os objetivos deste trabalho podem ser resumidos nos seguintes passos:

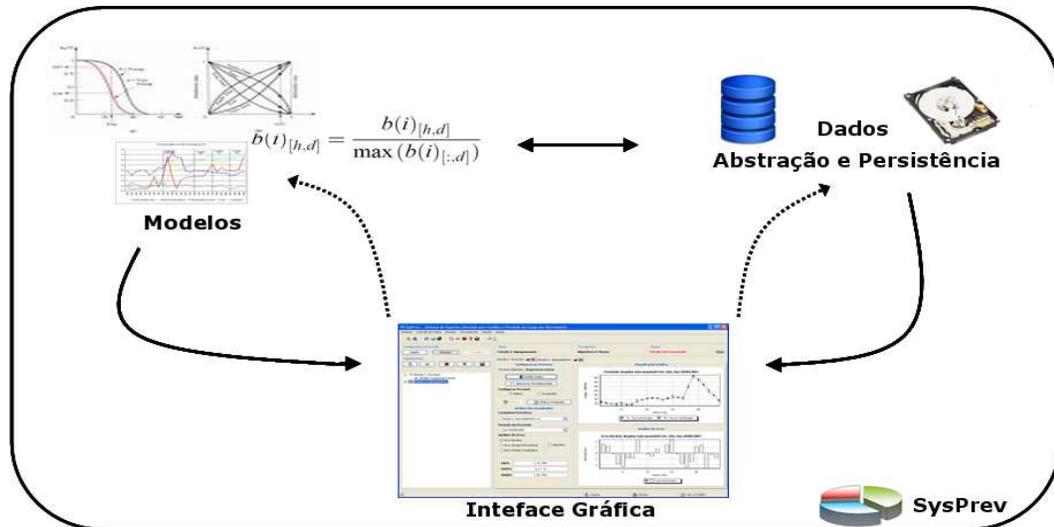


Figura 1.3: Modelagem - Sistema Computacional Proposto.

1. Análise do problema de previsão de carga por barramento e suas particularidades em relação à previsão de carga global;
2. Estudo do comportamento das séries buscando estabelecer perfis e similaridades entre os barramentos do sistema;
3. Desenvolvimento de uma sistemática de previsão capaz de estimar a carga por barramento de maneira rápida e eficiente, com bons resultados e reduzido tempo de processamento;
4. Construção de um sistema computacional de suporte à previsão, evidenciando suas contribuições no processo de previsão de carga por barramento.

## 1.6 Organização da Tese

Na redação de cada passo executado na construção das contribuições deste trabalho foi levada em consideração o caráter didático das informações,

buscando sempre definir o objetivo de cada tópico com exemplos de sua utilização. O desenvolvimento de cada fase neste trabalho de doutorado encontra-se detalhado de acordo com a seguinte seqüência:

- O presente capítulo apresenta o enfoque bem como a motivação para o desenvolvimento desta pesquisa, detalhando a seqüência do documento e o assunto que será tratado em cada tópico do presente trabalho.
- O Capítulo 2 faz uma apresentação formal do problema de previsão de carga por barramento, bem como uma revisão da bibliografia sobre os modelos já desenvolvidos para este tema. Além disso, são feitos alguns comentários sobre as características e particularidades inerentes ao problema.
- No Capítulo 3 é apresentada a metodologia de previsão agregada, desenvolvida neste trabalho para resolver o problema de previsão por barramento de forma simples e com bons resultados.
- A descrição do *SysPrev* bem como a forma adotada em sua implementação são comentadas no Capítulo 5, onde são mostradas algumas telas de configuração do sistema no momento de uso e geração de resultados.
- O desenvolvimento computacional do *SysPrev* bem como a forma adotada em sua implementação são comentadas no Capítulo 5, onde são apresentadas telas gráficas e configurações.
- O processo de construção de um sistema com base na arquitetura dirigida a componentes é apresentado no Capítulo 6, onde são comentados alguns exemplos práticos para a construção de componentes *Plug-and-Play*.
- O Capítulo 7 contém os resultados e as comparações entre as simulações de previsão de carga feitas nesta pesquisa.
- O Capítulo 8 apresenta uma análise crítica e uma avaliação de todas as contribuições provenientes desta pesquisa. Também são colocadas sugestões para continuidade deste tema em outras instâncias.

- 
- O Apêndice A aborda o problema de previsão de carga por meio de uma descrição detalhada do tema de pesquisa que originou esta pesquisa. A leitura deste capítulo é recomendada para quem não possui familiaridade com processos de previsão.
  - A modelagem relacional utilizada no decorrer desta pesquisa é apresentada no Apêndice B. Nesta seção, é feita uma descrição introdutória sobre **SGBDs** (Sistema de gerenciamento de banco de dados) e suas aplicações em geral. Em seguida é mostrado todo o processo para construção da modelagem das cargas elétricas utilizadas nesta pesquisa.



## Carga Por Barramento: Previsão e Características

Este capítulo traz uma descrição detalhada do problema de previsão de carga por barramento, evidenciando suas aplicações no contexto de planejamento e operação de sistemas elétricos de potência. Juntamente com esta descrição, é apresentada uma revisão bibliográfica dos trabalhos relacionados a este tema.

Os dados de carga utilizados neste trabalho são apresentados em seqüência, destacando a formulação matemática usada na representação e padronização da carga, bem como algumas medidas estatísticas sobre os conjuntos utilizados para validar as metodologias apresentadas ao longo deste trabalho. Por fim, são realizados estudos de agrupamento para encontrar barramentos com perfis similares entre os conjuntos analisados neste trabalho, sendo destacada a importância do processo de agrupamento de barramentos para tomada de decisões em sistemas de potência.

Em linhas gerais, neste capítulo, são apresentadas várias informações que justificam e fomentam algumas proposições feitas ao longo deste trabalho.

## 2.1 Descrição do Problema

A energia elétrica é, na grande maioria dos casos, produzida distante dos centros de consumo e transportada em grandes blocos em elevado nível de tensão através de sistemas de transmissão. Estes grandes blocos de energia são entregues aos sistemas de distribuição que, por sua vez, operam com blocos de energia cada vez menores e em níveis de tensão mais baixo, até atingir os consumidores finais. Ao longo do sistema de transmissão e distribuição, existem pontos de interligação entre diferentes linhas, transformadores e consumidores, denominados barramentos. Há barramentos associados à geração, interligação e também ao suprimento dos consumidores. Cada barramento deste último tipo atende um conjunto de consumidores, de modo que é possível elaborar um histórico de demanda de carga e estudar o seu perfil de demanda. Obviamente este perfil de demanda depende dos hábitos de consumo dos usuários atendidos e, devido a este fator tais perfis podem variar, tanto no ponto de vista do perfil de consumo diário, como também do nível de consumo médio. As Figuras 2.1 e 2.2 mostram alguns exemplos de históricos de demandas horárias de alguns barramentos onde é possível perceber além da diferença no perfil da curva de carga, grande variação no nível de carga médio.

Lógicamente, se o consumo em dado barramento for elevado em um certo instante de tempo, o fluxo de energia que passa pelas linhas de transmissão e transformadores que suprem este barramento também deve ser elevado. Ou seja, para avaliar a operação de um sistema de transmissão, é necessário que se conheça ou se tenha uma estimativa da carga em cada barramento do sistema. Por exemplo, seja um sistema simplificado como o mostrado na Figura 2.3, no qual há duas usinas produtoras de energia elétrica situadas nos barramentos 1 e 2 que atendem os centros de consumos nos barramentos 3 e 4. Suponha que as demandas de carga horárias previstas para os barramentos 3 e 4 sejam mostradas nas Figura 2.4. Baseado nestas previsões, é possível estimar como será a operação do sistema em cada intervalo de tempo  $t$ , considerando-se a carga em cada barramento de acordo com os valores previstos para o respectivo intervalo de tempo.

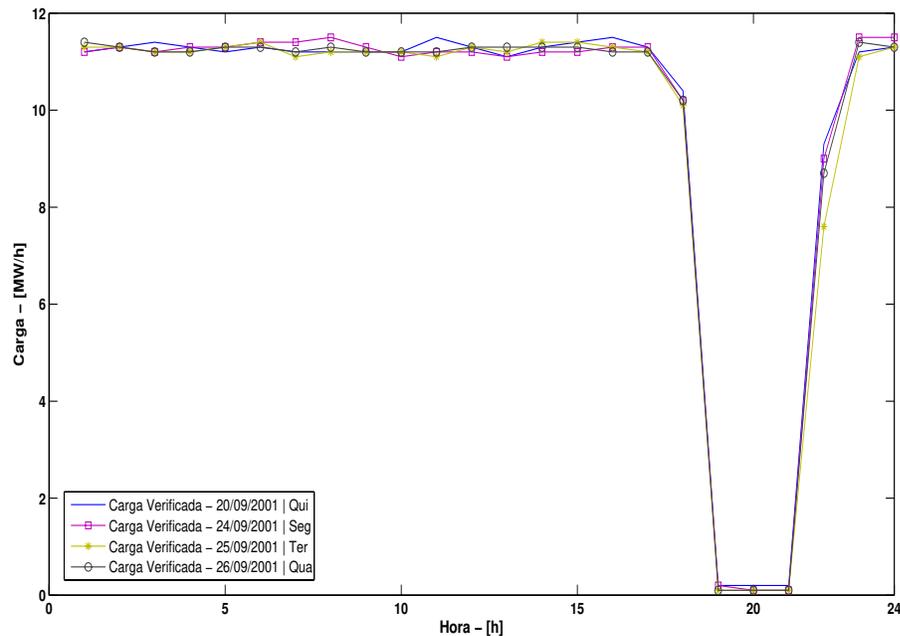


Figura 2.1: Perfil de Consumo - Barramento #47.

A operação de um sistema de transmissão é um processo complexo que exige um grande conjunto de ferramentas apropriadas para realizar estudos e simulações que auxiliem a tomada de decisão. Entre as aplicações que necessitam de sistemas específicos pode-se citar: fluxo de carga, planejamento e programação da operação, análise de segurança, análise de estabilidade, análise de desligamentos, entre outros. Em todos estes casos a previsão de carga por barramento é imprescindível. É importante destacar que a grande maioria das análises anteriormente citadas estão relacionadas com a operação de curto prazo e em tempo real do sistema, pois são nestas etapas que a operação do sistema de transmissão é considerada em maior detalhe.

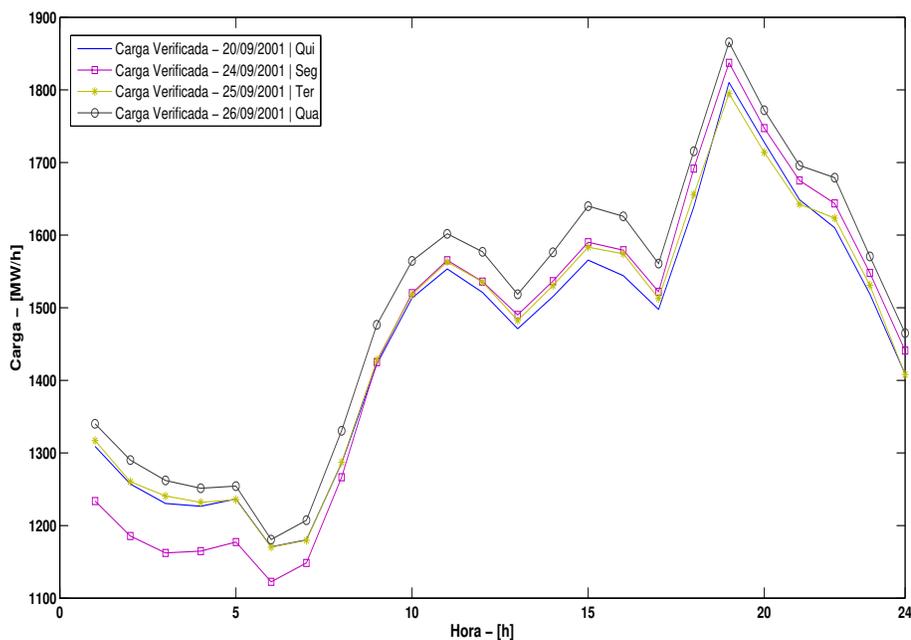


Figura 2.2: Perfil de Consumo - Barramento #59.

Neste contexto, a previsão por barramento de maior interesse é a previsão de carga a curto prazo por barramento, cujo o objetivo principal é estimar a carga horária dos próximos dias. Nesta previsão, é possível adotar diferentes intervalos de discretização, como por exemplo, intervalos maiores nos períodos de demanda mais estável e intervalos menores em períodos de demanda mais variável, como nos períodos de ponta. A previsão de carga a curto prazo, por barramento, pode ser utilizada em estudos estáticos como são, por exemplo, os estudos de fluxo de carga, e também pode ser utilizada pela programação da operação diária, para a qual é importante a curva de carga diária por barramento. A princípio, para cada barramento, é possível desenvolver um modelo de previsão de carga individual, similar aos tradicionais modelos de previsão de carga global. Entretanto, existem algumas considerações que dificultam este procedimento de estimação da carga para os barramentos.

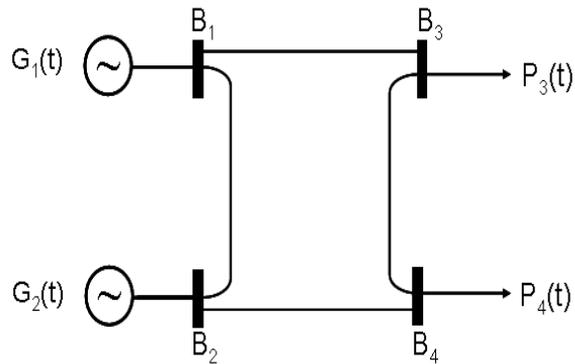


Figura 2.3: Exemplo: Rede Elétrica Simples.

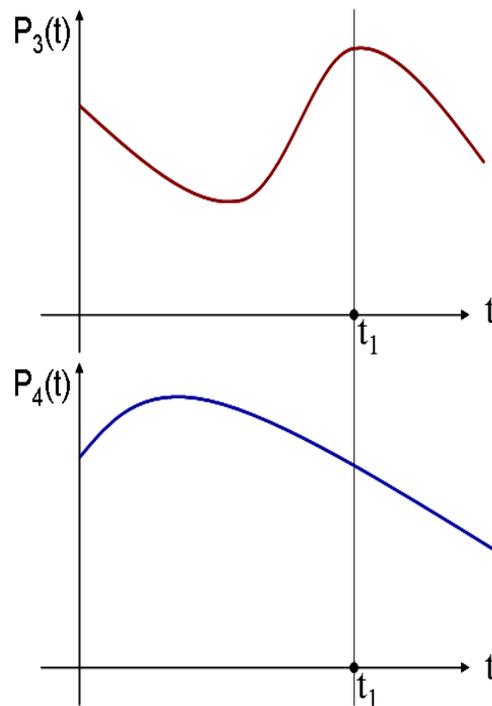


Figura 2.4: Curva Estimada - Barramentos.

Tão importante quanto os modelos de previsão por barramento é o contexto em que se dá o processo de cálculo destas previsões. Para os modelos de curto prazo, é interessante trabalhar com os dados mais recentes, pois estes trazem informações importantes sobre as tendências da carga, fortemente relacionadas com as variações nas condições climáticas. Mas, no caso de um sistema com um número muito grande de barramentos, para se trabalhar com as infor-

mações mais atualizadas, é necessário um sistema automatizado de aquisição e validação de dados. O processo de aquisição de dados é complexo, pois muitos barramentos se encontram em locais de difícil acesso e espalhados geograficamente, dificultando a medição da carga. A validação é uma atividade muito importante para assegurar a qualidade dos dados, pois é nesta etapa que são executadas tarefas de processamento e consolidação das medições com o objetivo de detectar tanto os dados inconsistentes, como também os dados anormais (“outliers”).

Como já dito anteriormente, a previsão de curto prazo é um dado essencial para muitos estudos realizados nas etapas de programação da operação diária e da operação em tempo real do sistema. Usualmente, a cada dia é determinada a programação da operação do próximo dia (ou próximos dois dias), que deve ser elaborada num período de poucas horas, seguindo um rigoroso e preciso cronograma diário. No processo de programação da operação, as previsões de carga por barramento devem estar disponíveis, pois fazem parte do conjunto de informações necessárias para alimentar os modelos utilizados. Já os estudos relacionados com a operação em tempo real, como os casos de cálculo de fluxo de carga, análise de segurança, e análise de estabilidade, podem ser realizados mais de uma vez ao dia, dependendo da evolução da carga ou das condições operativas e, neste caso, as previsões de carga também já devem estar disponíveis. Em muitos casos, as previsões devem ser atualizadas várias vezes ao longo do dia. Portanto, tanto para fins de programação da operação ou para uso na operação em tempo real, a rapidez no cálculo das previsões de carga por barramento é um requisito importante.

Além da questão de aquisição/manipulação dos dados e da necessidade de um sistema que realize estas atividades de maneira rápida e integrada, há também uma questão importante em relação aos modelos de previsão. Em primeiro lugar, dada a grande quantidade de barramentos e a diversidade de comportamentos nas demandas de carga em cada barramento, faz-se necessário um número muito maior de modelos de previsão que sejam capazes de tratar os diferentes tipos de perfil de carga em cada barramento.

Estes modelos podem diferir tanto em termos da técnica utilizada, pois

uma metodologia adequada para um determinado barramento pode não apresentar bons resultados em outros, quanto em termos de diferentes configurações, que é o caso de modelos que utilizam a mesma técnica, por exemplo redes neurais, mas com diferentes arquiteturas ou configurações. Nesse sentido, é desejável um sistema flexível em termos de modelagem, no qual seja fácil tanto trabalhar com diferentes técnicas, por exemplo, *redes neurais*, *redes neuro-fuzzy*, *modelos de regressão*, *modelos Box-Jenkins*, entre outros, com facilidades de configuração e troca de parâmetros.

Um segundo aspecto, importante em relação aos modelos, é a evolução das metodologias. A área de modelos de previsão tem recebido muita atenção dada a sua grande aplicação, e constantemente surgem novas abordagens que, em muitos casos, possuem desempenhos superiores às já existentes. Para a fácil incorporação destas evoluções é desejável que o sistema de previsão apresente recursos que possibilitem a integração de novas ferramentas sem a necessidade de reprogramação e/ou reconstrução do sistema.

Finalizando, quando se analisa do ponto de vista da aplicação da previsão de carga à curto prazo por barramento, além de modelos de previsão adequados, é importante a existência de um sistema de suporte ao processo de previsão. Este sistema deve integrar uma base de dados, uma base de modelos de previsão, interfaces homem-máquina, além de propiciar um ambiente computacional amigável e flexível.

## 2.2 Revisão Bibliográfica

A previsão de carga por barramento pode ser vista como um problema de previsão de carga tradicional, no qual cada barramento é visto como um série temporal individual cuja previsão pode ser feita utilizando-se um modelo tradicional da literatura. Entretanto, em sistemas com grande número de barramentos, o ajuste dos modelos de previsão para cada barramento demanda um considerável tempo computacional, o que dificulta seu uso em decisões de curto prazo.

A previsão de carga por barramento geralmente é utilizada como su-

porte à tomada de decisões em diversas áreas tradicionais em sistemas de potência. Dentre as aplicações que necessitam da previsão de carga por barramento, pode-se citar: análise do fluxo de potência e segurança na rede (Pyne, 1974), planejamento da expansão de redes de transmissão (Fischl et al., 1982), controle da carga em tempo real (Keyhani e Miri, 1983), conhecimento da carga ao longo da rede (Bose e Clements, 1987), análise de consumidores, tarifas e expansão da rede (Handschin e Dörnmann, 1988), (Lambert-Torres et al., 1992), (Nazarko e Zalewski, 1999), (Sinha e Mandal, 1999b) e (Amjady, 2007). A previsão de carga por barramento também é essencial para auxiliar os chaveamentos e mudanças no fluxo de carga em sistemas de transmissão (Billinton e Allan, 1996).

Na literatura especializada da área, existem poucos artigos que tratam do problema de previsão de carga por barramento, sendo que o primeiro trabalho que aborda parcialmente o tema foi proposto em 1974 por (Pyne, 1974). Muitos artigos adotam o termo previsão por barramento, porém a grande maioria destes artigos na verdade estudam uma série temporal gerada por um único barramento, e com isto faz-se uma previsão individual de uma série medida em um barramento isolado.

O termo previsão de carga por barramento foi utilizado pela primeira vez no trabalho de (Pyne, 1974), que desenvolveu uma estratégia para previsão de carga por barramento através de um estimador de estados que utiliza regressão linear múltipla e processos de *Markov* para realizar a previsão do fluxo de potência e análise da segurança do sistema. O trabalho comenta que faz a previsão de 100 barramentos localizados na área de *Seattle/Washington, Portland/Oregon e Spokane/Cascade* e, apesar do autor citar a previsão dos 100 barramentos, não são feitos comentários sobre os resultados de previsão de cada um dos barramentos e também não é encontrado nenhum detalhe específico sobre o procedimento adotado na previsão dos barramentos.

Com a premissa de criar um programa seguro de expansão para redes de transmissão de energia, o trabalho de (Fischl et al., 1982) propõe um modelo estatístico de previsão de carga por barramento. Este método observa o mínimo custo do plano de expansão da rede que garante o nível de suprimento de uma determinada demanda de carga em algumas subestações. Os autores assumem

que a carga em um dado barramento é dada pela soma algébrica de uma carga média prevista e um componente aleatório que representa a incerteza dos desvios em relação a carga média. De posse da estimativa da carga por barramento é feito o plano de expansão da rede visando obter o mínimo custo no despacho econômico das unidades geradoras. Apesar de realizar a previsão de carga em cada barramento, os autores deste trabalho não têm o enfoque na técnica de previsão, dando maior atenção ao problema de expansão da rede elétrica. Desta maneira, como no artigo de (Pyne, 1974), o problema de previsão de carga por barramento não é explorado com detalhes.

Um trabalho interessante na área é apresentado por (Keyhani e Miri, 1983). Neste trabalho, os autores propõem um modelo de previsão de carga por barramento que leva em consideração a influência das variáveis climáticas, projetado para ser embarcado em um microcontrolador. Neste sentido, foram propostas três (03) abordagens para o problema: **1-**Esta abordagem desenvolve um modelo separado para cada barramento baseado nos dados históricos e nas condições climáticas. **2-** Neste método os autores propõem um modelo de carga por área baseado nos dados históricos e nas condições climáticas, após a previsão deste modelo de área as cargas dos barramentos desta área são calculados com base de fatores pré-definidos. **3-** O método 3 faz uma análise de grupos buscando encontrar seqüências de carga similares. Após a definição dos grupos, é feita uma modelagem de previsão para cada grupo baseada nos valores históricos e condições climáticas, e as cargas dos barramentos do grupo são calculadas com base de fatores pré-definidos. Para o processo de previsão, os autores utilizam modelos auto-regressivos (AR) e auto-regressivos de médias móveis (ARMA). Os modelos são aplicados em um conjunto de vinte (20) barramentos com a mesma tensão (138KV) localizados na região de *Canton/Ohio* pertencentes à *American Electric Power Company*. Os resultados de previsão apresentaram erros na faixa de 2% a 7,8% dependendo do modelo e do barramento analisado. É interessante observar que a implementação no microprocessador é feita baseada em perfis de consumo, isto é, os autores realizaram uma implementação para consumidores residenciais, outra para comerciais e outra para industriais.

Buscando encontrar uma modelagem matemática para expressar as

redes em sistemas de potência em tempo real, o trabalho de (Bose e Clements, 1987) faz algumas referências à previsão de carga por barramento para encontrar uma pseudo-medição de um barramento não-monitorado (devido a falhas ou falta de equipamento). Apesar dos autores utilizarem a previsão de carga por barramento, eles não detalham qual e como é feito o processo para estimação de carga nos barramentos. Entretanto, eles retratam a previsão de carga por barramento como insumo essencial para modelar as redes de transmissão de sistemas de potência bem como para analisar a segurança e estabilidade do fluxo de carga ao longo dos nós do circuito elétrico.

Entre os trabalhos clássicos que abordam o tema de previsão de carga na literatura, pode-se citar o artigo de (Handschin e Dörnmann, 1988). O modelo de previsão de carga apresentado neste artigo baseia-se nas curvas típicas de consumo por grupo de consumidores e suas relações com os barramentos. Estas curvas são calculadas para cada grupo de consumidores específicos e a carga em cada barramento é estimada a partir das curvas dos grupos por meio de um modelo linear. Além disso, este modelo leva em consideração diversos fatores exógenos para representar a carga nos diversos grupos de consumidores. O modelo é aplicado para a previsão das 24 horas do dia seguinte no sistema de potência de uma grande cidade na Alemanha. Os resultados encontrados pelo autor apresentaram bons níveis de erro. Entretanto, o autor não menciona quantos barramentos são analisados, a tensão e as características da série de cada barramento utilizado no artigo.

O trabalho de (Lambert-Torres et al., 1992) apresenta um sistema especialista baseado em regras nebulosas para previsão de carga a curto prazo. Os dados utilizados pelo autor fazem parte da *Hydro-Quebec Power System/Canada* e contêm dados reais de duas linhas de transmissão pertencentes a este sistema. Apesar de citar a previsão de carga por barramento, os autores deste trabalho fazem a previsão de alguns passos à frente da carga agregada por estas duas linhas de transmissão. Neste sentido, o que é apresentado pelos autores é um modelo de previsão de carga individual aplicado a dados de dois (02) barramentos agregados. A previsão é feita em base horária e prevê até três horas à frente e, segundo os autores os resultados possuem bons níveis de erro, mas não enfocam

o problema de previsão de carga por barramento de maneira direta e clara.

(Nazarko e Zalewski, 1999) tratam o problema de previsão de carga por barramento através de um sistema de regressão nebuloso para previsão da carga elétrica no horário de pico nos barramentos. A abordagem nebulosa utilizada neste trabalho visa inserir um caráter de incerteza para prover informações quando existe incerteza nas medições utilizadas para o processo de regressão linear. O modelo de previsão foi aplicado em duas subestações pertencentes ao *Bialystok Power Distribution Utility Co*, no qual uma subestação atende consumidores residenciais e a outra atende consumidores comerciais. Os resultados encontrados pelos autores mostraram a eficiência do método para previsão da carga no horário de ponta. Entretanto, o autor aplica a metodologia individualmente em cada barramento, sendo necessário ajustar o modelo para cada barramento do sistema. Isto é, em termos de metodologia de previsão de carga por barramento, o autor não apresenta nenhuma inovação, mantendo o problema de esforço computacional necessário para ajustar um modelo de previsão para cada barramento do sistema.

Os artigos (Sinha e Mandal, 1999a) e (Sinha e Mandal, 1999b) tratam a previsão de carga por barramento como uma forma de obter informações para alimentar um estimador de estados dinâmicos para sistemas de potência. Este trabalho utiliza uma rede neural multicamadas treinada com algoritmo *back-propagation* para realizar a previsão de carga por barramento. A metodologia proposta faz um ajuste de uma rede neural para cada barramento do sistema no qual a carga prevista é utilizada para alimentar o estimador de estados proposto no trabalho. Os autores apresentam a previsão de carga para apenas um único barramento utilizando um modelo específico para esta série e obtiveram resultados interessantes em termos de erros de previsão. Esta abordagem de previsão por barramento apresenta a desvantagem do alto esforço computacional no qual é necessário um ajuste do previsor em cada barramento do sistema.

O problema de previsão de carga por barramento, bem como suas implicações em sistemas de potência, são tratados com detalhes no artigo de (Kassaei et al., 1999). Este trabalho apresenta uma abordagem híbrida que utiliza sistemas nebulosos com redes neurais artificiais multicamadas. Segundo os autores,

a componente neural é utilizada para prever os valores de carga normalizados e o sistema nebuloso é responsável por aplicar um fator de correção na carga através da temperatura levando em consideração a época no qual a previsão foi realizada. O modelo é aplicado em dados reais de um sistema elétrico localizado na cidade de *Hinton/Virginia*. Os autores comentam que este sistema elétrico é formado por três (03) barramentos de 138/46KV. Entretanto, para testar o modelo, foi utilizado apenas um barramento que atende consumidores residenciais nesta cidade. Os resultados alcançados apresentaram um erro percentual absoluto médio na faixa de 2%, mostrando que o modelo é competitivo em relação aos modelos de previsão descritos na literatura de potência. Entretanto, no que diz respeito à previsão de carga por barramento, este trabalho não traz nenhuma contribuição devido à aplicação do modelo em um barramento individualizado.

O artigo mais recente que aborda o tema de previsão de carga por barramento é o trabalho desenvolvido por (Amjady, 2007) que, além de propor um modelo para previsão de carga por barramento, faz uma descrição detalhada do problema. Neste trabalho, os autores propõem um modelo de previsão híbrido composto de um previsor de estimador de estados e uma rede neural multicamadas. O estimador de estados faz a previsão horária de cada barramento baseado nos valores de carga médios e a rede neural, por sua vez, é ajustada para aprender a relação entre o vetor de entradas/saídas do estimador de estados e a carga real desejada no barramento. O modelo híbrido foi aplicado em parte do sistema de potência do *Iran*, formado de três (03) barramentos, e os resultados obtidos mostram que o modelo híbrido obteve melhores resultados que a rede neural MLP, o estimador de estados e um modelo de auto-regressivo periódico (PAR) executados individualmente com as mesmas entradas do estimador de estados. O mesmo inconveniente de trabalhos anteriormente descritos é encontrado no trabalho de (Amjady, 2007), no qual o modelo de previsão é aplicado individualmente aos barramentos, gerando alta complexidade computacional na análise de um sistema de potência de grande porte.

Em linhas gerais, uma maneira de fazer a previsão de carga por barramento é implementar um modelo de previsão de carga específico para cada barramento, sendo a principal desvantagem desta abordagem a necessidade de

um grande número de modelos e previsões. Uma alternativa encontrada é reduzir o número de modelos necessários para a previsão dos barramentos, e uma das formas para atingir este objetivo é realizar previsões agregadas, em que um único modelo faz a previsão de um subconjunto de barramentos. A questão que surge é como formar estes subconjuntos de barramentos de modo a se obter uma boa previsão. Como, neste trabalho, o objetivo é desenvolver modelos para a previsão de curva de carga diária (horária) por barramento e, como neste tipo de previsão é importante estimar corretamente o perfil desta curva de carga, o critério adotado para a formação dos sub-conjuntos foi a similaridade do perfil da curva de carga diária. Desta forma, a metodologia de previsão proposta usa a abordagem agregada na qual o conjunto de barramentos é subdividido em grupos com elementos que possuem perfis de carga diário similar e, para cada grupo, é realizada a previsão<sup>1</sup>.

## 2.3 Carga Elétrica Por Barramento

Este trabalho utilizou um conjunto de dados históricos de um subsistema elétrico formado por 73 barramentos. Neste conjunto as medições de carga em base horária foram feitas no período de 06 de junho de 2001 a 03 de outubro de 2001, totalizando 125 dias de medição com 3000 horas em cada barramento. Neste conjunto, existem barramentos com tensão variando entre 38 a 230KV.

A Tabela 2.1 apresenta algumas informações sobre o conjunto de dados utilizado neste trabalho. É possível observar o número de barramentos, o período de medição, o nível de tensão e algumas medidas de posição e variabilidade. A análise dos dados mostra uma grande variação nas características entre os barramento. Por exemplo, se for observado a carga média por barramento, verifica-se que a menor carga média é de 1.4 MW, enquanto o barramento com maior carga média é de aproximadamente 1521.3 MW.

---

<sup>1</sup>A metodologia de previsão agregada encontra-se detalhada no Capítulo 3.

Tabela 2.1: Informações Estatísticas.

-	<b>Informações</b>
Número de Barramentos	73
Período de Medição	01/06 a 03/10/2001
Tensão (KV )	[38 - 230]
Carga Mínima (MW)	[0.1 - 930.8]
Carga Média (MW)	[1.4 - 1521.3]
Carga Máxima (MW)	[3.4 - 1922.9]
Desvio Padrão (MW)	[0.03 - 26.7]
Coef. Variação (%)	[0.93 - 26.4]

Cada medição pertencente às séries de carga em cada barramento é representada de acordo com a formulação matemática da Equação 2.1. Com esta indexação, é possível extrair os dados de cada barramento de maneira direta. Esta representação de carga por barramento será utilizada como referência aos dados nas metodologias de previsão apresentadas ao longo deste trabalho.

$$b(i)_{[h,d]} \quad (2.1)$$

sendo que:

- $i \leftrightarrow$  é o índice do barramento, onde  $i = 1, \dots, 73$ ;
- $d \leftrightarrow$  é o índice do dia que varia da seguinte forma:  $d = 1, \dots, 125$ ;
- $h \leftrightarrow$  é o índice da hora a hora do dia:  $h = 1, \dots, 24$ .

A Figura 2.5, no gráfico superior, mostra as curvas de carga diária de alguns barramentos. Neste caso, os barramentos apresentam curvas de carga horária com perfis similares, mas com níveis de carga média muito diferentes. Como o objetivo é selecionar barramentos com perfis similares, independentemente do nível médio de carga, então todas as curvas foram normalizadas de acordo com a Equação 2.2:

$$\widehat{b(i)}_{[h,d]} = \frac{b(i)_{[h,d]}}{\max(b(i)_{[:d]})} \quad (2.2)$$

sendo que:

- $\widehat{b(i)}_{[h,d]} \hookrightarrow$  carga em PU do barramento  $i$ , na hora  $h$  do dia  $d$ ;
- $b(i)_{[h,d]} \hookrightarrow$  carga absoluta do barramento  $i$ , na hora  $h$  do dia  $d$ ;
- $\max(b(i)_{[:,d]}) \hookrightarrow$  carga máxima medida no barramento  $i$  no dia  $d$ .

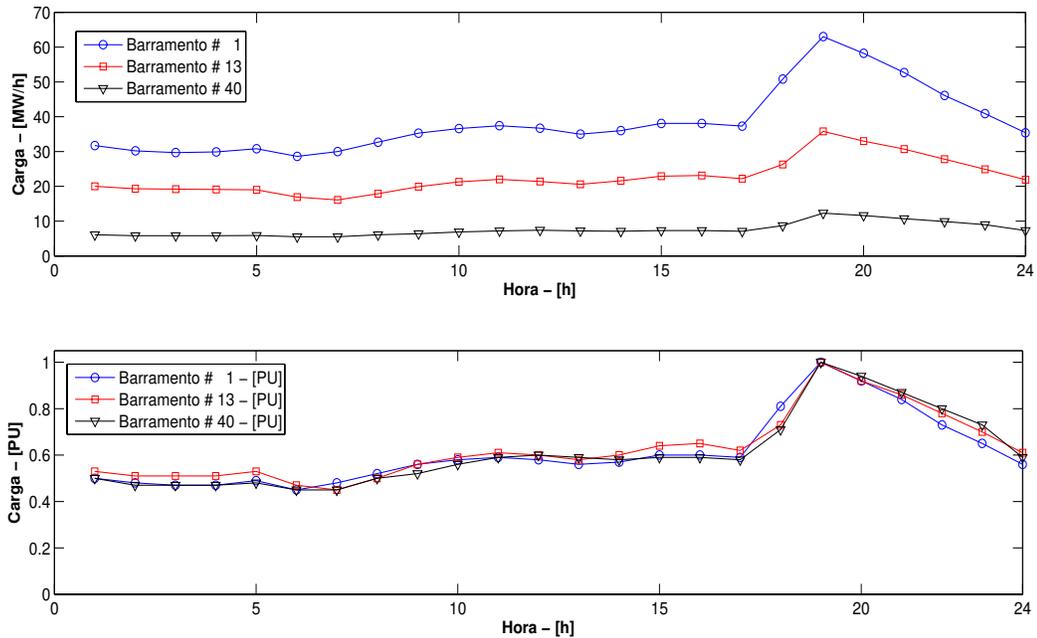


Figura 2.5: Motivação para Normalização de Barramentos.

Novamente, na Figura 2.5, é possível ver as séries de cada barramento antes e depois da aplicação do operador de normalização. A normalização eliminou a diferença de nível de carga, acentuando a similaridade dos seus perfis de carga diária, possibilitando assim reagrupar os barramentos de acordo com esta similaridade.

### 2.3.1 Alterações nas Características da Carga dos Barramentos

A rede de transmissão/distribuição tem a sua configuração, em termos de equipamentos em operação e fora de operação, alterada no tempo em função

de diversos fatores, tais como saídas forçadas de equipamentos e paradas para manutenção, entre outros. Estas alterações na rede podem fazer com que consumidores atendidos por determinado barramento sejam temporariamente atendidos por outro circuito, de modo que as demandas de carga em determinado barramento podem ser totalmente alteradas de um instante para outro, como mostrado na Figura 2.6. Analisando esta figura, é possível perceber a mudança no perfil de consumo entre os dias 03 e 04 de janeiro de 2002. Este tipo de mudança drástica no padrão aumenta a dificuldade no problema de previsão pois, neste caso, a carga no barramento é dependente da configuração da rede.

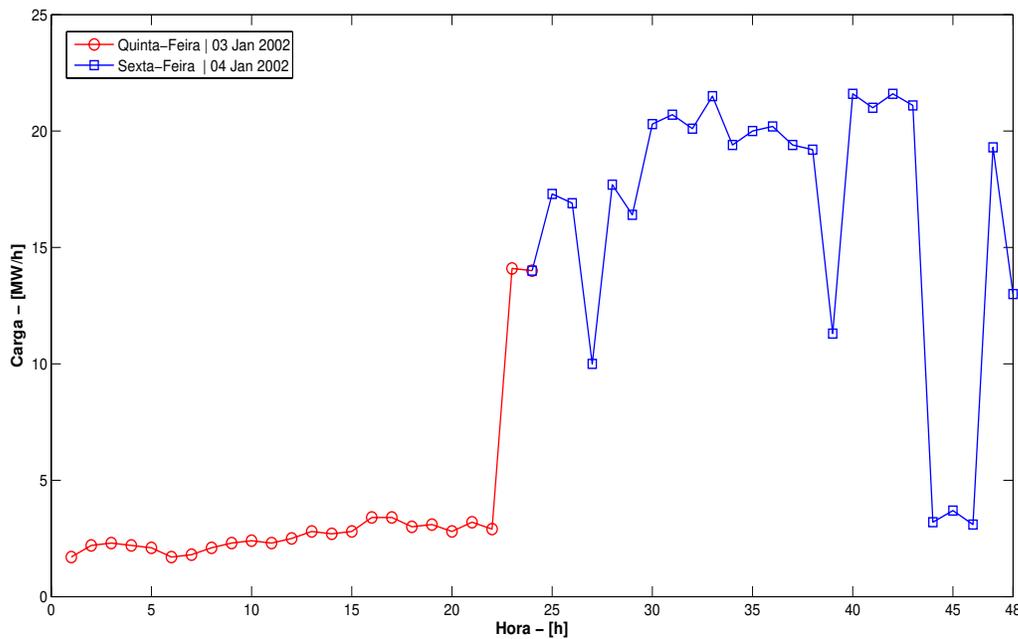


Figura 2.6: Mudança no perfil diário - Barramento #46.

## 2.4 Análise de Agrupamentos

A análise de agrupamentos aplicada a um conjunto de barramentos visa encontrar barramentos que possuem perfil de carga diário com alguma similaridade. Para analisar a similaridade dos barramentos, este trabalho testou diversas técnicas para agrupamento dos dados. De maneira sucinta, o objetivo

destes algoritmos é identificar duas ou mais coleções de dados que formem uma estrutura de grupo e que possam ser associadas a classes. O interesse pelas técnicas de agrupamento é obter os grupos de barramentos analisando o comportamento histórico de demanda diária de carga, sendo foco principal determinar quais são os barramentos que possuem perfis de consumo diário semelhantes.

Entre as técnicas analisadas pode-se destacar: o algoritmo *K-Means* ((MacQueen, 1967)), o algoritmo baseado em redes neurais de *Kohonen* ((Kohonen, 1982) e (Kaski e Kohonen, 1995)), o algoritmo *Pruning Technique Kohonen Self-Organizing Feature Map - PSOM* (Castro e VonZuben, 1999), o algoritmo *Fuzzy C-means - FCM* (Bezdek, 1981) e, por último, o algoritmo *Subtractive Clustering* (Chiu, 1994).

Os resultados encontrados pelas técnicas de agrupamento são bem estáveis, de forma que os barramentos agrupados em um determinado grupo tendem a permanecer no mesmo agrupamento independente da técnica utilizada (Salgado et al., 2004). Algumas pequenas variações podem acontecer no caso de barramentos com alta variabilidade diária, mas em barramentos com perfil de consumo com baixa variação, as técnicas de agrupamento tendem encontrar os mesmos grupos quando são submetidas ao mesmo conjunto de dados.

Após o estudo os algoritmos anteriormente descritos, a técnica de agrupamento padrão adotada para encontrar os grupos de barramentos similares neste trabalho foi o algoritmo *Subtractive Clustering* (SC) proposto por (Chiu, 1994). Esta técnica de agrupamento possui um diferencial interessante, pois tem a capacidade de realizar uma análise dos dados de entrada e encontrar o número de grupos ideal para o conjunto de dados apresentado. Esta capacidade é uma vantagem em relação às técnicas nas quais o analista deve informar o número de grupos ao algoritmo.

### **2.4.1 Exemplo de Aplicação**

Este exemplo visa analisar o conjunto formado por 73 barramentos, detectando quais barramentos possuem perfis similares em um determinado dia. A técnica utilizada nos testes de agrupamento foi o algoritmo *Subtractive Clustering*

- (SC). O dia escolhido para análise foi o dia 20 de setembro de 2001 (quinta-feira). A escolha deste dia foi baseada no fato dele ser um dia útil padrão (não é feriado ou tem algum caráter especial) que representa bem as informações de consumo do cotidiano do sistema analisado neste trabalho.

Antes de aplicar o algoritmo de agrupamento, as cargas dos 73 barramentos foram normalizadas segundo a Equação 2.2. Em termos de resultados, o algoritmo SC dividiu os 73 barramentos em 34 grupos, sendo possível verificar que 14 grupos tinham mais de um barramento em sua composição e 20 grupos eram formados por apenas 1 único barramento.

Os 14 grupos encontrados pelo SC concentraram 53 do total de 73 elementos, representando 72% do total de barramentos. A Tabela 2.2 mostra algumas informações para cada um dos 14 grupos com vários barramentos, onde é possível observar: o índice do grupo  $g$ , o número de barramentos em cada grupo (N. Barras), o índice de cada barramento pertencente nos grupos (Id), a carga total do grupo (Carga (MW)), o percentual da carga do grupo em relação a carga total do conjunto ((%) Carga), e o desvio padrão em cada grupo (DesvPad).

Analisando a Tabela 2.2, é possível verificar que existem vários grupos com poucos elementos e um grupo específico com 11 barramentos. Em termos de concentração de carga, os grupos são heterogêneos apresentando grandes variações de um grupo para outro. Entretanto, há um destaque para o grupo 14 que concentra mais de 55% da carga elétrica do dia analisado em 11 elementos. Em termos de variabilidade, pode-se perceber que o desvio padrão (PU) é baixo, destacando que os grupos formados tem alta similaridade entre seus elementos.

Na Figura 2.7, é possível observar alguns dos 14 grupos mostrados na Tabela 2.2. Pode-se perceber que o padrão de carga dos grupos é heterogêneo, mostrando a variação de consumidores que há na região analisada. A diversidade nos padrões de carga comentada no início deste capítulo pode ser vista bem de perto nesta figura, em que é possível ter uma maior compreensão da necessidade de modelos efetivos para representar o comportamento de cada grupo de barramentos.

Tabela 2.2: Análise de Agrupamentos.

<i>g</i>	<i>N. Barras</i>	<i>Id</i>	<i>Carga (MW)</i>	<i>(%) Carga</i>	<i>DesvPad - PU</i>
1	2	[2;37]	3.75	0.04%	0.0041
2	2	[6;24]	218.76	2.42%	0.0074
3	2	[29;32]	170.37	1.89%	0.0064
4	2	[36;72]	31.80	0.35%	0.0055
5	2	[47;53]	82.89	0.92%	0.0063
6	2	[48;71]	221.93	2.46%	0.0091
7	3	[1;13;40]	68.46	0.76%	0.0059
8	3	[19;20;41]	54.29	0.60%	0.0088
9	3	[25;39;60]	431.87	4.79%	0.0088
10	4	[5;8;10;27]	278.82	3.09%	0.0070
11	5	[4;45;52;57;66]	399.39	4.43%	0.0061
12	5	[11;26;28;34;38]	145.66	1.61%	0.0058
13	7	[3;21;31;35;43;68;69]	877.80	9.73%	0.0077
14	11	[7;9;14;18;59;61;62;63;64;67;70]	4983.44	55.22%	0.0043

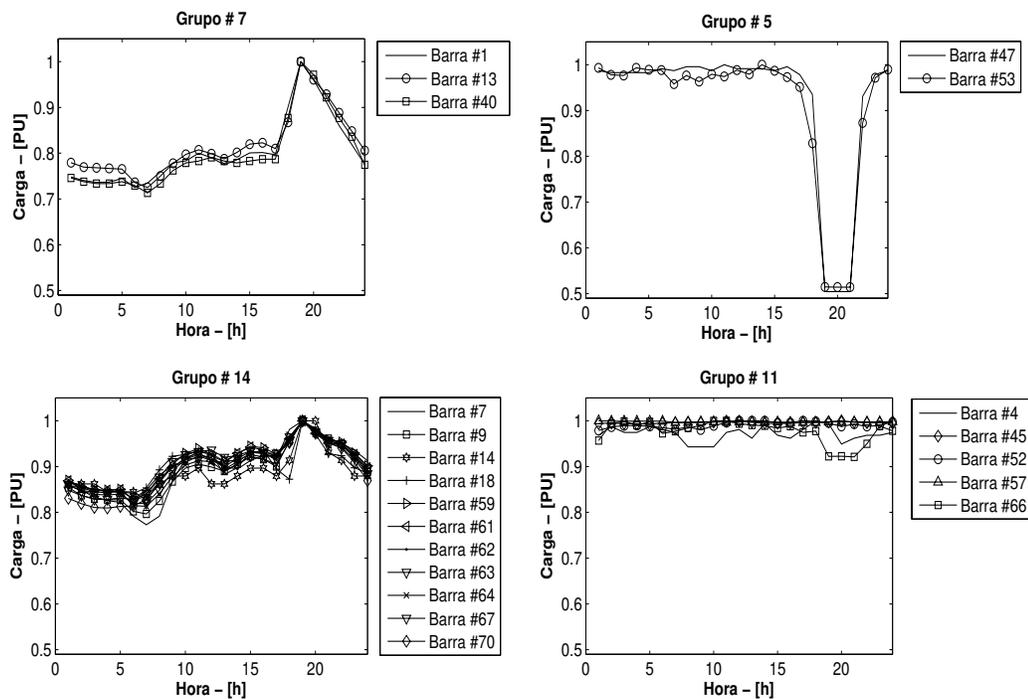


Figura 2.7: Exemplo: Grupos com 2 ou mais Barramentos.

A soma total da carga elétrica no dia analisado em todos os barramentos é de **9024.14MW**. Os 14 grupos que contêm vários elementos somam **7969.23MW**, concentrando **88.3%** da carga total neste dia. Desta forma, uma

boa previsão destes grupos representa uma boa estimativa da carga diária nos principais barramentos do conjunto.

A Figura 2.8 apresenta alguns grupos individuais e seus respectivos barramentos. Observando estes grupos, é possível verificar que os perfis de cada um dos barramentos é específico e por este motivo tais barramentos não foram classificados juntamente com outros barramentos pelo SC. Provavelmente, este tipo de barramento alimenta consumidores com grandes variações no consumo ou são barramentos afetados com as mudanças de fluxo de carga ocasionadas por alterações e chaveamentos nas redes de transmissão. Quando se trata de barramentos com comportamento particulares, é recomendada a análise individual através de um modelo específico capaz de tratar suas particularidades.

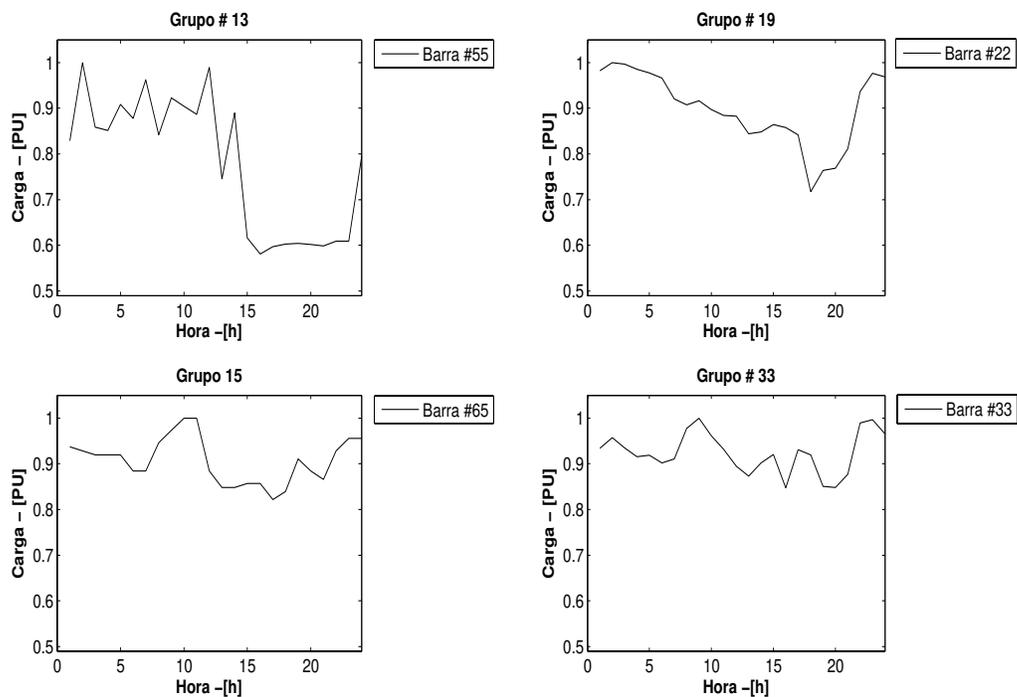


Figura 2.8: Exemplo: Grupos com Barramentos Individuais.

# Metodologia de Previsão de Carga por Barramento

Este capítulo faz a apresentação da formulação matemática utilizada para resolver o problema de previsão de carga por barramento. Serão apresentados os conceitos e as motivações que contribuíram para a criação do modelo de previsão de carga por barramento proposto neste trabalho.

Em linhas gerais, a metodologia de previsão agregada apresentada neste trabalho estará concentrada apenas nos grupos formados por barramentos com perfil similar. No caso de barramentos que possuem padrão específico, é indicada a utilização de uma abordagem individual para aprender suas características.

Além da descrição da metodologia de previsão agregada, é feito um comentário sobre técnica de compactação de informação, baseada na análise de componentes principais, que será utilizada para encontrar uma estrutura agregada enxuta, como boa representatividade da estrutura original.

### 3.1 Motivação

Barramentos que apresentam semelhanças em seu perfil de consumo diário tendem a manter esta similaridade ao longo do histórico de cargas, pois refletem os hábitos de cada região e clientes atendidos. Com base nesta premissa, o modelo de previsão de carga por barramento proposto neste trabalho concentra suas análises nos barramentos que se encontram nos grupos ou, em outras palavras, que possuem perfil de consumo similar. A utilização de grupos de barramentos com perfil similar para realização de procedimentos de previsão não é uma idéia inovadora, sendo utilizada nos trabalhos de (Keyhani e Miri, 1983) e (Handschin e Dörnmann, 1988) com bons resultados.

Além disso, conforme visto anteriormente (Capítulo 2), os grupos de barramentos com perfil similar obtidos após o processo de agrupamento concentram a maior parte da carga do sistema. Neste sentido, bons resultados de previsão nos grupos ocasionam boas estimativas da carga nos barramentos do sistema proporcionando informações relevantes para um processo operação do sistema seguro e eficiente.

A metodologia desenvolvida neste trabalho propõe uma abordagem que utiliza as informações dos grupos de barramentos para criar uma estrutura agregada que represente as informações de cada barramento em um único dispositivo. Neste sentido, um previsor capaz de aprender as relações desta estrutura implicitamente está aprendendo as relações de todos os barramentos pertencentes ao grupo. Logo, a previsão agregada visa estimar através de um único dispositivo, a carga de diversos barramentos.

### 3.2 Modelo Agregado - Simples Ilustração

De maneira geral, a previsão de carga por barramento pode ser vista como um problema de prever  $n$  séries temporais distintas em um determinado intervalo de tempo  $t$ . Conforme visto anteriormente, uma das formas de resolver este problema é tratar cada barramento de maneira individualizada, ou seja, aplicar um modelo de previsão em cada barramento. O inconveniente desta abor-

dagem é o esforço e o tempo computacional exigidos para a tarefa de ajustar um modelo de previsão para os diversos barramentos da rede elétrica.

O desenvolvimento de um modelo de previsão implica em várias decisões tais como a técnica a ser adotada e, uma vez escolhida a técnica resta ainda definir os seus parâmetros de configuração. Em relação às técnicas, há um elenco de possibilidades, como por exemplo *redes neurais artificiais*, *redes neurofuzzy*, *modelos auto-regressivos*, *modelos baseados em regras* sendo estes apenas alguns exemplos das diversas técnicas de previsão que existem na literatura. Após a escolha da técnica é preciso definir as entradas e saídas bem como a estrutura que será utilizada no processo de previsão.

Em uma metodologia de previsão, é necessário executar uma fase de ajuste onde os parâmetros do modelo são configurados de acordo com o tipo de série temporal apresentada ao previsor. Usualmente, o ajuste de um modelo é feito através da apresentação de um conjunto de padrões (*input × output*) utilizados para definir os parâmetros que irão representar, com a precisão desejada, as relações existentes entre as entradas e saídas na coleção adotada. Geralmente, este ajuste é feito por meio de um processo iterativo, executado até que um critério de parada seja satisfeito.

Para fazer a previsão, é necessário utilizar dados significativos que representem o comportamento da carga em um dado instante de tempo. Geralmente, nas previsões de carga, é comum utilizar o histórico da carga e dados exógenos (temperatura, cobertura, umidade, estação do ano, dados econômicos entre outros) para representar a carga em um instante futuro. Neste trabalho, a carga em um instante futuro será representada somente em função do histórico de cargas, não sendo utilizadas informações exógenas devido à indisponibilidade destas informações no sistema de barramentos analisados. Assim, a coleção (*input × output*) utilizada para ajustar os parâmetros do previsor será construída apenas com base no histórico de carga.

### 3.2.1 Exemplo: Previsão Individual

Suponha que se deseje ajustar um modelo de previsão para o intervalo das 16h da quinta-feira, dia 13 de setembro de 2001, nos barramentos #33 e #40 respectivamente. Antes de criar o conjunto de padrões para ajustar os previsores, é interessante analisar os dados de históricos de carga nos barramentos #33 e #40 na hora 16. A Figura 3.1 mostra a curva de carga de 75 (setenta e cinco) dias às 16h no barramento #40. Suponha que, através da análise de uma função de autocorrelação (PAF) (Mori e Kurata, 2007), determinou-se que as variáveis mais significativas para determinar o valor da carga neste horário são as cargas verificadas nos dois dias anteriores, na mesma hora. Observando esta figura, é possível ver algumas flechas que indicam informações sobre as cargas em determinados dias de medição; a flecha azul (saída) localizada abaixo da curva significa a medição do dia 13/09/2001 e as demais flechas (entradas) representam medições anteriores a este dia na mesma hora.

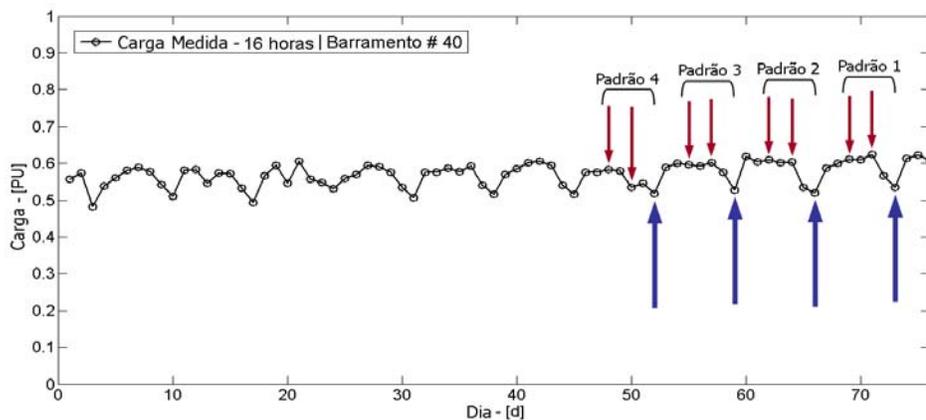


Figura 3.1: Carga 16h - Barramento #40.

Neste exemplo, a carga da quinta-feira (13/09), na hora 16, é dada como função das cargas de terça-feira (11/09) e quarta-feira (12/09) respectivamente. A coleção de padrões (*input*  $\times$  *output*) formada através da relação entre as entradas e a saída desejada para o barramento #40 servirá de base para ajuste do modelo de previsão.

Com o conjunto de padrões criado pelas entradas da Figura 3.1 é pos-

sível ajustar um previsor com qualquer característica (linear ou não-linear) para aprender as relações entre as entradas e saídas da coleção apresentada. Se, por exemplo, um preditor baseado em redes neurais multicamadas, com três neurônios na camada intermediária, for utilizado para aprender as relações desta estrutura, a seguinte arquitetura será formada (ver Figura 3.2), na qual os dois neurônios na camada de entrada representam as duas entradas e a resposta do neurônio  $s^{(1)}_{b(40)}$  representa a estimativa da saída desejada. Após o ajuste do previsor, a próxima etapa é utilizar o modelo ajustado para fazer a previsão da carga desejada.

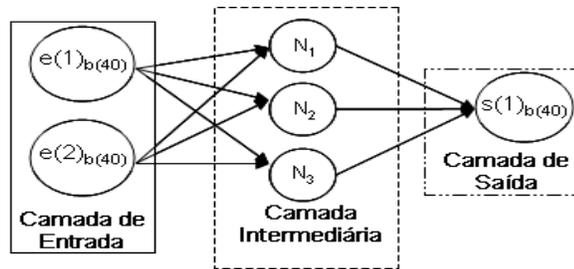


Figura 3.2: Exemplo: Modelo de Previsão para o Barramento #40.

De forma análoga ao procedimento realizado para o barramento #40, é possível encontrar uma estrutura similar (*input*  $\times$  *output*) para prever a hora 16 no barramento #33. A Figura 3.3 mostra o modelo utilizado para a previsão da carga às 16h como função apenas da carga verificada no dia anterior.

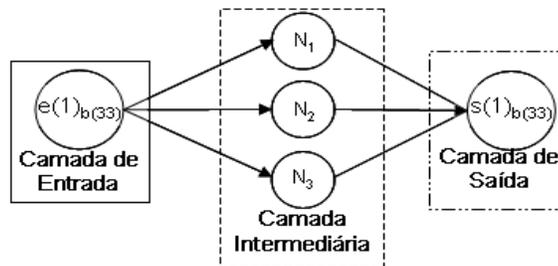


Figura 3.3: Exemplo: Modelo de Previsão para o Barramento #33.

A vantagem da utilização de um modelo individual para cada barramento é a especialização do previsor para uma determinada série possibilitando o aprendizado específico dos seus comportamentos e perfis particulares. Entre-

tanto, esta alternativa é trabalhosa e requer tempo para processar individualmente todos os barramentos de um sistema elétrico. Neste trabalho, investigou-se outra alternativa: desenvolver um modelo agregado para um conjunto de barramentos buscando, em um tempo menor de processamento, resolver o problema de previsão de carga por barramento.

### 3.2.2 Exemplo: Previsão Agregada

A metodologia de previsão agregada proposta neste trabalho se baseia na criação de um modelo para representar as informações dos barramentos. O objetivo desta abordagem é condensar as informações de diversas séries temporais em um único dispositivo, simplificando a representação através da utilização de apenas uma estrutura (*input*  $\times$  *output*) para representar as informações de um conjunto de barramentos.

O exemplo anterior mostrou o procedimento para realização da previsão individual para os barramentos #33 e #40. Para aplicar o modelo agregado nestes barramentos, a idéia foi criar uma estrutura que represente as informações de cada barramento individualmente em um único modelo.

Na Figura 3.4, é possível observar que a estrutura desenvolvida contém padrões de entrada para os barramentos #40 e #33, bem como suas respectivas saídas. Pode-se notar que com este arranjo de dados o conjunto de padrões de barramentos distintos foi representado por meio de um único dispositivo. Em termos práticos, observando a Figura 3.4, é possível verificar que o padrão relacionado ao barramento #40 é expresso através de duas entradas e uma saída, enquanto o barramento #33 tem seu comportamento descrito por uma entrada e uma saída. Como as informações de diferentes barramentos estão na mesma estrutura, são utilizados valores nulos para diferenciar os padrões de cada barramento. Esta estratégia faz com que parâmetros no modelo de previsão sejam utilizados para representar cada um dos barramentos na estrutura agregada. De maneira simples, a estrutura agregada é formada através dos conjuntos de padrões individuais (cada barramento), condensados em uma estrutura única. Esta abordagem mantém a estrutura individual respeitando as características (*input*

× *output*) de cada barramento.

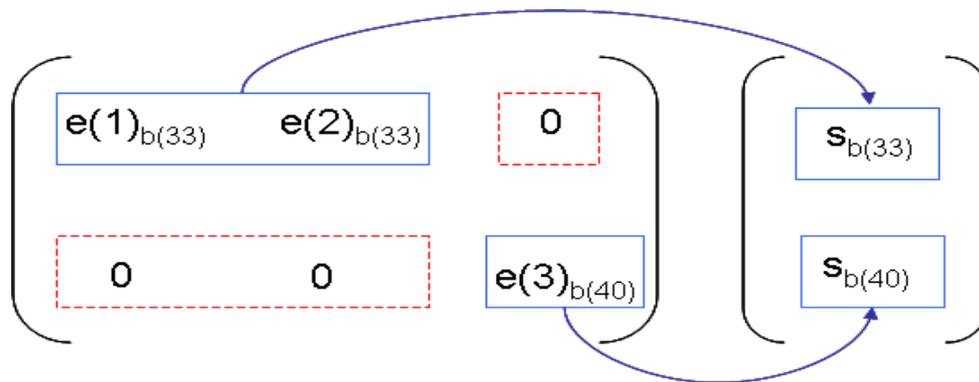


Figura 3.4: Diagrama de Estrutura Agregada.

Com a estrutura agregada mostrada na Figura 3.4, os barramentos #40 e #33 são expressos em termos de suas entradas e saídas. De posse do conjunto de padrões, é possível utilizar um previsor para aprender as características do conjunto e fornecer a previsão para os barramentos #40 e #33 simultaneamente, sendo necessário apenas um ajuste para o modelo. Este modelo agregado mantém as entradas específicas para o barramento #40 e #33 e, como pode ser observado as duas primeiras representam o barramento #40 e a última representa o #33. A Figura 3.5, mostra um diagrama de uma rede neural multicamadas utilizada para representar os dados dos barramentos #40 e #33, anteriormente descrito. Nesta ilustração, o ajuste dos parâmetros da rede é executado utilizando os padrões de cada um dos barramentos ou seja, no processo de ajuste do modelo ora são apresentados dados do barramento #40 e ora são apresentados dados do barramento #33. Quando são apresentados dados do barramento #40 a terceira entrada relativa ao barramento #33 é anulada. Por outro lado, quando são apresentados os dados do barramento #33, as duas primeiras entradas relativas ao barramento #40 são anuladas.

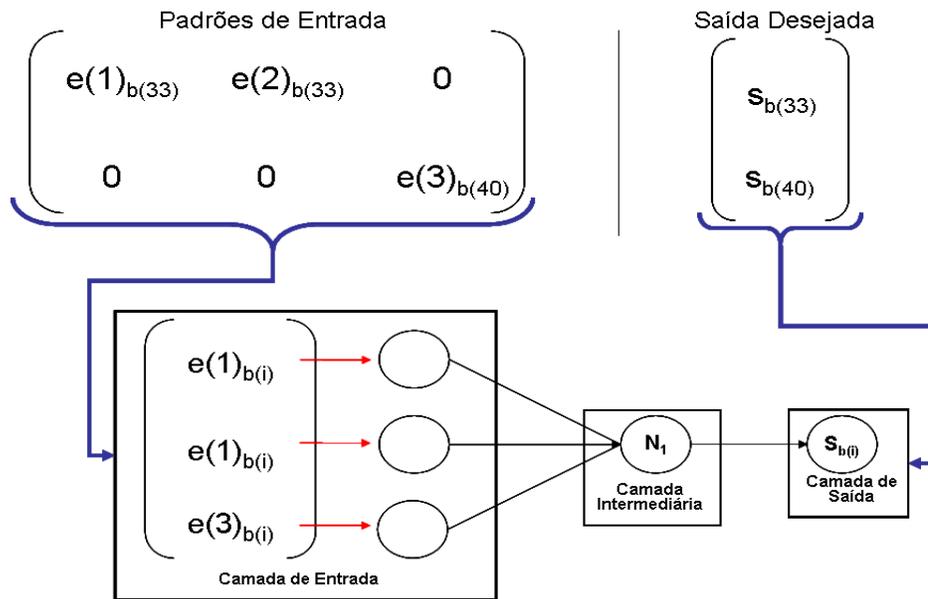


Figura 3.5: Esquema: Topologia Neural - (Caso Agregado).

### 3.2.2.1 Caso Elementar - Previsão Agregada

Na Figura 3.4, é possível observar entradas nulas associadas aos pares (*input* × *output*) de cada barramento. Os valores nulos apresentados têm a função de fazer com que as entradas utilizadas no conjunto de padrões de cada barramento exerçam maior influência sobre o próprio barramento. Este princípio visa obter com a metodologia agregada resultados similares aos obtidos via modelo individual através da utilização da mesma estrutura (*input* × *output*). Matricialmente, as informações apresentadas na Figura 3.4 podem ser enxergadas da seguinte forma:

$$I = \begin{bmatrix} e(1)_{b(40)} & e(2)_{b(40)} & 0 \\ 0 & 0 & e(1)_{b(33)} \end{bmatrix}$$

$$O = \begin{bmatrix} s_{b(40)} \\ s_{b(33)} \end{bmatrix}$$

Nesta representação, a matriz  $I$  representa as entradas e a matriz  $O$  a saída nos barramentos #40 e #33. Pensando em um modelo de regressão

linear múltipla, é possível escrever as relações das matrizes  $I$  e  $O$  através dos coeficientes do modelo linear. A Equação 3.1 mostra a matriz dos coeficientes do modelo linear  $W$  utilizada para representar a ligação existente entre as matrizes  $I$  e  $O$  respectivamente.

$$IW = O \quad (3.1)$$

A matriz de coeficientes do modelo de regressão linear  $W$  pode ser representada através da seguinte notação:

$$W = \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix}$$

Expandindo a Equação 3.1, tem-se uma representação das matrizes  $I$ ,  $O$  e  $W$  de acordo com seus elementos, como pode ser observado na Equação 3.2.

$$\begin{bmatrix} e(1)_{b(40)} & e(2)_{b(40)} & 0 \\ 0 & 0 & e(1)_{b(33)} \end{bmatrix} \times \begin{pmatrix} w_1 \\ w_2 \\ w_3 \end{pmatrix} = \begin{bmatrix} s_{b(40)} \\ s_{b(33)} \end{bmatrix} \quad (3.2)$$

Realizando as operações algébricas de multiplicação matricial na Equação 3.2, obtém-se o sistema algébrico de Equações lineares segundo a Equação 3.3. Nesta representação, as relações entre as matrizes  $I$  e  $O$  são expressas pelos valores dos coeficientes da matriz  $W$ .

$$\begin{cases} [e(1)_{b(40)}] w_1 + [e(2)_{b(40)}] w_2 + 0w_3 = s_{b(40)} \\ 0w_1 + 0w_2 + [e(1)_{b(33)}] w_3 = s_{b(33)} \end{cases} \quad (3.3)$$

Observando a disposição dos coeficientes na Equação 3.3, tem-se que os coeficientes  $w_1$  e  $w_2$  estão associados aos dados do barramento #40 e o coeficiente  $w_3$  está associado às informações do barramento #33; isto é, há uma independência nas equações que expressam as estruturas de cada um dos bar-

ramentos. Desta forma, as informações das equações representadas pelo sistema 3.3 podem ser reescritas através de dois sistemas lineares reduzidos conforme as equações 3.4 e 3.5.

$$\begin{bmatrix} e(1)_{b(40)} & e(2)_{b(40)} \end{bmatrix} \times \begin{pmatrix} w_1 \\ w_2 \end{pmatrix} = \begin{bmatrix} s_{b(40)} \end{bmatrix} \quad (3.4)$$

$$\begin{bmatrix} e(1)_{b(33)} \end{bmatrix} \times \begin{pmatrix} w_3 \end{pmatrix} = \begin{bmatrix} s_{b(33)} \end{bmatrix} \quad (3.5)$$

Este desmembramento das equações do sistema 3.3 em dois subsistemas (sistemas 3.4 e 3.5) mostra que as estruturas expressas na matriz agregada podem ser vistos como dois problemas, associados a cada barramento. Assim, quando o técnica escolhida tem princípio linear, a estrutura agregada pode ser vista como a união de vários problemas resolvidos pelo mesmo modelo de previsão.

Em modelos de previsão conexionistas (baseados em redes neurais artificiais), há uma mistura das informações dos conjuntos de (*input* × *output*) individuais na fase de ajuste dos parâmetros do previsor, que acontece devido ao princípio de funcionamento destes modelos. Por este motivo não é correto dizer que a inserção de valores nulos na matriz agregada elimina a influência de um barramento sobre o outro. A melhor descrição para o processo de inserção de valores nulos na estrutura agregada é que o seu uso faz com que partes do modelo de previsão (parâmetros ou pesos) fiquem especializados em dados de barramentos específicos.

### 3.3 Generalização do Modelo

O modelo de previsão desenvolvido neste trabalho propõe um processo de previsão agregada para cada grupo de barramentos similares no qual um conjunto de padrões individuais (*input* × *output*) são apresentados através de uma única estrutura agregada. A idéia principal consiste em criar um conjunto (*input* × *output*) que contenha, de forma condensada, as informações de cada

barramento através de seus padrões individuais. Desta forma, para cada grupo de barramentos é criada uma estrutura agregada que proporcionará o ajuste do modelo de previsão.

Para criar a estrutura agregada, em cada grupo encontrado no processo de agrupamento, a idéia principal é usar o conjunto individual (*input* × *output*) de cada barramento para formar a estrutura agregada (*input* × *output*) com base em todas informações dos barramentos que pertencem ao grupo analisado.

### 3.3.1 Procedimento Geral

A metodologia agregada desenvolvida neste trabalho pode ser executada a partir das seguintes etapas:

- **1.** Agrupamento;
- **2.** Criação do conjunto de padrões agregado;
- **3.** Ajuste do Previsor;
- **4.** Aplicação do Previsor Ajustado.

Dado um conjunto formado por diversos barramentos, a etapa de agrupamento objetiva encontrar subconjuntos formados por barramentos com perfis de carga similares. De posse dos subconjuntos de barramentos, a próxima fase visa criar uma estrutura agregada de padrões (*input* × *output*) para representar os barramentos pertencentes em cada subconjunto encontrado. Com as informações agregadas, a próxima fase executa o ajuste do previsor em cada estrutura e, logo após o ajuste, o modelo agregado está apto a realizar as previsões em cada barramento pertencente ao subconjunto escolhido. A Figura 3.6 mostra as etapas para execução da metodologia agregada em um exemplo didático, esboçando cada uma das etapas anteriormente descritas.

O Algoritmo 1 descreve, com maior detalhe, a seqüência de passos que definem o processo de execução para a metodologia agregada.

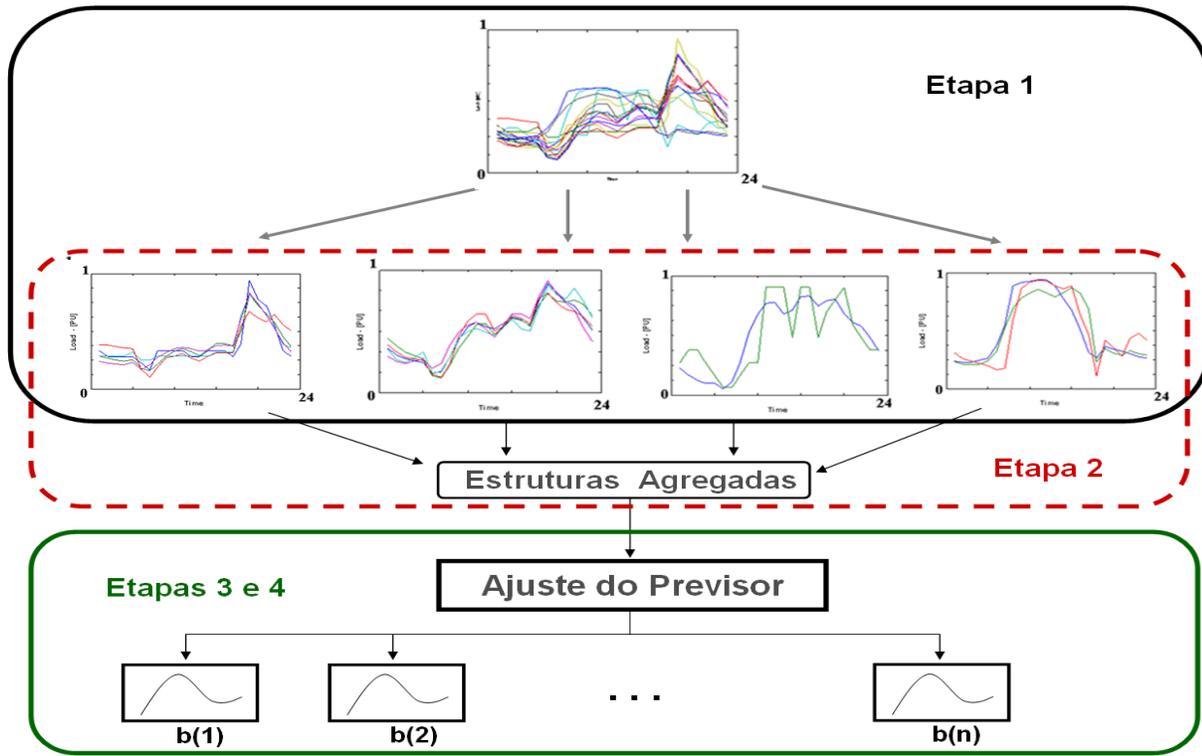


Figura 3.6: Fluxograma - Metodologia Agregada.

---

### Algorithm 1 Metodologia de Previsão Agregada

---

//Encontrar os grupos de barramentos similares

1. Seja um sistema  $B$  com  $n$  barramentos, onde  $B = \{b(1), b(2), \dots, b(n)\}$  e cada  $b(i) \in \mathfrak{R}^{24}$  é um vetor de 24 componentes que dimensionam as cargas diárias de cada barramento. Seja  $G = \{g(1), g(2), \dots, g(k)\}$  um conjunto de  $k$  grupos disjuntos onde  $k < n$ .  $G$  é obtido de forma que as seguintes condições sejam atendidas:  $g(1) \cup g(2) \cup \dots \cup g(k) = B$ ,  $g(i) \neq \emptyset, \forall i, 1 \leq i \leq k$  e  $g(i) \cap g(j) = \emptyset, \forall i \neq j, 1 \leq i, j \leq k$ .

//Gerar a estrutura agregada

2. Para cada  $g(i) \in G$  encontrar a estrutura agregada

//Realizar o treinamento do previsor

3. Fazer o treinamento do previsor via estrutura agregada

//Realizar a previsão para cada barramento

4. Realizar a previsão para cada  $b(i) \in g(i)$  utilizando o ajuste agregado realizado na etapa anterior

---

A base da metodologia agregada são as estruturas de padrões individuais de cada barramento do sistema. Assim, antes de comentar explicitamente a metodologia agregada, será realizada uma pequena discussão sobre a estrutura individual de cada barramento.

### 3.3.1.1 Estrutura Individual

A estrutura individual é representada por um conjunto de padrões (*input*  $\times$  *output*) que contém informações representativas sobre o barramento desejado. Para facilitar o entendimento, serão definidas duas matrizes,  $E_{b(i)}$  e  $S_{b(i)}$ , que serão utilizadas para representar a entrada e saída, respectivamente, na estrutura individual de cada barramento  $i$ .

As matrizes  $E_{b(i)}$  e  $S_{b(i)}$  têm a função de representar a estrutura individual para cada barramento  $i$  no sistema analisado, sendo que cada estrutura individual contém informações para realizar o ajuste do previsor individual no respectivo barramento  $i$ .

Os elementos da matriz  $E_{b(i)}$  são denotados por  $e_{(m,n)}[b(i)]$ , onde  $m = 1, \dots, M$  representa o número de padrões,  $n = 1, \dots, N$  o número de entradas e  $b(i)$  define a qual barramento os dados pertencem. Cada elemento  $e_{(m,n)}[b(i)]$  compõe os padrões de entrada do conjunto de padrões do barramento  $i$  conforme mostrado na Equação 3.6, onde a matriz  $E_{b(i)}$  contém  $M$  padrões com  $N$  elementos em cada padrão.

$$\overbrace{\begin{bmatrix} e_{(1,1)}[b(i)] & e_{(1,2)}[b(i)] & \cdots & e_{(1,N)}[b(i)] \\ e_{(2,1)}[b(i)] & e_{(2,2)}[b(i)] & \cdots & e_{(2,N)}[b(i)] \\ \vdots & \vdots & \ddots & \vdots \\ e_{(M,1)}[b(i)] & e_{(M,2)}[b(i)] & \cdots & e_{(M,N)}[b(i)] \end{bmatrix}}^{E_{b(i)}} \quad (3.6)$$

De maneira análoga, o vetor  $S_{b(i)}$  contém a saída desejada para cada padrão da matriz  $E_{b(i)}$ . Neste caso, cada elemento da matriz  $S_{b(i)}$  é matematicamente representado por  $s_{(m)}[b(i)]$ , onde  $m$  representa o número de padrões relativos ao barramento  $i$ . Um exemplo do vetor  $S_{b(i)}$  contendo  $M$  padrões pode ser visto pela

Equação 3.7.

$$\overbrace{\begin{bmatrix} s_{(1)}[b(i)] \\ s_{(2)}[b(i)] \\ \vdots \\ s_{(M)}[b(i)] \end{bmatrix}}^{S_{b(i)}} \quad (3.7)$$

A partir das matrizes  $E_{b(i)}$  e  $S_{b(i)}$ , é possível criar a estrutura (*input*  $\times$  *output*) para o barramento  $i$  e ajustar um previsor através das informações contidas nos elementos desta estrutura.

### 3.3.1.2 Estrutura Agregada

Seja  $r = 1, \dots, R$  o número de barramentos obtidos em um determinado grupo  $g = 1, \dots, G$  através de um processo de agrupamento. Para facilitar o entendimento da técnica foram criadas duas matrizes  $I$  e  $O$  para representar a entrada e saída para a estrutura agregada desenvolvida neste trabalho.

Como a estrutura agregada deve conter as informações de cada barramento, a matriz  $I$  será formada por  $r$  matrizes  $\{E_{b(1)}, E_{b(2)}, \dots, E_{b(R-1)}, E_{b(R)}\}$  que contêm os padrões de entrada para cada um dos  $r$  barramentos do grupo. Cada matriz  $E_{b(i)}$  representa a estrutura individual para o barramento  $i$  que contém os padrões (*input*  $\times$  *output*). De maneira análoga, a matriz  $O$  é uma estrutura vetorial formada por  $r$  elementos  $\{S_{b(1)}, S_{b(2)}, \dots, S_{b(R-1)}, S_{b(R)}\}$ , que contém a saída desejada para cada padrão na matriz  $E_{b(i)}$  pertencente ao barramento  $i$ .

Para cada barramento  $i$  no grupo  $g$  existe uma associação ( $E_{b(i)} \times S_{b(i)}$ ) que representa a estrutura individual (*input*  $\times$  *output*). A estrutura agregada contém todos os conjuntos individuais ( $E_{b(i)} \times S_{b(i)}$ ) pertencentes ao grupo  $g$  e pode ser matricialmente representada segundo as equações 3.8 e 3.9 abaixo descritas:

$$I = \begin{bmatrix} E_{b(1)} & 0 & \cdots & 0 & 0 \\ 0 & E_{b(2)} & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & E_{b(R-1)} & 0 \\ 0 & 0 & \cdots & 0 & E_{b(R)} \end{bmatrix} \quad (3.8)$$

$$O = \begin{bmatrix} S_{b(1)} \\ S_{b(2)} \\ \vdots \\ S_{b(R-1)} \\ S_{b(R)} \end{bmatrix} \quad (3.9)$$

De maneira resumida, a matriz  $I$  contém as informações de cada barramento pertencente ao mesmo grupo e a matriz  $O$  é formada pela saída desejada de cada barramento  $i$  respectivamente. Com as matrizes  $I$  e  $O$  definidas anteriormente, é possível criar a estrutura agregada e executar a previsão de carga ajustando um simples previsor para aprender as relações  $(I \times O)$  da coleção de padrões agregados.

O conjunto (matriz  $\times$  vetor) mostrado na Equação 3.10 apresenta a estrutura agregada  $(I \times O)$  para um caso geral. Nesta matriz, é possível ver a estrutura do barramento #1 expresso em termos das matrizes  $(E_{b(i)} \times S_{b(i)})$ , que detalham os elementos utilizados para formar as entradas/saídas que serão utilizadas para ajustar um algoritmo de previsão.

$$\begin{bmatrix} \left\{ \begin{array}{cccc} e_{(1,1)}[b(i)] & e_{(1,2)}[b(i)] & \cdots & e_{(1,n)}[b(i)] \\ e_{(2,1)}[b(i)] & e_{(2,2)}[b(i)] & \cdots & e_{(2,n)}[b(i)] \\ \vdots & \vdots & \ddots & \vdots \\ e_{(m,1)}[b(i)] & e_{(m,2)}[b(i)] & \cdots & e_{(m,n)}[b(i)] \end{array} \right\} & 0 & \cdots & 0 \\ & 0 & \cdots & E_{b(2)} & \cdots & 0 \\ & \vdots & & \vdots & \ddots & \vdots \\ & 0 & & 0 & \cdots & E_{b(R)} \end{bmatrix} \times \begin{bmatrix} \left\{ \begin{array}{c} s_{(1)}[b(i)] \\ s_{(2)}[b(i)] \\ \vdots \\ s_{(m)}[b(i)] \end{array} \right\} \\ S_{b(2)} \\ \vdots \\ S_{b(R)} \end{bmatrix} \quad (3.10)$$

Um fato a ser observado é que, se um grupo for formado por uma grande quantidade de barramentos, e cada barramento possuir uma dimensão elevada, a estrutura agregada irá possuir, conseqüentemente, uma alta dimensão associada aos barramentos presentes em sua formação.

Normalmente o processo de ajuste de uma estrutura com alta dimensão pode não ser eficiente devido a vários fatores (alta dimensionalidade, redundância nos dados, entre outros). Neste caso, deve-se realizar algum tipo de manipulação para obter uma estrutura agregada representativa que possua menor dimensão.

### 3.3.2 Dimensionalidade da Estrutura Agregada

A técnica de previsão agregada apresentada anteriormente usa uma única estrutura para representar todos os elementos de um determinado grupo de barramentos com perfil semelhante. O processo de inserir vários conjuntos de padrões individuais em uma única estrutura causa um impacto na dimensão do conjunto de padrões agregados. Este impacto na dimensionalidade é dependente do número de barramentos do grupo e também da dimensão do conjunto de padrões (*input*  $\times$  *output*) de cada barramento. O seguinte exemplo mostra este impacto no processo de agregação e a sua dependência em relação ao número e a dimensionalidade dos barramentos.

Suponha que seja necessário realizar a previsão da carga por barramento das 14 horas do dia 27 de outubro de 2001 e que, para este exemplo, o algoritmo de agrupamento tenha encontrado um grupo formado por 5 barramentos com perfil semelhante. Cada um dos barramentos possui uma estrutura individual que pode ser utilizada para ajustar um modelo específico (individual) e prever a carga desejada no barramento. A Tabela 3.1 mostra a dimensionalidade do conjunto de padrões para os barramentos pertencentes ao grupo encontrado. As dimensões são apresentadas em termos das variáveis  $m \times n$  sendo que  $m$  representa o número de padrões e  $n$  o número de entradas utilizadas para ajustar o modelo de previsão.

---

<sup>1</sup>Os valores  $m$  e  $n$  significam o número de padrões e entradas em cada barramento respectivamente.

Tabela 3.1: Exemplo: Dimensão dos Barramentos<sup>1</sup>.

<b>Barramento</b>	<b>Dimensão <math>m \times n</math></b>
#2	$7 \times 10$
#12	$6 \times 15$
#15	$10 \times 15$
#23	$5 \times 20$
#31	$5 \times 10$

Pode-se perceber, neste exemplo, que o número de entradas dos barramentos (variável  $n$ ) gira em torno de 10 a 20. Como o processo agregado visa representar todas as estruturas individuais, tem-se que a dimensão da estrutura agregada, para este pequeno exemplo será, de  $33 \times 70$ , isto é, 33 padrões formados por 70 entradas para representar a estrutura individual de cada barramento do grupo analisado.

De maneira geral, pode-se destacar que a dimensão da estrutura agregada é dada pela soma algébrica da dimensão de cada barramento. Desta forma, quanto maior for o número e a dimensão do conjunto de padrões dos barramentos maior será a dimensão da estrutura agregada.

### 3.4 Processo de Compressão de Informação

Conforme foi analisado no exemplo anterior, a dimensão da estrutura agregada pode se tornar demasiadamente alta dependendo do conjunto de barramentos analisado. Se um grupo possuir vários barramentos em sua formação e cada barramento for composto por muitas entradas, a estrutura agregada utilizada na representação deste grupo irá possuir alta dimensionalidade, e esta característica, na fase de ajuste do previsor pode causar problemas como: dificuldades na convergência e lentidão no processo de ajuste.

Para contornar este problema, isto é, manter o poder de representatividade da estrutura agregada em um conjunto com dimensão reduzida, uma solução encontrada é utilizar um algoritmo de compactação de informações.

### 3.4.1 Importância da redução da dimensionalidade

Uma forma de facilitar a análise de um conjunto de dados com grandes dimensões pode ser visto através da obtenção de uma representação num espaço de menor dimensionalidade. Esta redução pode ser obtida através de uma representação gráfica ou por meio da criação de um novo conjunto de coordenadas.

Vale ressaltar que, ao fazer a redução do espaço real de representação, corre-se o risco de perder informação. Esta perda de informação significa que o conjunto reduzido não revela de forma completa características presentes nos dados originais. Portanto, deve-se ter a devida atenção no momento de utilizar uma técnica de redução ou compactação de informação.

Uma técnica estatística muito conhecida e aplicada, que permite a redução de variáveis quantitativas, estudada por Pearson em 1901 (Pearson, 1901) e consolidada por Hotteling em 1933, é chamada análise de componentes principais (Lebart et al., 1995). Esta técnica multivariada consiste, basicamente, em analisar um conjunto de variáveis numéricas com alta dimensionalidade de representação, reduzindo o número de variáveis, mantendo a máxima variabilidade dos dados originais, minimizando assim a perda de informação no processo de redução. (Han e Kamber, 2001) citam a técnica de componentes principais entre as estratégias aplicadas na redução de base de dados. Esta técnica estatística é bem conhecida e alcança bons resultados na etapa de pré-processamento em grandes bases de dados (Johnson e Wichern, 2002).

### 3.4.2 Análise de Componentes Principais - PCA

A análise de componentes principais (*Principal Component Analysis - PCA*), também conhecida como transformada de *Hotelling* ou *Karhunen-Loève*, é uma técnica estatística clássica utilizada em análise de dados, extração de características e compressão de informação. O objetivo principal da análise de componentes principais é a obtenção de combinações lineares (componentes principais) de um conjunto inicial de variáveis, que retenham o máximo possível da informação contida nas variáveis originais.

Freqüentemente, o PCA tem sido utilizado em diversas aplicações tais como: previsão de carga elétrica (Liu e Yang, 2008), análise de agrupamento (Ding e He., 2004), compressão de informação (Ding et al., 2005) entre outras aplicações. Em linhas gerais, o PCA consiste em reescrever as variáveis originais em novas variáveis denominadas componentes principais, através de uma transformação de coordenadas.

O PCA, como etapa de pré-processamento, também é indicado como método para melhorar o desempenho do algoritmo de treinamento em redes neurais artificiais. Segundo (Haykin, 1994), o algoritmo de treinamento *backpropagation* tem sua performance melhorada se as variáveis não forem correlacionadas, e a tarefa de gerar variáveis não-correlacionadas pode ser executada pelo PCA.

Um dos objetivos da técnica de componentes principais é a simplificação estrutural dos dados, que consiste na transformação do conjunto original de variáveis em um outro conjunto. Isso permite resumir informações contidas no conjunto de variáveis originais, eliminando as informações redundantes existentes em decorrência das correlações entre variáveis.

O foco é avaliar a importância de cada variável e promover a eliminação daquelas que pouco contribuem no grupo. A análise de componentes principais é usada para explicar a estrutura de variância e covariância de um conjunto de variáveis através de um conjunto menor de combinações lineares das variáveis. A idéia é a de eliminar variáveis redundantes, isto é, que forneçam informações já contidas nas outras variáveis. Isto pode levar à economia na obtenção de novos dados, e simplificação na interpretação dos resultados. Através da análise da correlação entre as variáveis, combinações lineares destas (denominadas “componentes”) são construídas de forma a capturar a maior parte da variância contida nos dados. O desempenho da técnica é melhor quanto mais correlacionadas são as variáveis, pois isso indica a existência de componentes em comum que permitem a sintetização da informação nelas contida. Para aplicação da análise, as variáveis devem ser normalizadas de forma a remover eventuais efeitos de escala.

A análise das inter-relações entre variáveis permite identificar as di-

mensões subjacentes em um conjunto de dados. Tal identificação é feita reduzindo a dimensionalidade original que é determinada através da criação de um novo sistema de coordenadas. No novo sistema, a origem é a média multivariada da amostra e o número de eixos é igual ao do sistema original (correspondente ao número de variáveis na base de dados). O eixo do novo sistema, denotado por  $R_2$  na Figura 3.7, é posicionado na direção de maior variabilidade dos dados. O segundo  $R_1$  é posicionado ortogonalmente ao primeiro, passando pela origem, na segunda direção de maior variabilidade e assim, sucessivamente, até que todas as direções de variabilidade sejam representadas.

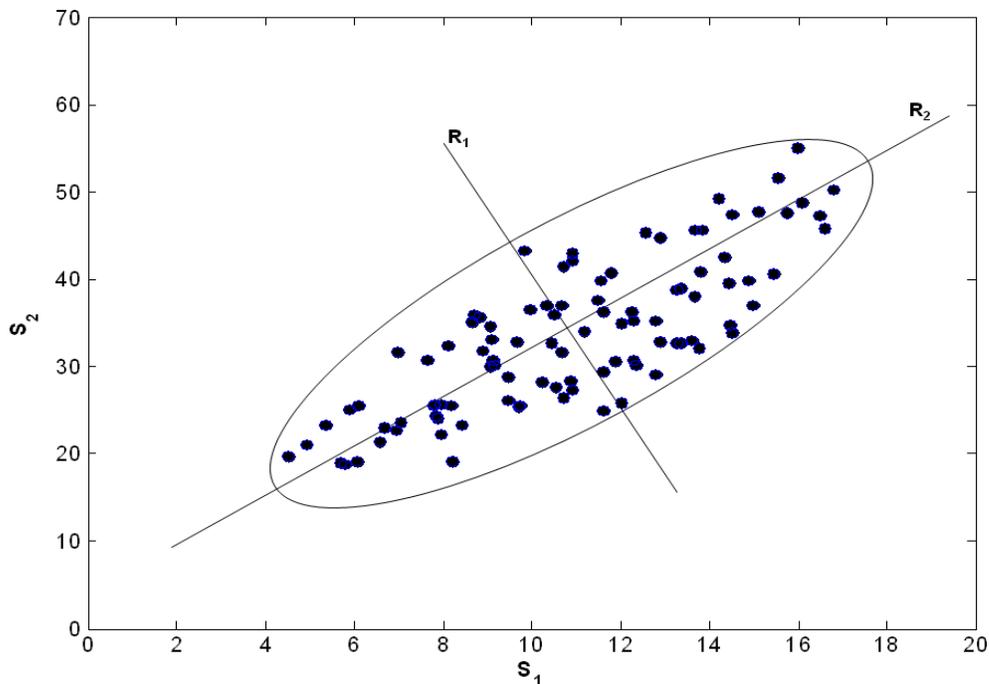


Figura 3.7: Exemplo: Sistema de Eixos - PCA.

O PCA é implementado extraindo autovalores e autovetores da matriz de correlações das variáveis originais. As projeções dessas variáveis nos eixos ilustrados na Figura 3.7, por exemplo, correspondem às coordenadas dos dois primeiros autovetores obtidos; analogamente, a variância representada em cada eixo é dada pelos dois primeiros autovalores. Cada eixo no novo sistema de coordenadas é denominado componente e os primeiros componentes, com autovalores mais altos, são os componentes principais, que representam a verdadeira dimensionalidade dos dados (isto é, a dimensionalidade suficiente para explicar

a maior parte da variabilidade presente nos dados originais).

Formalmente, o PCA transforma um vetor  $S \in \mathfrak{R}^m$  em um outro vetor  $R \in \mathfrak{R}^n$  (onde  $n \leq m$ ) projetando  $S$  nas direções ortogonais de maior variância. Os componentes são extraídos na ordem do mais explicativo para o menos explicativo. O número de componentes é sempre igual ao número de variáveis, entretanto alguns poucos componentes são responsáveis por grande parte da explicação total.

Os componentes principais são as novas variáveis geradas através de uma transformação matemática especial realizada sobre as variáveis originais. Nestas transformações, cada variável terá uma importância ou peso diferente. Após este processo os componentes com maior representatividade dos dados são escolhidos para representar as variáveis originais em um espaço reduzido.

### 3.4.3 Algoritmo PCA

Os componentes principais são encontrados através de passos seqüenciais aplicados nos dados originais. As etapas que realizam as manipulações podem ser sumarizadas de acordo com a seguinte ordem:

- ▷ : Padronização dos dados;
- ▷ : Cálculo da matriz de correlações;
- ▷ : Cálculo dos autovalores e autovetores;
- ▷ : Seleção dos componentes principais;

#### **Etapa 1** - Padronização dos dados

Para realizar a padronização geralmente utiliza-se um procedimento que envolve a média e o desvio-padrão dos dados originais. As Equações 3.11, 3.12 e 3.13 mostram o procedimento de padronização no conjunto de dados  $S$ .

- Cálculo da média  $\hat{\mu}$  e variância  $\hat{\sigma}^2$  para cada elemento usando as seguintes Equações:

$$\hat{\mu}_j = \frac{1}{n} \sum_{i=1}^n s_{ij} \quad (3.11)$$

$$\hat{\sigma}_j^2 = \frac{1}{n-1} \sum_{i=1}^n (s_{ij} - \hat{\mu}_j)^2 \quad (3.12)$$

- Padronização dos dados através da seguinte Equação:

$$V_{ij} = \frac{s_{ij} - \hat{\mu}_j}{\hat{\sigma}_j} \quad (3.13)$$

### **Etapa 2** - Calculo da Matriz de Correlações

Esta fase visa encontrar a matriz de correlações para os elementos padronizados. A Equação 3.14 apresenta o procedimento de cálculo que retorna a matriz de correlações  $W$ .

$$W = \frac{1}{n} (V^t V) \quad (3.14)$$

### **Etapa 3** - Cálculo dos Autovalores e Autovetores

Os autovalores  $\lambda_i$  e autovetores  $u_i$  são calculados a partir da matriz de correlação  $W$  segundo as técnicas da teoria de Álgebra Linear.

### **Etapa 4** - Seleção das Componentes Principais

Nesta etapa, os componentes principais que representam o conjunto original são selecionados. Após o processo de transformação, o número total de componentes obtido é igual ao número de elementos no conjunto inicial de dados. Entretanto, geralmente, apenas algumas variáveis são responsáveis por representar a informação do conjunto original.

Cada componente principal expressa quantidades de informação do conjunto original. Os primeiros  $n$  autovetores do total de  $m$ , quando ordenados de forma decrescente segundo seus autovalores ( $\lambda_i$ ), fornecem uma porcentagem de variância acumulada de acordo com a Equação 3.15. Uma forma de selecionar o número de componentes principais para representar o conjunto é utilizar o critério de representação da variação, selecionando, com base na Equação 3.15,

os autovalores que representam a maior porcentagem da variância dos dados. Neste sentido, a idéia é adicionar componentes ao conjunto reduzido até que se alcance uma boa representação do conjunto original.

$$\%var = \left( \frac{\sum_{i=1}^n (\lambda_i)}{\sum_{i=1}^p \lambda_i} \right) \quad (3.15)$$

#### 3.4.4 Redução de Dimensionalidade nos Barramentos via PCA

A técnica de redução de dimensionalidade baseada em PCA foi aplicada, neste trabalho, para realizar a compressão da estrutura agregada buscando encontrar um conjunto representativo em um espaço de menor dimensão. O objetivo de utilizar o PCA é a minimização do impacto da dimensionalidade na representatividade do conjunto de barramentos.

Encontrar uma estrutura agregada reduzida com capacidade de representatividade similar à estrutura original proporciona várias vantagens ao modelo de previsão agregado desenvolvido neste trabalho. Com a redução da estrutura, é possível minimizar os problemas na convergência do previsor e redundância de informações.

Considerando a estrutura agregada formada pela combinação *input* × *output* o algoritmo de compactação PCA será aplicado apenas nos padrões definidos na subestrutura *input*. Isto é, será criado um novo conjunto para representar as entradas (*inputs*) dos barramentos em um espaço de dimensão reduzida. Neste sentido, o conjunto agregado reduzido, será utilizado na etapa de ajuste dos modelos de previsão na etapa de previsão de carga por barramento.

Os resultados numéricos da metodologia agregada de previsão de carga por barramento, bem como a análise dos dados via PCA, serão apresentados no Capítulo 7.



## Sistema de Suporte - *SysPrev*

Este capítulo faz a apresentação do *SysPrev* como um sistema de suporte para análise e previsão de carga por barramento. Serão apresentados exemplos que mostram o *SysPrev* como ferramenta de suporte na realização de simulações, previsões e estudos envolvendo a análise dos dados e descoberta de conhecimento.

O enfoque principal será dado ao *SysPrev* como ferramenta de solução ao problema de previsão de carga por barramento. Neste sentido, os exemplos apresentados tratam da usabilidade do sistema na solução do problema utilizando a metodologia agregada apresentada no Capítulo 3.

Antes de descrever a usabilidade do *SysPrev*, serão feitos alguns esclarecimentos que tratam da importância de sistemas de suporte em processos de decisão.

## 4.1 Descrição Introdutória

Os procedimentos de análise de dados e previsão de séries temporais geralmente envolvem diversas variáveis e parâmetros. Uma boa compreensão dos dados temporais depende da disponibilidade de ferramentas e modelos que possibilitem o estudo detalhado da série.

Em termos de séries temporais de carga, a disponibilidade de uma ferramenta computacional adequada é imprescindível para viabilizar o estudo de cada série temporal associada a um barramento do sistema. Além disso, com um sistema adequado, é possível ter uma boa visão dos barramentos, em termos de carga elétrica, bem como realizar o acompanhamento da carga auxiliando processos decisórios em várias instâncias dentro da operação de sistemas elétricos.

No sentido de auxiliar a análise de um conjunto de barramentos do sistema elétrico, este trabalho propõe um sistema computacional de suporte denominado *SysPrev*, projetado para facilitar a previsão em um ambiente de fácil uso, amigável e intuitivo. Antes de descrever o funcionamento *software SysPrev*, serão apresentados alguns esclarecimentos que tratam da importância de sistemas de suporte em processos decisórios.

### 4.1.1 Sistemas de Suporte

Nas últimas décadas, o desenvolvimento de tecnologias da informação tem propiciado uma rápida coleta de informações viabilizando o armazenamento de grandes e variadas fontes de dados. Diante desta nova ótica, houve uma aceleração no desenvolvimento de novas técnicas e ferramentas que pudessem, além de processar essa enorme quantidade de dados, permitir sua análise para a descoberta de informações úteis, de maneira inteligente e automática, já que a análise de grandes quantidades de dados pelo homem é inviável sem o auxílio de ferramentas computacionais apropriadas. Neste cenário, os sistemas de informação como apoio à tomada de decisão têm sido utilizados cada vez mais ao longo das últimas décadas.

Historicamente, os conceitos envolvidos na área de sistemas de suporte

à tomada de decisão foram definidos por Scott-Morton, que usou o termo “sistema de gerenciamento de decisões” pela primeira vez no início da década de 70 (Turban, 1995). Segundo o trabalho de (Sprague e Watson, 1989), um sistema de suporte à decisão (*Decision Support System - DSS*) pode ser definido como um sistema computacional que, através da interação direta com dados e modelos, auxilia o processo de tomada de decisões na resolução de problemas específicos. Em outra visão, os DSS são vistos como sistemas baseados em computador que ajudam os decisores a utilizar dados e modelos para resolver problemas não-estruturados (Courtney, 2001). De acordo com (Bidgoli, 1989), um DSS é caracterizado como um sistema de informação formado de *hardware* e *software* que, juntamente com a intervenção humana, é capaz de dar suporte ao processo decisório.

De maneira pragmática, uma das definições de maior impacto na área de sistemas de apoio à decisão é encontrada no trabalho (Sprague e Watson, 1993), que caracteriza os DSS como sistemas informatizados e interativos, utilizados no processo decisório, que proporcionam ao decisor acesso fácil a banco de dados e modelos, apoiando a tomada de decisão semi-estruturada ou não-estruturada .

O modelo conceitual de um DSS proposto por (Sprague e Watson, 1993), chamado de paradigma DDM (Diálogos, Dados e Modelos), é composto pelos seguintes itens: banco de dados, banco de modelos, sistema gerenciador de dados, e um sistema gerenciador de modelos, controlados por intermédio de uma interface amigável.

O cálculo de uma previsão é um processo que envolve manipulação de dados e modelos. Para que estas etapas sejam executadas com facilidade e rapidez deve-se utilizar um ambiente computacional que suporte o processo de previsão em um ambiente de fácil uso controlado por meio de uma interface amigável. No contexto de sistemas elétricos de potência, o *software SysPrev* é caracterizado com um sistema que proporciona informações que são úteis em diversas etapas no controle funcional da rede elétrica. Em linhas gerais, o *SysPrev* não é exatamente um sistema de suporte à decisão, uma vez que o processo de cálculo de uma previsão de carga não determina nenhuma decisão propriamente

dita. Neste sentido, o *SysPrev* é caracterizado como um Sistema de Suporte à Previsão que conseqüentemente irá gerar uma decisão.

A Figura 4.1 apresenta os blocos que fazem parte do sistema *SysPrev*. Observando esta figura, é possível ver que o *SysPrev* conta com um **bloco de dados** responsável por armazenar e proporcionar acesso a qualquer informação inserida no sistema, um **bloco de modelos** formado pelos métodos de previsão, análise estatística, funções matemáticas e métodos baseadas em inteligência artificial que permitem extrair informações relevantes existentes nos dados carregados no sistema. O sistema conta, também, com um **gerenciador de comunicação** e acesso capaz de validar os usuários bem como realizar conexões em fontes de dados externas. Todos os blocos são controlados por um **gerenciador principal** que é disponibilizado ao usuário através de uma **interface gráfica** amigável e flexível que proporciona acesso a todas as funções do sistema através dos botões e menus intuitivos.

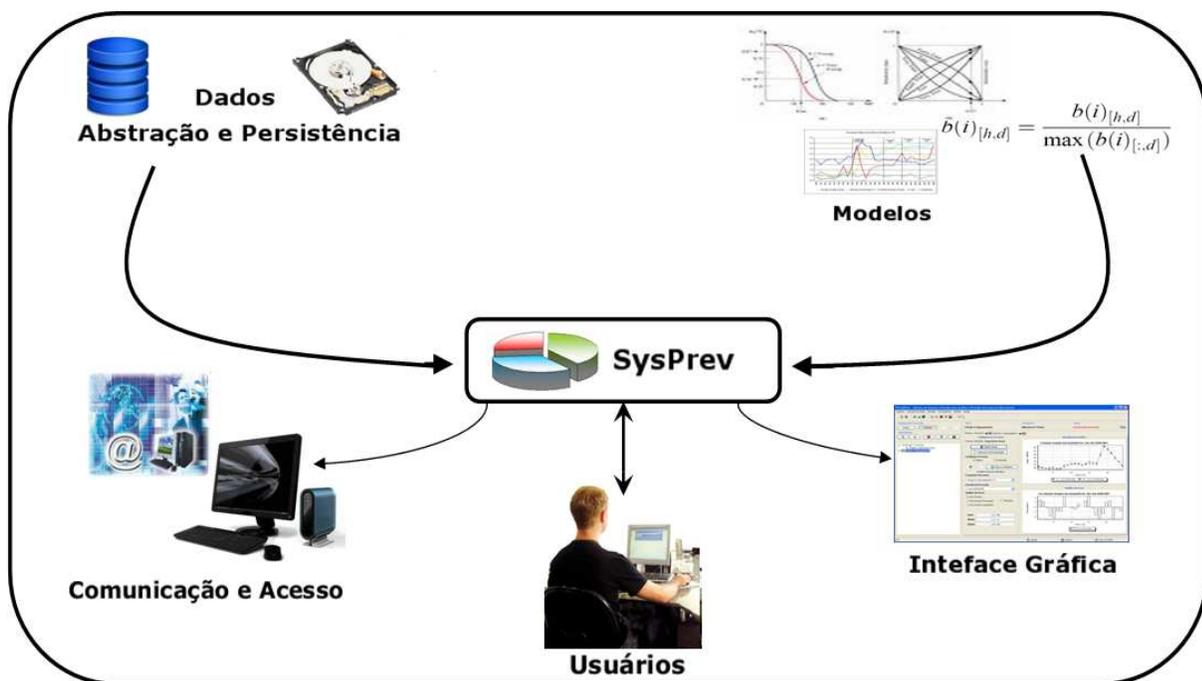


Figura 4.1: Esquema Funcional - *SysPrev*.

Como visto sucintamente, o *SysPrev* é um sistema que fornece ferramentas que dão suporte ao processo de obtenção de previsões em séries de carga

elétrica. Nas Seções a seguir serão apresentadas as etapas envolvidas no processo de previsão de carga e também a execução de um estudo de previsão de carga por barramento utilizando o *SysPrev*.

Neste trabalho, os modelos de previsão de carga inseridos no *SysPrev* são executados seguindo a ordem anteriormente recomendada para previsão de carga por barramento apresentado no Capítulo 3. O ambiente *SysPrev* foi desenvolvido para realizar as previsões em um ambiente prático e simples, facilitando a execução das etapas de análise de dados e configuração de modelos bem como simulações de vários estudos de previsão simultâneos com dados e configurações diversas.

## **4.2 Previsão de Carga - *SysPrev***

O *SysPrev* é um sistema de suporte ao processo de previsão desenvolvido para realizar previsões de carga elétrica global ou por barramento. Para evidenciar a utilização do *software* como sistema de suporte à previsão será apresentado, a seguir, um exemplo mostrando a utilização do *SysPrev* como ferramenta de suporte na realização de simulações, previsões, estudos envolvendo a análise dos dados e descoberta de conhecimento.

No Capítulo 3 foi apresentada a metodologia agregada, desenvolvida neste trabalho, que realiza a previsão de diversos barramentos de forma agregada proporcionando diversas vantagens. Os exemplos apresentados no decorrer deste capítulo tratam da usabilidade do sistema na solução do problema de previsão de carga por barramento utilizando a metodologia agregada proposta neste trabalho.

### **4.2.1 Exemplo: Processo de Previsão - *SysPrev***

Para que o processo de previsão seja realizado é necessário que exista um conjunto de dados e um modelo matemático que será utilizado para estimar os valores de previsão. Inicialmente, conforme definido no Algoritmo 1 apresentado no Capítulo 3, para executar a previsão agregada deve-se selecionar um conjunto de barramentos e carregá-los no sistema. Após o carregamento do con-

junto de dados para cada barramento, o próximo passo é executar o agrupamento visando detectar quais barramentos possuem perfis de consumo similares. Finalizado o processo de agrupamento, as previsões podem ser calculadas para o conjunto de barramentos desejado. Em termos práticos, o processo de previsão de carga por barramento, no *SysPrev*, pode ser resumido de acordo com as seguintes etapas:

- ▷ : **Carregamento e Preparação dos Dados;**
- ▷ : **Agrupamento;**
- ▷ : **Previsão e Análise dos Resultados;**

#### 4.2.1.1 Carregamento e Preparação dos Dados

Quando se pensa em um estudo de previsão, o primeiro passo é o carregamento dos dados, pois a disponibilidade das informações é fundamental para realização de análises, descoberta de conhecimento e previsões. No *SysPrev* as simulações de previsão foram realizadas em um conjunto de dados formado por 73 barramentos pertencentes a um sistema elétrico do Brasil.

Existem várias formas de inserir e acessar a fonte dados, no *SysPrev*. A Figura 4.2, mostra o botão **Data**<sup>1</sup>, responsável por carregar os dados e informações no sistema. O usuário pode carregar dados de diversas origens, arquivos texto escritos em diversos formatos e também carregar informações gravadas no banco de dados do sistema.

Na Figura 4.2 é possível ver os dados de diversas fontes carregados no sistema. Os dados de cada barramento no sistema podem ser acessados e processados de forma individual. Ainda na Figura 4.2 podem ser vistas abas de que cuidam especificamente da realização de manipulações que colaboram para a descoberta de conhecimento nos dados auxiliando o processo de previsão em geral.

---

<sup>1</sup>Nesta execução, o *SysPrev* está definido no idioma Inglês (*en\_US*) entretanto, este botão também pode ser apresentado como **Dados** se o sistema estiver configurado no idioma Português (*pt\_BR*).

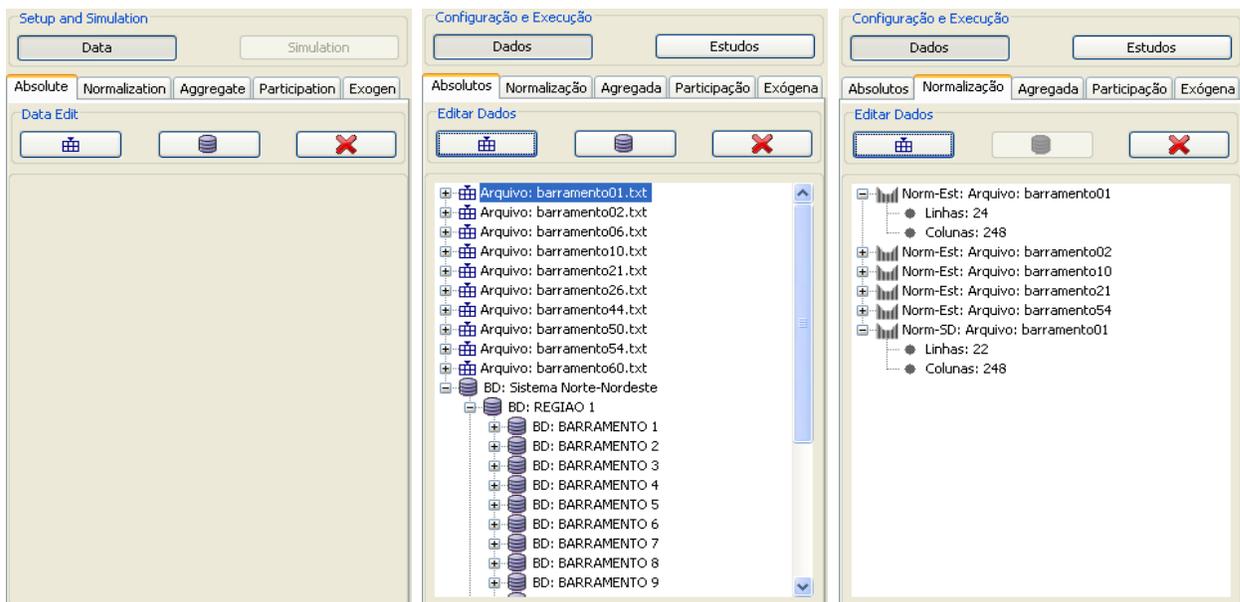


Figura 4.2: Exemplo: Inserção e Controle de Dados - SysPrev.

No *SysPrev* o usuário pode carregar dados em diversos formatos e tabulações. A Figura 4.3 mostra um exemplo da tela de escolha para dados no formato texto. Após a seleção do dado, o importador (implementado no *SysPrev*) é acionado para que sejam definidos os padrões de leitura que devem ser utilizados no carregamento das informações, conforme mostram as Figuras 4.4 e 4.4.

Após o carregamento dos dados, é imprescindível executar etapas de preparação nos dados. Neste sentido, o *SysPrev* conta um conjunto funções desenvolvidas especificamente para realizar a padronização e o tratamento nos dados. Em termos de técnicas, o usuário pode aplicar operadores de normalização bem como usar várias funções estatísticas no intuito de extrair informações importantes dos dados originais. A Figura 4.6 mostra a tela utilizada na escolha da função de normalização, esta facilidade dá ao *SysPrev* versatilidade para o tratamento das séries de dados com diversas abordagens. As Figuras 4.7 e 4.8 mostram o barramento #1 após a aplicação de dois operadores de normalização. Observar-se que os operadores apresentaram resultados diferentes que podem ser utilizados de acordo com o tipo de análise desejada no estudo de previsão.

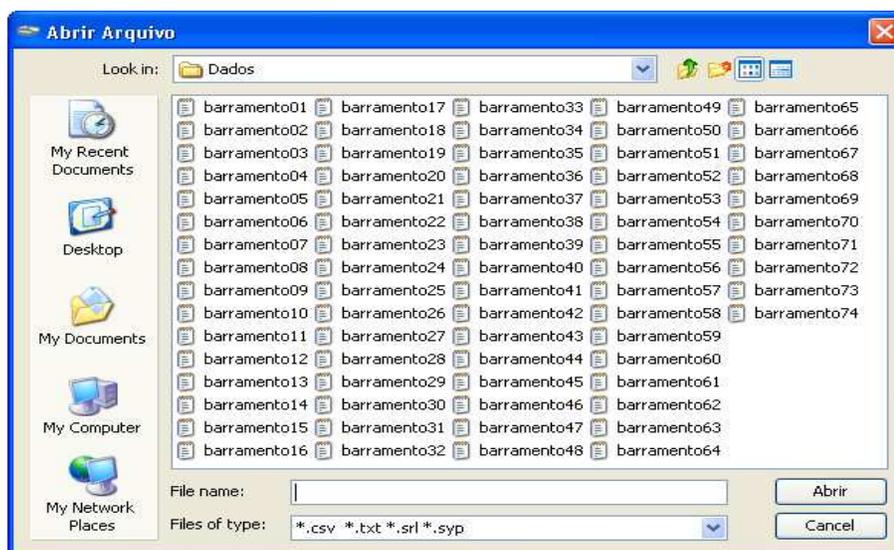


Figura 4.3: Exemplo: Inserção de Dados - SysPrev.

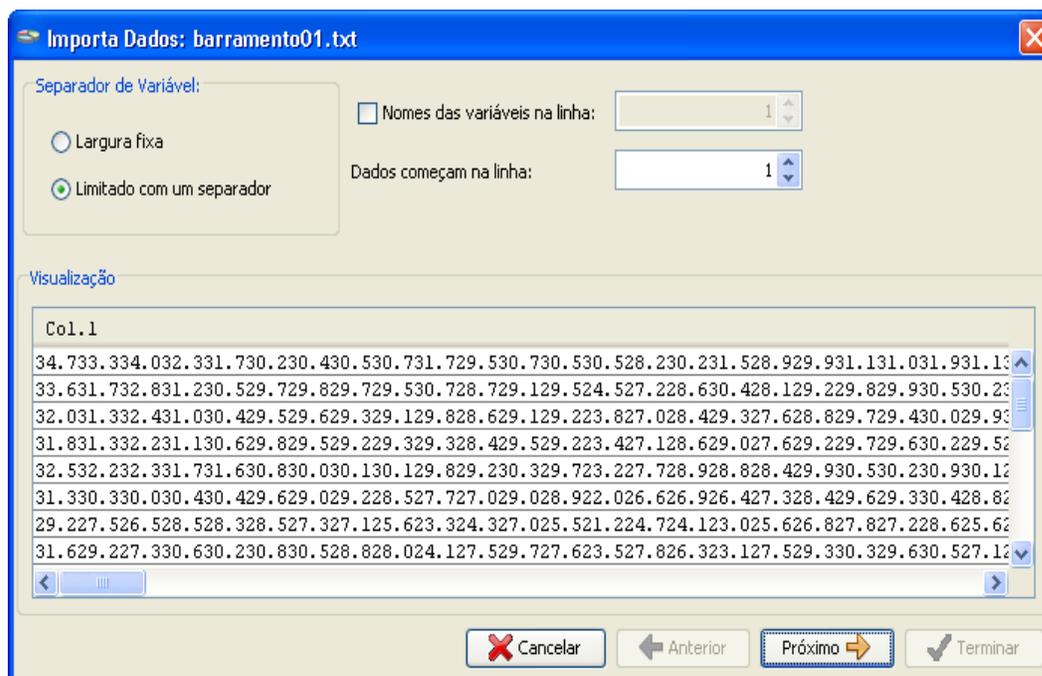


Figura 4.4: Exemplo: Importador de Dados (Tela 1) - SysPrev.

Um recurso que proporciona flexibilidade ao SysPrev é a facilidade de visualização gráfica. Neste sentido, foram implementadas diversas opções de visualização que colaboram para a descoberta de tendências e padrões nos dados.

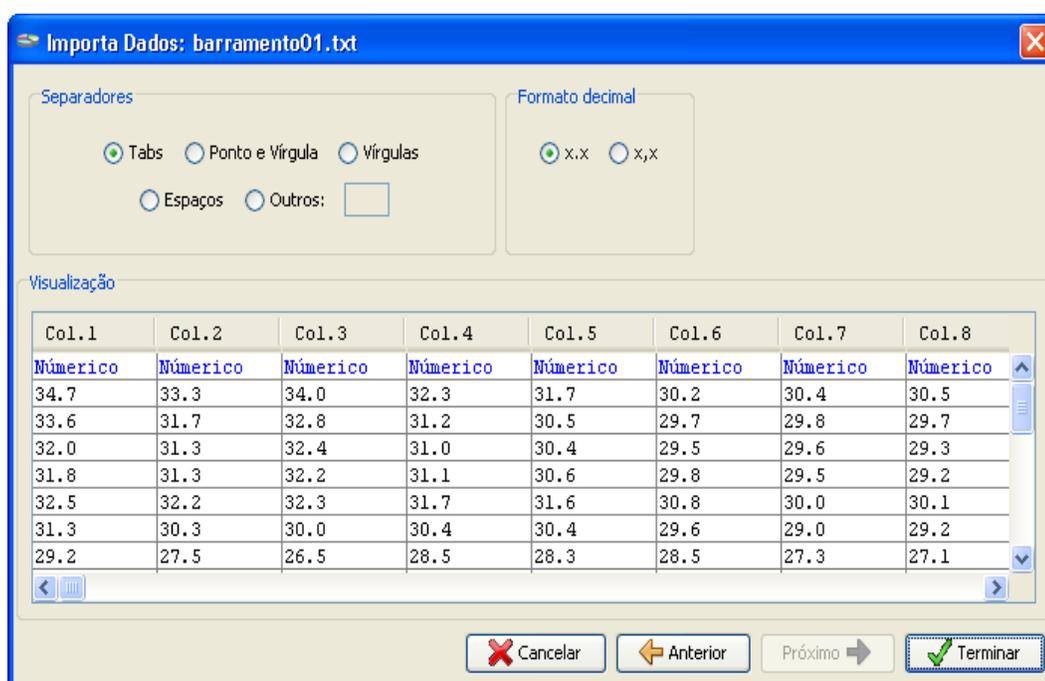


Figura 4.5: Exemplo: Importador de Dados (Tela 2) - SysPrev.

A Figura 4.9 apresenta o gráfico de curvas diárias do barramento #1. Além da apresentação em curvas diárias, é possível escolher outras formas de visualização e também, acompanhar numericamente a evolução das cargas entre os dias do histórico.

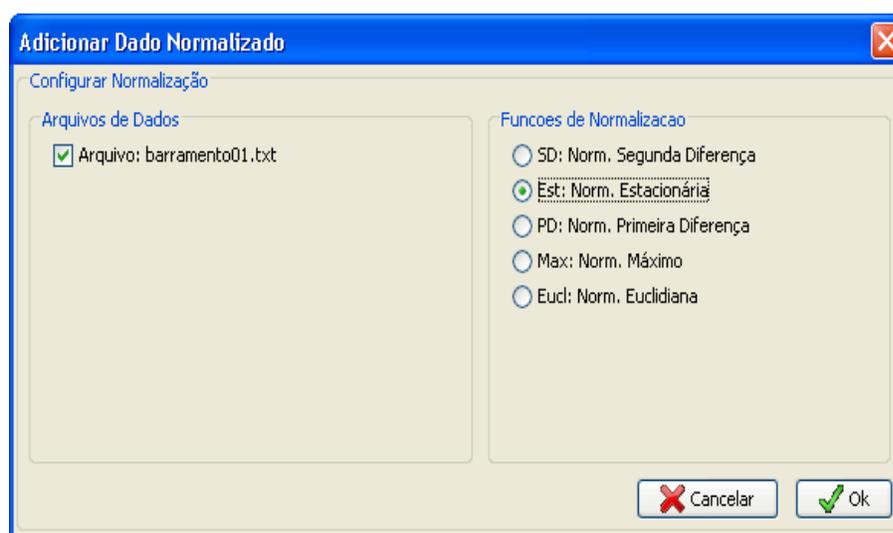


Figura 4.6: Exemplo: Funções de Normalização - SysPrev.

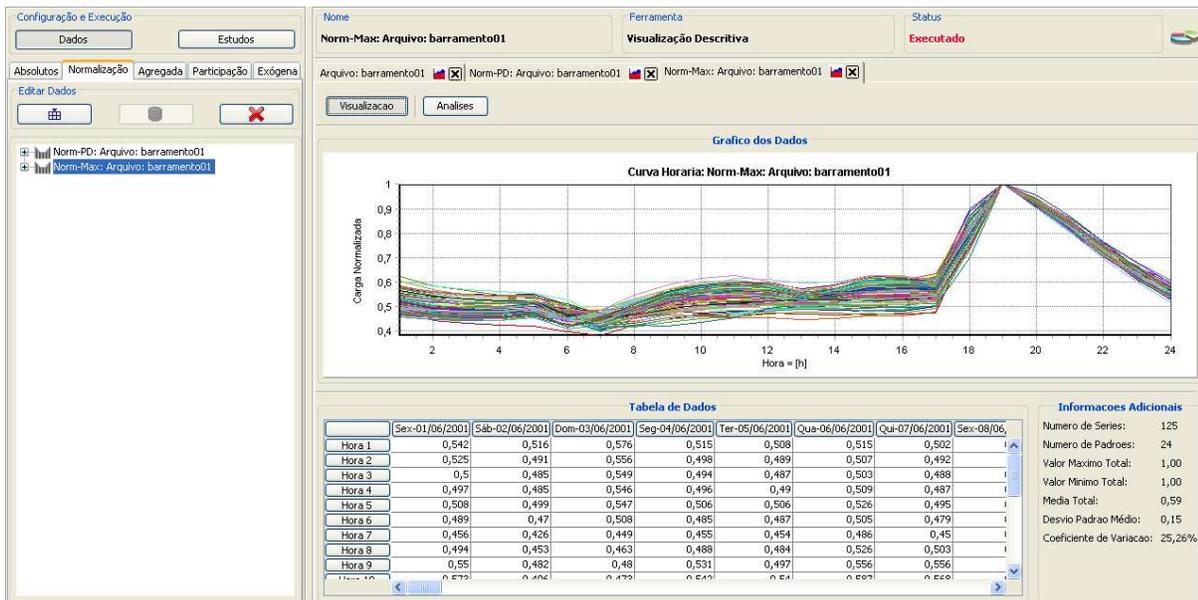


Figura 4.7: Exemplo: Normalização | Função Máximo - SysPrev.



Figura 4.8: Exemplo: Normalização | Função Primeira Diferença - SysPrev.

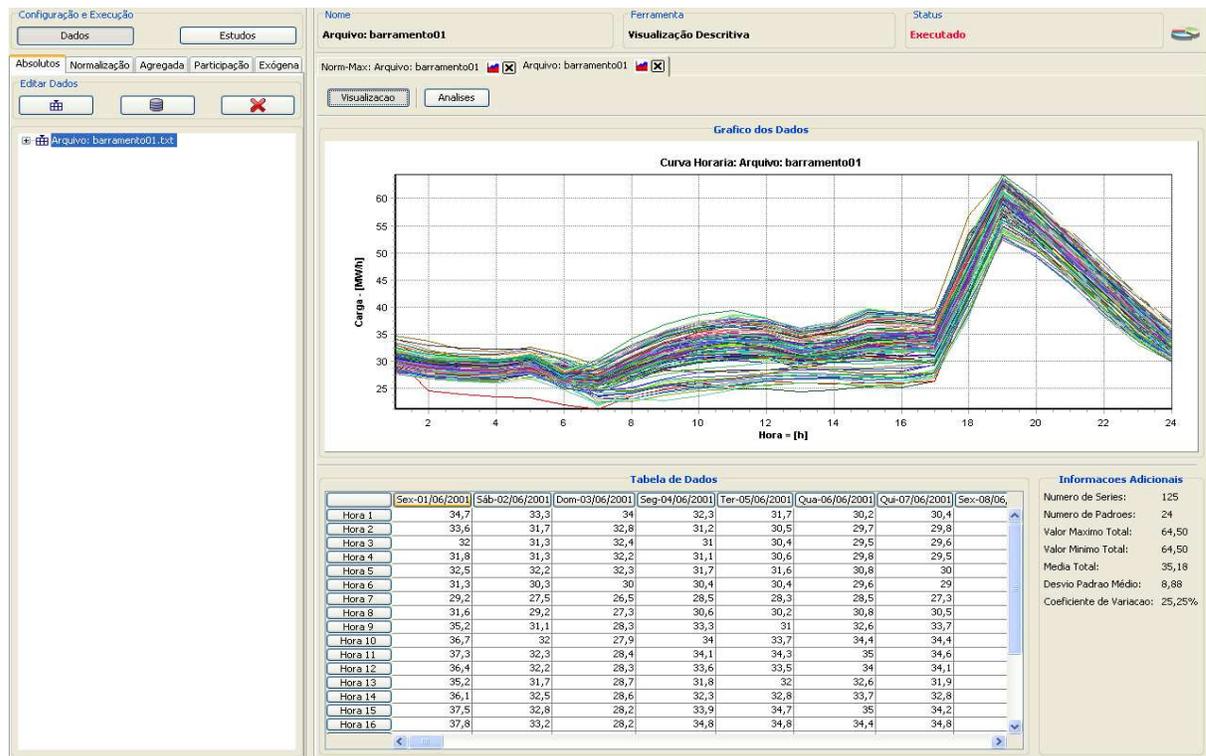


Figura 4.9: Exemplo: Apresentação de Dados - SysPrev.

Sabe-se que conhecer o comportamento estatístico entre as medições de carga é um importante fator em um modelo de previsão. O SysPrev conta com uma ferramenta para realizar análises de correlação visando a descoberta de informações pertinentes e importantes na etapa de previsão. A Figura 4.10 mostra a execução de um estudo de autocorrelação entre dados no barramento #1, apresentado anteriormente.

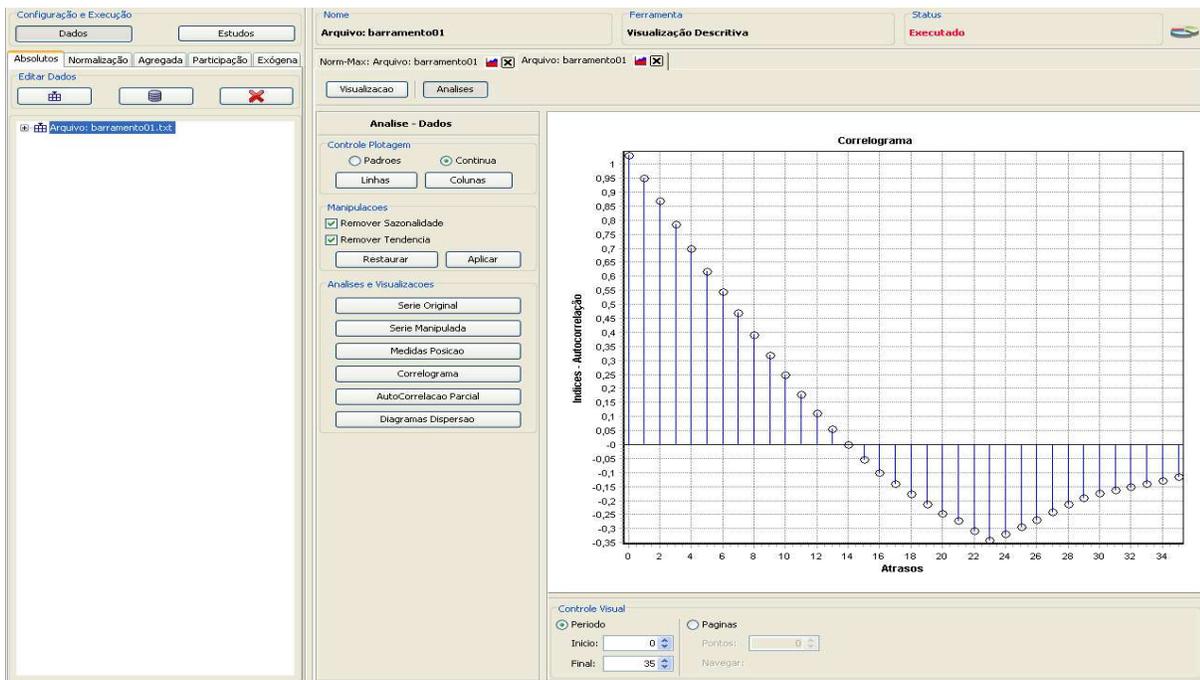


Figura 4.10: Exemplo: Gráfico de Correlograma.

#### 4.2.1.2 Agrupamento

No modelo de previsão agregado, após o carregamento, análise e preparação dos dados é necessário realizar o processo de agrupamento de dados. O SysPrev conta com vários algoritmos e técnicas de agrupamento, entre as técnicas implementadas no sistema estão: o algoritmo *K-Means* ((MacQueen, 1967)), o algoritmo baseado em redes neurais de *Kohonen* ((Kohonen, 1982) e (Kaski e Kohonen, 1995)), o algoritmo *Pruning Technique Kohonen Self-Organizing Feature Map - PSOM* (Castro e VonZuben, 1999), o algoritmo *Fuzzy C-means - FCM* (Bezdek, 1981) e, por último, o algoritmo *Subtractive Clustering* (Chiu, 1994). Cada um dos algoritmos realiza o processo de agrupamento segundo uma técnica e podendo ser aplicado na classificação de cargas com perfis semelhantes.

A Figura 4.11 mostra o ambiente de configuração e resultados disponível no SysPrev. Nesta tela de configuração, o usuário é capaz de escolher o algoritmo de agrupamento definindo seus parâmetros bem como o número de grupos desejado.

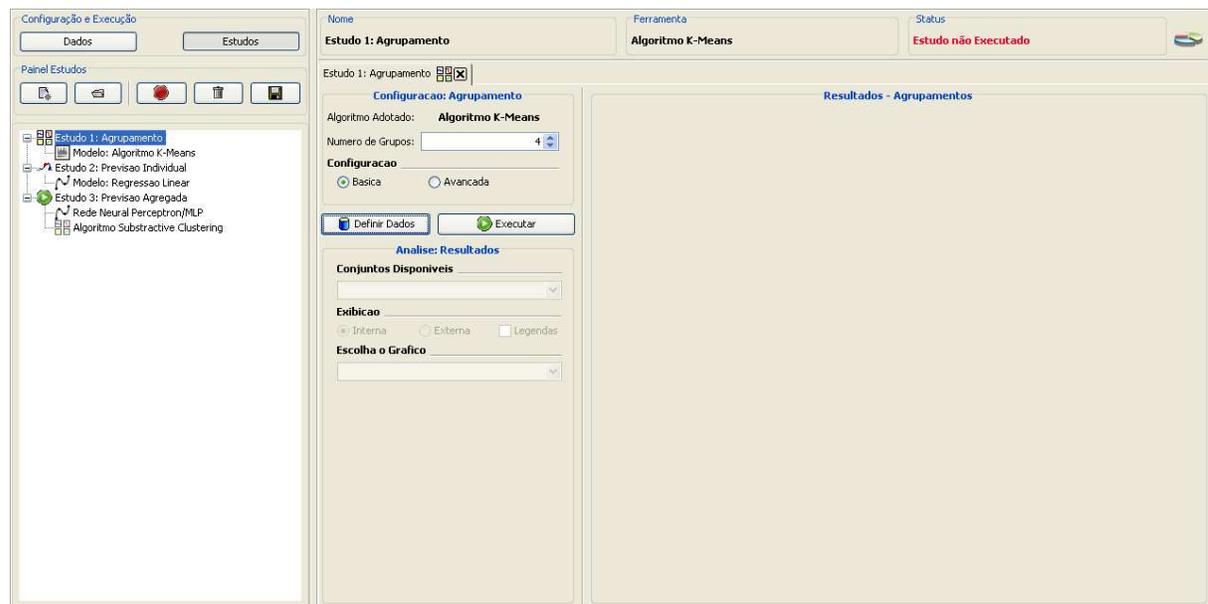


Figura 4.11: Exemplo: Configurações - Agrupamento.

Após a configuração do modelo, os resultados de agrupamento são exibidos conforme a Figura 4.12. Nesta tela de controle de resultados o usuário pode verificar os grupos encontrados detectando-se os barramentos possuem mesmo perfil de consumo. O bom desempenho na etapa de agrupamento é importante para proporcionar bons resultados na etapa de previsão agregada.

#### 4.2.1.3 Previsão e Análise de Resultados

Com os resultados de agrupamento o *SysPrev* está apto a executar as simulações de previsão agregada. O *SysPrev* conta com um ambiente desenvolvido especificamente para este tipo de estudo. A Figura 4.13 mostra a tela de configuração desenvolvida para definir as opções nos estudo de previsão agregada, no qual o usuário pode carregar dados, executar estudos de agrupamento, definir os parâmetros e o tipo de modelo de previsão.

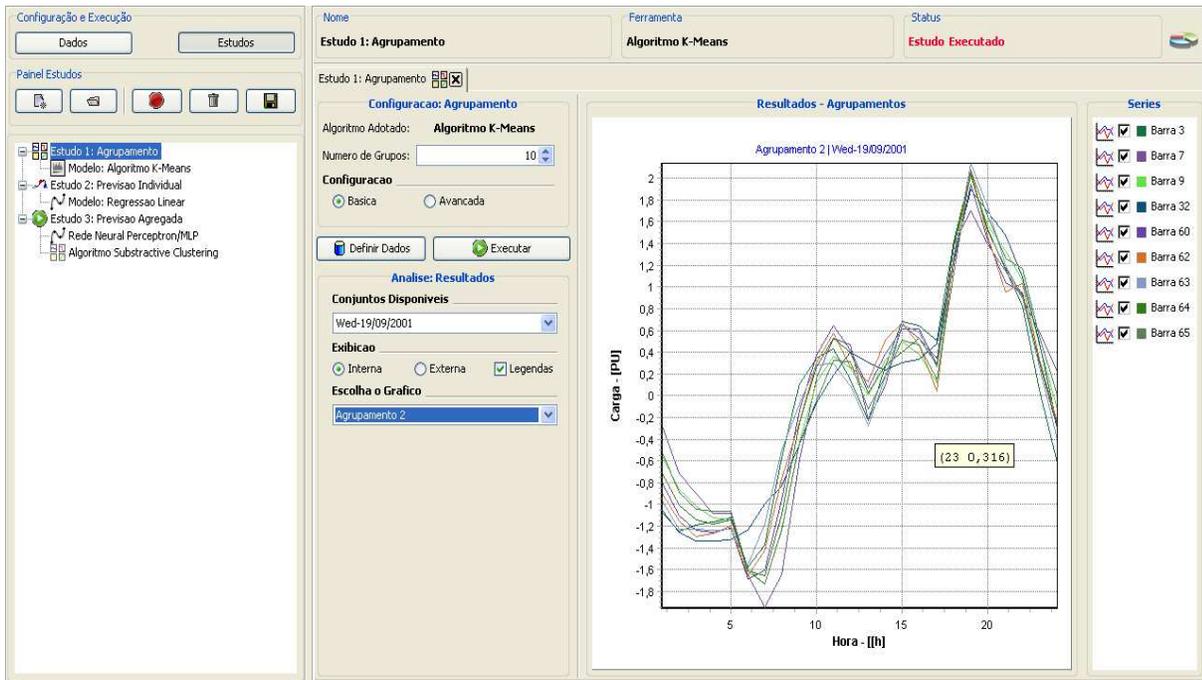


Figura 4.12: Exemplo: Resultados - Agrupamento.

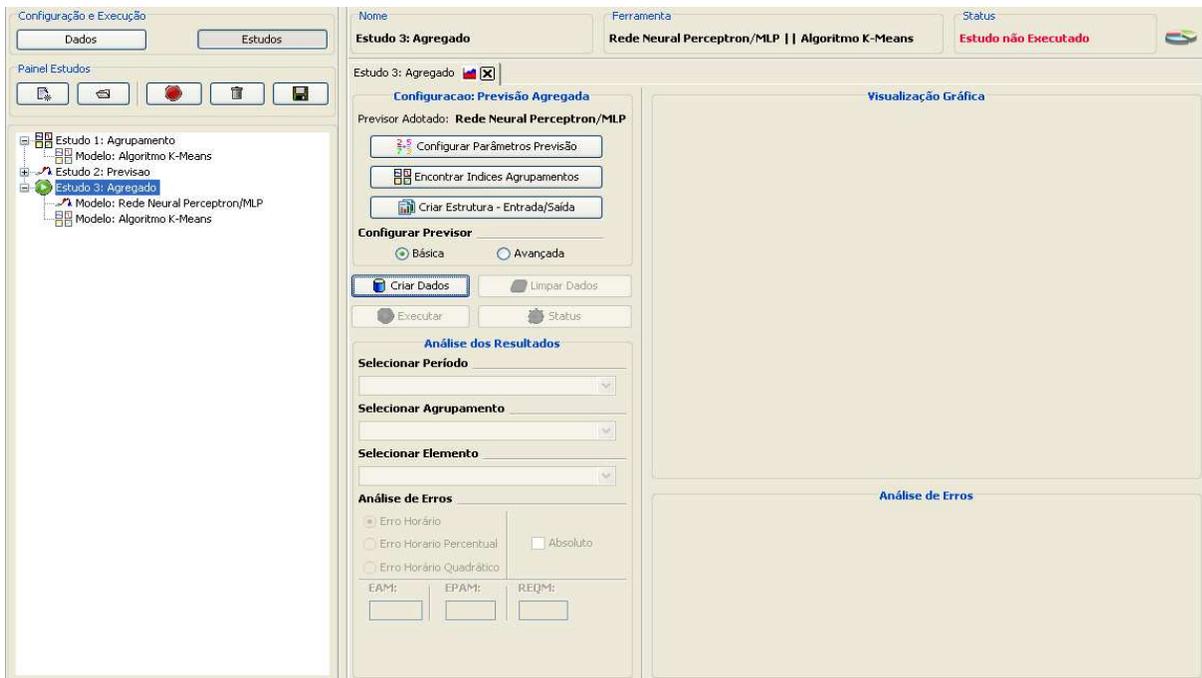


Figura 4.13: Exemplo: Configuração - Previsão Agregada.

Os resultados obtidos após a execução do estudo de previsão agregada são mostrados ao usuário conforme a tela exibida pela Figura 4.14. Nesta tela, o usuário pode verificar os valores de previsão encontrados em cada grupo de barramentos tendo acesso ao nível de erro de cada barramento nos intervalos de previsão definidos na execução do estudo. Estas facilidades fazem com que o usuário tenha condições de avaliar onde o modelo foi mais eficiente podendo também analisar quais foram os fatores que colaboraram para a obtenção das previsões nas simulações.

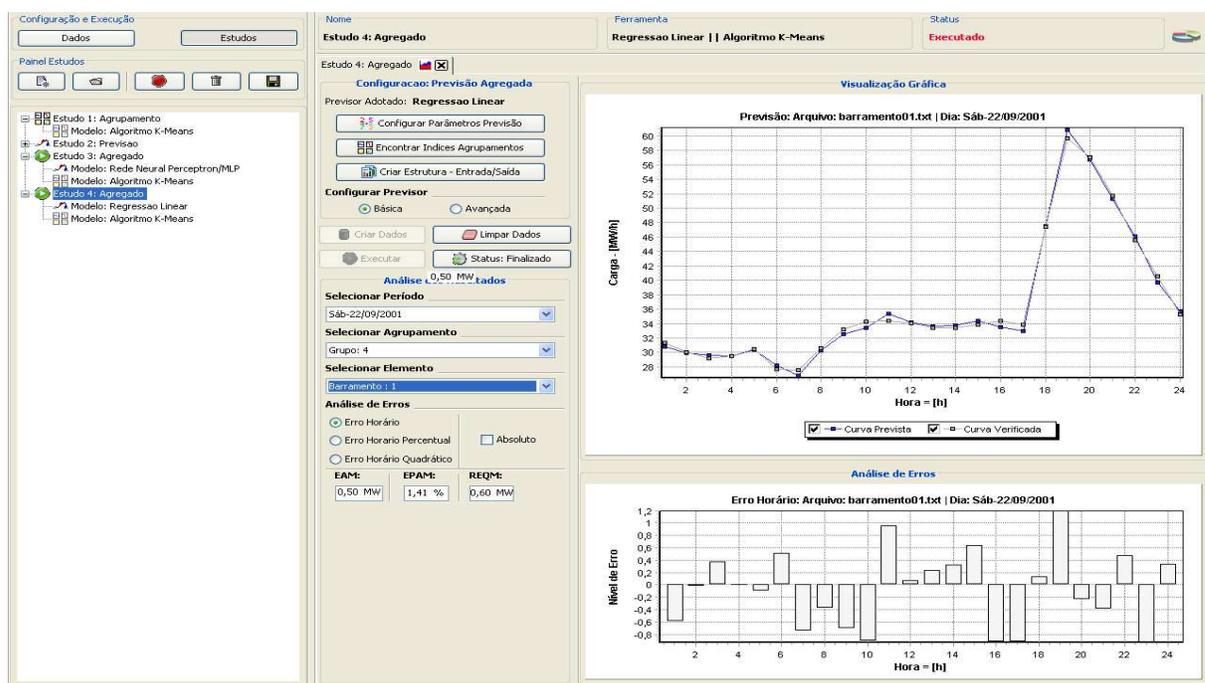


Figura 4.14: Exemplo: Resultados - Previsão Agregada.

Conforme demonstração vista anteriormente, a utilização do *SysPrev* como ferramenta de suporte ao processo de previsão proporciona inúmeras vantagens no estudo de previsão de séries temporais de carga. Sem a disponibilidade de um sistema de suporte com as características do *SysPrev* o processo de previsão seria lento e custoso, principalmente o processo de previsão de carga por barramento que necessita da análise de uma grande quantidade de dados simultaneamente.

Uma descrição detalhada do sistema e suas funcionalidades pode ser acessada no Capítulo 5 que apresenta a forma e a tecnologia utilizada no desenvolvimento do sistema de suporte *SysPrev*.

## Sistema Computacional - *SysPrev*

Este capítulo apresenta com maiores detalhes o sistema computacional *SysPrev*, desenvolvido neste trabalho. Juntamente com a análise de todos os pacotes projetados para integrar o sistema, será feita uma descrição das funcionalidades do *SysPrev*, destacando a sua contribuição ao processo de previsão de carga por barramento.

Para facilitar a compreensão das ferramentas implementadas no *SysPrev*, as janelas gráficas, que fornecem os controles do sistema, serão mostradas em ordem seqüencial em que o nível de complexidade é crescente.

São apresentados, via interface do *SysPrev*, estudos de agrupamento, previsão individual e previsão agregada, destacando os procedimentos que devem ser seguidos para configuração e execução de cada tipo de simulação do *SysPrev*. Ao final do capítulo é feito um rápido comentário envolvendo algumas ferramentas auxiliares que complementam e propiciam facilidades nas comparações e manipulações executadas no sistema. Vale ressaltar que o objetivo deste capítulo é dar uma visão do *software SysPrev* na solução do problema de previsão de carga por barramento. Desta forma, não são realizadas apresentações detalhadas dos botões, caixa de textos bem como menus e outros itens que compõem o sistema.

## 5.1 Estratégia de Desenvolvimento

Na criação de um aplicativo, deve-se analisar, testar e pesar todas as possibilidades para que o resultado seja um projeto de alta capacidade de abstração, capaz de suportar mudanças e novas etapas não previstas no projeto inicial. Desta forma, é desejável que o analista/desenvolvedor mantenha uma relação estreita com o problema a ser resolvido. Esta proximidade com o problema ajuda e faz com que as decisões de projeto se tornem mais estruturadas e menos sujeitas a erros.

O conjunto de ferramentas disponíveis para a construção de um *software* integrado permite abstrair o projeto original de tal forma que seja viável adicionar novos recursos sem a necessidade de reestruturar totalmente o projeto original. Visando melhorar a relação *produtividade*  $\times$  *tempo de desenvolvimento* e construir um projeto com o maior nível de abstração, optou-se por adotar, na construção do *SysPrev*, uma metodologia de desenvolvimento em módulos, totalmente baseado no conceito das linguagens orientadas a objetos.

Por meio desta abordagem em blocos, o *SysPrev* é um *software* desagregado, isto é, as suas funcionalidades estão formalmente desconectadas podendo ser acionadas individualmente ou em conjunto, quando forem invocadas pelo sistema principal. Esta visão de projeto faz com que um componente que contém um previsor ou até mesmo uma interface gráfica seja acessado somente no momento em que é necessário, evitando a má utilização de recursos computacionais (memória, processamento, entre outros). Entretanto, esta não é a principal vantagem de adotar uma arquitetura de blocos. Estudos mostram que, quando o desenvolvedor faz a opção por este tipo de abordagem, os processos de construção e manutenção do sistema se tornam menos complexos, pois existe um mapeamento completo da estrutura lógica do sistema através de blocos modulares. Outra vantagem é que as atualizações de código dentro do sistema tornam-se menos trabalhosas (Deitel e Deitel, 2005).

### 5.1.1 Características Técnicas

O *SysPrev* foi implementado utilizando a tecnologia JAVA<sup>1</sup>. Esta escolha se fundamentou nas facilidades apresentadas por esta plataforma em termos de programação modular, reusabilidade e portabilidade, tornando o sistema executável em vários contextos que vão desde os diversos sistemas operacionais existentes no mercado até a execução em navegadores de internet via conexões remotas.

No desenvolvimento do sistema, o uso da linguagem JAVA foi feito por meio do ambiente de desenvolvimento integrado *NetBeans IDE*<sup>2</sup>. O ambiente *NetBeans* foi escolhido por apresentar, em seu escopo, inúmeras facilidades integradas, com destaque para criação de janelas gráficas interativas e bem definidas. Estas características proporcionam total flexibilidade no momento do desenvolvimento do sistema, sendo possível utilizar conceitos e bibliotecas estáveis na construção de pacotes. Por esta razão, *NetBeans* foi definido como o principal ambiente de desenvolvimento na construção do aplicativo *SysPrev*.

No desenvolvimento do *SysPrev*, houve a preocupação em criar um conjunto de funcionalidades baseadas nos paradigmas de reusabilidade visando minimizar esforços com manutenções e facilitar atualizações do sistema. Neste sentido, o sistema foi construído com base no padrão MVC (*Model-view-controller*). O MVC é um padrão de projeto usado em engenharia de *software* que visa isolar a lógica de negócios da interface gráfica, facilitando manutenções e atualizações no *software*. No MVC o bloco *model* representa as informações (dados) que vão alimentar o aplicativo; *view* corresponde a todas as telas gráficas, tais como caixas de texto, botões entre outros itens utilizados para construir interfaces gráficas de *software*, e o módulo *controller* faz o gerenciamento da comunicação dos dados e as regras de negócios do sistema.

O projeto de construção modularizada arquitetado para o *SysPrev* foi executado segundo o princípio “*dividir para conquistar*”. Com esta linha estratégica, todas as funções e métodos criados nos arquivos e estruturas foram agru-

---

<sup>1</sup>JAVA 1994-2009 Sun Microsystems, Inc.

<sup>2</sup>O *NetBeans IDE* é um ambiente de desenvolvimento integrado gratuito e de código aberto para desenvolvedores de software na linguagem Java mantido pela *Sun Microsystems Inc.*

pados em blocos de acordo com a função específica que cada um executa no sistema. Esta catalogação e divisão do *software*, segundo semelhanças funcionais, faz com que haja relacionamento entre as funções catalogadas no mesmo pacote. Por exemplo, as classes que geram a interface gráfica do *SysPrev* estão todas armazenadas dentro da mesma estrutura do sistema e, independentemente da utilização, elas são encontradas em uma mesma pasta de arquivos que contém somente as janelas gráficas do sistema.

Um diferencial do *SysPrev* é a possibilidade da inserção/atualização e remoção de ferramentas no *software*. A grande maioria dos sistemas de previsão existentes são estáticos e não permitem alterações no seu conjunto de ferramentas de maneira fácil e simples. Como na área de previsão há um desenvolvimento contínuo de modelos, um sistema capaz de incorporar novas ferramentas ou implementações de modo simples seria importante, pois faria com que o *software* pudesse sempre estar contextualizado com as abordagens de previsão atuais, possibilitando o tratamento de vários tipos de problemas. Com este intuito, o *SysPrev* foi desenvolvido com o recurso “*plug-and-play*”, através do qual um novo modelo pode ser adicionado, atualizado ou até mesmo removido sem a necessidade de alterações ou compilações no sistema principal.

As interfaces ou janelas gráficas, também conhecidas como *Graphical User Interfaces* ou *GUIs*, são partes do sistema computacional que determinam como os usuários operam e controlam o sistema. Quando o projeto de interface gráfica é bem definido, o ambiente de controle do *software* se torna compreensível, agradável e intuitivo, dando aos usuários uma sensação de satisfação e aumentando o interesse pelo sistema (Fowler e Stanwick, 1994).

As janelas gráficas do *SysPrev* contam com diversos tipos de ambientes que visam simplificar a utilização do *software*, tornando-o mais interativo e fácil de manipular. Um dos objetivos do *SysPrev* é apresentar um conjunto de interfaces gráficas que permitam realizar a previsão de carga de forma simples e direta, facilitando a obtenção de informações que auxiliem o entendimento das curvas de carga por barramento, bem como de outras variáveis utilizadas na previsão.

O desenvolvimento de sistemas que utilizam conhecimentos extraídos

de bases de dados tem propiciado valiosas ferramentas de apoio à decisão (Weiss e Indurkha, 1998). De acordo com o trabalho de (Olaru e Wehenkel, 1999), pode-se classificar o *SysPrev* como programa de *data mining* com as seguintes características: *forecasting, clustering, summarization, classification, regression e statistical techniques, data view tool*. Esse tipo de classificação justifica a utilização do *SysPrev* como um sistema de suporte para análise de dados e previsão de carga por barramento em sistemas elétricos de potência.

Os próximos itens trazem a descrição dos recursos, ferramentas e janelas gráficas do *SysPrev*, destacando os pontos principais e sua usabilidade na resolução do problema de previsão de carga por barramento.

## 5.2 Sistema SysPrev

O *SysPrev*, representado pelo logotipo (  ), é um sistema de suporte ao processo de previsão que auxilia as funções de análise de dados e previsão de valores através de informações históricas. O objetivo principal do *SysPrev* é dar suporte ao processo de previsão de carga global e por barramento e auxiliar a análise das variáveis utilizadas nos procedimentos de previsão. Para isto, o sistema foi desenvolvido para proporcionar a comunicação entre os **Dados e Modelos** através de uma interface gráfica amigável e flexível. O ambiente visual foi projetado com janelas personalizadas com diversos níveis de abstração, dando ao usuário várias maneiras de configurar e acessar as funcionalidades do sistema. O *SysPrev* contém diversas ferramentas com pacotes específicos para realizar tarefas em diferentes segmentos no contexto de previsão de carga por barramento e análise de dados. Entre as principais características disponíveis no *SysPrev* pode-se destacar:

- ↪ **Ambiente Plug-and-Play:** Proporciona a inserção de novos elementos segundo o conceito *plug-and-play*. Esta abordagem possibilita inserção, atualização e/ou remoção de novas ferramentas no sistema de maneira simples;
- ↪ **Ambiente Visual Interativo:** Projetado para que o usuário acesse as funcionalidades do sistema de maneira intuitiva, facilitando o uso e a com-

preensão da dinâmica da interface gráfica do sistema;

- ↪ **Controle de Dados:** O módulo de controle de dados é responsável pela organização, catalogação e administração de toda a massa de informações disponíveis no sistema;
- ↪ **Controle de Estudos:** Responsável pela criação, organização e execução dos estudos de previsão e agrupamento do *SysPrev*. Disponibiliza acesso às ferramentas de configurações em cada modelo utilizado nos estudos do sistema;
- ↪ **Comparação de Resultados:** Funcionalidade responsável pela análise dos resultados do *SysPrev* em que é possível gerar análises personalizadas, comparações e inferências sobre o desempenho dos modelos;
- ↪ **Pacote Gráfico:** Ferramenta extremamente útil na análise de dados e validação de resultado. No *SysPrev*, foi desenvolvido um conjunto de ferramentas gráficas para comparar, analisar e gerar gráficos nos variados estilos necessários à análise de séries temporais;
- ↪ **Árvore de Navegação:** A ferramenta de navegação baseada em árvores (*TreeView*) atua de maneira a facilitar o acesso a dados, informações e estudos executados no sistema. Esta facilidade aumenta a produtividade em análises de previsão, dando ao usuário opções de navegabilidade entre as informações disponíveis;
- ↪ **Exportação de Resultados:** O sistema conta com um gerenciador de exportação que pode ser aplicado a dados numéricos bem como a gráficos, sendo possível exportar informações no modo texto ou imagens gráficas, possibilitando a criação de relatórios e apresentações.

### 5.2.1 Modelo de Interface Gráfica

A interface gráfica do *SysPrev* teve seu projeto inspirado em sistemas que adotam o princípio de desenvolvimento das linguagens orientadas a objetos. O objetivo da interface gráfica de um sistema com as características do *SysPrev* é

fornecer recursos tais como gráficos, botões, menus, caixas de texto, entre outros que possibilitem a interação do usuário com dados e modelos de forma a obter resultados.

A construção da interface gráfica do *SysPrev* foi consolidada através de pesquisas realizadas na área de *Interface Homem Computador* (Shneiderman, 1998) e (Dix et al., 1998), nos quais foi possível constatar que o modelo de interface que melhor atenderia às necessidades de uma ferramenta como o *SysPrev* seria o modelo mostrado na Figura 5.1, em que é possível observar três quadros bem definidos e com funções específicas.

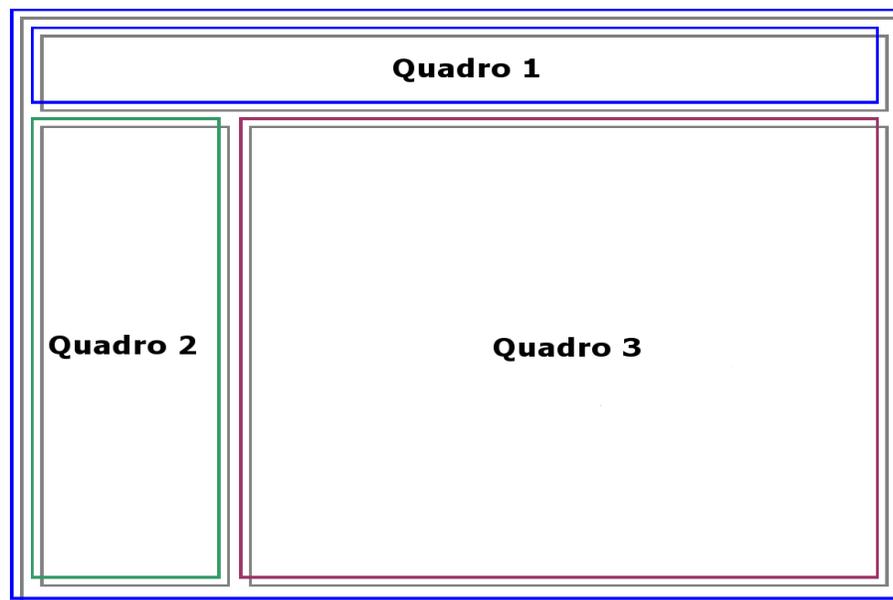


Figura 5.1: *Layout* da Interface Gráfica com o Usuário.<sup>3</sup>

O primeiro quadro, localizado no topo da tela, traz o menu principal e a barra de ferramentas com ícones que possibilitam acessos e execuções e controles do sistema. O segundo quadro, localizado à esquerda, concentra as informações de dados através de várias abas e *TreeViews* com opções para a organização e fácil acesso de dados e estudos no sistema. A parte superior deste quadro, observada na Figura 5.2, contém três botões *Dados e Estudos*, que controlam acessos e alteram as visualizações dos quadros 2 e 3, possibilitando uma visão de múltiplos estudos e vários cenários. O terceiro e último quadro à direita,

<sup>3</sup>Fonte: (Cicogna, 2003).

possui diversas funcionalidades podendo ser usado para apresentar dados, resultados de análises, previsões, gráficos e informações gerais disponibilizadas pelo sistema. Para facilitar o acesso, as informações são organizadas em categorias utilizando um recurso visual de “abas” lembram um fichário. O usuário pode facilmente mudar de uma categoria para outra escolhendo uma das abas do fichário.

O *SysPrev* foi projetado com base no *layout* da Figura 5.1, com áreas bem definidas para controlar, configurar, bem como apresentar os resultados de forma simples e acessível. A Figura 5.2 mostra o *SysPrev* no momento da execução de um determinado estudo onde é possível distinguir os quadros de maneira fácil e imediata.

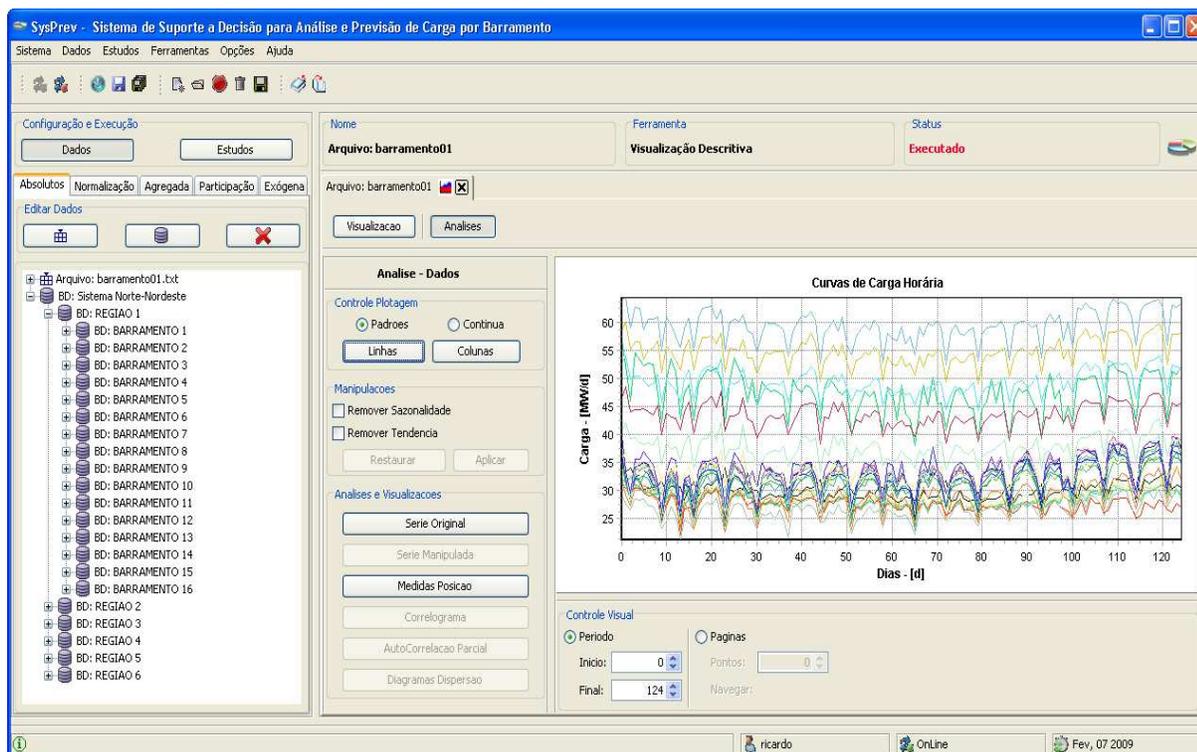


Figura 5.2: Ambiente de Estudos e Análise - *SysPrev*.

## 5.3 Descrição das Funcionalidades

O *Layout* principal e inicial do *SysPrev* é apresentado na Figura 5.3. Nesta tela, é possível observar, logo abaixo da barra de ferramentas, o gerenciador de dados/estudos, bem como o quadro de conteúdos, ambos anteriormente definidos.

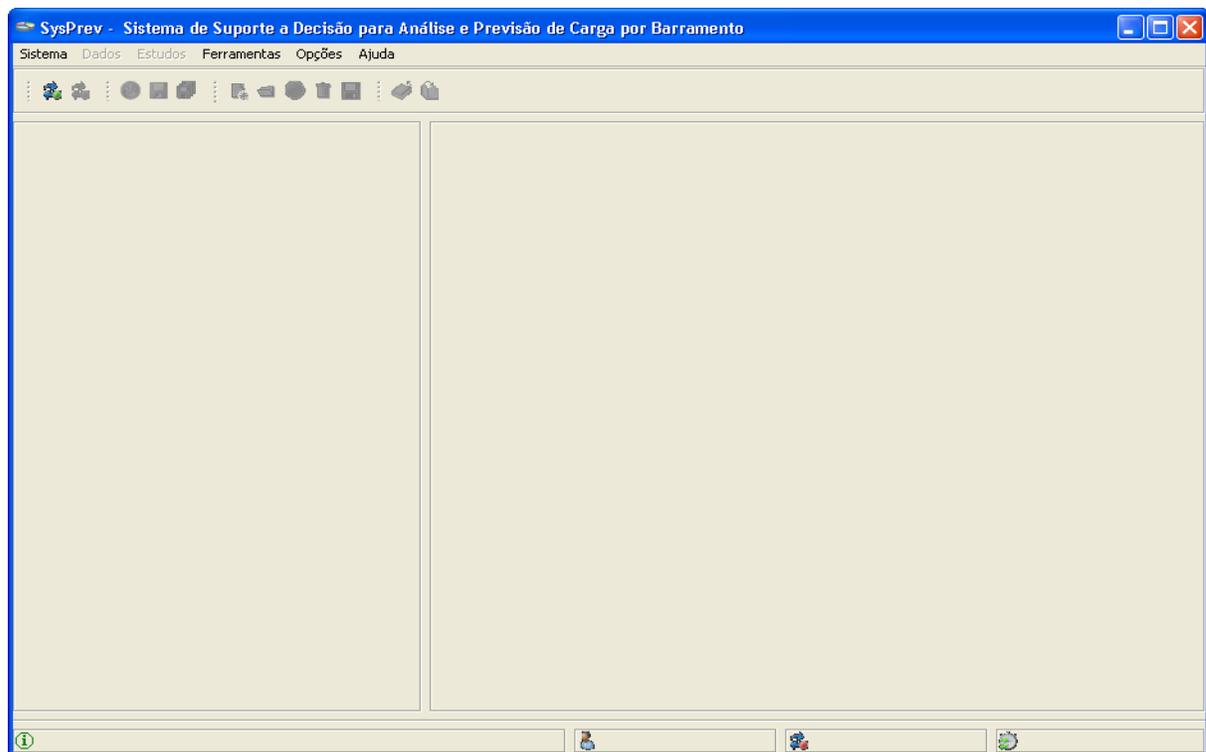


Figura 5.3: Tela de Principal - *SysPrev*.

Para facilitar o entendimento da lógica de funcionamento do *SysPrev*, optou-se por apresentar as telas gráficas do sistema em uma ordem de execução seqüencial. Assim, serão mostradas as principais janelas do *SysPrev* desde o momento de sua inicialização até a geração dos resultados de previsão. Esta ordem de apresentação tende a facilitar o entendimento e a lógica de construção adotada na implementação do sistema, dando uma visão de complexidade crescente do ambiente gráfico do sistema.

Vale ressaltar que a descrição do *software SysPrev* apresentada neste capítulo não objetiva explorar e analisar em detalhe as funcionalidades do sis-

tema. O objetivo desta descrição é apenas mostrar como o *SysPrev* pode ser utilizado, através de suas ferramentas, para realizar a estudos nos dados de carga por barramento, gerando previsões e informações que auxiliem o processo decisório.

### 5.3.1 Inicialização do Sistema

A partir do momento em que o usuário inicializa o *SysPrev* automaticamente, instancia-se um objeto que invoca a janela principal do sistema (Figura 5.3), que ficará em *standby* até que o usuário faça alguma ação. A Figura 5.4 mostra a visualização desta janela, em que pode-se notar que vários Menus e ícones na barra de ferramentas encontram-se não ativos. Esta janela permanecerá neste estado de espera até que o usuário acione um comando do sistema através do caminho: Sistema -> Conectar ou no ícone (  ) ativo na barra de ferramentas do sistema. A Tabela 5.1 apresenta os ícones de autenticação do *SysPrev* descrevendo suas funcionalidades.

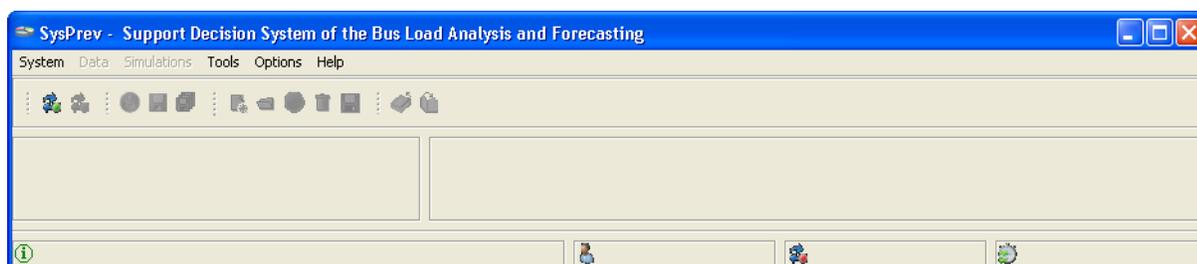


Figura 5.4: Menus e Barra de Ferramentas - Tela Inicial *SysPrev*.<sup>4</sup>

Tabela 5.1: Ícones: Conexão e Acesso - *SysPrev*.

Ícone	Descrição
	Fornece a tela de <i>login</i> para o usuário
	Faz o <i>logout</i> do usuário

<sup>4</sup>Ao longo do texto algumas janelas gráficas do *SysPrev* foram reduzidas para viabilizar a otimizações na descrição do *software*. Algumas janelas, ao longo do texto, são exibidas em idioma Inglês-US para demonstrar o pacote de internacionalização desenvolvido no *SysPrev*.

### 5.3.2 Gerenciadores de Acesso

No desenvolvimento do *SysPrev*, uma das preocupações foi o fator segurança. Em linhas gerais, para realizar previsões normalmente utiliza-se uma base de dados que pode conter diversos tipos de informações. Nesta ótica, existe a possibilidade dos dados utilizados na previsão revelarem informações estratégicas e restritas a algum setor. Para manter o sigilo das informações, optou-se por realizar a implementação de uma política de segurança para restringir o acesso de usuários às informações disponíveis na base de dados do sistema. Outro objetivo da política de segurança é garantir a integridade dos dados evitando que as informações sejam corrompidas por manipulações indesejadas. Neste sentido, o *SysPrev* conta com um gerenciador de acessos através de um sistema de autenticação e validação de usuários.

Inicialmente, foram criadas duas classes de usuário no *SysPrev*: a classe **administrador** e a classe **standardUser**. O usuário que pertence à classe **administrador** tem acesso total às informações do sistema e, é responsável por cadastrar e validar as permissões dos demais usuários. O usuário da classe **standardUser** tem funcionalidades limitadas, podendo acessar apenas parte dos dados disponíveis no sistema. O acesso dos usuários da classe **standardUser** pode variar de acordo com as permissões especificadas no momento da definição da política de segurança.

Basicamente, os tipos de acesso ao sistema são definidos por meio de regras configuradas no sistema gerenciador de banco de dados - SGBD (no caso do *SysPrev*, utiliza-se MySQL - 1995-2009 MySQL - Sun Microsystems), que podem definir acesso a bases específicas, permissões em tabelas entre outras configurações. Com esta abordagem é possível definir quais informações estarão disponíveis aos diversos usuários do sistema.

A Figura 5.5 mostra a tela de autenticação utilizada para liberar o acesso ao *SysPrev*. Vale ressaltar que as restrições aplicadas aos usuários são específicas aos dados do sistema, isto é ao módulo de controle de dados. Esta catalogação faz com que a restrição do usuário fique limitada apenas aos dados, fazendo com que qualquer usuário, independentemente do tipo de permissão,

tenha acesso às funcionalidades de previsão e análise de dados do sistema.

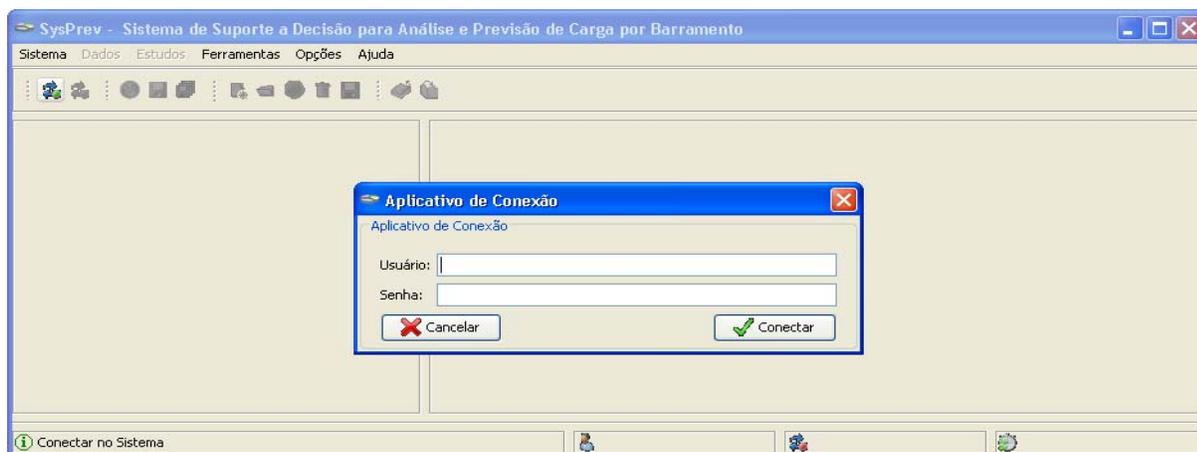


Figura 5.5: Tela Login - SysPrev.

### 5.3.3 Controle de Execução

Após a validação do usuário, no sistema, os ícones inicialmente inativos na tela inicial tornam-se ativos, dando ao usuário a opção de acessar algumas funções. Observando as Figs. 5.3 e 5.6, pode-se ver a diferença na disponibilidade dos ícones da tela principal. Observa-se também no rodapé da Figura 5.6 a existência de uma barra de *status* que apresenta informações úteis como: data ( 🕒 ), usuário ativo ( 👤 ) e um *display* ( ⓘ ) que mostra dicas sobre a função dos botões do sistema.

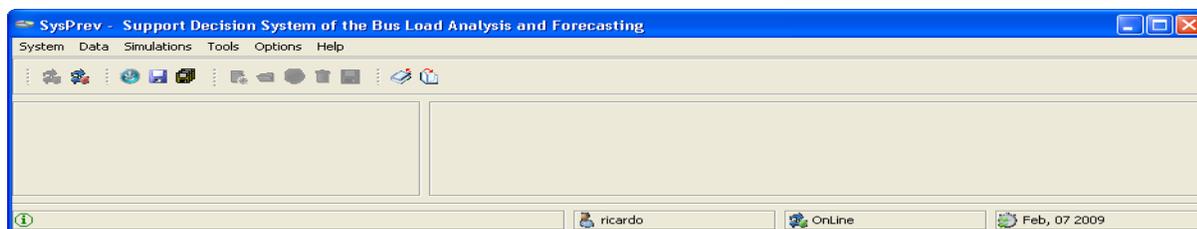


Figura 5.6: Tela Principal - Usuário Ativo: ricardo.

Os ícones habilitados imediatamente após o *login* do usuário são aqueles que tratam da manipulação de dados e estudos do sistema, nos quais encontram-se disponíveis as opções de inserção ( 📥 ), salvamento ( 💾 e 📂 ) de dados no

sistema. Outro grupo de ícones, disponibilizados após a autenticação do usuário, tem a função de alterar a exibição dos quadros de dados/resultados, expandindo (  ) ou contraindo (  ) as telas para possibilitar melhores visualizações dos resultados providos pelo sistema. A Tabela 5.2 descreve as funcionalidades de alguns ícones presentes na barra de ferramentas.

Tabela 5.2: Ícones: Gerenciamento de Dados - *SysPrev*.

Ícone	Descrição
	Permite a inserção da massa de dados no sistema;
	Salva um conjunto de dados específico;
	Salva todos os conjuntos de dados carregados no sistema;
	Muda o <i>layout</i> do programa expandindo o quadro de resultados;
	Retorna ao <i>layout</i> padrão do sistema.

Quando o usuário escolhe a opção de inserção de dados (botão ), o *SysPrev* disponibiliza botões para manipular as funcionalidades do *software*. Na Figura 5.7, são mostrados os botões que controlam as principais funções do sistema de previsão. Conforme pode ser visto, os controles do *SysPrev* encontram-se divididos em dois níveis: **Dados** e **Estudos**<sup>5</sup>.

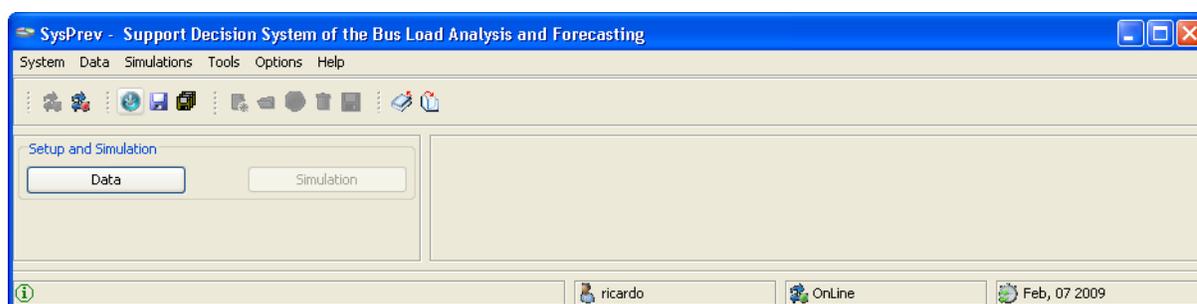


Figura 5.7: Tela Controles - *SysPrev*.

Cada um destes elementos é responsável por definir um conjunto específico de ferramentas do sistema. O botão **Dados** é responsável por apresentar todas as ferramentas de acesso a dados e manipulações nas séries temporais carregadas no sistema. O botão **Estudos** concentra as simulações que podem ser

<sup>5</sup>Na Figura 5.7 o sistema está apresentado no idioma Inglês-US. Logo o botão **Estudos** é representado pelo botão **Simulation**.

feitas com diversas combinações de **dados** × **modelos**. Juntamente com estes dois botões, que concentram as ferramentas para manipulação de dados e geração de resultados, o *SysPrev* também conta com um conjunto de ferramentas para realizar comparações gráficas e análises detalhadas das informações.

### 5.3.4 Controle de Dados

O ambiente de controle de dados foi projetado para possibilitar o acesso e a manipulação das informações carregadas no sistema. Neste ambiente, é possível inserir dados provenientes de arquivos texto (no formato ASCII (Encyclopedia, 1985)), importar planilhas e também acessar informações armazenadas no banco de dados.

O controle de dados no *SysPrev* é feito por meio de “abas” desenvolvidas para armazenar informações segundo categorias pré-estabelecidas. Na Figura 5.8, observa-se, no controle de dados, a existência das “abas” **Absoluto**, **Normalização**, **Agregada**, **Participação** e **Exógena** sendo que cada aba tem um papel específico. A aba **Absoluto** é a principal fonte de informações projetada para armazenar os dados de carga elétrica por barramento. Em contrapartida, as abas (**Normalização**, **Agregada**, **Participação**) armazenam as séries obtidas por meio de transformações nos dados da aba **Absoluto**. Para facilitar o carregamento de dados externos (que não sejam dados de carga) a aba **Exógena**, foi implementada com objetivo de possibilitar a inserção de informações relevantes no processo de previsão. Com esta ferramenta, o usuário poderá fazer a ligação de uma série de carga de um barramento com sua respectiva temperatura, entre outras correlações viáveis no estudo de previsão. Este fator faz com que seja possível criar diversas combinações de dados em um tipo específico de estudo.

Por meio das abas de controle, é possível normalizar os dados de carga dos barramentos usando diversas funções de normalização, executar procedimentos de agregação de barramentos, calcular a participação de cada barramento em relação a demanda agregada, entre outras funcionalidades que viabilizam a extração de diversas informações em cada elemento disponível no sistema.

Na Figura 5.8, observa-se, na aba **Absoluto**, três botões responsáveis

por inserir/excluir os dados no sistema. O botão associado ao ícone ( 🏠 ) cuida do carregamento de dados provenientes de arquivos texto que são validados antes de serem adicionados no sistema. Analogamente, o botão ( 🗄 ) cuida do acesso aos dados armazenados na base de dados relacional do sistema. O botão ( ✖ ) atua na exclusão dos dados não utilizados no sistema.



Figura 5.8: Abas de Manipulação - Controle de Dados.

As abas do controle de dados mostradas na Figura 5.8 compartilham o mesmo *layout* e também o mesmo conjunto de botões. Logo, a análise anterior feita para a aba **Absoluta**, apresentada na Figura 5.8, é também aplicada às demais abas do sistema, mantendo-se a descrição das funcionalidades dos botões.

Através da Figura 5.9, pode-se observar o ambiente de controle de dados após a execução de algumas inserções de dados. A navegação através de uma estrutura de árvores (*Treeview*) foi adotada para facilitar o acesso aos dados carregados no *SysPrev*. É interessante destacar que o ambiente de navegação é intuitivo e amigável, proporcionando ao usuário conforto e clareza no momento de acessar o conjunto de dados.

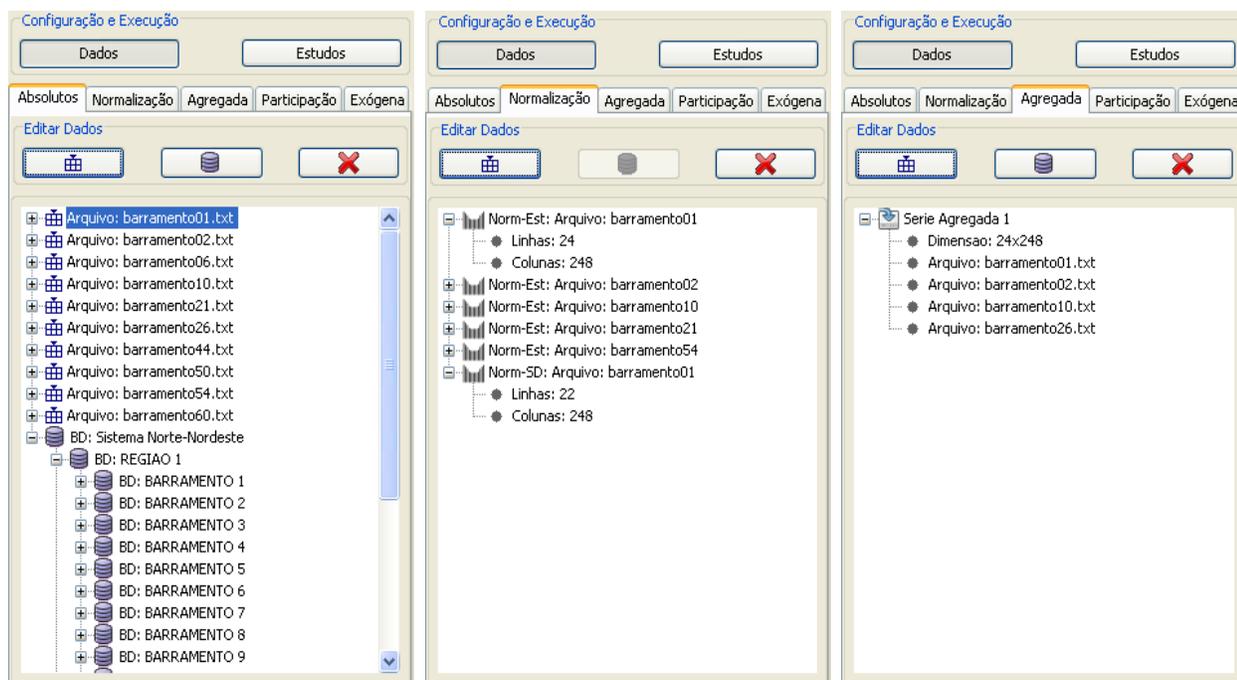


Figura 5.9: Exemplo: Abas de Carregadas - Controle de Dados.

Na estrutura de árvore, utilizada para navegação dos dados, cada nó representa um barramento. Logo, as informações disponíveis para cada barramento ficam concentradas em um único dispositivo. Com esta organização dos dados, na forma de árvore, o acesso ao conteúdo pode ser feito através de um “duplo clique” sobre o nó que representa a informação desejada. Outra maneira de enxergar os dados é via menu flutuante exibido após um “ clique”, no botão direito do mouse, sobre sobre o nó desejado.

Observando o menu flutuante implementado, (Figura 5.10), pode-se perceber a existência de ferramentas que facilitam o trabalho de exploração dos dados. Entre as ferramentas existentes, destaca-se o item **Visualizar Dados Gráficamente**, que exibe as informações armazenadas nos dados através de uma ferramenta gráfica implementada no *SysPrev*. Outro item importante é o **Adicionar Rótulos - Tabelas**, que possibilita a inserção de rótulos em séries temporais definindo seu significado prático de acordo com o seu evento gerador. Esta função torna o *SysPrev* capaz de trabalhar com qualquer tipo de série temporal, rotulada e tratada segundo suas características particulares.

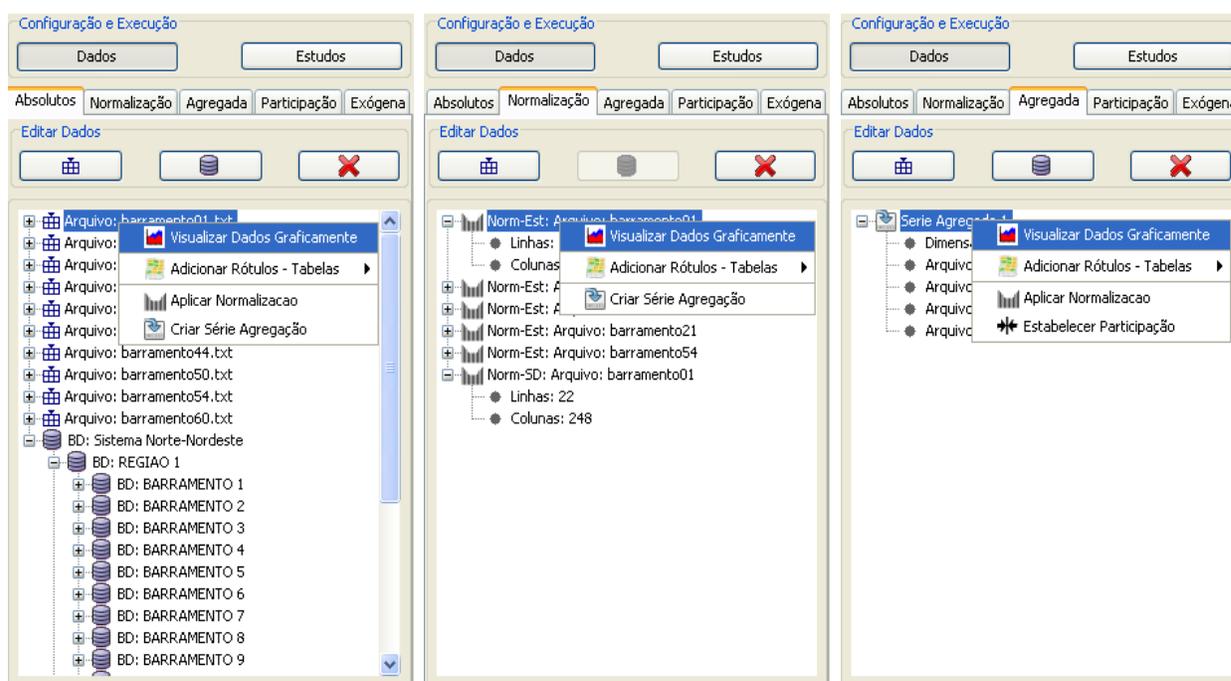


Figura 5.10: Exemplo: Menu Flutuante - Abas | SysPrev.

No menu flutuante, apresentado na Figura 5.10, tem-se a opção de enviar elementos para as demais abas de controle, facilitando a interatividade entre as abas. A Figura 5.11 exibe o procedimento adotado no envio de um conjunto de dados pertencentes à aba **Absoluto** para a aba **Normalização**. Neste exemplo, o usuário pode selecionar quais dados deseja normalizar e também escolher qual será a função de normalização será aplicada em cada conjunto de dados. Estas facilidades na realização de manipulações deixam o SysPrev com alta produtividade evitando-se o gasto de tempo com tratamento manual dos dados.

#### 5.3.4.1 Visualização de Resultados - Controle de Dados

Cada dado, ou série temporal, carregado no sistema pode ser representado graficamente por meio das funções de visualização gráfica desenvolvidas no SysPrev. Um exemplo do pacote de exibição gráfica é apresentado na Figura 5.12, onde é possível ver a exibição gráfica das informações do barramento #01 no quadro de resultados do sistema.

Cada aba do controle (**Absoluto**, **Normalização**, **Agregada**, **Partici-**

**pação, Exógena)** tem a capacidade de enviar elementos para exibição gráfica e, além da exibição gráfica, também podem ser vistos, nesta janela, a matriz numérica das medições e algumas informações estatísticas que definem conjunto de dados analisado.

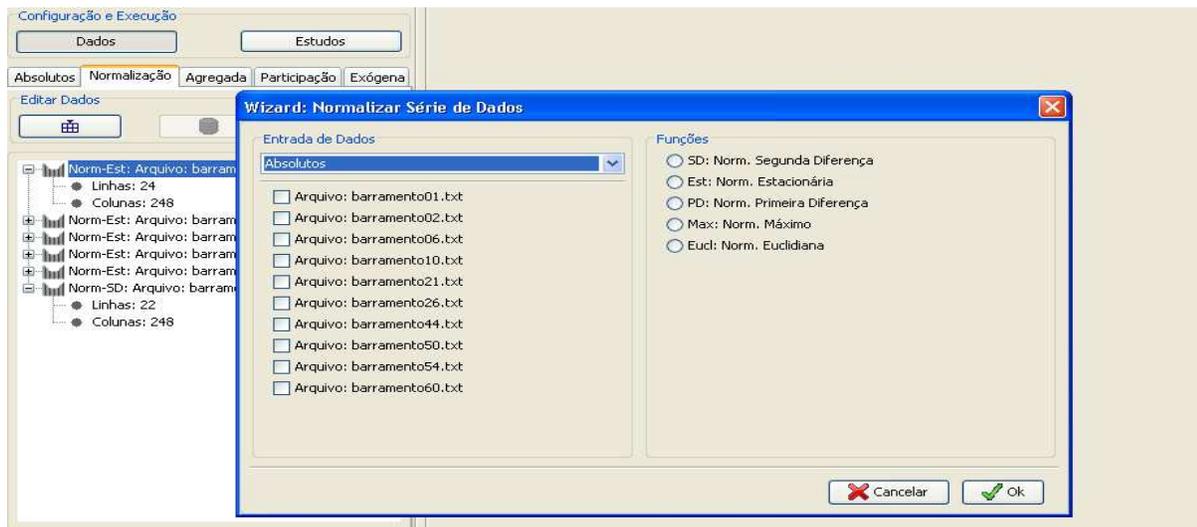


Figura 5.11: Exemplo: Normalização de Dados | SysPrev.

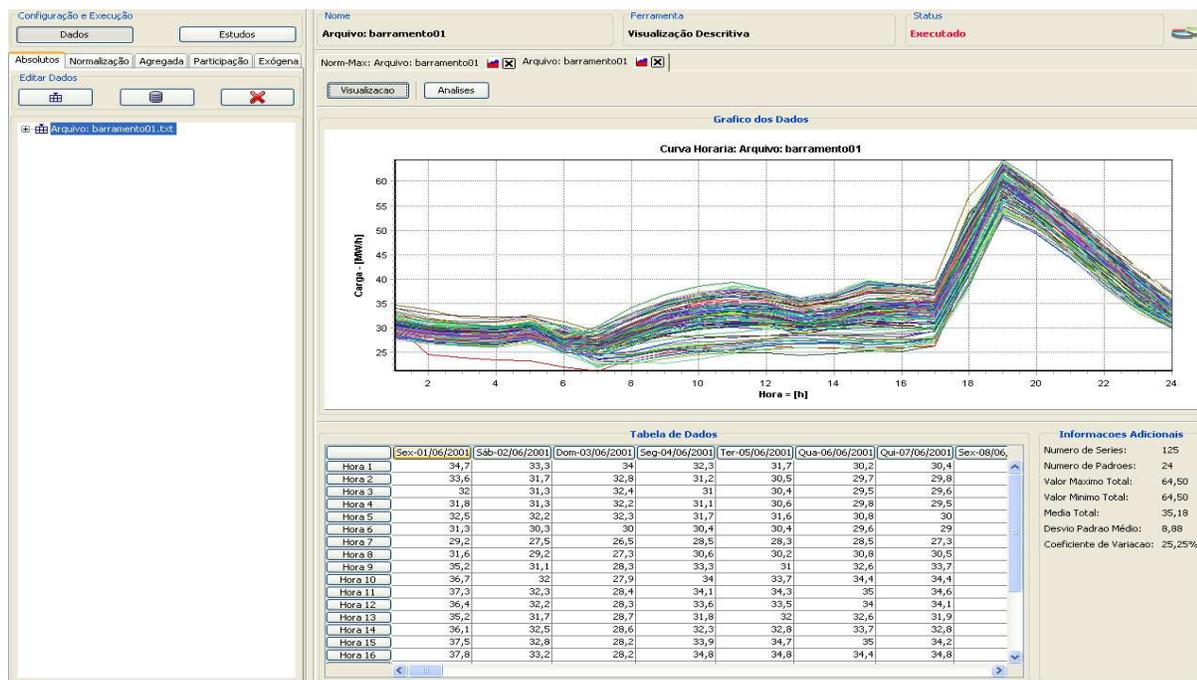


Figura 5.12: Visualização Gráfica I - SysPrev.

Analisando a Figura 5.12, pode-se observar, no quadro de resultados, a existência de dois botões: (  ) e (  ). O botão **Visualização** é responsável por apresentar os gráficos, a matriz de dados e outras informações descritivas. Por outro lado, o botão **Análises** foi implementado no sentido de realizar alguns cálculos estatísticos visando prover informações para os estudos de previsão. A Figura 5.13 mostram algumas das funcionalidades disponíveis no botão **Análises**.

Um fator interessante no botão (  ) é a possibilidade de escolher a forma de exibição dos dados. Percebe-se, na Figura 5.13, os dados do barramento #01 expressos através de outra visão, diferente daquela mostrada na Figura 5.12. Este tipo de facilidade é interessante para verificar como é o comportamento da série em diversas visões, facilitando a descoberta informações relevantes. Muitas vezes, a falta de investigações detalhadas faz com que o analista tome decisões precipitadas, prejudicando o resultado de um estudo de previsão.

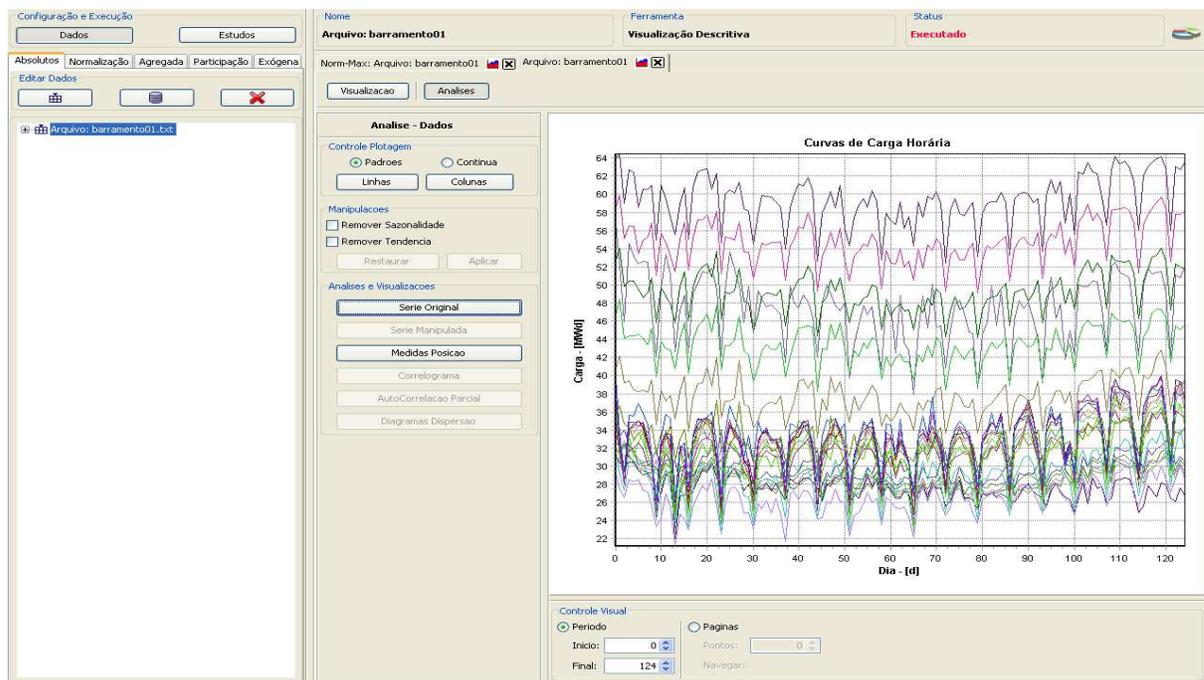


Figura 5.13: Visualização Gráfica II - SysPrev.

Uma forma de visualização interessante é mostrada na Figura 5.14, onde os padrões são representados em uma única série. Este tipo de gráfico é

interessante para diagnosticar tendências, sazonalidades entre outros comportamentos existentes nas séries. A funcionalidade apresentada nesta figura torna esta análise mais simplificada por meio de um navegador que mostra apenas partes do gráfico, facilitando a visualização de séries e a descoberta de propriedades específicas.

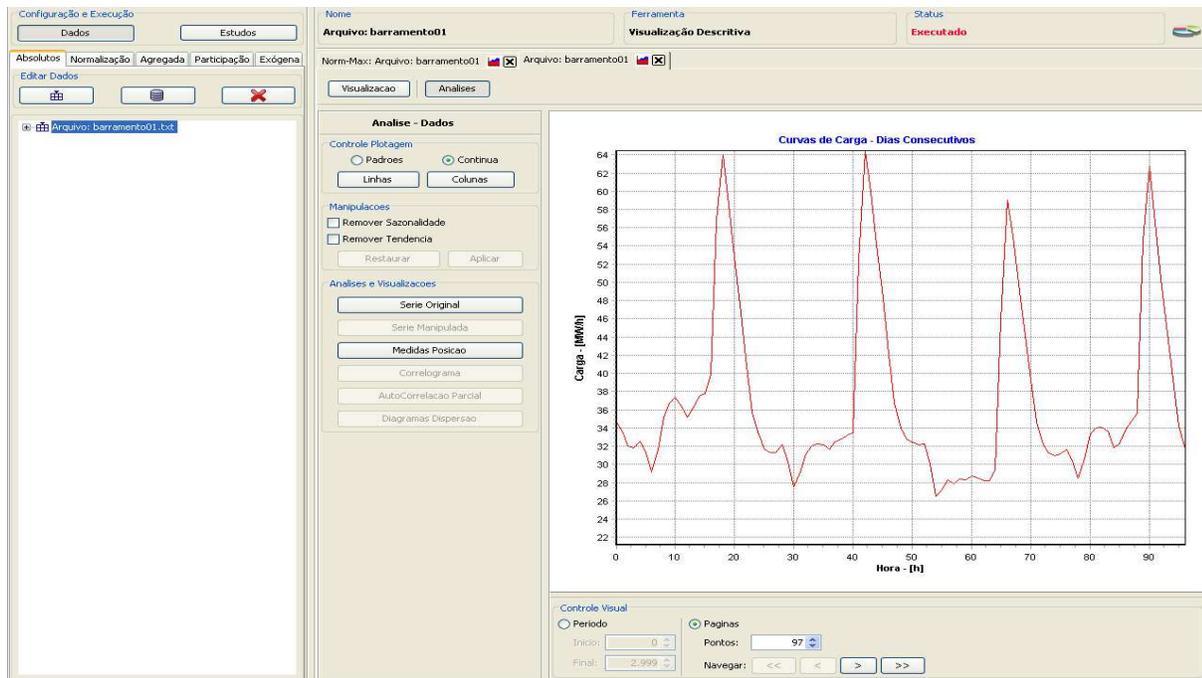


Figura 5.14: Visualização Gráfica III - SysPrev.

Outra facilidade disponível no SysPrev é o cálculo de medidas estatísticas para extração de informações relevantes. O gráfico mostrado na Figura 5.15 mostra o correlograma calculado para o conjunto de dados do barramento01 e, de posse destas informações, o analista tem melhores condições de definir quais são as configurações ideais para uma metodologia de previsão levando em consideração o tipo de série analisado.

Juntamente com as funções acima apresentadas é possível, através de ferramentas do botão **Análises**, manipular os dados de forma a remover tendências, sazonalidades, verificar a autocorrelação parcial, entre outras funcionalidades importantes no estudo de séries temporais. Vale ressaltar que todas as funcionalidades apresentadas e exemplificadas anteriormente podem ser aplica-

das em qualquer tipo de dado que esteja carregado no sistema. Esta facilidade torna possível a interação e captação de informações inseridas nos dados viabilizando análises detalhadas e específicas em cada elemento do sistema.

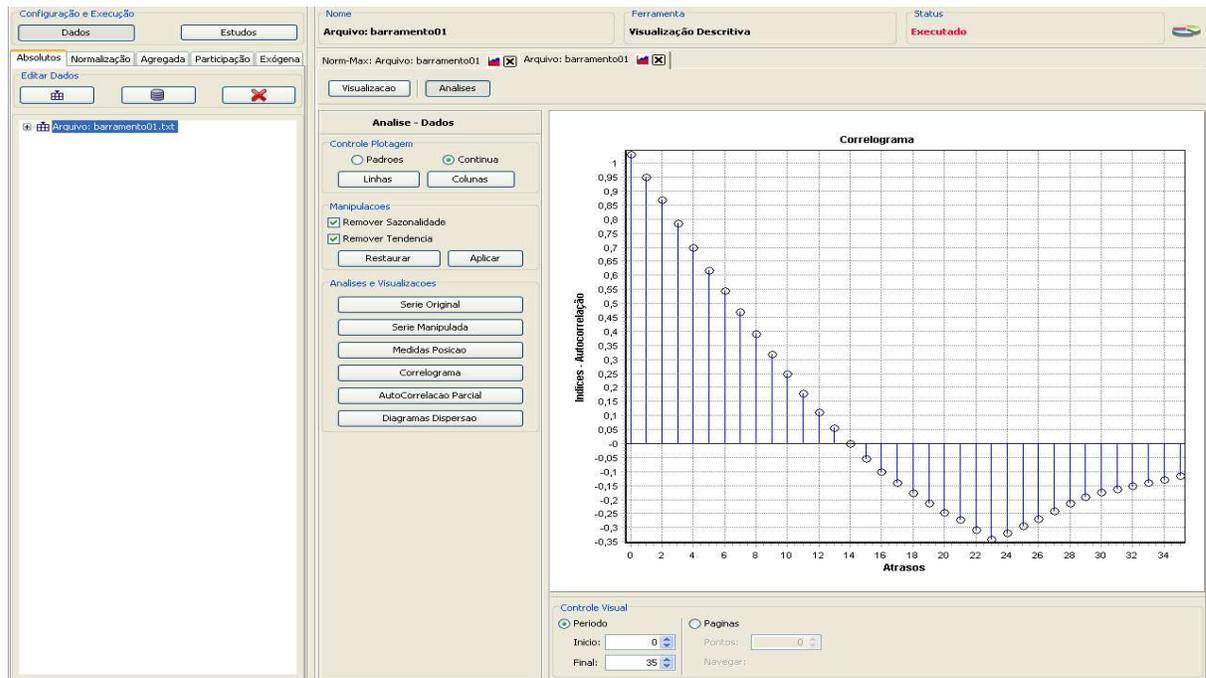


Figura 5.15: Visualização Gráfica IV - SysPrev.

### 5.3.5 Controle de Estudos

O ambiente de controle de estudos implementado no *SysPrev* foi projetado para possibilitar a criação, configuração e execução de simulações que envolvam algoritmos de previsão, agrupamento ou ambos, aplicados na previsão de séries temporais, facilitando a obtenção de resultados.

Logo após a inserção de dados, nas abas disponibilizadas pelo controle de dados, o acesso ao controle de estudos é liberado aos usuários. A Figura 5.16 mostra o ambiente de controle de estudos e simulações do *SysPrev*, no qual é possível **criar** (  ), **abrir** (  ), **parar** (  ), **salvar** (  ) e **excluir** (  ) um determinado estudo do sistema. Estas ferramentas de controle são complementadas com janelas e menus disponíveis em cada modelo de previsão/agrupamento inserido no sistema.

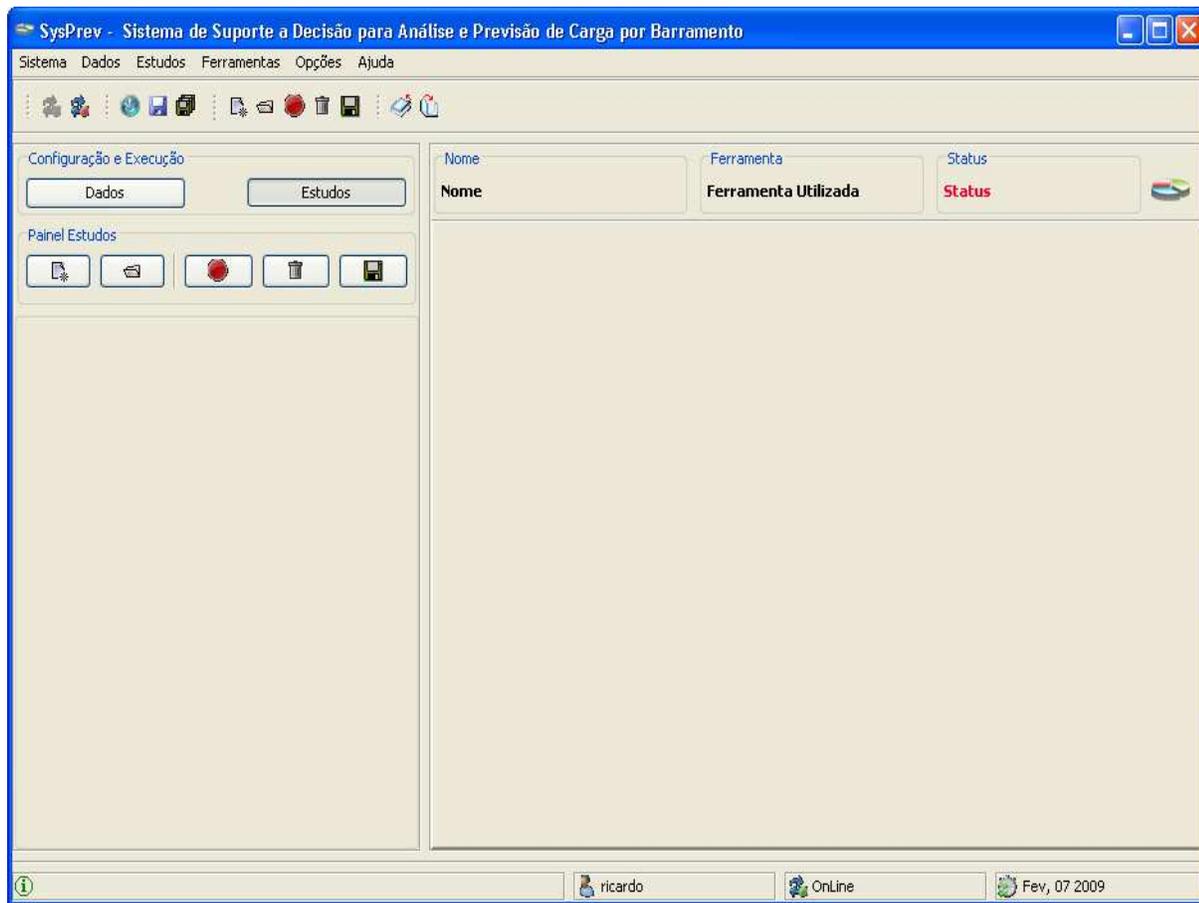


Figura 5.16: Ambiente de Navegação - Controle de Estudos.

O ambiente de controle de estudos foi projetado para ser acessado através de telas tipo “Wizard”. Este tipo de ambiente de configuração possibilita fácil acesso a todos os modelos disponíveis no sistema de maneira simples e direta. Atualmente, o *SysPrev* conta com três tipos de estudos implementados: **Agrupamento**, **Previsão Individual** e **Previsão Agregada**. Cada classe de estudo é responsável por um tipo de análise específica dentro de seu contexto. Desta forma:

- **Estudo de Agrupamento:** Possibilita a descoberta de associações entre perfis de barramentos distintos, visando a definição de subestruturas que podem ser utilizadas para catalogar determinados tipos de comportamentos comuns em vários barramentos;

- **Estudo de Previsão Individual:** Fornece ferramentas para realizar a previsão individual em diversos barramentos do sistema. De acordo com as funcionalidades da previsão individual, é possível realizar a previsão, em batelada, de um grupo de barramentos ou até mesmo configurar um estudo específico para cada barramento, visando tratá-lo de forma específica;
- **Estudo de Previsão Agregada:** Estudo formado através da junção de informações provenientes de modelos de agrupamentos e modelos de previsão. Neste tipo de estudo, o objetivo é utilizar as informações dos grupos de barramentos com perfis similares para a criação de uma estrutura que viabilize a previsão agregada dos barramentos<sup>6</sup>.

Em cada um dos estudos definidos anteriormente, os algoritmos (agrupamento e/ou previsão) utilizados são disponibilizados através da estrutura de componentes *plug-and-play*<sup>7</sup> implementado neste trabalho.

A Figura 5.17 mostra a tela “Wizard”, na qual são apresentados os tipos de estudos disponíveis no sistema, bem como algumas de suas opções. Através desta tela, pode-se escolher qual é o tipo de estudo, bem como a técnica que será utilizada para executar o estudo. No exemplo da Figura 5.17, pode-se perceber as opções disponíveis na seleção de um estudo de previsão agregada, no qual o sistema oferece as opções para escolhas dos modelos de *agrupamento* e *previsão* com base nos componentes *plug-and-play* inseridos no sistema.

Cada estudo criado no *SysPrev* é enviado para uma área especificamente reservada para alojar os diferentes estudos em execução (ou não) carregados no *SysPrev*. Para facilitar o acesso, o controle de estudos conta com um sistema de navegação baseado em árvores (*TreeView*) (similar ao implementado no controle de dados). Neste ambiente de navegação, o acesso aos estudos é direto e intuitivo, sendo possível realizar configurações, bem como executar cada estudo do sistema de maneira independente. A Figura 5.18 apresenta o ambiente de navegação em árvores que contém a lista de estudos criados através no *SysPrev* e, como pode ser observado, esta lista tem características similares àquela

<sup>6</sup>O estudo agregado, implementa a metodologia proposta no capítulo 3 deste trabalho.

<sup>7</sup>O desenvolvimento de componentes *plug-and-play* será abordado com maiores detalhes no capítulo 6 nesta tese de doutorado.

apresentada anteriormente no controle de dados do sistema.

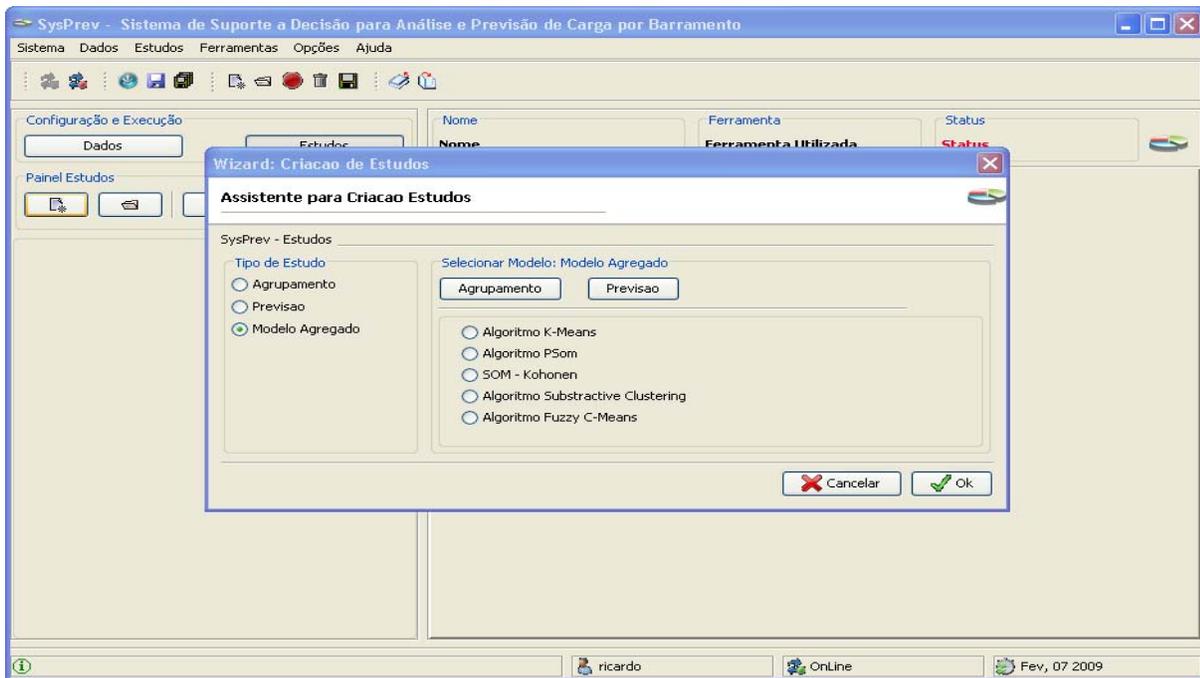


Figura 5.17: Tela Principal - Criação de Estudos.

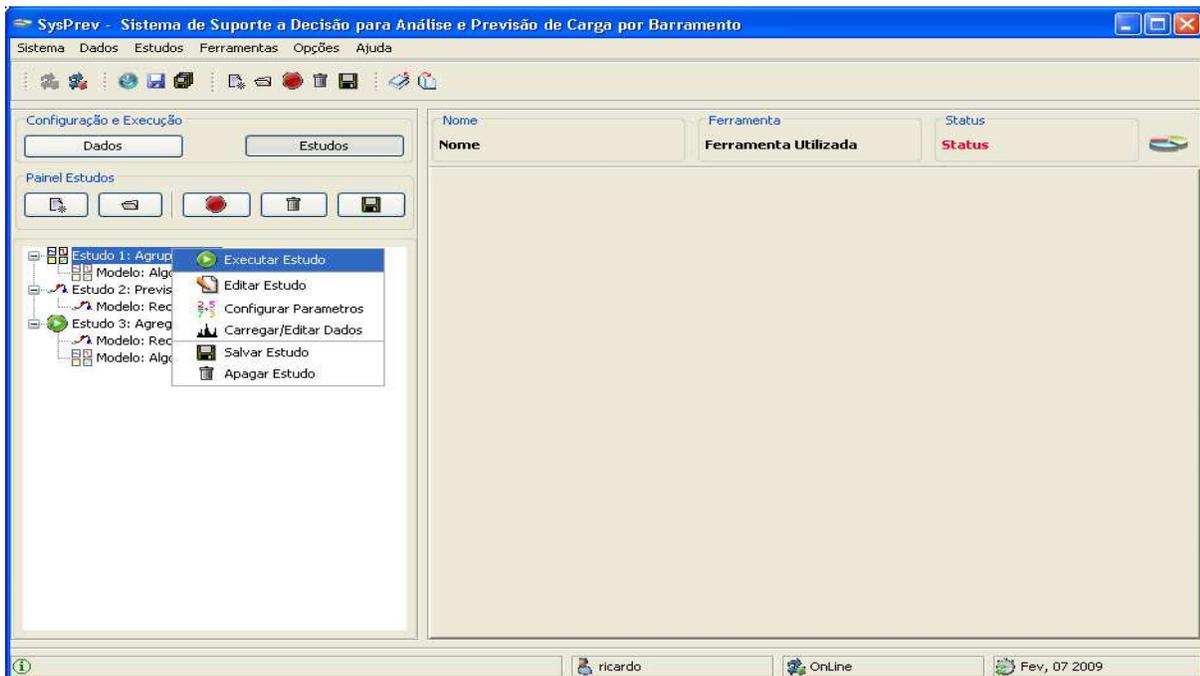


Figura 5.18: Navegação em Árvores - Controle de Estudos.

Ainda observando a Figura 5.18, pode-se notar a existência de um menu flutuante que viabiliza o acesso a diversos itens que facilitam a utilização das ferramentas disponíveis em cada estudo. Neste menu, estão disponíveis as seguintes ferramentas: **executar estudo**, **editar estudo**, **configurar parâmetros**, **carregar/editar dados**, **salvar estudo** e **apagar estudo**. Com estas ferramentas, é possível definir as configurações que proporcionam a execução dos estudos criados no *SysPrev*.

### 5.3.5.1 Estudos de Agrupamento

Cada estudo do *SysPrev* conta com ambientes de configuração personalizados e determinados por sua característica específica. Para configurar um determinado estudo do sistema, deve-se definir características que farão parte da simulação, bem como a técnica que será utilizada para prover os resultados do estudo. No *SysPrev*, existe um conjunto de janelas de configuração implementadas para cada tipo de estudo do sistema, facilitando a configuração.

A Figura 5.19 mostra o ambiente padrão desenvolvido para configurar e visualizar os resultados em estudos de agrupamento. No painel direito do *SysPrev*, pode-se perceber a existência de vários parâmetros que devem ser ajustados quando deseja-se executar um estudo de agrupamento. Juntamente com a escolha do estudo a ser realizado, deve-se definir o algoritmo adotado, bem como os dados de entrada e outras informações de configuração. No exemplo apresentado nesta figura, a técnica de agrupamento escolhida foi o algoritmo **KMeans** (MacQueen, 1967), que, conforme pode ser observado, foi configurado para realizar a divisão do conjunto de barramentos em 4 grupos.

O botão (  ), mostrado na Figura 5.19, é responsável por acionar uma janela “Wizard” responsável por definir os dados que serão utilizados no estudo de agrupamento. No caso específico do problema de previsão de carga por barramento, esta janela visa determinar quais barramentos irão participar do estudo de agrupamento com o objetivo de detectar similaridades.

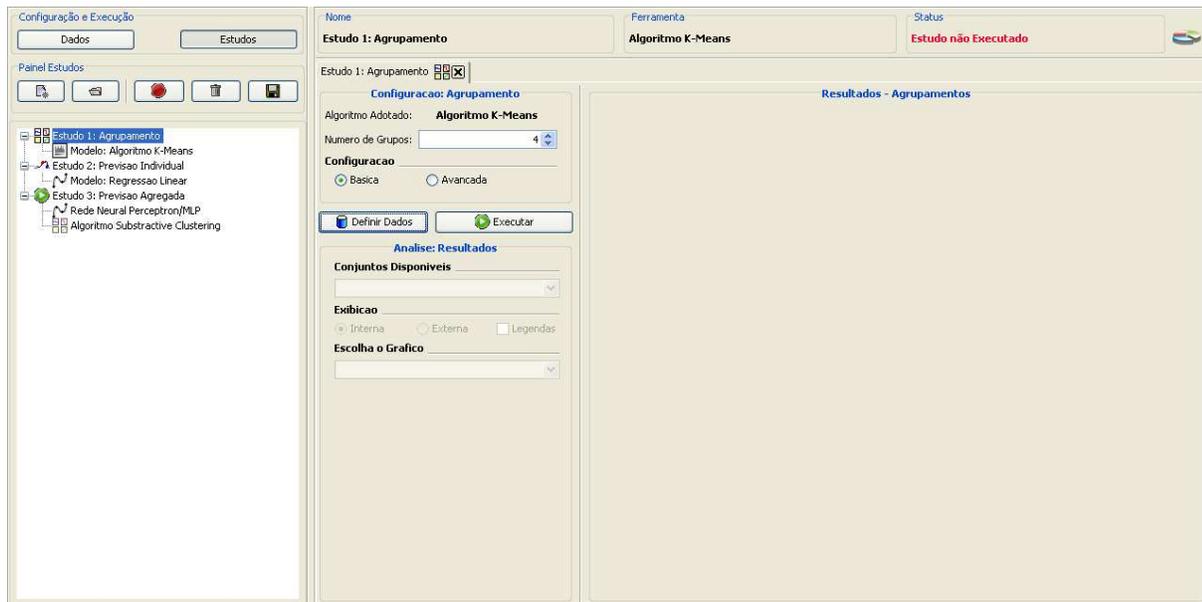


Figura 5.19: Configurações - Estudo Agrupamento.

A Figura 5.20 apresenta a janela utilizada para definição dos dados do estudo de agrupamento. Neste ambiente, é possível definir vários parâmetros que vão desde a escolha do conjunto de barramentos até o formato em que cada padrão deste conjunto será apresentado ao algoritmo. Esta facilidade de configuração deixa o sistema capaz de realizar estudos variados possibilitando a detecção de várias informações implícitas nos dados de carga dos barramentos.

Antes de executar qualquer estudo no sistema, é necessário configurar o algoritmo escolhido determinando os parâmetros que serão utilizados no momento da execução. No *SysPrev*, é possível configurar os algoritmos segundo duas visões. A primeira utiliza parâmetros básicos (“*default*”), que geralmente apresentam desempenho razoável na execução do algoritmo. A segunda visão dá ao usuário a opção de alterar as configurações do modelo segundo seus conhecimentos, visando um melhor desempenho da técnica.

Conforme dito anteriormente, cada algoritmo disponível no *SysPrev* foi implementado segundo a ótica *plug-and-play*. Assim, cada técnica (previsão ou agrupamento) possui uma janela de configuração individual desenvolvida especificamente para suas características. Esta janela, presente no interior da compo-

nente, exibe os parâmetros necessários à configuração do algoritmo, fornecendo opções para definição dos parâmetros que influenciam o seu desempenho. Na Figura 5.21, observam-se as janelas de configuração de parâmetros do modelo de agrupamento **KMeans** e **SOM**, nos quais é possível definir os parâmetros específicos necessários à sua execução.

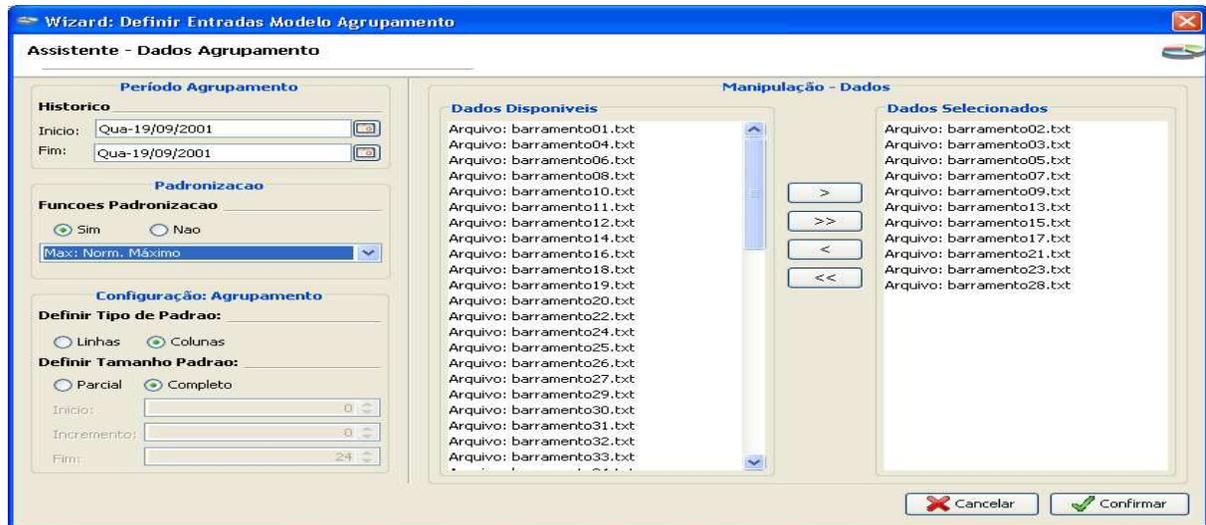


Figura 5.20: Tela de Escolha de Dados - Estudo Agrupamento.

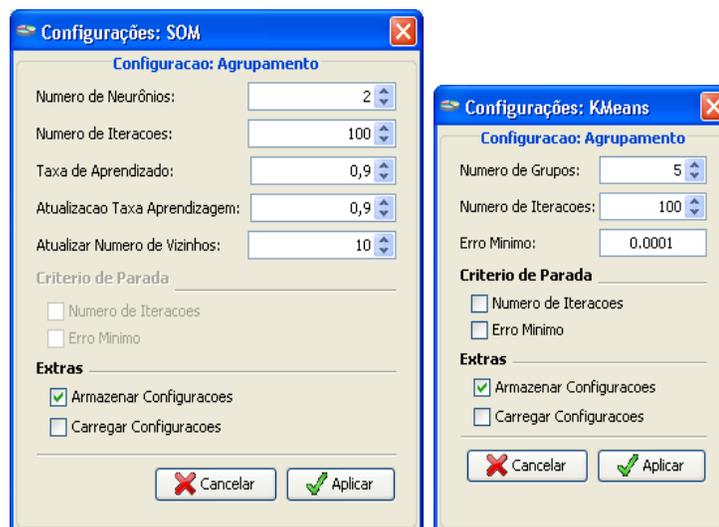
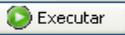


Figura 5.21: Parâmetros de Configurações - Técnicas de Agrupamento.

Após a definição dos dados e a configuração dos algoritmos, o estudo está apto a ser executado. Na Figura 5.19, o botão (  Executar ) executa o estudo

de agrupamento, disponibilizando o acesso aos resultados através do painel **Análise: Resultados**, também apresentado nesta figura. Os resultados obtidos após a execução do algoritmo, no estudo de agrupamento, podem ser observados na Figura 5.22, onde é possível observar cada um dos elementos pertencentes a cada grupo encontrado na simulação. Juntamente com a exibição gráfica dos resultados, o sistema fornece outras opções de visualização e seleção dos elementos, conforme pode ser observado nesta tela de resultados.

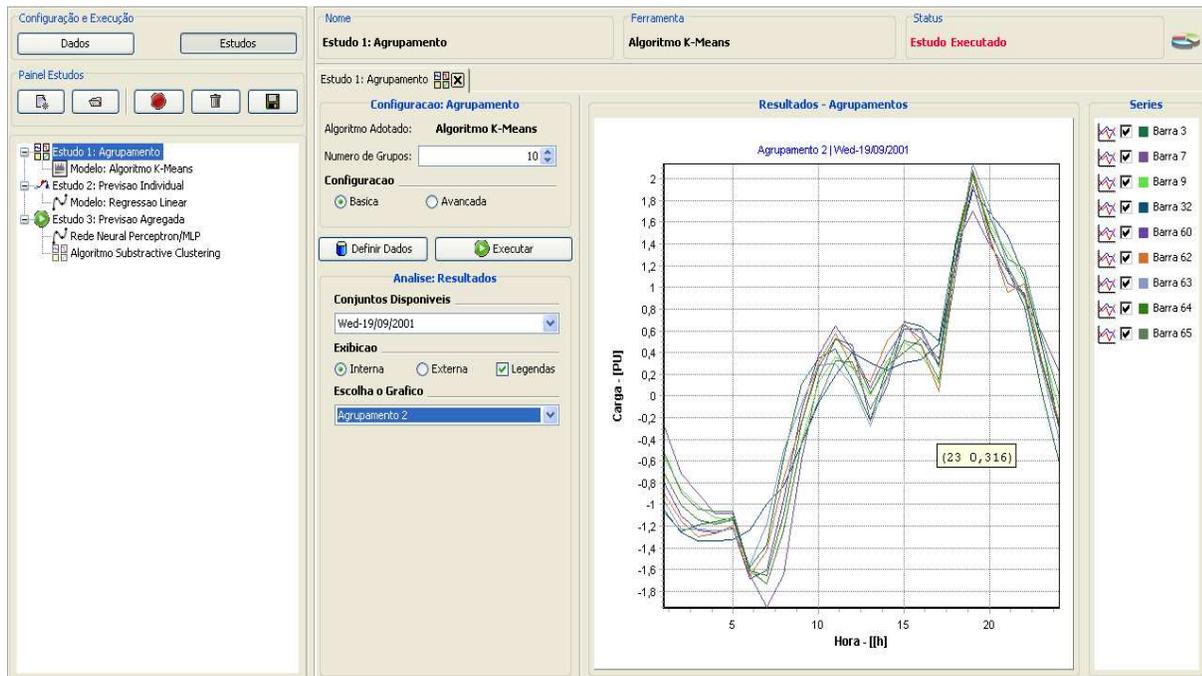


Figura 5.22: Tela de Resultados - Estudo Agrupamento.

### 5.3.5.2 Estudos de Previsão Individual (PI)

De maneira análoga ao exemplo apresentado para agrupamento, os estudos de PI realizados no *SysPrev* também possuem janelas “Wizard” que possibilitam a configuração dos estudos de previsão. A Figura 5.23 apresenta o painel de configuração dos estudos de (PI), onde é possível definir o modelo de previsão, escolher seus parâmetros, bem como o selecionar conjunto de dados e as entradas utilizadas na etapa de treinamento/teste.

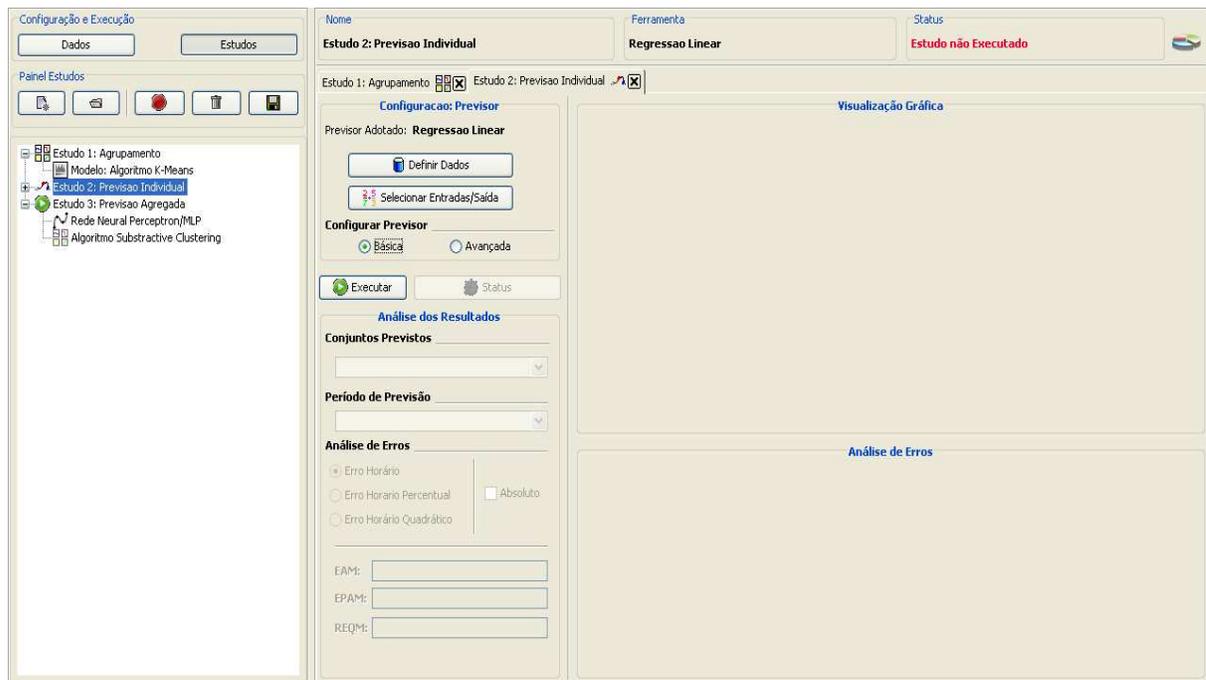


Figura 5.23: Configuração - Previsão Individual.

Na Figura 5.23, o botão (  ) é utilizado para disponibilizar o acesso a janela de escolha de dados. A Figura 5.24 apresenta a tela “Wizard” utilizada para para selecionar os conjuntos de dados nos quais deseja-se realizar as previsões. Nesta figura, é possível selecionar cada dado de carga por barramento e também definir se é ou não necessário aplicar uma função de normalização nos dados originais.

A Figura 5.25, disponibilizada pelo botão (  ), apresenta a janela gráfica para escolha das entradas (ou atrasos) utilizados na criação dos padrões que servirão de base para ajuste dos modelos de previsão. Esta tela possibilita o detalhamento dos dados, dando a opção de escolha através dos dias disponíveis no histórico bem como a definição dos períodos de previsão desejado no estudo.

As janelas apresentadas nas Figura 5.24 e 5.25 trabalham em simbiose, dando ao usuário condições de avaliar o cenário existente nos dados disponíveis, possibilitando uma escolha personalizada nos dados de treinamento e no período que deverá ser previsto no estudo criado. Observa-se também que

estas janelas de configuração são intuitivas e de fácil uso, tornando o processo de obtenção de previsão simples e ágil.

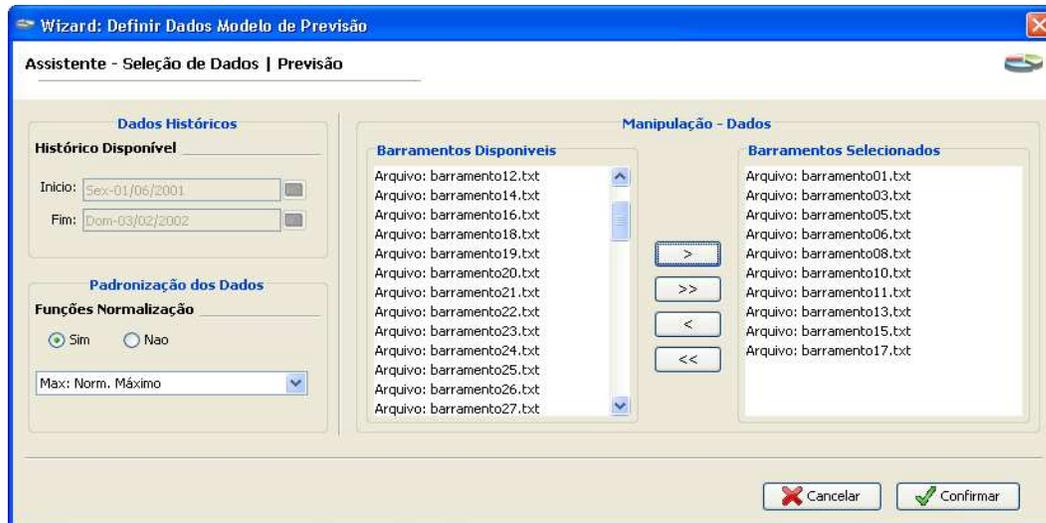


Figura 5.24: Escolha de Dados - Modelo de Previsão.

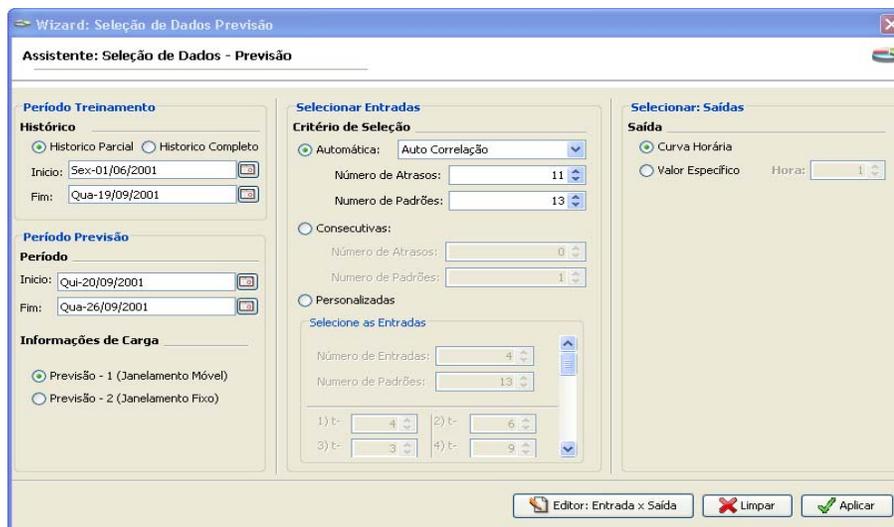


Figura 5.25: Seleção de Entradas - Modelo de Previsão.

De acordo com a tela apresentada na Figura 5.23, o modelo definido para realizar o estudo de previsão foi uma rede neural tipo perceptron multicamadas (perceptron/MLP). Como descrito no caso dos algoritmos de agrupamento, cada componente do sistema possui uma janela individual de configuração. Quando a opção **Configuração -> Avançada** é selecionada, o sistema disponibiliza a janela de configuração apresentada na Figura 5.26 para que o usuário possa definir os parâmetros desejados na execução do modelo. Se a opção **Configuração -> Básica** o sistema utiliza as configurações padrões para o modelo escolhido pelo usuário.

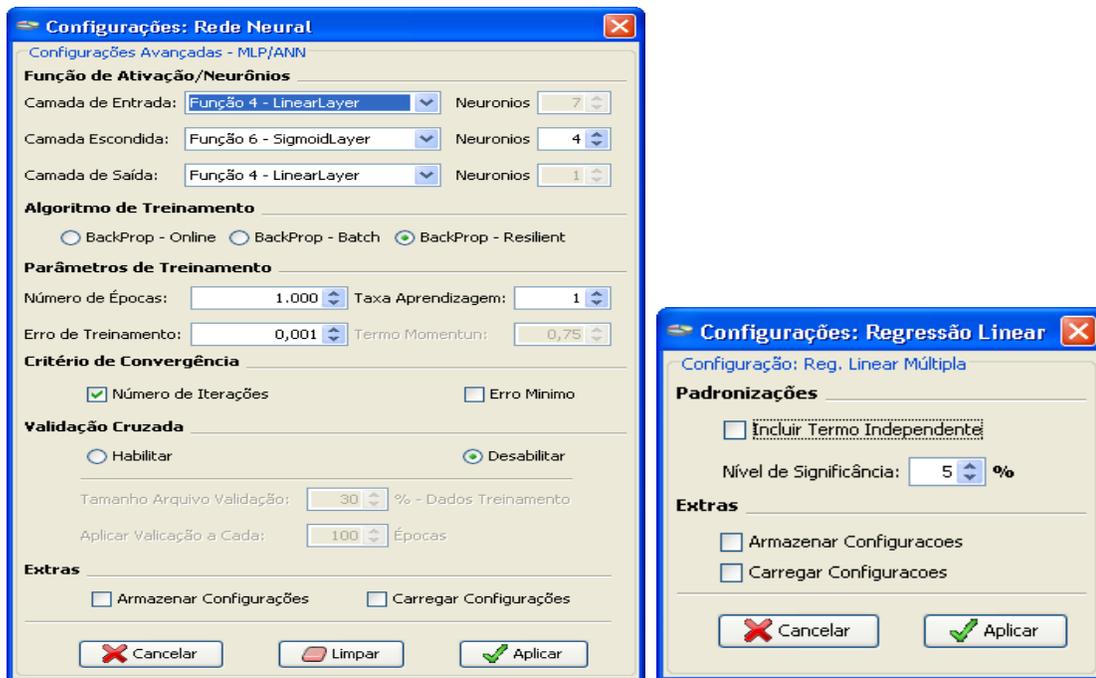
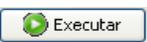


Figura 5.26: Configuração Avançada - Previsores.

Nas opções de configuração avançada disponíveis na Figura 5.26, percebe-se que é possível definir os parâmetros necessários à execução dos previsores. É importante destacar que cada componente de previsão do sistema apresenta uma janela de configuração incorporada em sua estrutura de pacote, que possibilitam a configuração de parâmetros avançados no modelo.

Após a definição do(s) conjunto(s) a ser(em) previsto(s), a seleção das entradas e a configuração dos parâmetros do previsor o botão (  ), mos-

trado na Figura 5.23, se tornará ativo possibilitando a execução do estudo desejado. A tela do *SysPrev* mostrada pela Figura 5.27 contém a exibição dos resultados de previsão após a execução do processo de treinamento e validação.

Observando os itens apresentados na Figura 5.27 verifica-se que, além da curva prevista e verificada para o barramento desejado, é mostrado também um gráfico de barras que apresenta o erro horário para cada hora do dia previsto. Outro fator é que é possível visualizar as previsões de todos os conjuntos previstos com facilidade sendo possível verificar os erros horários e o erro médio em cada barramento.

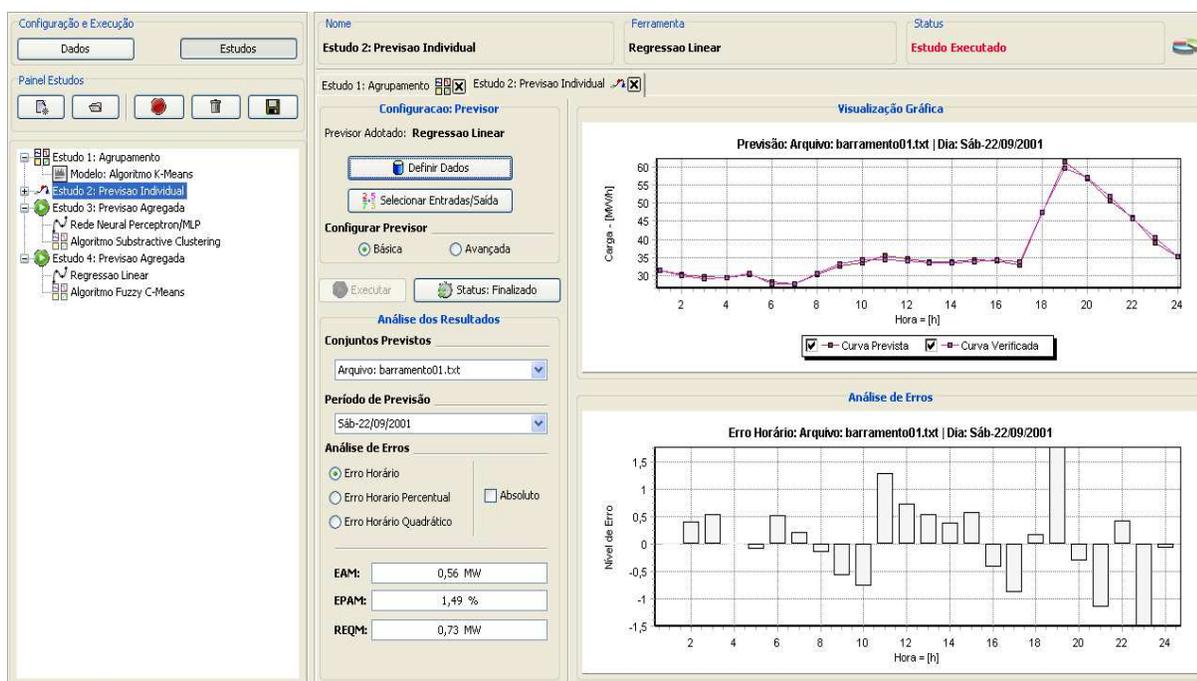


Figura 5.27: Tela de Resultados - Previsão Individual.

### 5.3.5.3 Estudos de Previsão Agregada

O ambiente de controle de estudos projetado no *SysPrev* foi idealizado visando possibilitar a integração dos dados com os modelos disponíveis no sistema. Assim, é possível realizar diversas combinações de parâmetros através de novos estudos, sendo possível visualizar as informações geradas através do pacote gráfico do sistema.

A estrutura de previsão agregada definida para o *SysPrev* consiste na utilização das informações de agrupamento de dados na previsão. Especificamente, esta metodologia foi idealizada para resolver o problema de previsão de carga por barramento, que é o objeto de investigação desta pesquisa. No *SysPrev*, a metodologia agregada foi configurada usando algumas das janelas de agrupamento e previsão (comentadas anteriormente).

A janela gráfica na Figura 5.28 apresenta os botões de configuração e análise de resultados para o estudo de previsão agregada. Conforme descrição anterior, muitas das janelas utilizadas na configuração de um estudo agregado são herdadas dos estudos de agrupamento e previsão individual, outrora discutidos.

A função dos botões apresentados na Figura 5.28 é liberar o acesso às ferramentas de configuração, possibilitando a definição da sistemática de agrupamento, utilizada na previsão agregada, bem como a configuração do modelo de previsão escolhido.

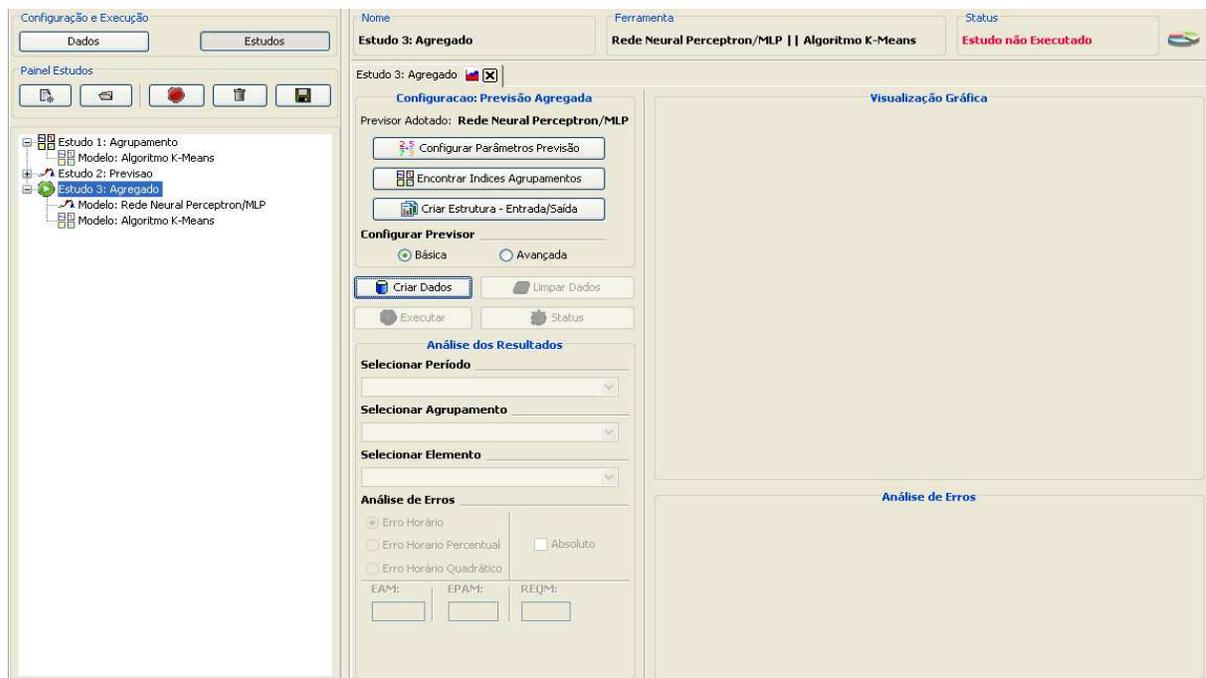
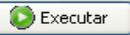


Figura 5.28: Tela de Configuração - Previsão Agregada.

Com as configurações definidas, o botão (  Executar ) é ativado, possi-

bilitando a execução do estudo de previsão. Conforme pode ser visto na Figura 5.29, a forma de apresentação dos resultados de previsão (individual e agregada) são similares. Entretanto, no caso agregado, pode-se notar opções mais variadas no quadro **Análise dos Resultados** em que é possível definir opções para que possibilitem o acesso a curva prevista encontrada pelo predictor.

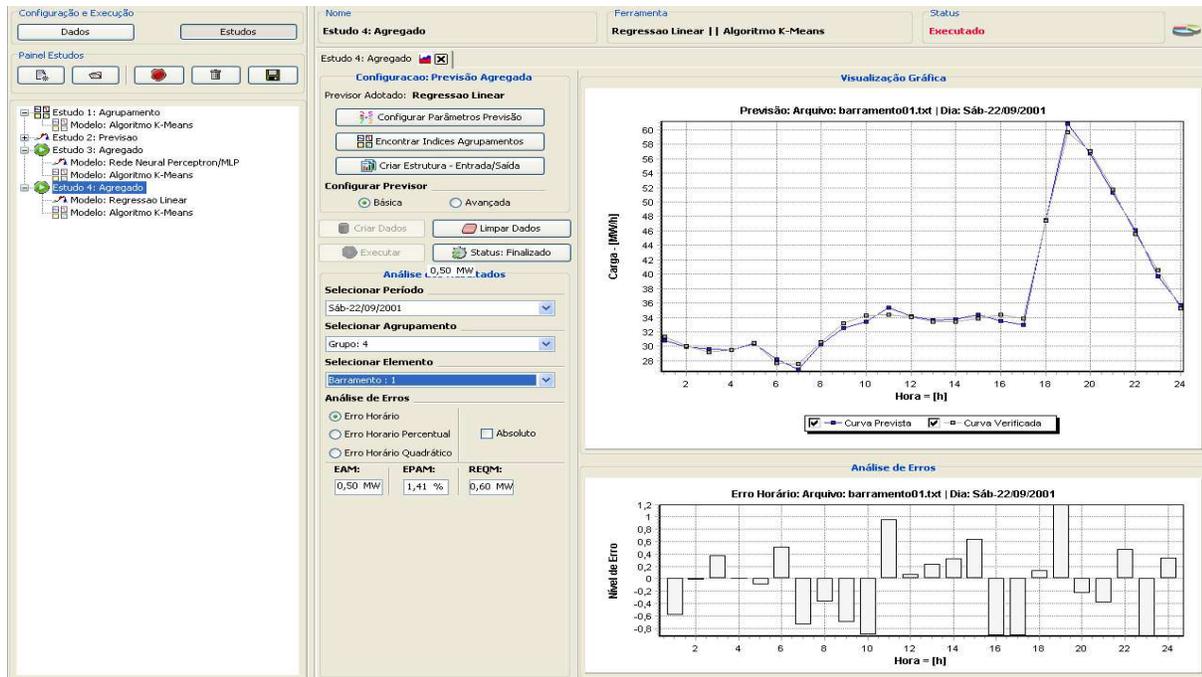


Figura 5.29: Tela de Resultados - Previsão Agregada.

## 5.4 Ferramentas - SysPrev

Uma das grandes deficiências existentes nos sistemas de previsão de séries temporais é a dificuldade de analisar simultaneamente o resultado gerado por diversas simulações de estudos distintos. Geralmente, a análise de resultados é um procedimento artesanal, que demanda um grande esforço por parte do analista, que muitas vezes necessita de utilizar diversos ambientes computacionais para realizar a interpretação dos resultados gerados pelos modelos.

O SysPrev proporciona um conjunto de janelas para selecionar os resultados dos diversos estudos do sistema e compará-los de forma eficiente. As-

sim, é possível avaliar o resultado de diversos previsores em uma mesma janela gráfica com extrema facilidade.

Um diferencial que torna o *SysPrev* atrativo é o seu pacote de internacionalização, implementado para possibilitar sua utilização em diversos idiomas. A inserção de um novo pacote com um novo idioma pode ser feita facilmente seguindo um princípio similar ao desenvolvido para inserção de novas ferramentas. Uma amostra do ambiente *SysPrev* internacionalizado pode ser observada também na Figura 5.30, onde o sistema é mostrado no idioma Inglês-USA.

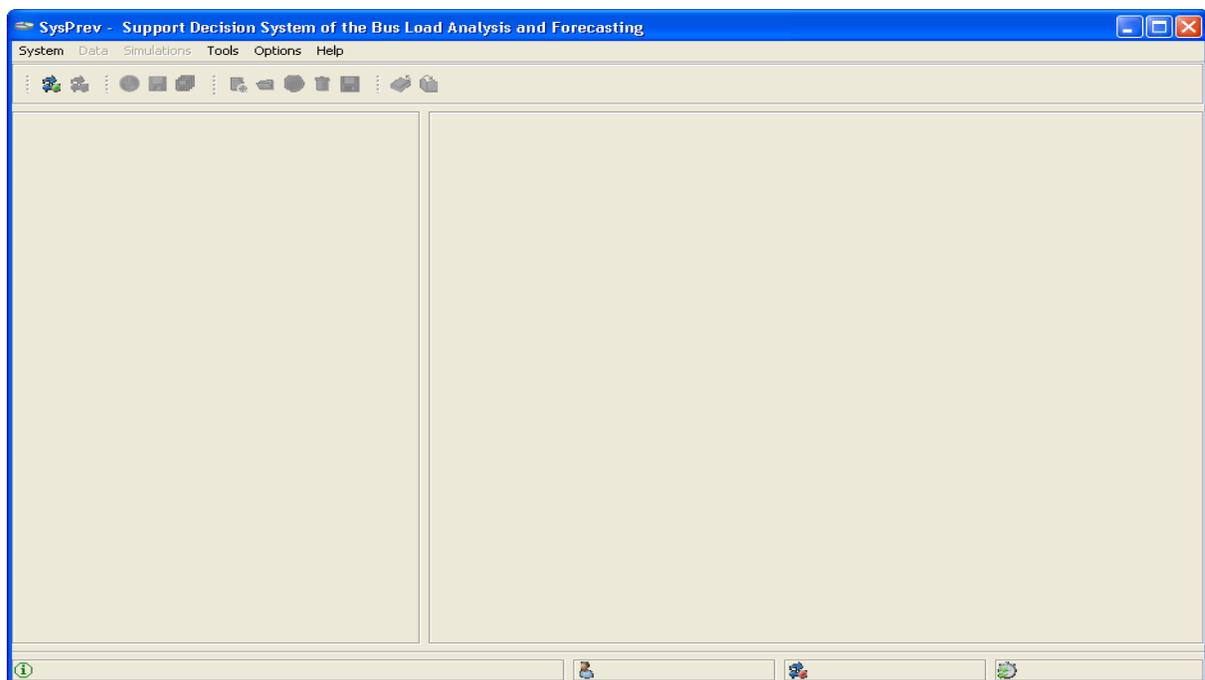


Figura 5.30: Tela de Principal - *SysPrev* | (en\_US).

O pacote de funções complementares implementado no *SysPrev* tem o objetivo de possibilitar facilidades na realização de análises nos diversos módulos do sistema. Com este foco, foram construídos alguns conjuntos contendo várias funcionalidades que, quando agregadas, complementam o *SysPrev*, provendo vários elementos úteis que viabilizam a descoberta de informações nos elementos do sistema. Os pacotes de ferramentas disponíveis no sistema podem ser separados pela funcionalidade proporcionada, e são catalogados da seguinte forma:

- **Pacote Gráfico:** Proporciona ferramentas para visualização gráfica de ele-

mentos, facilitando a comparação e interpretação de resultados;

- **Pacote de Manipulação Matricial:** Auxilia a análise matricial, provendo diversas formas de extração de informações, busca e catalogação de informações;

#### 5.4.0.1 Pacote Gráfico - SysPrev

O pacote gráfico implementado no *SysPrev* foi utilizado largamente nos exemplos definidos nas seções anteriores deste capítulo. Entretanto, existem outras funcionalidades que tornam o pacote atraente e possibilitam a execução de diversos comandos úteis ao contexto de análise de dados.

Basicamente, as funções deste pacote estão disponíveis em cada gráfico gerado através do sistema, podendo ser acessada por meio de um menu flutuante que contém as diversas funcionalidades implementadas pelo pacote. Entre os elementos disponíveis, pode-se destacar:

- *Ferramentas de Manipulação Visual:* Proporcionam ferramentas para mudar a forma de exibição do gráfico selecionado. Através deste elemento, pode-se rotacionar, expandir/contrair, mover, colocar o gráfico em três dimensões. Estas ferramentas são úteis quando deseja-se visualizar o gráfico de forma não usual;
- *Ferramentas de Edição:* Possibilitam a edição de elementos tais como: nome dos eixos, mudar a cor de cada curva, excluir linhas, definir legendas, entre outros. Esta ferramenta é extremamente útil para personalizar um gráfico para um determinado estudo;
- *Ferramentas de Impressão:* Permitem impressão do gráfico, bem como a visualização prévia do gráfico e configurações tais como: definição de margens, formato de impressão, tamanho da impressão, entre outros;
- *Copiar para área de Trabalho:* Exporta o gráfico para o “workspace” do sistema operacional, possibilitando a sua utilização por meio de editores de texto convencionais;

- *Salvar Gráfico em Arquivo*: Salva o gráfico em um arquivo, utilizando o formato de imagens;
- *Abrir Gráfico em outra Janela*: Cria uma cópia do gráfico em uma janela flutuante do sistema, facilitando a análise e edição;
- *Ativar Comparação entre Gráficos*: Envia o gráfico para um ambiente onde é possível realizar a comparação simultânea de diversos gráficos, extraindo informações importantes e novas visualizações.

#### 5.4.0.2 Pacote Matricial - SysPrev

O pacote matricial disponível no *SysPrev* foi idealizado para dar suporte às transações realizadas por meio de cálculos algébricos em matrizes/vetores que compõe as séries temporais de caga por barramento. Dentro de seu contexto, suas funcionalidades podem ser catalogadas da seguinte forma:

- *Definição de Rótulos*: Possibilita a criação de rótulos personalizados para as linhas e colunas de matrizes, atribuindo significado físico ao seu conteúdo;
- *Geração de Gráficos Específicos*: Permite a criação de diversos tipos de gráficos a partir de elementos selecionados na matriz original;
- *Criação de Janelas Matriciais*: Abre a matriz de dados em uma janela independente do sistema, viabilizando o acesso a várias funções de manipulação nos dados.



## Sistema Baseado em Componentes

Este capítulo traz uma descrição da metodologia utilizada para construção dos modelos de previsão e agrupamento utilizados no sistema de previsão desenvolvido neste trabalho, sendo apresentadas e destacadas as vantagens de se trabalhar com a arquitetura dirigida a componentes, bem como a sua utilização no *SysPrev*.

Juntamente com a descrição da metodologia, é feita uma apresentação do conceito denominado *interfaces* (presente em algumas linguagens orientadas a objeto). Este conceito tem a função de viabilizar a construção do sistema modular utilizando a herança e o polimorfismo. Especificamente neste trabalho, toda a sistemática e construção foi realizada utilizando a linguagem de programação JAVA, devido à sua robustez e capacidade de suportar aplicativos com componentes plugáveis. Neste sentido, todos os exemplos apresentados no decorrer do capítulo fazem alusão a pseudocódigos que têm semelhanças com a sintaxe utilizada pelo ambiente JAVA.

Para facilitar o entendimento do método, são apresentados diagramas UML (*Unified Modeling Language*) para ilustrar a relação de uma componente com seus moldes (ou *interfaces*). Este capítulo apresenta a base para a formalização do processo de construção de sistemas baseados em componentes *Plug-and-Play*.

## 6.1 Motivação

No processo de previsão de uma série temporal, podem ser utilizados diversos tipos de modelos com características lineares ou não-lineares para realizar a previsão de um determinado valor. A escolha do modelo utilizado para previsão depende de vários fatores que estão ligados ao tipo de série no qual se deseja que a previsão seja feita. Dependendo do comportamento e da não-linearidade existente na série, determinados modelos de previsão podem apresentar melhores resultados que outros.

No problema de previsão de carga por barramento, existem vários tipos de perfis de comportamento nas séries históricas nos nós do sistema. Devido a esta diversidade nos comportamentos, pode-se afirmar que alguns modelos de previsão têm maior eficiência em um tipo de barramento enquanto outros modelos representam com maior precisão o comportamento de nós da rede com perfil diferenciado.

Na prática, para encontrar o melhor previsor, é interessante testar diversos modelos buscando aquele que melhor representa a série analisada no período desejado. Vale lembrar que, devido às alterações do padrão de carga que podem ocorrer nos barramentos, um modelo de previsão que tem boa capacidade de generalização em um período pode não representar a série satisfatoriamente em outro período devido à mudanças no perfil de carga.

Desta forma, é possível perceber que, para realizar a previsão de uma série de carga por barramento de maneira eficiente, é necessário testar diversas abordagens com várias configurações em um processo de tentativa e erro para encontrar o modelo que representa a série temporal de forma precisa e acurada. Normalmente, este processo de busca pela técnica de previsão com maior nível de representatividade é feito experimentalmente por meio de um sistema computacional adequado que facilite o processo de busca.

Os sistemas computacionais disponíveis atualmente para previsão de séries de carga geralmente são dotados de um conjunto de ferramentas de previsão pré-programadas que estão à disposição para que o usuário possa interagir

e encontrar, entre o conjunto de previsores disponíveis, aquele que melhor represente a série em estudo. Contudo, mesmo utilizando todo conjunto de ferramentas de previsão disponibilizado pelo *software*, nem sempre é possível encontrar a abordagem ideal para um tipo de série temporal de potência.

O *SysPrev* foi projetado para suportar a inserção automática de novas técnicas de previsão e análise de dados. Desta forma, optou-se por construir os “*componentes do sistema*” (algoritmos que realizam previsões, análises estatísticas e agrupamentos) em blocos independentes. A vantagem desta abordagem é a facilidade na inserção de novos modelos, que podem ser feitos para analisar tipos específicos de séries temporais de carga, viabilizando o estudo da série por meio de um modelo desenvolvido especialmente para seu comportamento.

## 6.2 Componentes *Plug-and-Play*

Historicamente, o primeiro modelo de componentes *plug-and-play* (ou simplesmente *plugin*) foi desenvolvido e utilizado no ano de 1978 em programas para a *Macintosh HyperCard*, criados por Bill Atkinson, e no *QuarkXPress*, desenvolvido pela *Quark Inc.* Na realidade, os *plugins* utilizados no *HyperCard* eram exemplos adiantados do conceito atual de *plugins*. Eles possuíam as mesmas facilidades dos atuais, porém eram colocados no mesmo diretório da documentação do sistema (chamado pilhas) e, desta mesma maneira, eram distribuídos junto à aplicação, como uma única entidade, sem a necessidade de outras instalações (Goodman, 1987). Os *plugins* evoluíram e, atualmente, são executados como bibliotecas ou componentes compartilhados (instaláveis ou não) que ocupam um lugar predefinido pela aplicação principal.

Cada vez mais, a utilização de *plugins* explicita a sua importância na construção de aplicações, seja para fracionar o sistema principal a fim de reduzir o seu tamanho, como também para poder incluir funcionalidades opcionais ao sistema ou modificar as já existentes de maneira dinâmica sem a necessidade de sua recompilação. Os *plugins* geralmente não funcionam sozinho, eles dependem de um programa principal que os chamam e utilizam as suas funcionalidades sob demanda do sistema ou do usuário.

O *SysPrev* foi desenvolvido com base na arquitetura de componentes *plug-and-play*. Com esta abordagem, é possível inserir novas funcionalidades ao sistema sem a necessidade de acessar e compilar o código fonte do programa. No sistema de previsão de carga por barramento, a utilização do conceito *plug-and-play* visa basicamente a inserção, atualização e remoção de modelos de previsão e agrupamento de dados.

### 6.2.1 Desenvolvimento de *Plugins*

Para que um sistema computacional seja construído com base em componentes *plug-and-play*, vários fatores devem ser considerados. Primeiramente, é necessário determinar uma forma de implementação padronizada que deverá ser adotada por todos dos modelos inseridos no sistema. Após a criação deste padrão, cada componente deverá adotar a padronização definida para manter a compatibilidade funcional do *software*.

Nas linguagens orientadas a objeto, especificamente na linguagem JAVA, este tipo de padronização é estabelecido através do conceito de *interfaces* (Deitel e Deitel, 2005). Sucintamente, uma interface é um tipo de metodologia que padroniza implementações; é um molde que define quais funcionalidades devem existir em um determinado componente. A Figura 6.1 mostra um modelo intuitivo da utilização de interfaces em uma aplicação. Nesta figura, a interface **Padrao** foi criada definindo um modelo de implementação, e os componentes **A** e **B** utilizam o molde estabelecido na interface para implementar seus métodos. Obrigatoriamente, todos os métodos definidos na interface devem estar presentes nos componentes **A** e **B**, respeitando a implementação definida na interface **Padrao**. A diferença existente entre os componentes **A** e **B** está na lógica de funcionamento dos métodos, isto é, o mesmo método **novaOperacaoA()** tem lógicas de implementação distintas em **A** e **B**, gerando um polimorfismo de comportamento entre os componentes derivados da interface **Padrao**.

As aplicações do conceito de *interface* variam de acordo com o objetivo do *software* em desenvolvimento. Pode-se pensar em *interfaces* para modelos de previsão de carga, modelos de agrupamento, métodos de otimização, busca

inteligente, fluxo de potência, entre outros.

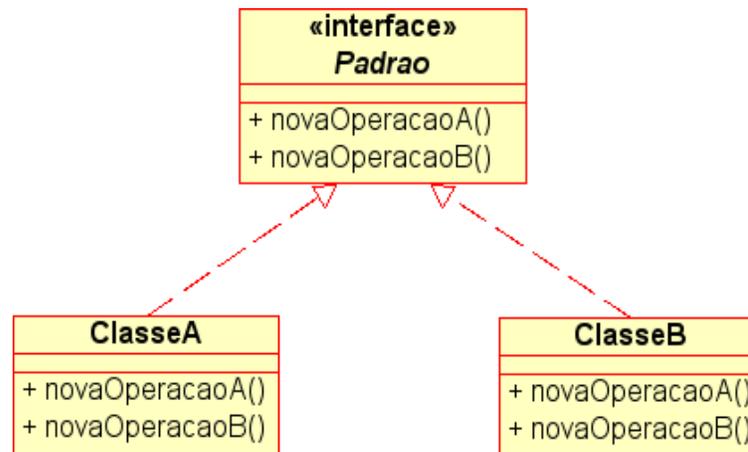


Figura 6.1: Modelo Intuitivo - *Interface* × Componentes.

### 6.2.2 Interfaces

Em linguagens orientadas a objeto, o conceito de *interfaces* foi criado para representar um molde dotado de diversas características desejadas em determinados componentes. Em termos práticos, uma *interface* estabelece um modelo que deve ser seguido para criação de vários tipos de componentes que fazem a mesma tarefa de maneiras diferentes.

O princípio utilizado para a criação de uma *interface* é o alicerce da programação modular. Com base nos moldes definidos em cada *interface*, um *software* pode ser facilmente atualizado sem grandes esforços. Quando um analista utiliza o conceito de *interfaces* na construção dos componentes de um sistema, implicitamente ele está fazendo uso da *herança* e do *polimorfismo*, que são conceitos amplamente conhecidos em linguagens orientadas a objetos.

Neste trabalho, o conceito de *interfaces* foi utilizado para propor um modelo genérico que será utilizado para a criação de vários componentes com funções e técnicas específicas. De forma objetiva, este conceito será aplicado para criar dois tipos de *interface*:

1. *Interface* para modelos de previsão;

## 2. Interface para modelos de Agrupamento.

### 6.2.2.1 Interfaces para Modelos de Previsão

Para desenvolver uma *interface* que padronize modelos de previsão de séries temporais, deve-se, inicialmente, investigar qual é a estrutura de um algoritmo de previsão. O objetivo desta investigação é encontrar parâmetros que estejam presentes em todos os modelos de previsão.

Observando a estrutura de um previsor pode-se notar que, independentemente da teoria utilizada para a sua construção, todo previsor é dotado de alguns fatores comuns. Em termos práticos pode-se dizer que, para seu funcionamento, cada previsor necessariamente deve apresentar os seguintes elementos:

- **Dados Entradas:** Informações que viabilizam o aprendizado no modelo de previsão;
- **Configurações:** Parâmetros necessários para maximizar o aprendizado do previsor;
- **Fase - Ajuste:** Etapa onde o modelo utiliza os dados de entrada e as configurações definidas para extrair e aprender relações entre as informações de entrada;
- **Fase - Previsão:** Etapa que utiliza as informações aprendidas pelo previsor e retorna um valor previsto;
- **Dados Saída:** Informações resultantes na etapa de previsão ;

Formalmente, através dos parâmetros comuns a todos os previsores, foi possível projetar uma *interface* padronizada passível de utilização por qualquer tipo de modelo de previsão. Por meio dos conceitos presentes no ambiente JAVA, uma interface padrão para algoritmos de previsão pode ser definida conforme a descrição do Quadro 6.1:

Quadro 6.1: *Interface* Padronizada - Algoritmo de Previsão.

```
//Importando as classes utilizadas na Interface;
import br.com.sistema.data.Data
import java.swing.JPanel;
public interface Previsor{
    //Metodos para execução do Previsor;
    public void executaAjuste();
    public Data executaTeste();
    //Metodos para definir dados e parâmetros no Previsor;
    public void setDadosAjuste();
    public void setDadosTeste();
    public void setJPanelConfiguracoes();
    //Metodos para recuperar informações utilizadas pelo Previsor;
    public Data getDadosAjuste();
    public Data getDadosTeste();
    public JPanel getJPanelConfiguracoes();
}
```

Cada método pertencente a *interface* acima tem um significado bem definido dentro do modelo de previsão:

- Método **executaAjuste()**: Executa o ajuste no modelo de previsão;
- Método **executaTeste()**: Recupera o valor previsto encontrado pelo previsor;
- Método **setDadosAjuste()**: Define os dados utilizados para o ajuste do modelo;
- Método **setDadosTeste()**: Define os dados utilizados na fase de testes do modelo;
- Método **setJPanelConfiguracoes()**: Define os parâmetros de configuração específicos de cada modelo;
- Método **getDadosAjuste()**: Retorna os elementos utilizados para ajuste do modelo;

- Método **getDadosTeste()**: Retorna os dados utilizados na etapa de teste do modelo;
- Método **getJPanelConfiguracoes()**: Retorna o painel de configurações do modelo de previsão;

Um previsor implementado para o sistema de previsão desenvolvido neste trabalho deve ser uma extensão do modelo de interface previamente definido, isto é, cada modelo de previsão deve prover um tipo de implementação particular para cada um dos métodos definidos na interface<sup>1</sup>. Esta padronização faz com que todos os previsores tenham os mesmos métodos, sendo a diferença vista apenas na implementação lógica.

#### 6.2.2.2 Interfaces em Modelos de Agrupamento

Analogamente, para desenvolver uma *interface* padrão para modelos de agrupamento, deve-se analisar a estrutura dos algoritmos com o objetivo de encontrar elementos que sejam comuns nas técnicas de agrupamento. De maneira similar ao caso dos previsores, pode-se notar que todo algoritmo de agrupamento é dotado das seguintes características:

- **Dados Entradas**: Insumo básico para o funcionamento no modelo de agrupamento;
- **Configurações**: Parâmetros ajustáveis que influenciam o aprendizado do modelo;
- **Fase - Ajuste**: Etapa que usa os dados de entrada e as configurações definidas para extrair relações existentes entre os dados de entrada;
- **Dados Saída**: Informa os resultados do modelo de agrupamento;

Utilizando os conceitos do ambiente JAVA, foi possível projetar uma interface padrão para algoritmos de agrupamento conforme a descrição do Quadro 6.2:

---

<sup>1</sup>Cada implementação é baseada na teoria no qual o previsor foi desenvolvido.

Quadro 6.2: Interface Padronizada - Algoritmo de Agrupamento.

```
//Importando as classes utilizadas na Interface;
import br.com.sistema.data.Data
import java.swing.JPanel;
public interface Agrupamento{
    //Metodos para execuao do algoritmo;
    public void executaAjuste();
    public Data getResultados();
    //Metodos para definir dados e parâmetros;
    public void setDadosAjuste();
    public void setJPanelConfiguracoes();
    //Metodos para recuperar informaoes no modelo;
    public Data getDadosAjuste();
    public JPanel getJPanelConfiguracoes();
}
```

Cada método definido no Quadro 6.2 tem uma funcionalidade específica dentro do modelo de agrupamento:

- Método **executaAjuste()**: Realiza o ajuste no modelo de agrupamento;
- Método **getResultados()**: Retorna o resultado principal contendo os grupos definidos pelo algoritmo de agrupamento;
- Método **setDadosAjuste()**: Define os dados utilizados para o ajuste do modelo;
- Método **setJPanelConfiguracoes()**: Define os parâmetros de configuração específicos do modelo de agrupamento;
- Método **getDadosAjuste()**: Retorna os dados utilizados no ajuste do modelo de agrupamento;
- Método **getJPanelConfiguracoes()**: Retorna o painel de configurações do modelo de previsão;

Para inserir um novo modelo de agrupamento no sistema, deve-se implementar o novo algoritmo como uma extensão da interface padronizada. Assim, o novo algoritmo irá dispor das mesmas funcionalidades padronizadas pela interface bastando apenas prover a implementação específica segundo a teoria no qual o algoritmo foi desenvolvido.

### 6.2.3 Exemplos - Componentes Implementados

A implementação do conceito de interface foi desenvolvida de acordo com os passos definidos nas seções anteriores. As Figura 6.2 e 6.3 mostram exemplos de componentes implementadas utilizando esta abordagem.

Pode-se observar, na Figura 6.2, um exemplo da implementação de dois componentes de previsão que estendem a interface **Previsor**. Neste caso, especificamente, os previsores **PerceptronMLP** e o **RegressaoLinear** implementam os métodos definidos pela interface padrão.

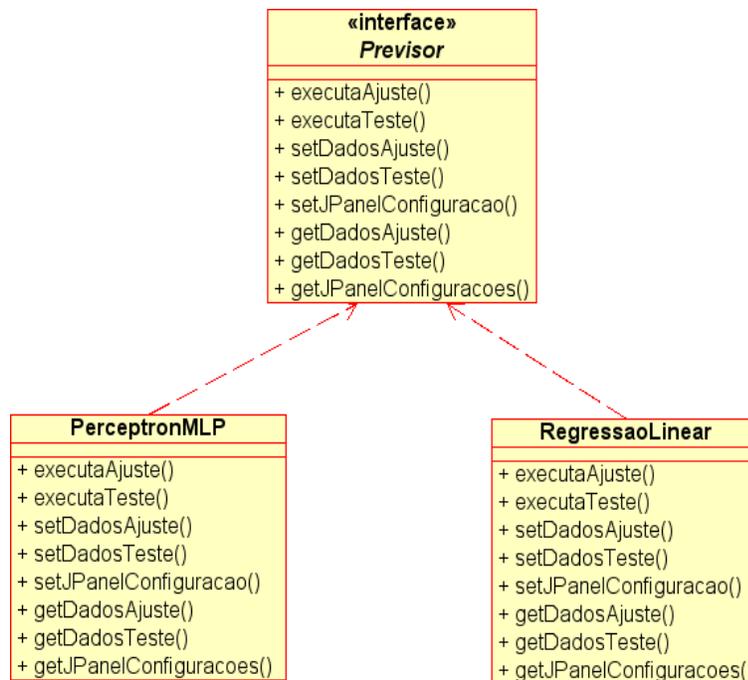


Figura 6.2: Modelo *Interfaces*: Previsor.

Todos os métodos definidos na *interface* estão presentes em ambos os

previsores. Esta obrigatoriedade de implementação dos métodos da *interface* facilita a inserção de novos componentes, pois sabe-se que todos os métodos de execução são os mesmos, independente do previsor. Como os métodos são idênticos em todos os componentes que estendem a *interface*, a mudança de uma abordagem a outra é imediata devido ao conceito de polimorfismo e herança da linguagem JAVA.

Cada um dos métodos herdados da *interface* deve ser implementado de maneira específica através do tipo de técnica utilizada pelo previsor. No caso do componente **PerceptronMLP** o método **executaTreinamento()** é executado através de uma instância do algoritmo *backpropagation* (Rumelhart et al., 1986); em contra partida, o mesmo método na componente **RegressaoLinear** (Box et al., 1994) executa o treinamento através do cálculo de médias aritméticas com diversos atrasos. Desta forma, os demais métodos são implementados segundo a funcionalidade indicada pelo tipo de técnica do previsor.

A Figura 6.3 mostra a *interface* **Agrupamento** e suas extensões: os componentes **KMeans** (MacQueen, 1967) e **SOM** (Kohonen, 1982). Segundo a mesma analogia descrita anteriormente, os componentes que estendem a *interface* **Agrupamento** devem prover implementação para os métodos segundo a teoria utilizada em cada um dos componentes. Esta padronização nos métodos fornecida pela *interface*, quando aplicada aos componentes, facilita o desenvolvimento do aplicativo que passa a ser desenvolvido com base na *interface* (visão geral) e não nos componentes (visão específica).

#### 6.2.4 Exemplo - Acesso a Métodos com Polimorfismo

Conforme descrição anteriormente apresentada, os componentes construídos com base na *interface* genérica devem implementar todos os métodos existentes no molde pré-definido. Analisando os Quadros 6.1 e 6.2, é possível perceber que as *interfaces* criadas para algoritmos de previsão e agrupamentos possuem o método **getJPanelConfiguracoes()**. O objetivo deste método é retornar um painel gráfico contendo opções de configuração para os modelos de previsão e agrupamento e, como cada modelo possui configurações específicas,

é natural que as opções de controle sejam distintas em cada modelo analisado havendo a necessidade de janelas específicas para cada um.

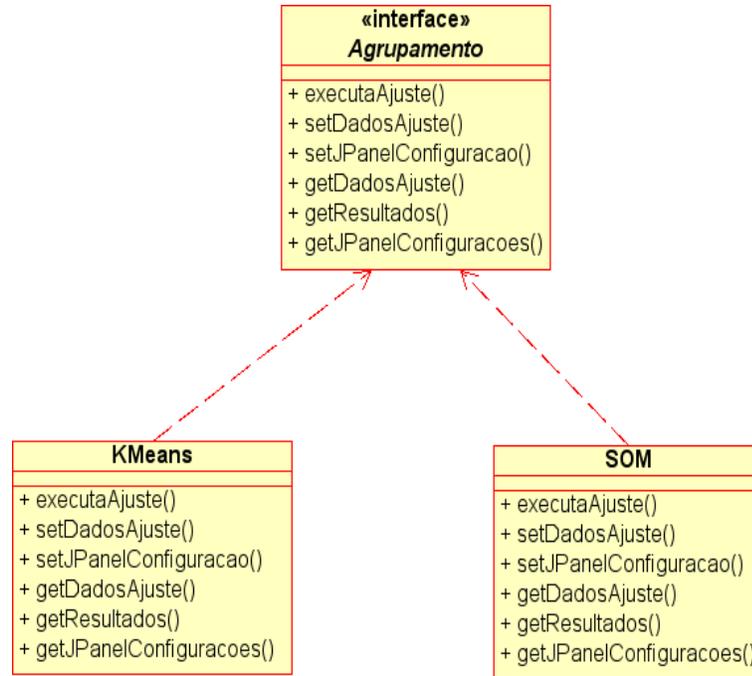


Figura 6.3: Modelo *Interfaces*: Agrupamento.

A Figura 6.4 mostra o resultado da execução **getJPanelConfiguracoes()** para os componentes **PerceptronMLP** e **RegressaoLinear** respectivamente. Observando os painéis apresentados por cada componente, é possível verificar grandes diferenças nas funcionalidades apresentadas por cada janela. Estas diferenças estão diretamente relacionadas ao processo teórico usado na criação de cada elemento. Nota-se que a utilização do polimorfismo, por meio da implementação realizada via *interface*, foi capaz de proporcionar o acesso a conteúdos distintos, cada um relativo ao seu componente, por meio do mesmo método.

Uma análise similar ao caso anterior pode ser executada na Figura 6.5, onde é mostrado o resultado da chamada ao método **getJPanelConfiguracoes()** nos componentes **SOM** e **Kmeans** da *interface* de agrupamento respectivamente. Novamente, é possível notar que, as janelas gráficas mostram as opções particulares de configuração de cada algoritmo quando invocados pelo mesmo método, através do polimorfismo, criando uma padronização no acesso aos métodos de

cada componente que implementa a *interface* agrupamento.

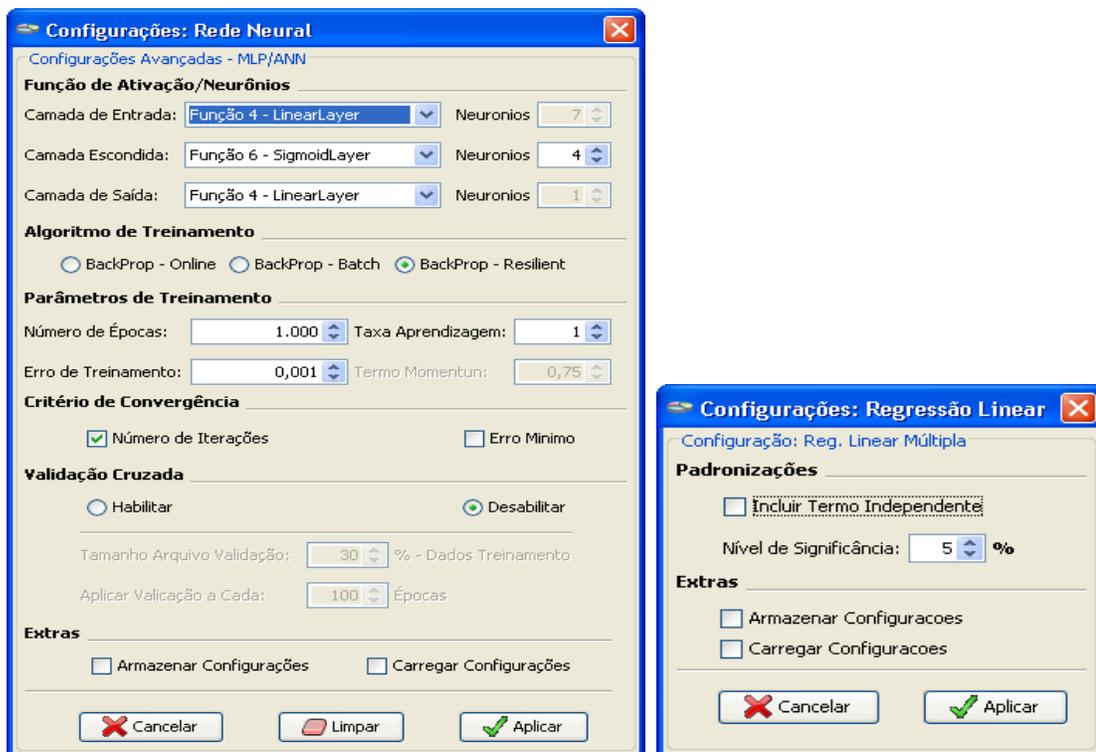


Figura 6.4: Método `getJPanelConfiguracoes()` - Previsão.

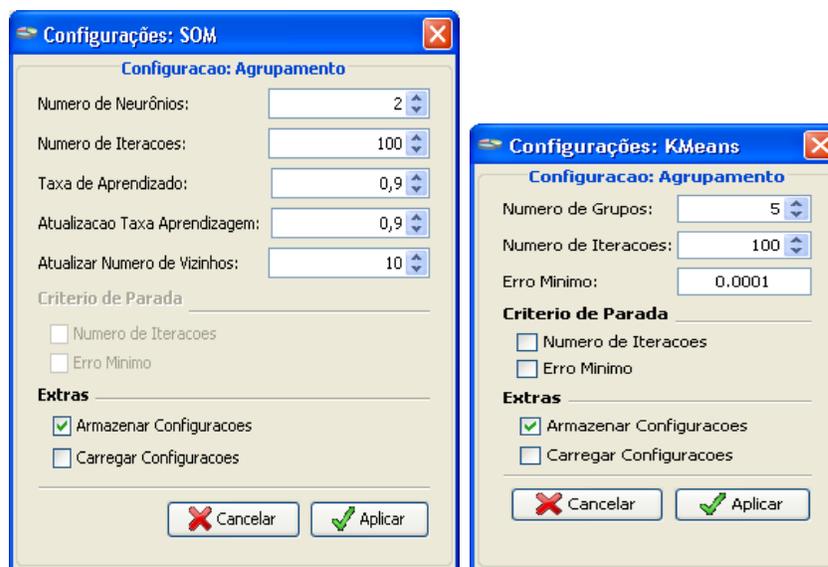


Figura 6.5: Método `getJPanelConfiguracoes()` - Agrupamento.

O exemplo visto anteriormente, apresentado via janela gráfica, é um

caso prático do uso da técnica de polimorfismo presente nos *plugins* desenvolvidos neste trabalho. De forma geral, cada método descrito nos Quadros 6.1 e 6.2 utiliza este princípio para acessar funcionalidades específicas nos modelos implementado via o molde fornecido pelas *interfaces*. Devido a esta padronização, mostrada na prática, o processo de atualização, remoção ou inserção de um novo componente não afeta o sistema principal (que não precisa ser reprogramado) mantendo a uniformidade e a padronização nas ferramentas desenvolvidas, tornando o processo de atualização fácil e simples.

### 6.3 Inserção, Atualização e Remoção de Componentes

A abordagem proposta para inserir os componentes no *SysPrev* é baseada na premissa: “*Atualizar sem Compilar*”. Assim, não existe a necessidade de uma recompilação do sistema para que novas ferramentas sejam adicionadas, removidas ou atualizadas. Para que esta premissa seja atendida, alguns passos principais devem ser levados em consideração.

Primeiramente, deve-se criar e implementar o componente com base em sua *interface* padrão. Após a sua implementação, o próximo passo é a construção de uma estrutura para guardar os arquivos executáveis. Neste sentido, os arquivos que fornecem a implementação do componente são encapsulados e empacotados em uma estrutura da linguagem Java conhecida como *Java ARchive* com extensão *\*.JAR*. A sigla JAR significa *Java ARchive*, e é o formato criado pela *Sun Microsystems* para distribuir aplicações e bibliotecas na plataforma Java. Estes arquivos têm vantagens na compactação e segurança de aplicações.

O componente construído precisa ser representado por meio de um único arquivo JAR. Este arquivo contém informações diversas sobre a técnica utilizada para desenvolvimento (*perceptron/MLP, modelos autotegressivos, redes de kohonen, entre outros*), a categoria a qual o componente pertence (*modelos de Previsão ou Agrupamento*), bem como informações sobre a forma de acessar e executar o componente.

No *SysPrev*, os componentes encapsulados devem ser inseridos no diretório *SystemFerramentas*. A Figura 6.6 apresenta uma lista com alguns componentes que estão disponíveis no diretório *SystemFerramentas*. Para verificar a existência de novos componentes, é realizada uma leitura no diretório *SystemFerramentas* a cada inicialização do sistema. Com esta leitura, verificam-se dependências e valida-se o componente, disponibilizando ao usuário apenas as ferramentas operacionais no momento da inicialização do sistema.

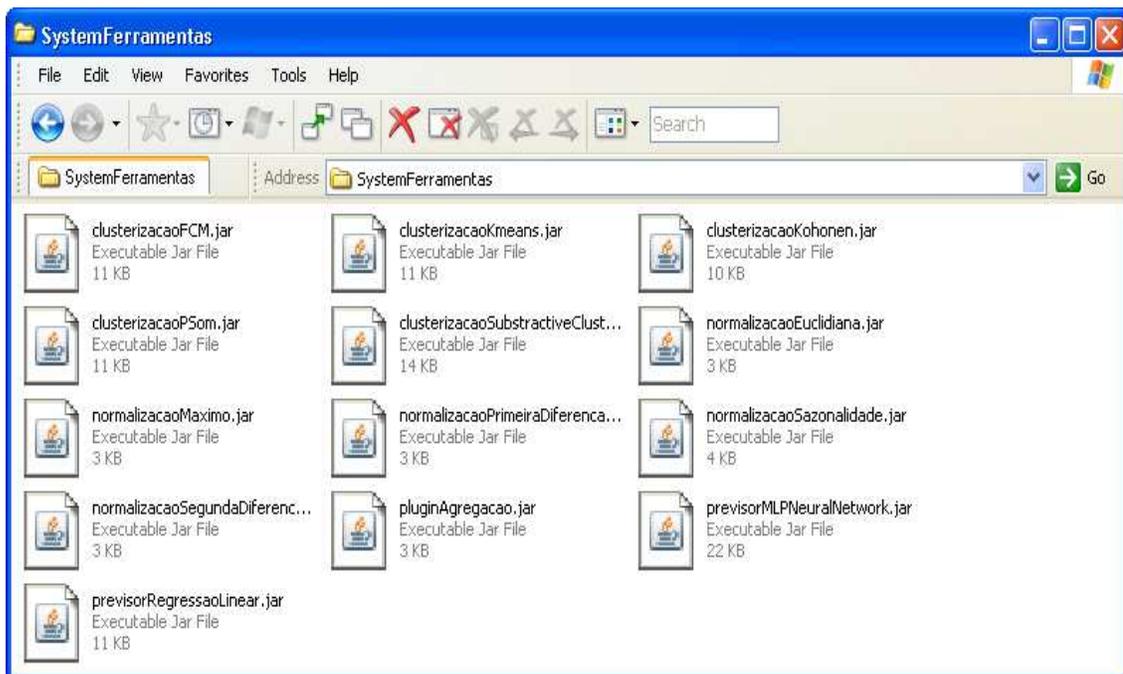


Figura 6.6: Diretório de Ferramentas.

### 6.3.1 Gerenciador de Componentes

Outro fator interessante no *SysPrev* foi o desenvolvimento de um gerenciador de componentes que minimiza o uso de recursos computacionais. No processo de validação de um componente, cria-se uma estrutura contendo nome e endereço (em nível de objeto e memória) para cada componente. Esta estrutura possibilita a instanciação do componente somente quando este for utilizado e uma vez instanciado o componente estará pronto para o uso em diversos estudos, evitando a criação de vários “clones” do mesmo componente que aumen-

tam o uso de memória e processamento, desnecessariamente. Segundo (Gama et al., 1995), o uso deste gerenciador possibilita a minimização do uso de processamento e memória no sistema.

## Estudo de Casos

Este capítulo faz a apresentação dos estudos de casos e simulações realizadas com o intuito de verificar a eficiência do modelo de previsão de carga proposto neste trabalho. As previsões obtidas pela metodologia agregada foram comparadas com os resultados das previsões individuais feitas para cada série de carga nos barramentos pertencentes ao sistema analisado. O custo computacional para obtenção das previsões foi estimado, sendo também um parâmetro importante para avaliar a eficiência da metodologia desenvolvida nesta tese de doutorado.

O Capítulo 5 realizou uma descrição funcional do *SysPrev*, apresentando suas funcionalidades e facilidades no processo de previsão de carga por barramento. De posse das ferramentas disponíveis no sistema, foi possível realizar uma análise de sensibilidade nos parâmetros da metodologia agregada, levando em consideração mudanças nas informações dos algoritmos de agrupamento, utilização de procedimentos de redução de dimensionalidade, teste de previsão em períodos distintos com o objetivo de verificar quais são os parâmetros que têm maior impacto nos resultados de previsão de carga por barramento.

Desta forma, neste capítulo, além dos resultados de previsão de carga por barramento, será apresentada uma análise de variação de parâmetros, buscando verificar a robustez da metodologia em diversos cenários que podem ocorrer no cotidiano de previsão de carga.

## 7.1 Descrição

As simulações apresentadas neste trabalho foram executadas no Sistema de Suporte para Análise Previsão de Carga por Barramento - *SysPrev*, desenvolvido exatamente para proporcionar um ambiente com facilidades na manipulação de dados e obtenção de resultados. Inicialmente, o *SysPrev* foi utilizado para avaliar o desempenho da metodologia de previsão agregada. Desta forma, ao longo do texto que trata dos resultados, serão comentados alguns parâmetros utilizados na configuração dos dados e modelos visando obtenção dos resultados através do *SysPrev*.

A metodologia de previsão de carga agregada desenvolvida neste trabalho foi testada utilizando medições de carga pertencentes a um subsistema elétrico de distribuição/transmissão. A utilização de medições reais faz com que a metodologia seja testada em condições similares àquelas encontradas no campo de aplicação do sistema, sendo um parâmetro interessante para validar e avaliar a abordagem.

O conjunto de dados utilizado é formado por 73 barramentos, localizados na região nordeste do Brasil. Neste conjunto, as medições de carga, em base horária, foram coletadas no período de 06 de junho a 03 de outubro de 2001, totalizando 125 dias com 3000 horas de medição em cada um dos barramentos. No sistema em análise, os barramentos possuem tensões variando entre 38 a 230KV. Infelizmente, as informações de localização geográfica dos barramentos não foram disponibilizadas, o que inviabilizou o acesso às variáveis climáticas nas regiões onde estão situados os barramentos.

Devido a esta indisponibilidade de informações, os estudos de previsão apresentados neste trabalho utilizarão exclusivamente as medições de carga horária, sendo esta a principal fonte de informações para as simulações realizadas ao longo do trabalho. As simulações apresentadas no decorrer do texto contemplam diversos cenários de previsão, sendo a principal diferença encontrada no processo de escolha de entradas, nos agrupamento e no período escolhido para previsão.

Para medir o desempenho da metodologia, foram feitas simulações de previsão individual em cada barramento. Estes resultados foram tomados como base para avaliar o desempenho da metodologia agregada. Como discutido no Capítulo 3, a metodologia de previsão agregada pode ser aplicada utilizando diversos modelos de previsão existentes na literatura. Por simplicidade, e também pela disponibilidade das ferramentas no *SysPrev*, neste trabalho optou-se por utilizar um modelo não-linear baseado em redes neurais artificiais e outro linear que realiza a previsão usando um processo de regressão múltipla. Para facilitar a identificação das técnicas de previsão, as seguintes siglas foram definidas e serão citadas ao longo do capítulo para fazer referência aos processos de previsão.

- **1-Ind\_RLM:** Metodologia individual com Regressão Linear Múltipla;
- **2-Ind\_RNA:** Metodologia Individual com Redes Neurais Artificiais MLP;
- **3-Agg\_RLM:** Metodologia agregada com Regressão Linear Múltipla;
- **4-Agg\_RNA:** Metodologia agregada com Redes Neurais Artificiais MLP.

Os estudos apresentados no trabalho foram repetidos exaustivamente considerando condições iniciais similares<sup>1</sup> visando garantir a consistência nos resultados. Para avaliar a eficiência da previsão, foram utilizadas duas medidas largamente utilizadas em estatística: o *Erro Percentual Absoluto Médio* - ( $MAPE(\%)$ ) e o *Erro* - ( $E(MW)$ ) entre as cargas observadas  $x_j$  e estimadas na previsão  $\hat{x}_j$ .

O *MAPE* é um termo estatístico usado para medir e avaliar os modelos de previsão através de um valor percentual. Por sua vez, o *E* apresenta os erros mantendo a unidade de medida adotada na série, no caso particular deste trabalho (*MW*). Os dois parâmetros de avaliação são úteis para definir a eficiência da metodologia agregada neste trabalho. Matematicamente, o *MAPE* e o *E* são definidos pelas equações 7.1 e 7.2 respectivamente.

---

<sup>1</sup>Entende-se como condições iniciais similares situações onde os parâmetros permanecem fixos e apenas as componentes aleatórias do modelo variam de uma instância para outra. Em modelos onde não há presença de componentes aleatórias (por exemplo: regressão linear) os resultados são mantidos na execução de diversas instâncias com condições iniciais similares.

$$MAPE(\%) = \frac{100}{24} \sum_{j=1}^{24} \frac{|x_j - \hat{x}_j|}{x_j} \quad (7.1)$$

$$E(MW) = x_j - \hat{x}_j \quad (7.2)$$

O pacote gráfico implementado no *SysPrev* foi essencial nas comparações, possibilitando a visualização de vários gráficos de resultados com facilidades de comparações e extração de informações.

### 7.1.1 Informações Relevantes no Processo de Previsão

Nas simulações executadas, o conjunto de medições de carga foi subdividido para proporcionar a criação de subconjuntos que possibilitassem o ajuste e o teste da metodologia. Neste sentido, o subconjunto utilizado para ajuste (treinamento) foi formado pelas cargas elétricas medidas no período de **01 de Junho a 19 de Setembro de 2001** e o conjunto de teste foi formado pelas cargas medidas entre os dias **20 a 26 de Setembro de 2001**<sup>2</sup>.

O processo de previsão executado neste trabalho realiza a previsão da carga elétrica de maneira horária, isto é, considera-se a previsão de 24 séries temporais para cada hora do dia visando encontrar a curva de carga diária. Nesta visão, o processo de treinamento/teste precisa ser realizado para cada intervalo. Em outras palavras, as estruturas que representam os conjuntos de teste/treino devem ser atualizadas em cada intervalo do dia. Este procedimento foi adotado para as metodologias individual e agregada.

#### 7.1.1.1 Agrupamentos

Para realizar a previsão de carga por barramento via método agregado, é necessário definir grupos de barramentos onde a metodologia será aplicada. No Capítulo 2, é mostrado um exemplo que analisa o conjunto de 73 barramentos para detectar quais possuem perfis de carga diária similares. Este exemplo

---

<sup>2</sup>Qualquer alteração no período de ajustes e testes será informada no decorrer do texto.

utilizou o algoritmo *subtractive clustering-SC* (Chiu, 1994) para agrupar os barramentos e, em termos de resultados, foram encontrados 34 grupos, sendo 14 formados por mais de um barramento. Os demais grupos representavam barramentos isolados com características particulares. Neste sentido, a metodologia agregada, proposta neste trabalho, realizou a previsão de todos os grupos com mais de um barramento, conforme a Tabela 2.2.

### 7.1.1.2 Rede Neural Artificial

Utilizando as telas de configuração de modelos de previsão, disponibilizadas para cada ferramenta do *SysPrev*, foi possível realizar diversas configurações e obter vários cenários de previsão. Desta forma, para fins de conhecimento, o tipo de rede neural adotada neste trabalho (abordagens individual e agregada) é a conhecida rede perceptron multicamadas treinada com método *backpropagation* (Rumelhart et al., 1986). O número e neurônios na camada escondida e o termo momento foram estimados por uma busca exaustiva no domínio [1,15] e [0,0.99] respectivamente, sendo que os limites de busca para o caso dos neurônios foram encontrados usando a métrica de Baum-Haussler (Baum e Haussler, 1989).

A taxa inicial para aprendizado dos pesos foi de 0.001 e, em cada iteração, foi utilizada uma busca unidimensional para encontrar seu próximo valor (Groot e Würtz, 1994) e (Bromberg e Chang, 1992). O número de neurônios nas camadas de entrada/saída dependem da dimensão das matrizes de entrada  $\times$  saída, que variam para cada série prevista.

## 7.2 Resultados Numéricos - Caso Geral

Neste primeiro conjunto de simulações, o objetivo das previsões foi comparar o desempenho da metodologia agregada com a metodologia individual. As informações que formam os padrões (*entrada  $\times$  saída*), para ajuste das metodologias, foram determinadas via função de autocorrelação parcial (PAF) (Mori e Kurata, 2007). A Figura 7.1 mostra cargas às 16h ao longo de um período de

tempo para o barramento #40. Nesta figura, é possível observar um exemplo de determinação das entradas, via PAF, no qual as flechas (na cor vermelha) acima da curva determinam as entradas, que estão relacionadas a uma saída desejada apontadas pelas flechas (na cor azul) abaixo da curva.

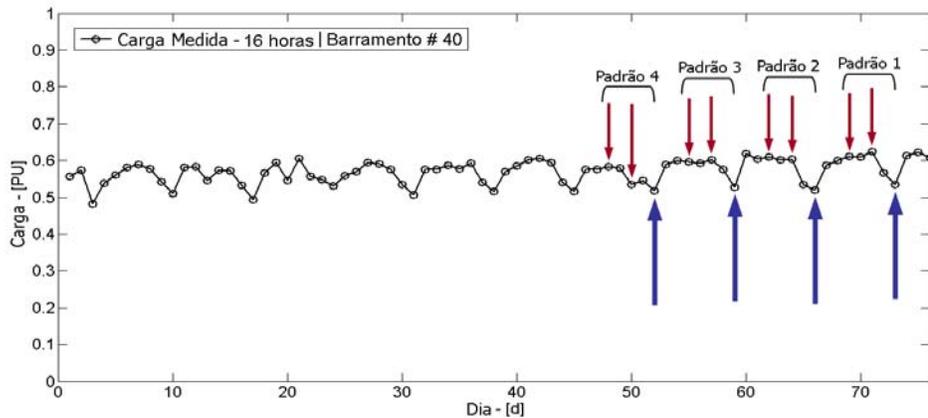


Figura 7.1: Conjunto Entradas (PAF) - Barramento #40 | Hora 16.

Para cada intervalo, o conjunto de padrões (*entrada*  $\times$  *saída*) foram formados utilizando o PAF, conforme o exemplo definido anteriormente. Na simulação apresentada ao longo desta seção, a metodologia de previsão de carga desenvolvida neste trabalho foi analisada em duas etapas. Na primeira etapa é feita a análise da previsão das 24h de um dia específico, onde são mostradas as curvas horárias verificada e prevista bem como os erros *MAPE* e o *E* para cada hora do dia analisado. A segunda etapa faz o estudo da metodologia na previsão de 7 dias consecutivos, sendo o objetivo verificar o desempenho da metodologia, em termos de nível de erro, na previsão de tipos de dias distintos.

### 7.2.1 Previsão: Dia Específico.

A metodologia agregada inicialmente foi configurada para realizar a previsão das 24 horas de um único dia. Para testar e comparar os modelos, o dia escolhido foi a terça-feira, 25 de Setembro de 2001. Este dia foi escolhido por se tratar de um dia útil típico. Na realização da previsão deste dia, estabeleceu-se que as medições de carga eram conhecidas até a 23h do dia anterior.

Na Tabela 7.1, os resultados de previsão são apresentados para cada um dos grupos descritos na Tabela 2.2. Observando estes resultados, é possível notar que as metodologias *Ind\_RNA* e *Agg\_RNA* apresentam os melhores resultados se comparadas as metodologias *Ind\_RLM* e *Agg\_RLM* sendo que este fato pode ser atribuído ao comportamento não-linear presente nos dados de carga em cada barramento e principalmente ao caráter de aprendizado não-linear presente nos modelos baseados em redes neurais artificiais.

Comparando-se as metodologias *Ind\_RNA* e *Agg\_RNA* é possível ver, observando a Tabela 7.1, que a metodologia *Agg\_RNA* obteve melhores resultados na maioria dos 14 grupos. Se observarmos o erro em cada grupo, pode-se verificar que variação de nível de erro é baixa quando comparam-se os modelos *Ind\_RNA* e *Agg\_RNA*. Por exemplo, no grupo #1 o erro do modelo *Ind\_RNA* foi de 3.67% enquanto o erro do modelo *Agg\_RNA* foi de 3.75%. Esta pequena diferença nos resultados se mantêm para a maioria dos grupos, a exceção acontece no grupo #4 onde o valor do erro da metodologia *Ind\_RNA* é alto se comparado à metodologia *Agg\_RNA*.

Tabela 7.1: Comparativo MAPE: Individual  $\times$  Agregado.

<b>B. Grupos</b>	<b><i>Ind_RLM</i></b>	<b><i>Ind_RNA</i></b>	<b><i>Agg_RLM</i></b>	<b><i>Agg_RNA</i></b>	<b><i>Carga Média - (MW)</i></b>
1	7.65	3.67	7.65	3.83	3.75
2	7.57	3.30	7.57	3.50	218.76
3	5.57	3.67	5.57	3.77	170.37
4	9.11	17.13	9.11	7.32	31.80
5	3.04	1.87	3.04	1.90	82.89
6	5.00	2.94	5.00	2.83	221.93
7	6.05	3.96	6.05	3.70	68.46
8	3.02	2.59	3.02	2.48	54.29
9	6.48	1.97	6.48	1.89	431.87
10	3.10	2.36	3.10	2.34	278.82
11	7.90	3.42	7.90	3.91	399.39
12	3.60	3.59	3.60	3.68	145.66
13	14.46	4.59	14.46	4.20	877.80
14	7.18	3.26	7.18	2.96	4983.44
<b>Erro Médio</b>	<b>6.41</b>	<b>4.17</b>	<b>6.41</b>	<b>3.45</b>	-

Na última coluna da Tabela 7.1, pode ser observado que os grupos que têm maior nível de carga média no dia analisado são os grupos #14 e #13. Desta forma, em termos de potência, pode-se dizer que estes grupos contém os

barramentos com maior nível de carga. Logo, é interessante verificar o comportamento da previsão nos barramentos destes grupos para analisar como são os resultados de previsão, via metodologia agregada, nos barramentos que possuem carregamento pesado no sistema.

A Tabela 7.2 apresenta o erro percentual absoluto médio (MAPE), ao longo do dia 25/09/2001, para os barramentos do grupo #14. Observando os resultados, é possível verificar que, neste estudo, o desempenho da metodologia agregada, na média, foi superior em relação aos demais modelos implementados. Verifica-se também que a metodologia agregada obteve melhores níveis de erro em 8 dos 11 barramentos pertencentes a este grupo. Desta forma, pode-se concluir que para este estudo de previsão a metodologia agregada se mostrou competitiva, provendo resultados de boa qualidade na maioria dos casos melhores que as demais abordagens.

Tabela 7.2: MAPE: Grupo #14.

<b>Barramento</b>	<b>Ind_RLM</b>	<b>Ind_RNA</b>	<b>Agg_RLM</b>	<b>Agg_RNA</b>
7	7.21	4.07	7.21	3.98
9	4.09	2.01	4.09	1.74
14	6.15	7.87	6.15	5.59
18	11.94	7.98	11.94	7.39
59	3.67	1.12	3.67	1.17
61	21.69	5.04	21.69	5.35
62	2.83	1.93	2.83	1.41
63	2.84	1.10	2.84	0.89
64	3.26	2.34	3.26	2.86
67	6.99	1.04	6.99	0.96
70	8.33	1.33	8.33	1.17
<b>Erro Médio</b>	<b>7.18</b>	<b>3.26</b>	<b>7.18</b>	<b>2.96</b>

Na Tabela 7.3, podem ser vistos os resultados levando em consideração o grupo #13. Observando os valores numéricos, é possível verificar que também neste caso, o desempenho da metodologia agregada foi superior em relação às demais metodologias. Nota-se também que a previsão agregada obteve melhores níveis de erro em 5 dos 7 barramentos pertencentes a este grupo. De forma análoga, pode-se concluir que, nesta simulação, a metodologia agregada novamente mostrou-se competitiva com bons resultados em relação às demais abordagens.

Tabela 7.3: MAPE: Grupo #13.

<b>Barramento</b>	<b>Ind_RLM</b>	<b>Ind_RNA</b>	<b>Agg_RLM</b>	<b>Agg_RNA</b>
3	3.69	2.64	3.69	2.85
21	53.04	5.10	53.04	4.03
31	10.57	7.83	10.57	7.10
35	8.27	1.81	8.27	1.80
43	9.23	8.02	9.23	8.15
68	8.32	3.49	8.32	2.63
69	8.15	3.23	8.15	2.81
<b>Erro Médio</b>	<b>14.46</b>	<b>4.59</b>	<b>14.46</b>	<b>4.20</b>

As Figuras 7.2 e 7.3 mostram o *MAPE* para cada um dos barramentos nos grupos #9 e #11 apresentados na Tabela 2.2. De maneira pragmática, é possível ver que a metodologia *Agg\_RNA* apresentou melhores resultados em 5 dos 8 barramentos que integram os grupos #9 e #11. Vale ressaltar que os resultados da metodologia *Agg\_RNA*, mesmo com maior nível de erro, não apresentaram grandes diferenças em relação ao modelo *Ind\_RNA*, mostrando que, na maioria dos casos mostrados, estas metodologias têm desempenho compatível se o critério analisado for o nível de erro.

Um fato interessante pode ser verificado no barramento #4 pertencente ao grupo #11. Nota-se que, neste barramento, a metodologia de previsão que utilizou modelo baseado em regressão linear apresentou melhores resultados se comparado às abordagens baseadas em modelos não-lineares (redes neurais). Este fato é explicado pelo perfil de consumo deste barramento que representa consumidores industriais com carga *flat* e constante ao longo do dia, o que justifica o bom resultado apresentado pelos modelos lineares.

Quando se tem uma abordagem de previsão, é importante verificar seu desempenho em barramentos que são fundamentais para o desempenho do sistema elétrico. Em termos de nível de carga, um dos barramentos mais importantes do subsistema em análise é o barramento #59, que possui uma carga horária média de aproximadamente 1510.3MW. A Figura 7.4 apresenta as curvas de carga verificada e prevista para o barramento #59 no dia 25 de setembro de 2009.

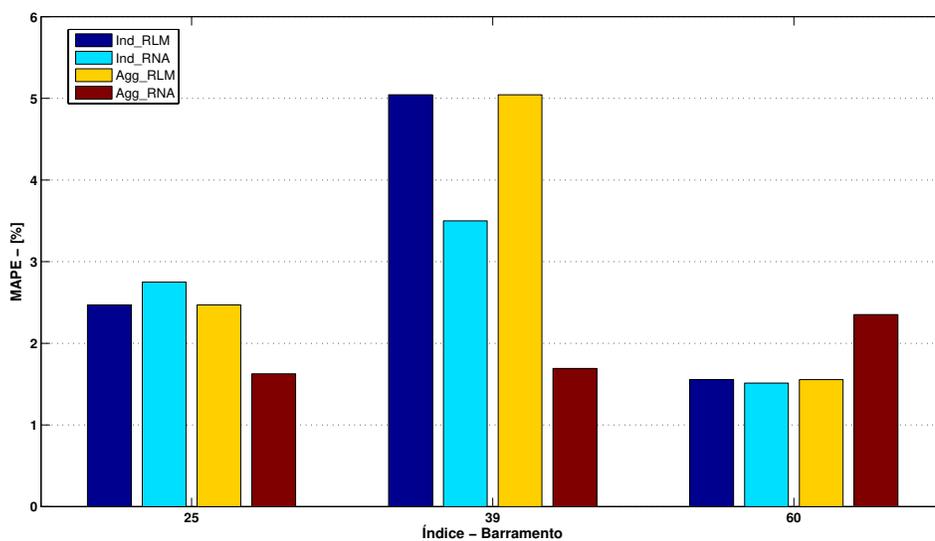


Figura 7.2: MAPE - Grupo #9.

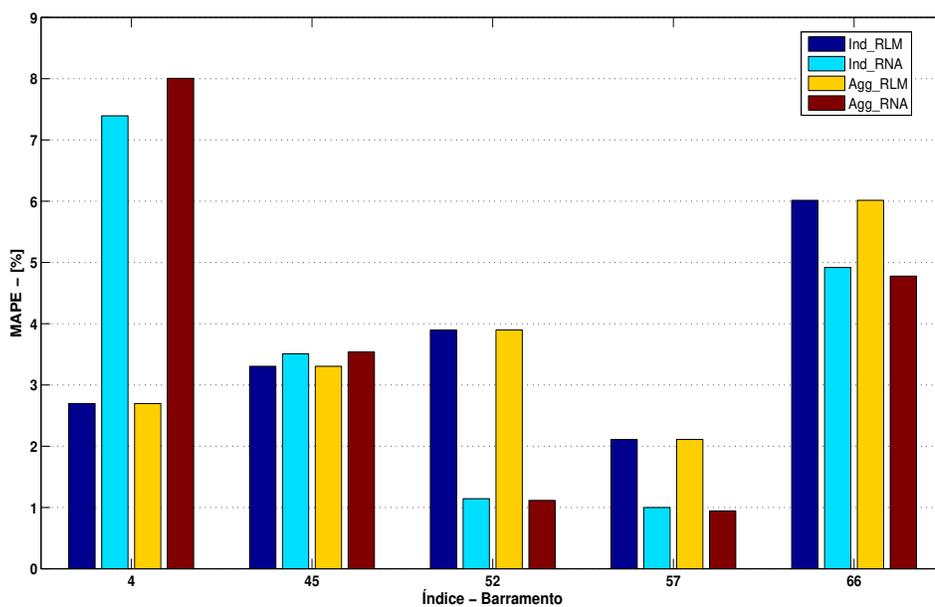


Figura 7.3: MAPE - Grupo #11.

Observando a evolução das cargas na Figura 7.4, é possível verificar que as metodologias *Ind\_RNA* e *Agg\_RNA* apresentaram comportamento com alto grau de precisão e similaridade. As metodologias individual e agregada executadas com regressão linear múltipla não apresentaram um bom desempenho e este fato pode estar associado ao comportamento não-linear presente na série de carga horária.

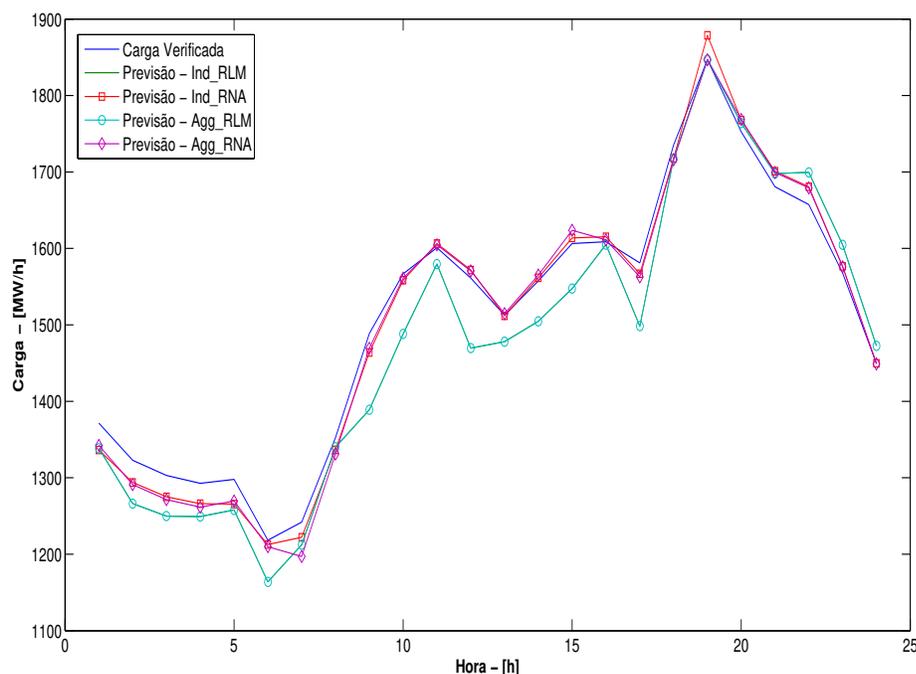


Figura 7.4: Curva: Prevista  $\times$  Verificada - Barramento #59 | 25/09/2001.

Na Figura 7.5, pode-se observar o erro percentual absoluto para cada hora do dia 25/09/2001 no barramento #59. Pelo comportamento do erro, verifica-se que as metodologias *Ind\_RNA* e *Agg\_RNA* têm comportamento similar com, na maioria das horas, mesma intensidade no nível dos erros. Em termos de erro percentual médio diário, pode-se afirmar que as metodologias *Ind\_RNA* e *Agg\_RNA* apresentam desempenho compatível com erro médio semanal de 1.12% no caso do *Ind\_RNA* e 1.17% no caso do *Agg\_RNA*, evidenciando novamente a compatibilidade dos modelos.

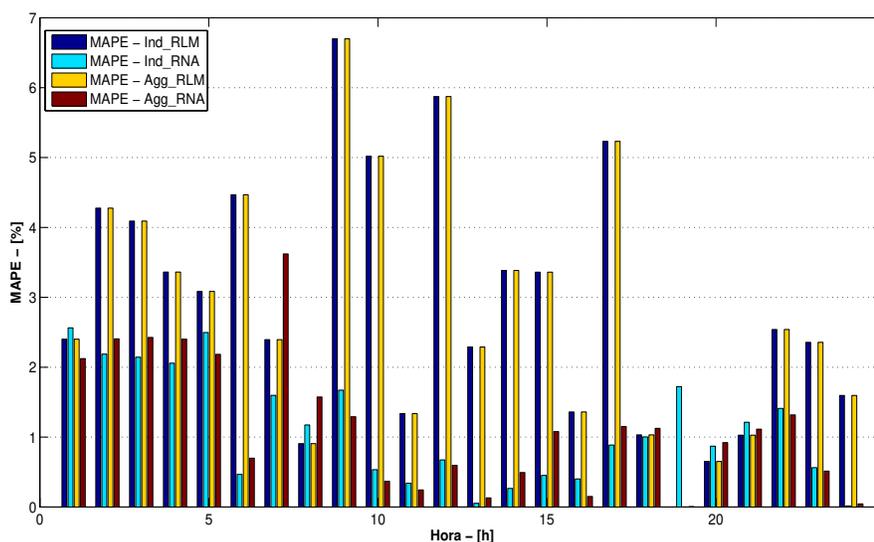


Figura 7.5: MAPE - Barramento #59 | 25/09/2001.

A Figura 7.6 trata especificamente as metodologias *Ind\_RNA* e *Agg\_RNA*. O nível de erro, neste caso, tem uma padronização na intensidade e direção no erro seguido pelas metodologias. Em algumas horas, por exemplo 7 e 19, os modelos divergem bruscamente nas suas previsões. Entretanto, na maioria dos casos, os resultados dos modelos são extremamente similares e, conforme comentário descrito no parágrafo anterior, na média o nível de erro dos modelos são praticamente idênticos.

Na Figura 7.7, são mostradas as curvas de previsão para cada metodologia tomando como base o barramento #47, que possui um perfil diferenciado com baixo nível de carga no horário de ponta. Observando os valores previstos, nota-se que a curva estimada pela metodologia individual *Ind\_RNA* não foi capaz de representar alguns intervalos de previsão de maneira adequada, gerando um alto erro em relação à carga verificada. Neste caso, o erro de previsão no horário de ponta é atribuído a instabilidade numérica gerada pelo baixo valor de saída que utilizado por este barramento no período de ponta (19, 20 e 21h)<sup>3</sup>. Um fato interessante é que a metodologia agregada não apresentou este tipo de comporta-

<sup>3</sup>Geralmente, a estratégia de baixar o nível de carga no horário de ponta é utilizada por indústrias, estrategicamente, para evitar altos valores nas tarifas.

mento e, nesta série em particular, apresentou maior robustez na generalização dos padrões em relação ao caso individual.

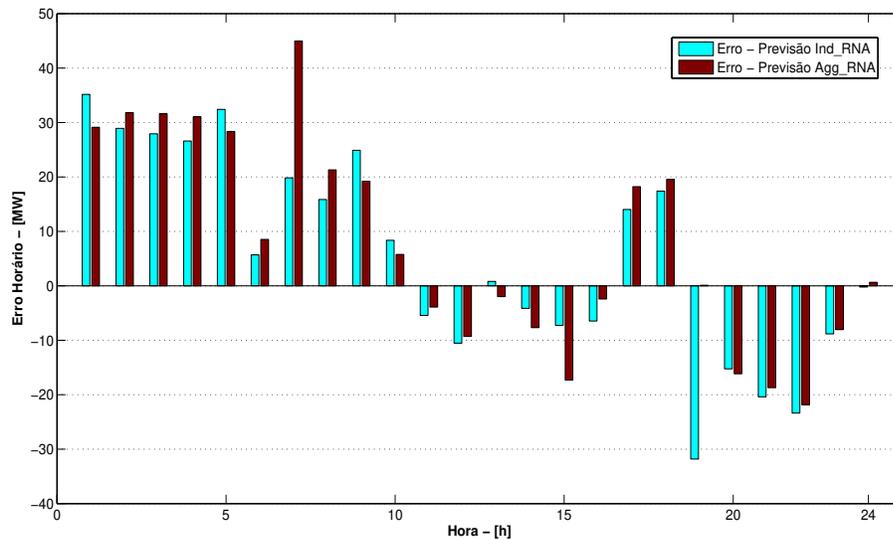


Figura 7.6: Erro de Previsão - Barramento #59 | 25/09/2001.

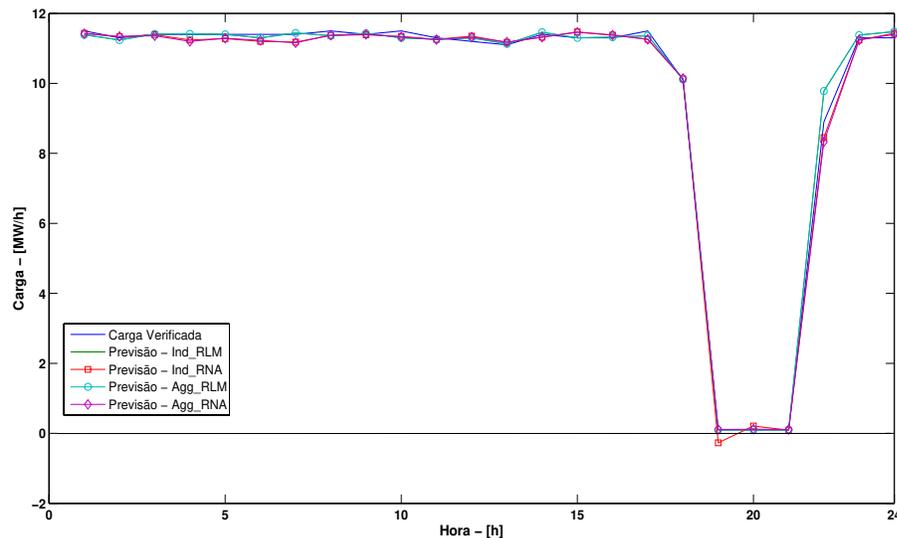


Figura 7.7: Curva: Prevista  $\times$  Verificada - Barramento #47 | 25/09/2001.

Através da Figura 7.8 e da Tabela 7.4, pode-se observar o erro horário bem como o erro percentual horário para o barramento #47. Observando

os níveis de erro nota-se que as metodologias *Ind\_RNA* e *Agg\_RNA* possuem, na maioria dos casos, mesma intensidade e sentido no erro, reforçando a compatibilidade de resultados existente entre as metodologias. Vale ressaltar que, na média, o modelo *Agg\_RNA* apresentou, no barramento #47, menor erro se comparado às demais metodologias, conforme mostrado na Tabela 7.4.

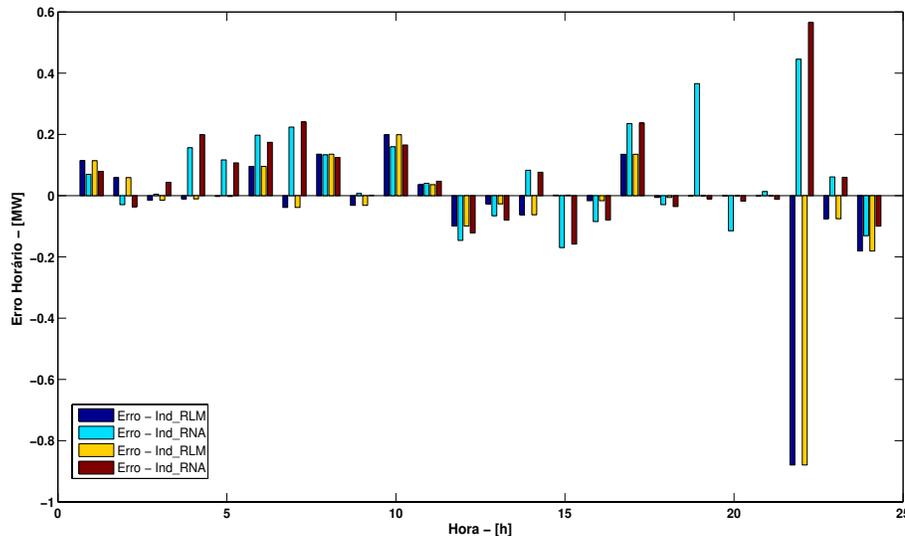


Figura 7.8: Erro Horário - Barramento #47 | 25/09/2001.

Observando a Tabela 7.4, pode-se dizer que no caso específico do barramento #47 os modelos baseados em regressão linear múltipla apresentaram resultados superiores aos baseados em redes neurais artificiais. Este fator pode ser atribuído a característica linear existente no padrão de consumo deste barramento conforme mostra a Figura 7.7. O fato do modelo baseado em regressão linear ter obtido sucesso nas previsões deste barramento reforça o fato da necessidade de utilização de várias abordagens de previsão para obter melhores resultados no problema de previsão de carga por barramento.

Em linhas gerais, pode-se dizer que os modelos *Ind\_RNA* e *Agg\_RNA* têm um comportamento com alto nível de similaridade, quando se observa a intensidade, sentido e valor médio do erro de previsão. Esta semelhança entre os resultados de ambas as metodologias reforça o uso da abordagem agregada, que pode ser aplicada em um conjunto de barramentos com resultados tão precisos,

ou até melhores, às abordagens de previsão individual.

Tabela 7.4: MAPE Horário - 25/09/2001 | Barramento #47.

<b>B. Grupos</b>	<b>Ind_RLM</b>	<b>Ind_RNA</b>	<b>Agg_RLM</b>	<b>Agg_RNA</b>
1	0.99	0.61	0.99	0.69
2	0.52	0.26	0.52	0.32
3	0.13	0.04	0.13	0.38
4	0.09	1.37	0.09	1.75
5	0.02	1.02	0.02	0.94
6	0.84	1.73	0.84	1.53
7	0.34	1.96	0.34	2.11
8	1.18	1.16	1.18	1.09
9	0.28	0.07	0.28	0.02
10	1.73	1.39	1.73	1.44
11	0.32	0.36	0.32	0.42
12	0.88	1.30	0.88	1.08
13	0.24	0.59	0.24	0.72
14	0.55	0.73	0.55	0.67
15	0.02	1.50	0.02	1.40
16	0.15	0.75	0.15	0.70
17	1.17	2.05	1.17	2.06
18	0.06	0.29	0.06	0.35
19	0.21	366.02	0.21	10.32
20	0.10	114.38	0.10	17.78
21	0.37	13.63	0.37	11.74
22	9.88	5.01	9.88	6.35
23	0.66	0.54	0.66	0.53
24	1.60	1.16	1.60	0.88
<b>Erro Médio</b>	<b>0.93</b>	<b>21.58</b>	<b>0.93</b>	<b>2.72</b>

### 7.2.1.1 Comentários - Metodologia Agregada

Como visto anteriormente, nos testes realizados, o modelo agregado apresenta resultados altamente competitivos em relação ao modelo individual. Entretanto, o nível de erro apresentado no caso agregado, apesar de ser mais vantajoso em alguns casos, na média não apresenta grandes vantagens em relação ao modelo individual. O diferencial da metodologia agregada apresentada neste trabalho é o fato desta proporcionar a obtenção dos resultados em um tempo de processamento reduzido na ordem de grandeza de 14 vezes se comparado ao caso individual, tomando como motor de previsão as redes neurais artificiais.

A Tabela 7.5 mostra o tempo de processamento computacional usado na previsão do dia 25/09/2001 para as metodologias individual e agregada. Para prover igualdade nos testes todas as metodologias de previsão foram executadas em um único equipamento com mesmo sistema de *hardware*, mesmo sistema operacional bem como bibliotecas matemáticas idênticas. O *hardware* utilizado nos experimentos possui as seguintes características: CPU: AMD Opteron 175 Dual Core 2.2GHz; 4GB Memória DDR 400, rodando sobre a plataforma Linux Kubuntu 8.04 Kernel 2.6.26.

Nos resultados obtidos, pode-se verificar que o modelo agregado *Agg\_RNA* foi mais rápido que o modelo individual *Ind\_RNA* em um fator de 15 para 1. Se forem observados os valores de tempo de processamento na Tabela 7.5, é possível verificar que a metodologia *Agg\_RLM* foi a mais rápida entre todas as abordagens. Entretanto, seus resultados de previsão não apresentaram rendimento satisfatório, não sendo recomendado em estudos onde seja necessário boa precisão no nível de carga.

Tabela 7.5: Esforço Computacional - Metodologia de Previsão.

	<b>Ind_RLM</b>	<b>Ind_RNA</b>	<b>Agg_RLM</b>	<b>Agg_RNA</b>
<b>Tempo - [min]</b>	<b>0.22</b>	<b>22.3</b>	<b>0.20</b>	<b>1.5</b>

Outra vantagem apresentada por esta metodologia é a possibilidade de se escolher qualquer técnica de previsão para aprender as relações entre os padrões e realizar a previsão. Neste trabalho, escolheu-se uma rede neural artificial multicamadas por ser um modelo clássico largamente usado para previsão de carga elétrica. Entretanto, é possível utilizar, sem qualquer impedimento, outras técnicas de previsão (lineares ou não-lineares) para generalizar as relações existentes entre os padrões de (entrada×saída).

No problema de previsão de carga foi comprovado que existem importantes variáveis, chamadas de exógenas, (temperatura, cobertura, luminosidade, entre outras) que podem melhorar a qualidade da previsão se suas informações que tiverem relações com o comportamento da carga ((Quayle e Diaz, 1980), (LeCOMTE e Warren, 1981), (Warren e LeDuc, 1981) e (Segal et al., 1992)). Na

metodologia agregada, é possível adicionar variáveis climáticas, bem como outras informações através da estrutura agregada nos dados de cada barramento. Esta facilidade é interessante pois permite verificar o impacto destas variáveis na previsão. Acredita-se que, com inserção de variáveis exógenas (principalmente temperatura), os resultados de previsão de carga por barramento podem ser melhorados, devido à influência que estas variáveis têm sobre o comportamento da carga.

### 7.2.2 Previsão: 7 dias Consecutivos

Para verificar o desempenho da metodologia em diferentes tipos de dias da semana, foram feitos testes de previsão durante sete dias no período de 20/09/2001 (quinta-feira) até 26/09/2001 (quarta-feira). Com esta abordagem, foi possível avaliar as metodologias em diversas situações.

Analisando a Tabela 7.6, é possível observar que, em geral, as metodologias individual e agregada têm uma certa estabilidade em termos de erro. Os resultados do modelo *Ind\_RNA* e *Agg\_RNA* possuem nível de erro semelhantes com vantagem numérica para o modelo agregado na maioria dos dias. Apenas os modelos *Ind\_RLM* e *Agg\_RLM* não apresentaram bons resultados, e a razão deste alto nível de erro pode estar associada ao número de entradas e/ou o número de padrões para ajustar os coeficientes do modelo de regressão linear múltipla. Outro fator decisivo pode ser a não-linearidade presente nos dados de carga por barramento dificultando a extração de informações via metodologia linear. Os resultados encontrados com esta bateria de simulações mostraram que a metodologia agregada obteve bons resultados, compatíveis com a metodologia individual, em um reduzido tempo de processamento.

De acordo com a Tabela 7.6, é possível ver que a metodologia de previsão agregada *Agg\_RNA* apresentou melhor desempenho em 6 dos 7 dias analisados. Em outras palavras, com base nos resultados numéricos alcançados pelas simulações, pode-se afirmar que a metodologia agregada alcançou excelente resultado se comparado à metodologia individual. Outro fator a ser destacado é que, quando o nível de erro da metodologia agregada é superior ao caso indivi-

dual, a distância entre os níveis de erro é baixa, fazendo com que mesmo nestas situações a abordagem agregada seja indicada devido à rapidez no processamento dos resultados.

Tabela 7.6: MAPE: Dias Consecutivos - 20 a 26/9/2001.

	Qui 20/09	Sex 21/09	Sab 22/09	Dom 23/09	Seg 24/09	Ter 25/09	Qua 26/09	<b>Erro Médio</b>
Ind_RLM	9.98	13.70	12.48	6.82	8.09	6.41	9.26	<b>9.54</b>
Ind_RNA	4.09	5.68	6.73	4.34	6.37	4.17	5.18	<b>5.22</b>
Agg_RLM	9.98	13.70	12.48	6.82	8.09	6.41	9.26	<b>9.54</b>
Agg_RNA	3.65	4.26	6.52	4.21	3.61	3.45	5.39	<b>4.44</b>

A Tabela 7.7 apresenta o tempo computacional usado para estimar as cargas dos barramentos durante os 7 dias nas metodologias individual e agregada. Conforme definido anteriormente, os testes de previsão executados nesta simulação seguem a mesma configuração de *hardware* e *software* definida anteriormente no caso da previsão de um dia específico. Em termos de tempo de processamento, pode-se verificar que o modelo agregado *Agg\_RNA* foi aproximadamente 14 vezes mais veloz que o modelo *Ind\_RNA* com resultados equivalentes ou melhores que o modelo individual.

A diferença entre o tempo de processamento existente entre as abordagens individual e agregada pode ser explicada pela forma com que a estrutura agregada foi concebida. Em termos práticos, supondo um conjunto formado por 15 barramentos, para prever a curva horária utilizando uma abordagem individual, seriam necessários 24 ajustes para cada barramentos totalizando  $24 \times 15$  (ou 360) ajustes para realizar a previsão do próximo dia. Se a metodologia agregada for utilizada, considerando o conjunto de 15 barramentos seriam necessários apenas 24 ajustes para realizar a previsão do próximo dia neste conjunto de barramentos. A variação na quantidade de ajustes para obtenção das previsões faz com que a metodologia agrega seja mais veloz se comparada a abordagem individual.

Em linhas gerais, a metodologia agregada mostrou-se eficiente, apresentando bons resultados. Desta forma, a técnica de agregação desponta como uma excelente alternativa com grande capacidade de representação e previsão de

Tabela 7.7: Comparativo: Tempo de Processamento Computacional.

	<b>Ind_RLM</b>	<b>Ind_RNA</b>	<b>Agg_RLM</b>	<b>Agg_RNA</b>
<b>Tempo - [min]</b>	<b>0.76</b>	<b>143.6</b>	<b>0.75</b>	<b>10.3</b>

séries temporais de consumo elétrico por barramento. Outro fator, que torna a abordagem agregada flexível é a possibilidade de utilizar diversos tipos de aproximadores de funções (lineares ou não-lineares) para a generalização dos padrões de entrada. Esta possibilidade de escolha de previsor, juntamente com a estrutura *plug-and-play* do *SysPrev* tornam a metodologia agregada uma excelente ferramenta para resolver problema de previsão múltiplas de séries temporais de carga por barramento.

### 7.3 Análise de Sensibilidade

Conforme visto na seção anterior, a metodologia agregada se mostrou robusta e eficaz na solução do problema de previsão de carga por barramento. Para verificar seu comportamento em situações diversas, passíveis de ocorrência nas etapas de previsão, foi realizada uma análise de sensibilidade na metodologia agregada visando testar seu desempenho frente a diversos cenários. Em termos didáticos a metodologia foi confrontada com variações nos seguintes itens:

- **Diferentes Conjuntos de Entrada;**
- **Mudanças nos Agrupamentos;**
- **Processo de Redução de Dimensionalidade;**
- **Alteração no Período de Previsão.**

Como nesta seção o objetivo foi realizar uma análise de sensibilidade nos parâmetros utilizados pela metodologia agregada, os resultados serão apresentados tomando como base apenas a metodologia agregada na variação *Agg\_RNA* que, conforme a seção anterior, foi a metodologia agregada com maior precisão nos resultados.

A disponibilidade do *SysPrev*, no processo de análise de sensibilidade da metodologia agregada, foi fundamental pois através do ambiente interativo de seleção dos parâmetros dos modelos, dados e configurações diversas foi possível criar vários cenários avaliando, com rapidez, a influência das variáveis na metodologia de previsão proposta.

### 7.3.1 Resultados: Diferentes Conjuntos de Entrada

A determinação das entradas que serão utilizadas para alimentar os modelos de previsão é uma preocupação constante dos pesquisadores em séries temporais devido à influência das entradas no resultado da previsão (Bartlett, 1994) e (Engelbrecht et al., 1995). Neste trabalho, foram testadas três abordagens para a seleção das entradas utilizadas no ajuste dos modelos de previsão. A primeira determina as entradas com base nos resultados da função de autocorrelação parcial (PAF) (Mori e Kurata, 2007). A segunda abordagem leva em consideração os atrasos imediatamente anteriores ao dia de previsão (DA), na hora desejada. Este processo visa utilizar a influência de curto prazo que existe na série de carga elétrica. A terceira e última abordagem, calcula as entradas com base nos valores médios de dias anteriores (MDA) sendo que a idéia é representar a carga em função do valor médio diário.

A Figura 7.1, apresentada e comentada anteriormente, mostra o esquema utilizado para encontrar os padrões de entrada via função de autocorrelação parcial (PAF). Com objetivo similar, a Figura 7.9 apresenta o processo de localização das entradas via abordagem dos dias anteriores (DA). Neste processo, a carga horária em um determinado dia é calculada em função da carga, na mesma hora, em dias anteriores ao dia desejado. Nesta figura as cargas apontadas pelas flechas vermelhas correspondem às entradas dos modelos enquanto as flechas azuis representam a saída desejada e, observando a curva horária, é possível verificar que a carga em um dado instante é função das três últimas medições. Desta maneira, a carga em um instante  $t$ , com esta sistemática, é representada em função das três cargas de dias anteriores  $(t-1)$ ,  $(t-2)$  e  $(t-3)$ , na mesma hora  $h$ .

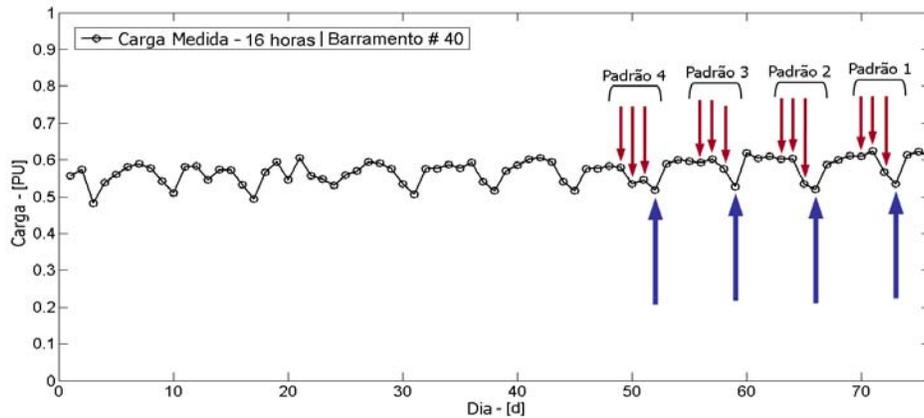


Figura 7.9: Conjunto Entradas (DA) - Barramento #40 | Hora 16.

O processo de determinação de entradas via média dos dias anteriores (MDA) possui uma sistemática similar ao caso (DA) visto anteriormente. Nesta abordagem, o diferencial, em relação ao processo (DA), é que a carga no dia  $t$  em uma hora  $h$  é dada em função da carga média diária dos três últimos dias ( $t-1$ ), ( $t-2$ ) e ( $t-3$ ) e não das três leituras da mesma hora em dias anteriores. Utilizar a carga média no lugar da carga horária faz com que ruídos encontrados na série horária sejam minimizados pela média diária, aumentando a probabilidade de encontrar padrões (entrada×saída) com menor nível de variação. Através destes processos de determinação de entradas, anteriormente definidos, a metodologia agregada foi executada gerando diversos cenários com o objetivo de verificar o impacto da alteração nas entradas sobre a metodologia agregada.

Seguindo os moldes definidos na seção anterior, a metodologia agregada foi submetida à previsão de um dia específico (terça-feira dia 25 de setembro de 2001). As Figura 7.10 e 7.11 mostram a curva horária prevista por cada um dos procedimentos de entrada para os barramentos #47 e #59 respectivamente. Através da observação das curvas, é possível perceber que, para estes barramentos neste dia específico, a variação na escolha das entradas usadas para representar as cargas não alterou significativamente o perfil da carga em ambos os barramentos analisados.

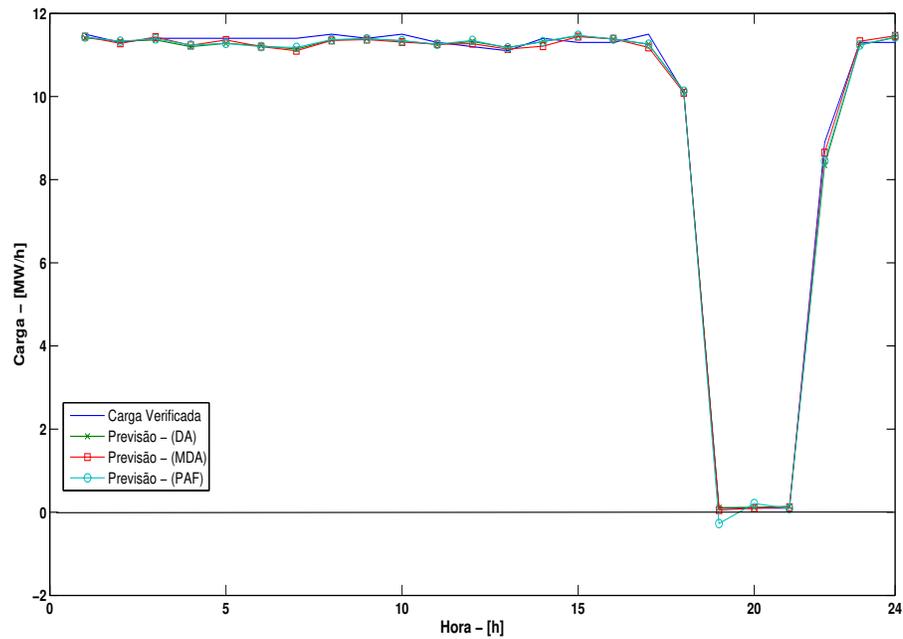


Figura 7.10: Curva: Prevista  $\times$  Verificada - Barramento #47 | 25/09/2001.

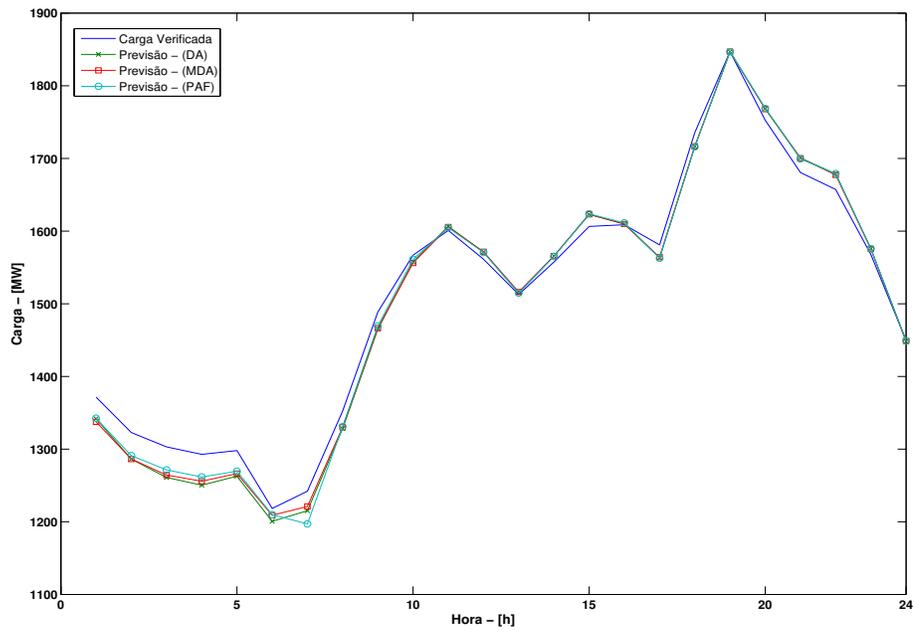


Figura 7.11: Curva: Prevista  $\times$  Verificada - Barramento #59 | 25/09/2001.

A Tabela 7.8 mostra o erro médio diário ao longo da semana de testes na metodologia agregada para cada abordagem de determinação de entradas utilizando os 14 grupos de barramentos apresentados no Capítulo 2. Levando em consideração a análise dos resultados de previsão de 7 dias consecutivos para os grupos e barramentos, pode-se observar que os níveis de erro diário apresentados deixam claro que a troca no processo de determinação de entradas ocasionou mudanças no erro médio semanal. Em termos gerais, na média a seleção de entradas via PAF obteve uma eficiência de 10% se comparado à seleção via dias anteriores. Este comportamento mostra a importância e o impacto existente no processo de seleção de entradas em um modelo de previsão.

Tabela 7.8: MAPE: Influência das Entradas | 14 Grupos.

	Qui 20/09	Sex 21/09	Sab 22/09	Dom 23/09	Seg 24/09	Ter 25/09	Qua 26/09	<b>Erro Médio</b>
<b>DA</b>	4.28	4.77	6.83	4.99	3.89	3.78	5.66	4.89
<b>MDA</b>	4.32	4.80	6.55	4.62	3.57	3.88	5.36	4.73
<b>PAF</b>	3.65	4.26	6.52	4.21	3.61	3.45	5.39	4.44

### 7.3.2 Resultados: Mudanças nos Agrupamentos

As informações sobre os agrupamentos são fundamentais para criar as estruturas necessárias para a etapa de ajuste e validação na metodologia agregada. Nesta seção, o foco foi verificar a influência das informações providas pelos agrupamentos no desempenho da metodologia de previsão agregada. Assim, serão apresentados algumas simulações com diferentes agrupamentos visando determinar o nível de importância na disposição dos barramentos em grupos na previsão via metodologia agregada.

Neste sentido, foram definidas três simulações envolvendo agrupamentos distintos que serão utilizados na previsão do mesmo período anteriormente definido (20 a 26/9/2001). Os agrupamentos testados nesta seção podem ser divididos de acordo com as seguintes categorias:

#### 1. **G. Algoritmo;**

## 2. **G. Aleatório;**

## 3. **G. Único;**

O processo *G. Algoritmo* determina os grupos de barramentos utilizando uma técnica de agrupamento convencional (*K-Means*, *Kohornen*, *Fuzzy C-Means*, entre outros). Nesta simulação os grupos de barramentos foram encontrados utilizando a técnica *subtractive clustering-SC* (Chiu, 1994). Segundo os trabalhos (Salgado, 2004) e (Salgado et al., 2004), os barramentos pertencentes a um mesmo grupo tendem a se manter na mesma estrutura por um determinado período de tempo. Desta forma, para determinar os agrupamentos que serão utilizados na previsão de um determinado dia  $d$ , os grupos serão formados tomando como base as informações do dia  $(d - 7)$  que representa o mesmo tipo de dia em uma semana anterior.

*G. Aleatório* é um processo que forma os grupos de barramentos com base em uma função aleatória. Esta abordagem determina os grupos de barramentos aleatoriamente, sem levar em consideração nenhum tipo de informação que caracterize os barramentos. A catalogação dos grupos sem critério lógico visa verificar se há ou não necessidades de criar a estrutura agregada com base nos barramentos com similaridades no perfil.

O último processo, *G. Único*, faz a catalogação dos barramentos em uma única estrutura, criando um grupo único formado por todos os barramentos do sistema elétrico. Este tipo de procedimento também não leva em consideração nenhum tipo de informação dos barramentos, preocupando-se apenas em criar uma estrutura que possibilite a utilização da metodologia agregada. Esta variação visa verificar o desempenho da metodologia agregada frente a um grupo que contém um número elevado de barramentos.

Em cada um dos três processos de agrupamento, o PAF foi utilizado na criação dos padrões de (entrada×saída) que alimentam a metodologia agregada. O PAF foi adotado para possibilitar a utilização de entradas idênticas àquelas utilizadas no primeiro conjunto de testes apresentado nas primeiras seções deste capítulo, possibilitando comparações na mesma base com os demais resultados.

A Tabela 7.9 mostra o MAPE ao longo da semana de testes para cada um dos procedimentos de agrupamento desta seção. Inicialmente, observa-se que o processo de agrupamento que alcançou os menores erros ao longo da semana de testes foi aquele realizado por um algoritmo especializado em encontrar grupos com elementos semelhantes (*G. Algoritmo*). Este resultado mostra que a utilização de grupos formados por barramentos com semelhanças no perfil faz com que as previsões, via metodologia agregada, tenham menores erros. É interessante destacar que as demais simulações realizadas com as informações fornecidas pelos processos (*G. Aleatório* e *G. Único*) se mostraram menos eficientes em todos os dias da semana.

Tabela 7.9: MAPE: 7 dias Consecutivos - 20 a 26/9/2001.

	Qui 20/09	Sex 21/09	Sab 22/09	Dom 23/09	Seg 24/09	Ter 25/09	Qua 26/09	<b>Erro Médio</b>
G. Algor.	3.93	4.25	6.21	3.12	6.98	3.43	4.94	<b>4.69</b>
G. Aleat.	7.08	5.56	6.55	4.67	8.55	4.55	6.13	<b>6.16</b>
G. Único	9.17	40.66	8.60	5.71	7.43	7.75	8.31	<b>12.52</b>

Na metodologia agregada, as informações de agrupamentos são responsáveis por fornecer os subsídios para cálculo da estrutura agregada que é construída com base nos barramentos que compõem o grupo. A estrutura agregada formada com as informações fornecidas pela abordagem *G. Algoritmo* tem, em sua composição, barramentos com mesmo perfil de consumo diário. Esta característica faz com que exista uma uniformidade nas entradas dos modelos minimizando problemas de convergência e instabilidade numérica na fase de ajuste da metodologia de previsão.

Nos grupos obtidos pela abordagem *G. Aleatório*, não há um compromisso com a similaridade dos elementos do grupo, e este fato faz com que a estrutura agregada, neste grupo, tenha informações de diversos barramentos com variados perfis de consumo. Em termos numéricos, neste caso, é possível que o processo de ajuste seja prejudicado pela não uniformidade nas entradas dificultando a convergência do previsor e, conseqüentemente a etapa de testes/validação da metodologia.

No caso do processo *G. Único* o problema é ainda mais grave pois, neste caso, todos os barramentos do sistema devem ser representados em uma única estrutura agregada. Logicamente, nesta situação, o previsor adotado será ajustado para aprender as relações dos barramentos em um único processo de treino. O fato de utilizar as informações de um único agrupamento sem filtros ou regra de escolha pode amplificar os ruídos dos barramentos na estrutura agregada aumentando os problemas no ajuste do previsor na estrutura formada no processo *G. Aleatório*. Além disso, a estrutura agregada, para este cenário, terá sua dimensão dependente do número de barramentos do sistema, podendo causar lentidão no processo de convergência bem como a paralisação do processo de ajuste em um mínimo local prejudicando a etapa de previsão. Numericamente, os resultados da Tabela 7.9 mostram claramente os problemas das abordagens *G. Aleatório* e *G. Único* através do nível de erro obtido por estas abordagens no problema de previsão.

Nas Figura 7.12 e 7.13 são apresentadas as curvas previstas e verificadas para cada um dos processos de agrupamentos nos barramentos #47 e #59 respectivamente. Pela análise da Figura 7.12 pode-se verificar que, para o barramento #47, as informações dos agrupamentos fornecidas via *G. Algoritmo* e *G. Aleatório* proporcionaram à metodologia agregada previsões que representam corretamente o perfil de consumo deste barramento. A previsão feita com as informações do *G. Único* conseguiu bons resultados em algumas horas do dia. Entretanto, nos intervalo das 19 às 21 horas a previsão falhou apontando consumo negativo, fato este provavelmente associado à instabilidade numérica causada pela representação de todos os barramentos em um único grupo.

Uma análise similar pode ser feita para a Figura 7.13, na qual pode-se observar as curvas verificada e prevista para o barramento #59. Observando o comportamento das previsões percebe-se que, no caso geral, todas as abordagens de agrupamento foram capazes de representar a previsão da curva deste barramento da forma desejada.

De maneira geral, com os resultados de previsão obtidos pelas diferentes abordagens de agrupamento, foi possível notar que a metodologia agregada apresentada neste trabalho sofre influência causada pela forma com que

os barramentos são agrupados. Logo, deve-se levar em consideração o grau de similaridade nos grupos de barramentos para alcançar bons resultados com a metodologia agregada.

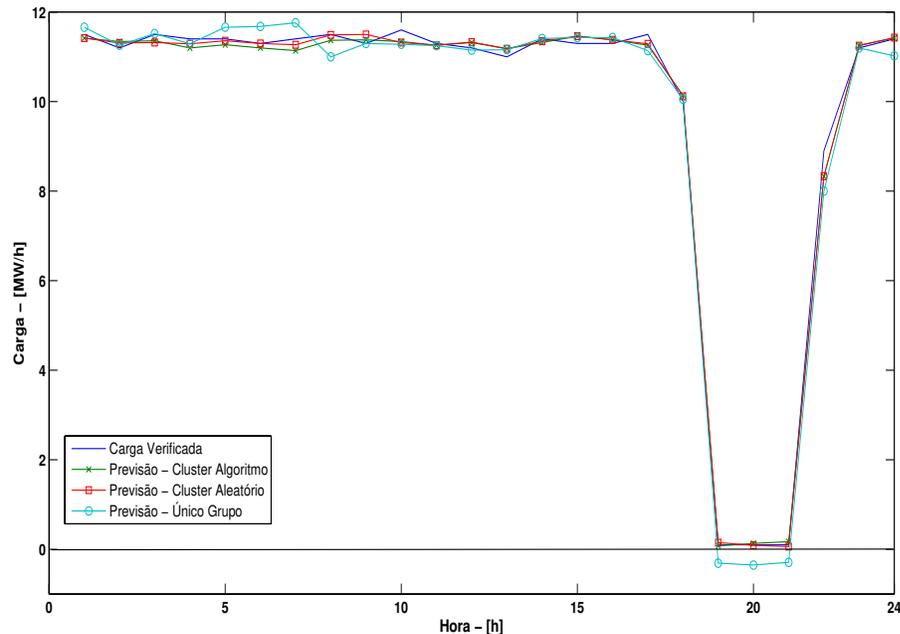


Figura 7.12: Curva: Prevista  $\times$  Verificada - Barramento #47 | 25/09/2001.

### 7.3.3 Resultados: Processo de Redução de Dimensionalidade

A metodologia de previsão agregada desenvolvida neste trabalho, realiza a previsão de um conjunto de barramentos através da criação de uma estrutura (entrada $\times$ saída) que contém as informações individuais de cada barramento pertencente ao conjunto. Conforme a descrição apresentada na Seção 3.4, quando um grupo é formado por vários barramentos existe a probabilidade da dimensão da estrutura (entrada $\times$ saída), usada no ajuste do previsor, ser excessivamente alta podendo causar problemas no processo de ajuste dos parâmetros do previsor.

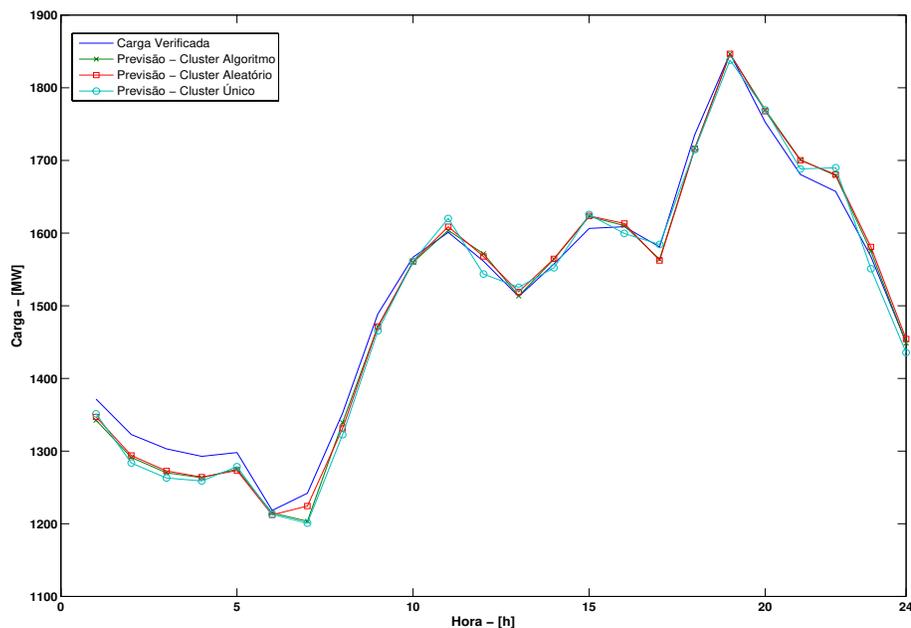


Figura 7.13: Curva: Prevista  $\times$  Verificada - Barramento #59 | 25/09/2001.

Para contornar este problema, geralmente aplica-se um algoritmo de compressão de informação visando reduzir a dimensão da estrutura, sem perder o poder de representatividade. Neste trabalho, o algoritmo escolhido para realizar a compressão da estrutura agregada foi o PCA (*Principal Component Analysis*). O PCA foi aplicado com o objetivo de encontrar uma estrutura agregada com dimensão reduzida visando evitar problemas na convergência do predictor no período de ajuste.

A Tabela 7.10 contém exemplos numéricos com variações no número de entradas utilizadas para representar um conjunto de barramentos na previsão da carga em determinados instantes de tempo  $t$ . Pode-se observar, nesta tabela, a existência de três colunas, sendo a primeira responsável por informar o número de entradas encontradas pelo PAF para estimar as cargas de alguns barramentos do sistema. As demais colunas representam o número de entradas obtidos após a aplicação do PCA no conjunto encontrado pelo PAF, considerando a representação de 99, 95 e 90% da informação existente nos dados. Pode-se verificar, observando os resultados, que houve uma redução de 78%, 83% e 90%

da dimensionalidade quando são analisadas as colunas **Redução-1, 2 e 3** repectivamente. Desta maneira, em termos de redução de dimensionalidade, pode-se ressaltar que o PCA foi eficaz provendo uma representação reduzida do conjunto de barramentos. Entretanto, é importante destacar que no processo de compactação de informação pode ocorrer perda de informação e, neste sentido deve-se ter um compromisso entre a redução de dimensionalidade e representação de informação para que as etapas de previsão não sejam prejudicadas com dados incompletos.

Tabela 7.10: Exemplo: Redução de Dimensionalidade - PCA.

<b>Dimensão</b>	<b>Redução-1</b>	<b>Redução-2</b>	<b>Redução-3</b>
<b>Original</b>	<b>99%</b>	<b>95%</b>	<b>90%</b>
46	10	8	5
45	10	8	5
44	10	8	4
39	10	8	5
39	10	9	5
38	10	7	4
36	10	9	4
35	10	8	4
34	10	9	4
31	10	9	3

Os resultados de previsão apresentados a seguir foram executados tomando como referência o procedimento de compactação que armazena 95% das informações dos dados originais. A Tabela 7.11 apresenta os resultados de previsão durante a semana de testes para a metodologia agregada com o PCA. Pelos valores numéricos obtidos, pode-se notar que a metodologia agregada treinada com dados manipulados com o PCA apresentou bons resultados. O nível de erro encontrado pela abordagem original (sem PCA) e abordagem alternativa (com PCA) tem alto grau de similaridade com vantagens para o caso “Sem PCA” na maioria dos dias da semana analisada. Ainda pode-se observar que, ao longo da semana de testes, a aplicação do PCA na estrutura agregada foi eficaz, proporcionando erros na mesma magnitude dos encontrados pela metodologia agregada original.

Tabela 7.11: MAPE: Dias Consecutivos - 20 a 26/9/2001.

	Qui 20/09	Sex 21/09	Sab 22/09	Dom 23/09	Seg 24/09	Ter 25/09	Qua 26/09	<b>Erro Médico</b>
<b>Sem PCA</b>	3.65	4.26	6.52	4.21	3.61	3.45	5.39	<b>4.44</b>
<b>Com PCA</b>	3.64	4.24	6.58	4.33	3.65	3.46	5.53	<b>4.49</b>

A vantagem da utilização do PCA é a obtenção de uma estrutura agregada (entrada×saída) com dimensão reduzida e boa representatividade das variáveis, se comparado ao caso original. Em um sistema com número reduzido de barramentos, a aplicação do PCA não apresenta grandes vantagens. Já, em um sistema de grande porte com alto número de barramentos a utilização do PCA pode minimizar os problemas de instabilidade causado pela alta dimensão da estrutura agregada.

A Figura 7.14 apresenta um comparativo, em termos de erro percentual médio, efetuado nos grupos de barramentos da Tabela 2.2. Conforme pode ser observado, os níveis dos erros encontrado em cada abordagem têm alta similaridade e aproximadamente o mesmo nível de intensidade em cada um dos grupos. Além do nível de erro nos grupos, pode-se observar nas Figura 7.15 e 7.16 que a curva de carga estimada através de cada uma das abordagens representa cada um dos barramentos analisados com bom nível de precisão.

Este processo de utilização da técnica de compressão de informações, apesar de prover bons resultados, deve ser utilizado somente quando necessário, pois mesmo com a boa representatividade no espaço reduzido, podem ocorrer perdas de informações relevantes (processo de compressão) prejudicando os resultados das previsões.

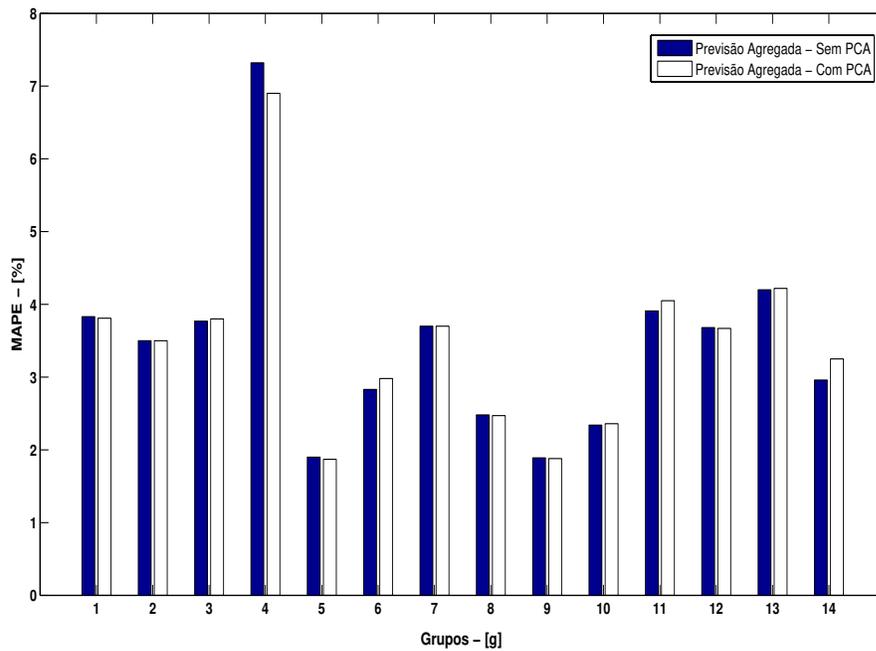
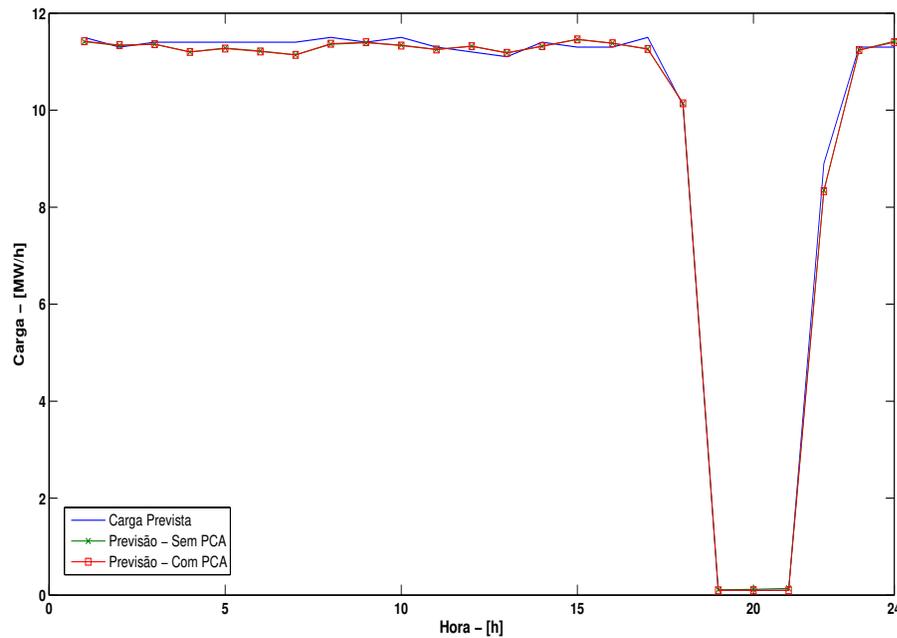


Figura 7.14: MAPE: Abordagem PCA x Convencional | Grupo de Barramentos

Figura 7.15: Curva: Prevista  $\times$  Verificada - Barramento #47 | 25/09/2001.

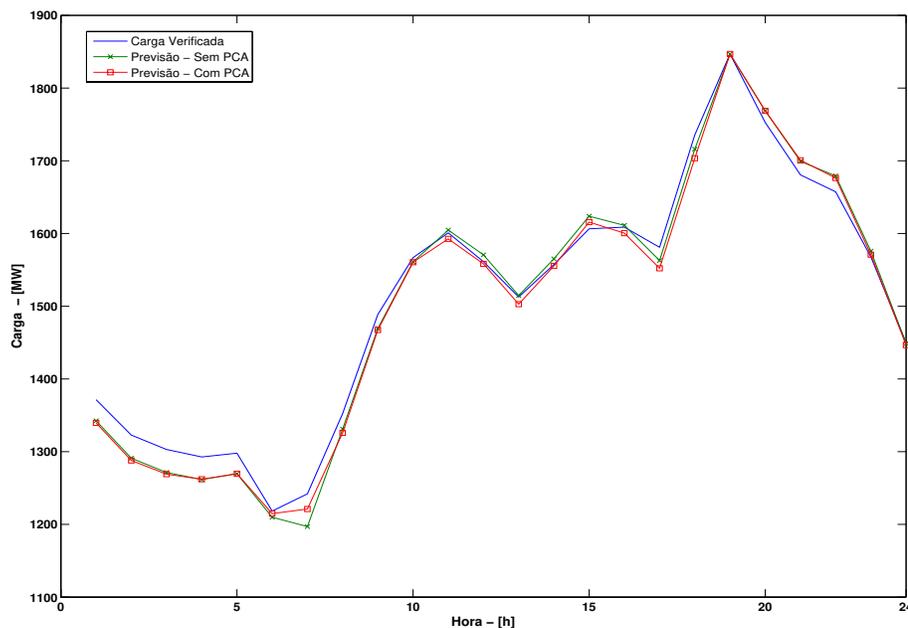


Figura 7.16: Curva: Prevista  $\times$  Verificada - Barramento #59 | 25/09/2001.

### 7.3.4 Resultados: Alteração no Período de Previsão

Outra forma de avaliar o desempenho de uma metodologia de previsão é alterar o período utilizado para ajustes e testes verificando se a capacidade de generalização ainda é preservada pela ferramenta. Com o *SysPrev*, a alteração dos períodos de previsão nos estudos é imediata, podendo ser feita somente com mudança de poucos parâmetros na interface gráfica. Desta forma, o *SysPrev* foi configurado para realizar a previsão, via metodologia agregada, em um período distinto daquele apresentado nos estudos anteriormente descritos neste capítulo.

O objetivo desta mudança nos dias de previsão é verificar o comportamento da metodologia, bem como o nível do erro, na previsão de períodos distintos. Desta forma, nesta simulação, o subconjunto utilizado para ajuste (treinamento) será formado pelas cargas elétricas medidas no período de **01 de Junho a 26 de Setembro de 2001**. O conjunto de teste, por sua vez, será formado pelas cargas medidas entre os dias **27 de setembro a 03 de Outubro de 2001**.

As informações utilizadas pela metodologia agregada, nesta simulação, seguiram os padrões aplicados nos casos anteriores no qual as informações dos agrupamentos foram definidos na Tabela 2.2 e a função de autocorrelação parcial (PAF) foi utilizada na formação dos padrões de processo de ajuste. Os resultados apresentados comparam os modelos *Ind\_RNA* e *Agg\_RNA* para avaliar se o desempenho e a similaridade das metodologias se mantêm em outros períodos de previsão.

A Tabela 7.12 apresenta o erro percentual médio durante 7 dias (27/09 a 03/10/2001). Observando os valores numéricos, é possível afirmar que a proximidade no desempenho entre as metodologias individual e agregada permanece nesta simulação, reforçando a compatibilidade existente entre as abordagens. Com relação aos valores dos erros, pode-se observar que a metodologia *Agg\_RNA* foi superior em 100% do período analisado provendo, neste caso, melhores previsões. Vale ressaltar que os níveis de erros obtidos pelas abordagens individual e agregada têm alta similaridade mantendo, entre os dias previstos, compatibilidade aproximada em relação ao sentido e intensidade do erro. Novamente, como nos casos vistos anteriormente, a metodologia agregada se mostrou eficaz apresentando resultados de boa qualidade e, principalmente, de forma rápida e direta.

Tabela 7.12: MAPE: Dias Consecutivos - 27/09 a 03/10/2001.

	Qui 27/09	Sex 28/09	Sab 29/09	Dom 30/09	Seg 01/10	Ter 02/10	Qua 03/10	<b>Erro Médio</b>
<b>Ind_RNA</b>	4.49	6.38	3.57	3.92	7.26	6.89	6.30	<b>5.54</b>
<b>Agg_RNA</b>	4.03	6.06	3.48	3.83	7.19	6.83	5.39	<b>5.26</b>

A descrição feita pela Tabela 7.13 mostra o erro médio em cada uma das metodologias analisando os agrupamentos da Tabela 2.2. É interessante verificar que os valores de erro obtidos para cada grupo possuem altíssima similaridade, levando em consideração as metodologias *Ind\_RNA* e *Agg\_RNA*. Em cada um dos grupos, o nível do erro se manteve dentro de uma pequena faixa, e o interessante, nesta análise, é que a metodologia agregada foi capaz de reproduzir os resultados da metodologia individual através de sua estrutura agregada em um reduzido

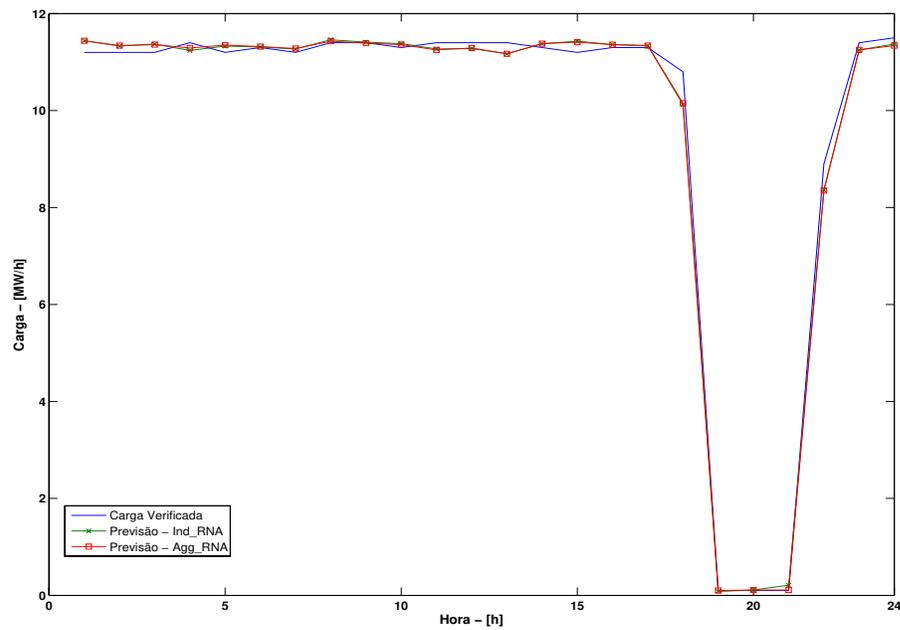
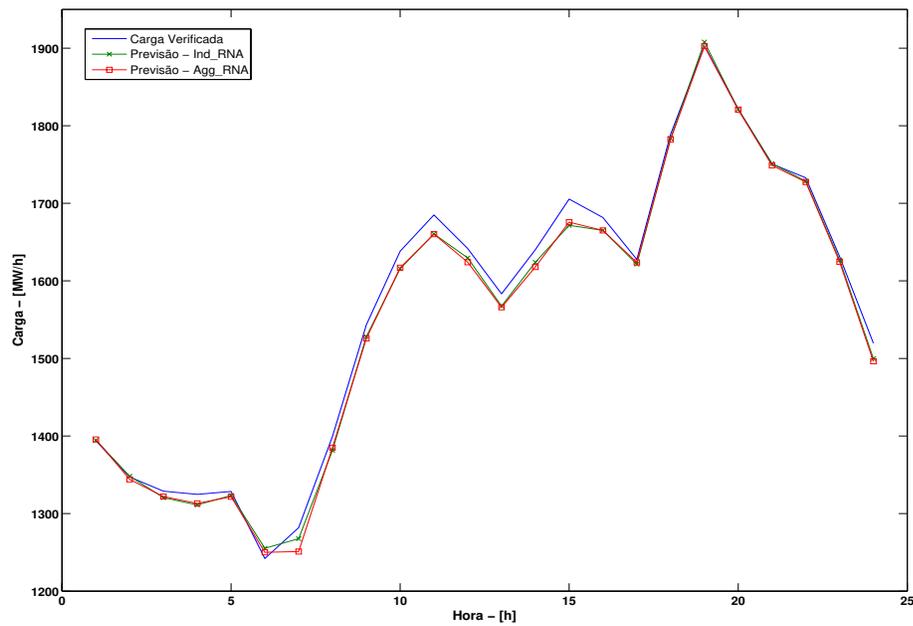
tempo de processamento.

Tabela 7.13: MAPE: Individual  $\times$  Agregado | 02/10/2001.

<b>Id. Grupo</b>	<b>Ind_RNA</b>	<b>Agg_RNA</b>
1	4.0	4.0
2	6.1	5.5
3	30.0	34.5
4	10.7	6.6
5	1.6	1.6
6	5.2	5.1
7	3.9	4.3
8	1.5	1.6
9	2.3	2.3
10	2.2	2.3
11	6.3	5.0
12	17.6	17.5
13	2.7	2.7
14	2.4	2.7
<b>Erro Médio</b>	<b>6.89</b>	<b>6.83</b>

As Figura 7.17 e 7.18 mostram as curvas verificada e prevista levando em consideração as abordagens *Ind\_RNA* e *Agg\_RNA* para os barramentos #47 e #59 respectivamente. Nota-se que as curvas estimadas pelas técnicas *Ind\_RNA* e *Agg\_RNA* seguiram o mesmo perfil da carga verificada e as previsões fornecidas pelos modelos praticamente apresentam os mesmos valores com a mesma tendência entre os intervalos de tempo.

Os gráficos apresentados pelas Figura 7.19 e 7.20 mostram o erro horário para a previsão do dia 02/10/2001 nos barramentos #47 e #59 respectivamente. Observando o comportamento do erro na Figura 7.19, é possível concluir que, nesta previsão, o nível do erro alcançado pelas metodologias apresentou comportamentos semelhantes em cada intervalo de tempo. Este comportamento, em nível de erro horário, mostrado pela Figura 7.19, reflete o bom desempenho apresentado pelas metodologias na obtenção da curva prevista da Figura 7.17. O que pode ser observado de forma direta é a compatibilidade de resultados das metodologias individual e agregada na previsão de carga por barramento. Estes resultados fortalecem o uso da abordagem agregada no processo de previsão de séries temporais de carga por barramento.

Figura 7.17: Curva: Prevista  $\times$  Verificada - Barramento #47 | 02/10/2001.Figura 7.18: Curva: Prevista  $\times$  Verificada - Barramento #59 | 02/10/2001.

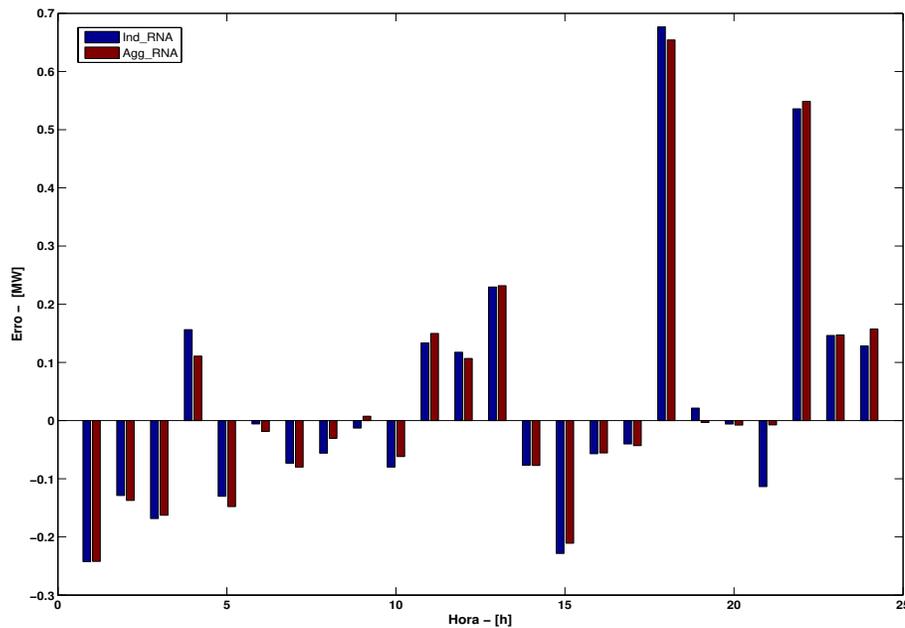


Figura 7.19: Erro Horário - Barramento #47 | 02/10/2001.

No comportamento da Figura 7.20 pode ser feita a mesma análise do caso anterior, podendo-se verificar que a intensidade do erro tem aproximadamente a mesma magnitude em cada hora de previsão. Neste barramento, ocorre uma exceção no sentido do erro às 19h, em que as metodologias agregada e individual divergem. Na média, pode-se dizer que o desempenho dos modelos foi equivalente na previsão da curva diária neste barramento, com um erro percentual médio de 0.75% para a metodologia *Ind\_RNA* e 0.81% para a abordagem *Agg\_RNA*, mostrando a compatibilidade das técnicas na solução do problema de previsão de carga por barramento.

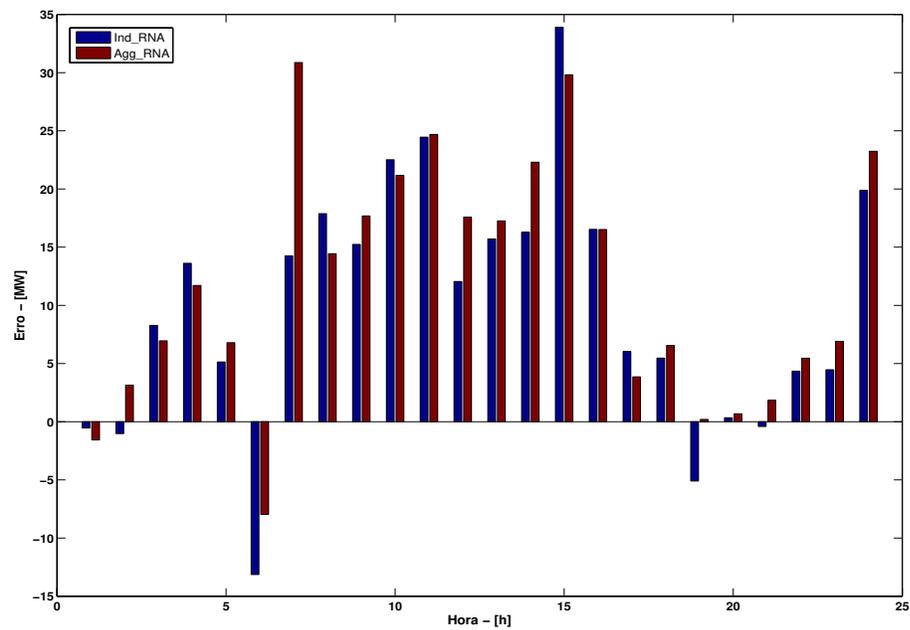


Figura 7.20: Erro Horário - Barramento #59 | 02/10/2001.



# Capítulo 8

## Conclusões, Comentários e Contribuições

### 8.1 Conclusões e Contribuições

Como mencionado, no capítulo primeiro, a tomada de decisão, em qualquer setor e nos mais diversos níveis, constitui um processo complexo em função do nível de incerteza em relação ao futuro. É possível perceber que a disponibilidade de informações precisas sobre cenários futuros é um fator essencial, que viabiliza a escolha da decisão correta e a confiabilidade.

A área de previsão de séries temporais é um campo de pesquisa vasto, onde diversas ferramentas são constantemente desenvolvidas visando atender os diferentes tipos de séries existentes. A disponibilização de um sistema de suporte para análise conjunta das séries temporais e previsão é fundamental tanto para o desenvolvimento de novos modelos de previsão, bem como para o cálculo de previsões.

A operação de um sistema elétrico é um processo extremamente complexo que exige um grande conjunto de ferramentas apropriadas para realizar estudos e simulações que auxiliem a tomada de decisão. Entre as aplicações que necessitam de sistemas específicos pode-se citar: estudos de fluxo de carga, planejamento e programação da operação, análise de segurança, análise de esta-

bilidade, análise de desligamentos, entre outros. Em todos estes casos a previsão de carga por barramento é imprescindível. Visando atender estas necessidades, este trabalho de doutorado apresentou duas contribuições efetivas na análise de séries temporais de carga por barramento. A primeira contribuição foi o desenvolvimento de uma metodologia de previsão de carga por barramento rápida e efetiva que provê os resultados de previsão para diversos barramentos. A segunda contribuição foi a construção de um sistema computacional de previsão de carga por barramento denominado *SysPrev* criado para facilitar a busca por metodologias de previsão de carga através da realização de vários cenários e simulações. O *SysPrev* também foi desenvolvido para possibilitar uma boa compreensão do comportamento das séries temporais de carga por barramento facilitando a extração de informações relevantes para a previsão.

Em termos de técnica de previsão pode-se concluir, com base nos resultados apresentados, que a metodologia de previsão agregada proposta neste trabalho se mostrou altamente eficaz na resolução do problema de previsão de carga por barramento. Como visto anteriormente, existe a necessidade de rapidez na disponibilidade dos resultados de previsão de carga e, o modelo agregado proposto se mostrou na média aproximadamente 14 vezes mais rápido que os modelos convencionais, baseados em previsão individual, na previsão da carga por barramento.

Uma desvantagem da previsão agregada, é o problema da dimensionalidade associada ao número de barramentos a serem previstos no modelo. Conforme pôde ser observado, quanto maior o número de barramentos maior será a dimensão da estrutura agregada. Para contornar este problema foi proposta uma variação do modelo que utiliza um processo de compressão de informação que objetiva encontrar uma estrutura de dimensão reduzida que possibilite o processo de previsão sem queda no desempenho. Os resultados deste processo mostraram que é possível encontrar uma estrutura agregada com dimensão reduzida capaz de prover previsões com nível de qualidade similar ao encontrado pela estrutura agregada convencional, solucionando o problema da elevada dimensionalidade.

O sistema de suporte à previsão *SysPrev* proporcionou a busca por soluções de previsão efetivas em um ambiente gráfico amigável e intuitivo. Pode-se

dizer que a disponibilidade do *SysPrev* viabilizou uma melhor compreensão dos dados, o que possibilitou a obtenção de resultados de forma rápida e prática. Outro fator decisivo no *SysPrev* está associado às suas ferramentas gráficas no qual foi possível gerar diversos cenários de previsão através da variação de parâmetros que possibilitando a detecção das variáveis de maior impacto na previsão de carga por barramento.

Sabe-se que a área de modelos de previsão tem recebido muita atenção dada a sua grande aplicação e, constantemente surgem novas abordagens que em muitos casos possuem desempenhos superiores àquelas já existentes. Para a fácil incorporação destas evoluções é desejável que o sistema de previsão apresente recursos que possibilitem a integração de novas ferramentas sem a necessidade de reprogramação e/ou reconstrução do sistema. Neste sentido, o *SysPrev* foi desenvolvido com base na arquitetura de componentes *plug-and-play* onde, é possível inserir, remover ou atualizar as funcionalidades no sistema sem a necessidade de acessar e compilar o código fonte do programa ou recompilar o programa. Esta facilidade, proporcionada pelo conceito *plug-and-play*, torna o sistema robusto e fácil de ser atualizado, fazendo com que o mesmo tenha fáceis condições de sempre estar atualizado em relação às novas abordagens de previsão desenvolvidas

Pode-se concluir que, as contribuições deste trabalho tanto em termos de metodologia quanto sistema de suporte trazem novas alternativas para resolver o problema de previsão de carga por barramento, possibilitando a obtenção de soluções de boa qualidade em um sistema computacional prático e de fácil uso, fundamental para os processos de operação em um sistema elétrico de potência.

## 8.2 Comentários e Trabalhos Futuros

De maneira geral, as contribuições deste trabalho trazem grandes avanços à área de previsão de carga por barramento. Em termos de trabalhos futuros pode-se pensar em algumas frentes de pesquisa que podem ser investigadas para o aprimoramento das soluções:

1. Ampliação do banco de modelos do *SysPrev*;
2. Consolidação do banco de dados com informações reais do setor elétrico;
3. Implementação de algoritmos de filtragem e validação de dados, buscando detectar os dados não relevantes e fornecer informações consistentes aos modelos;
4. Testar a metodologia agregada com a inserção de variáveis exógenas;
5. Realizar, no *SysPrev*, simulações que levem em consideração as necessidades do setor elétrico na área de previsão de carga global e por barramento.
6. Aprimoramento da interface gráfica de forma a deixá-la cada vez mais amigável e fácil de utilizar;
7. Construção e implantação de uma versão “*web*” do *SysPrev* fazendo com que este possa ser executado diretamente de navegadores de internet dispensando os processos de instalação e configuração de *software* e, principalmente dando portabilidade ao sistema.

Por fim, como o leitor pode constatar, o sistema computacional contido neste trabalho bem como a formulação da metodologia de previsão colocam-se como alternativas concretas no suprimento de necessidades reais do setor elétrico podendo ser utilizada com sucesso para auxiliar os processos decisórios na operação do sistema.

## Referências

- Advantica (2009). Synergee load forecasting, Acessado em: 20/01/2009 no endereço: <http://www.advanticagroup.com/>.
- Al-Kandari, A. M., Solimn, S. A. e El-Hawary, M. E. (2004). *Fuzzy short-term electric load forecasting*, Vol. 26, Electric Power & Energy Systems.
- Amjady, N. (2007). Short-term bus load forecasting of power systems by a new hybrid method, *Proceedings of the IEEE Transactions on Power Systems* **22**: 333–341.
- ANSI (1986). Database language sql, *American National Standards Institute - ANSI X3.135-1986*.
- Azevedo-Filho, J. M. (2000). *Imperativos da centralização e coordenação da operação energética no Âmbito da reforma institucional do setor elétrico brasileiro*, Master's thesis, COPPE-UFRJ, Rio de Janeiro, RJ.
- Ballini, R. e Gomide, F. (2001). Learning in recurrent, hybrid neurofuzzy networks, *10 th Inter International Conference on Fuzzy Systems* **2**: 120–124.
- Barbosa, D. U. S., Carneiro, M., Camponogara, E., Andrade, F. B. e Vidal, F. M. (2007). Desenvolvimento de um sistema de previsão de demanda na tractebel, Acessado em: 20/01/2009 no endereço: <http://www.tractebelenergia.com.br/uploads/12.pdf>.
- Bartlett, E. B. (1994). Self determination of input variable importance using neural networks, *Parallel and Scientific Computations* **2**(1): 103–114.
- Baum, E. B. e Haussler, D. (1989). What size net gives valid generalization?, *Neurocomputing* **1**: 151–160.
- Bezdek, J. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York.

- Bidgoli, H. (1989). *Decision Support System - Principles and Practice*, West Publishing Company, New York/USA.
- Billinton, R. e Allan, R. N. (1996). *Reliability Evaluation of Power Systems*, 2 edn, Plenum, New York.
- Bo-Juen, C., Ming-Wei, C. e Chih-Jen, L. (2004). Load forecasting using support vector machines: A study on eunite competition 2001, *IEEE Transactions on Power Systems* **19**(4): 1821–1830.
- Bose, A. e Clements, K. A. (1987). Real-time modeling of power networks, *Proceedings of the IEEE* **75**(12): 1607 – 1622.
- Box, G., Jenkins, G. e Reinsel, G. (1994). *Time Series Analysis: Forecasting and Control*, 2 edn, Holden Day.
- Bromberg, M. e Chang, T. S. (1992). One dimensional global optimization using linear lower bounds, *C. A. Floudas & P. M. Pardalos (Eds.) - Recent advances in global optimization* pp. 200–220.
- Castro, L. e VonZuben, F. (1999). An improving pruning technique with restart for the kohonen self-organizing feature map, *In Proceedings of the IEEE International Joint Conference on Neural Networks* **3**: 1916–1919.
- Cepel (2000). Relatório do projeto prevcar ii: Sistema de previsão mensal de carga elétrica para o horizonte de 12 meses, *Technical report*, Centro de Pesquisas em Energia Elétrica, Rio de Janeiro.
- Chen, P. (1977). The entity-relationship model – a basis for the enterprise view of data, *Proc. of National Computer Conference - AFIPS Press* pp. 77–84.
- Chiu, S. (1994). Fuzzy model identification based on cluster estimation, *Journal of Intelligent & Fuzzy Systems* **2**(3).
- Cicogna, M. A. (2003). *Sistema de Suporte à Decisão para o Planejamento e a Programação da Operação de Sistemas de Energia Elétrica*, PhD thesis, FEEC/Unicamp.
- Codd, E. F. (1972). Relational completeness of data base sublanguages, *In: R. Rustin (ed.): Database Systems: 65-98*, Prentice Hall and IBM Research Report RJ 987, San Jose, California .
- Courtney, J. F. (2001). Decision making and knowledge management in inquiring organizations: toward a new decision-making paradigm for dss, *Decision Support Systems* **31**(1): 17–38.
- Date, C. J. (2003). *An introduction to Database Systems*, 8 edn, Addison-Wesley, Bosten-Massachusets-USA.

- Deitel, H. M. e Deitel, P. J. (2005). *JAVA - Como Programar*, 5 edn, Bookman, São Paulo.
- Ding, C. e He., X. (2004). K-means clustering via principal component analysis, *Proceedings of International Conference on Machine Learning* pp. 225 – 232.
- Ding, S.-F., Shi, Z.-Z., Liang, Y. e Jin, F.-X. (2005). Information feature analysis and improved algorithm of pca, *Proceedings of 2005 International Conference on Machine Learning and Cybernetics* **3**: 1756 – 1761.
- Dix, A. J., Finlay, J. E., Abowd, G. D. e Beale, R. (1998). *Human-computer interaction*, Vol. 2, Prentice-Hall, London.
- EFACEC (2009). Scada/ems, Acessado em: 20/01/2009 no endereço: <http://www.efacec.pt/>.
- ELETROBRÁS (2008). Plano decenal de expansão 2008/2017.
- Encyclopedia, C. (1985). American standard code for information interchange, *The Computer Language Company Inc* .
- Engelbrecht, A. P., Cloete, I. e Zurada, J. M. (1995). Determining the significance of input parameters using sensitivity analysis, from natural to artificial neural computation, *Proceedings of International Workshop on Artificial Neural Networks* p. 382 – 388.
- ETAP, E. S. (2009). Adaptive bus load forecasting real-time trending load profile library forecasting scenario archiving, Acessado em: 20/01/2009 no endereço: <http://www.etap.com/>.
- Ferreira, O. C. (2002). O sistema elétrico brasileiro, *Economia e Energia* **32**.
- Fischl, R., Guvenis, A. e Halpin, T. (1982). Statistical power transmission network design, *IEEE Transactions on Circuits and Systems* **29**(10): 679 – 687.
- Fowler, S. L. e Stanwick, V. R. (1994). *The GUI Style Guide*, Morgan Kaufmann.
- Gama, E., Helem, R., Johnson, R. e Vlissiledes, J. (1995). *Design Patterns: Elements of Reusable Object-Oriented Software*, Addison Wesley.
- Goodman, D. (1987). *The Complete HyperCard Handbook*, Bantam Books.
- Groot, C. d. e Würtz, D. (1994). Plain backpropagation and advanced optimization algorithms: A comparative study, *Neurocomputing, NEUCOM 291* **6**: 153–161.
- Gross, G. e Galiana, F. (1987). Short-term load forecasting, *Proceedings of the IEEE* **75**(12): 1558–1573.

- Guille, A. E. e Paterson, W. (1977). *Electrical Power Systems*, Vol. 1, 2, 2 edn, Pergamon Press.
- Gulutzan, P. e Pelzer, T. (2002). *SQL Performance Tuning*, Addison-Wesley, New York.
- Han, J. e Kamber, M. (2001). *Data Mining: Concepts and Techniques*, Academic Press, San Diego.
- Handschin, E. e Dörnmann, C. (1988). Bus load modelling and forecasting, *IEEE Transactions on Power Systems* **3**(2): 627–633.
- Haykin, S. (1994). *Neural Networks, A Comprehensive Foundation*, Macmillan Publishing Company.
- Hesterberg, A. D. P. T. C. (1989). A regression based approach to short-term system load forecasting, pp. 414–923.
- Itron (2009). Energy forecasting & load research, Acessado em: 20/01/2009 no endereço: <http://www.itron.com/>.
- Johnson, R. A. e Wichern, D. W. (2002). *Applied Multivariate Statistical Analysis*, 5 edn, Prentice-Hall, New Jersey.
- Kadowaki, M., Ohishi, T., Soares, S. e Ballini, R. (2002). Short term load forecasting using a neurofuzzy network model, *Congresso Brasileiro Automática* **1**: 365–370.
- Kaski, S. e Kohonen, T. (1995). Exploratory data analysis by the self-organizing map: Structures of welfare and poverty in the world, *Proceedings of the Third International Conference on Neural Networks in the Capital Markets* pp. 498–507.
- Kassaei, H. R., Keyhani, A., Woung, T. e Rahman, M. (1999). A hybrid fuzzy, neural network bus load modeling and prediction, *IEEE Transactions on Power Systems* **14**(2): 718 – 724.
- Keyhani, A. e Miri, S. M. (1983). On-line weather sensitive and industrial group bus load forecasting for microprocessor-based application, *IEEE Transactions on Power Apparatus and Systems* **102**(12): 3868 – 3876.
- Kim, K. H., Park, J. K., Hwang, K. J. e Kim, S. H. (1995). Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems, *IEEE Transactions on Power Systems* **10**(3): 1534–1539.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps, *Biological Cybernetics* **43**: 59–69.

- Lambert-Torres, G., da Silva, L. E. B., Valiquette, B., Greiss, H. e Mukhedkar, D. (1992). A fuzzy knowledge-based system for bus load forecasting, *IEEE International Conference on Fuzzy Systems* pp. 1211 – 1218.
- Lebart, L., Morineau, A. e Piron, M. (1995). *Statistique Exploratives Multidimensionnelle*, Dumond, Paris.
- LeCOMTE, D. M. e Warren, H. (1981). Modeling the impact of summer temperatures on national electricity consumption, *Journal of Applied Meteorology* **20**(12): 1415–1419.
- Liu, B. e Yang, R. (2008). A novel method based on pca and ls-svm for power load forecasting, *Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies* pp. 759 – 763.
- Maciaszek, L. A. (1990). *Database Design and Implementation*, Prentice Hall, Australia.
- MacQueen, J. B. (1967). Some methods for classification and analysis of multivariate observations, proceedings of 5-th berkeley symposium on mathematical statistics and probability, **1**: 281–297.
- Mori, H. e Kurata, E. (2007). Graphical modeling for selecting input variables of short-term load forecasting, *Proceedings of the Power Tech 2007 IEEE Lausanne* pp. 1084–1089.
- Nazarko, J. e Zalewski, W. (1999). The fuzzy regression approach to peak load estimation in power distribution systems, *IEEE Transactions on Power Systems* **14**(3): 809 – 814.
- NewFound, E. L. (2009). Atlas load control - automatic load control system, Acessado em: 20/01/2009 no endereço: <http://www.newfound-energy.co.uk/>.
- Olaru, C. e Wehenkel, L. (1999). Data mining, *IEEE Computer Applications in Power Magazine* **12**(3): 19–25.
- Park, D. C., El-Sharkawi, A., M. e Marks II, R. J. (1991). Electric load forecasting using an artificial neural network, *IEEE Transactions on Power Systems* **6**(2): 442–449.
- Pearson, K. (1901). On lines and planes of closest fit to systems of points in space, *Philosophical Magazine* **2**: 559–572.
- Pereira, J., Salgado, R., Ohishi, T. e Ballini, R. (2006). Short-term load forecasting using support vector machines, *IEEE PES Transmission and Distribution Conference and Exposition Latin America* pp. 1–6.

- Pyne, R. A. (1974). Short-term bus load forecasting and its intended use in scheduled outage analysis, *Decision and Control including the 13th Symposium on Adaptive Processes* **13**(1): 593 – 597.
- Quayle, R. G. e Diaz, H. F. (1980). Heating degree day data applied to residential heating energy consumption, *Journal of Applied Meteorology* **19**(3): 241–246.
- Rahman, S. (1990). Formulation and analysis of a rule-based short-term load forecasting algorithm, *Proceedings of IEEE* **78**(5): 805–816.
- Rocha, C. A., de Santana, A. L., Francês, C. R. L., Rego, L., Costa, J. C. W. A., Favero, E., Bezerra, U., Gato, V. e Tupiassú, A. (2006). Sistema de suporte à decisão para predição de cargas e modelagem de dependência em sistemas elétricos de potência, *Proceedings of Congresso da SBC* pp. 376 – 390.
- Rumelhart, D., Hinton, G. e Williams, R. (1986). *Learning internal representation by error propagation, parallel distributed processing: Explorations in the Microstructure of Cognition*, Vol. 1, MIT Press, Cambridge.
- Saadat, H. (2002). *Power Systems Analysis*, 2 edn, McGraw-Hill.
- Salgado, R. (2004). *Um modelo de previsão de carga por barramento*, Master's thesis, FEEC-Unicamp, Campinas, SP.
- Salgado, R., Ohishi, T. e Ballini, R. (2004). Clustering bus load curves, *Proceedings of Power Systems Conference Exposition PSCE- IEEE* .
- Salgado, R., Pereira, J., Ohishi, T. e Ballini, R. (2006). Máquinas de vetores suporte para previsão de carga à curto prazo, *Proceedings of Congresso Brasileiro de Automática - IFAC* pp. 1716–1721.
- Salgado, R., Pereira, J., Ohishi, T., Ballini, R., Lima, C. e VonZuben, F. (2006). A hybrid ensemble model applied to the short-term load forecasting problem, *Proceedings of the International Joint Conference on Neural Networks* pp. 4934–4941.
- Segal, M., M., Shafir, M. e P. Albert and Y, B. (1992). Climatic-related evaluation of the summer peak-hour's electric load in israel, *Journal of Applied Meteorology* **31**: 1492–1499.
- Shahidehpour, M. e ans Z. Li, H. Y. (2002). *Market Operations in Electric Power Systems : Forecasting, Scheduling, and Risk Management*, 1 edn, Wiley-IEEE Press Hardcover.
- Shneiderman, B. (1998). *Designing the user interface : strategies for effective human-computer interaction*, Vol. 2, Addison-Wesley, Reading, MA.

- Silva, A. P. A., R., U. P., Reis, A. J. R. e Moulin, L. S. (2001). Neurodem - a neural network based short term demand forecaster, *Proceedings of IEEE - Porto Power Tech Conference* pp. 1 – 6.
- Silva, A. P. A., R., U. P., Reis, A. J. R., Moulin, L. S. e Neto, C. A. S. (2001). OrÁculo Ú uma ferramenta para previsão de carga, *Proceedings of XVI SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica* pp. 1 – 6.
- Sinha, A. K. e Mandal, J. K. (1999a). Dynamic state estimator using ann based bus load prediction, *Proceedings of the IEEE Transactions on Systems* **14**(4): 1219–1225.
- Sinha, A. K. e Mandal, J. K. (1999b). Hierarchical dynamic state estimator using ann based dynamic load prediction, *Proceedings of the IEE Generation, Transmission and Distribution* **146**(6): 541–549.
- SNC-Lavalin (2009). Snc-lavalin energy control systems (ecs), Acessado em: 20/01/2009 no endereço: <http://www.snclavalin.com/>.
- Sprague, R. H. J. e Watson, H. J. (1989). *Decision support systems: putting theory into practice*, 2 edn, Englewood Cliffs: Prentice Hall, USA.
- Sprague, R. H. J. e Watson, H. J. (1993). *Decision support systems: putting theory into practice*, 3 edn, Prentice-Hall, USA.
- Srinivasan, D., Liew, A. C. e Chen, J. S. P. (1991). A novel approach to electrical load forecasting based on a neural network, *IEEE International Joint Conference on Neural Networks* **2**: 1172–1177.
- Stoft, S. (2002). *Power System Economics : Designing Markets for Electricity*, 1 edn, Wiley-IEEE Press Paperback.
- Suarez-Farinas, M., de Sousa, R. L. e Souza, R. C. (2004). A methodology to filter time series: Application to minute-by-minute electric load series, *Pesquisa Operacional* **24**(3): 355 – 371.
- Suehring, S. (2002). *MySQL Bible*, John Wiley and Sons Ltd.
- Sullivan, R. L. (1977). *Power System Planning*, McGraw-Hill Inc, New York.
- Toshiba, I. C. P. L. (2009). Toscan-3500 - (toshiba ems/scada/das network), Acessado em: 20/01/2009 no endereço: <http://www.tic.toshiba.com.au/>.
- Turban, E. (1995). *Decision Support and Expert Systems: Management Support Systems*, 4 edn, Prentice-Hall, New York/USA.
- Vehviläinen, I. e Keppo, J. (2003). Managing electricity market price risk, *European Journal of Operational Research* **145**(1): 136–147.

- Vieira, J. P., Juhas, J. L., Negri, J. C., de Magalhães, C. H. N., Atmann, J. L., Neto, L. D. e Accioli, R. (2001). Sistema de caracterização da carga e dimensionamento da ponta do sistema elétrico do estado de são paulo, *Proceedings of XVI SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica* pp. 1 – 6.
- Warren, H. e LeDuc, S. (1981). Impact of climate on energy sector in economic analysis, *Journal of Applied Meteorology* **20**: 1431–1439.
- Watts, D. e Alvarado, F. L. (2004). Futures market impacts on electricity prices, *8a International Conference on Probabilistic Methods Applied to Power Systems - IEEE* pp. 20–25.
- Weiss, S. M. e Indurkhya, N. (1998). *Predictive Data Mining: A Practical Guide*, Morgan Kaufmann Publishers - Inc., San Francisco, CA.
- Wood, A. J. e Woolenber, B. F. (1984). *Power Generation, Operation and Control*, John Wiley & Sons.

# ***APÊNDICE A - Consumo de Energia e Previsão de Carga***

## **A.1 Consumo de Energia**

A energia é um insumo indispensável ao desenvolvimento econômico, e desempenha papel singular nas sociedades contemporâneas. De um lado, é a locomotiva da vida econômica que fornece os serviços e infra-estrutura essenciais para a civilização. De outro, sua abundância ou carência determinam vários fatores como segurança nacional, competitividade industrial, economia e a estrutura social.

Desde a antiguidade até os dias contemporâneos, o consumo energético, em diversas esferas, tem tido um comportamento com tendência positiva, acompanhando o desenvolvimento industrial nos setores da economia. Este nível crescente no consumo faz com que sejam necessárias ações para garantir a disponibilidade de energia. Neste sentido, visando garantir o crescimento econômico, a sociedade deve-se preocupar com o planejamento para maximizar a utilização dos recursos energéticos e minimizar o desperdício, principalmente quando se trata de insumos não renováveis. O problema de otimização dos recursos energéticos está presente em diversas áreas e visa manter o desenvolvimento da sociedade baseado numa política de sustentabilidade, buscando conciliar o desenvolvimento econômico com a preservação ambiental.

Quando se trata de energia elétrica, o governo tem a constante preocupação em atender o suprimento eletro-energético de forma eficiente e eficaz. Desta maneira, devem existir estratégias e planos de ação que visem produzir

energia elétrica de maneira segura, atendendo toda a demanda produtiva, minimizando riscos e perdas. Para que estas estratégias sejam coerentes e coesas, deve-se buscar alternativas que resolvam o problema de planejamento e programação do sistema elétrico de maneira otimizada (Ferreira, 2002).

O problema de planejamento e programação da operação do sistema elétrico, que compreende geração, transmissão e distribuição de eletricidade, é um problema complexo que envolve uma infinidade de variáveis, sendo necessário estimar diversos parâmetros para determinar o ponto ideal nas etapas de operação do sistema elétrico (Guille e Paterson, 1977) e (Saadat, 2002).

Atualmente, a eletricidade corresponde a uma grande parcela do consumo total de energia do Brasil (cerca de 40%) entre todos os componentes energéticos que constituem a *matriz energética nacional*. A capacidade de geração de energia elétrica no Brasil é predominantemente hidrelétrica, com apenas 16% de capacidade de origem termelétrica. Essa concentração na produção de eletricidade por fontes hidrelétricas distingue o país dentre as demais nações do mundo (ELETROBRÁS, 2008). Algumas dessas características são apresentadas a seguir:

1. Predominantemente hidrelétrico, com grandes extensões geográficas e grandes distâncias entre as fontes geradoras e os principais centros consumidores;
2. Diversos potenciais, com reservatórios de regularização plurianual;
3. Sistema interligado de transmissão entre os sub-sistemas geradores;
4. Regimes hidrológicos e pluviométricos diversos nas diferentes regiões;
5. Grande potencial hidrelétrico a ser explorado (cerca de 200 GW de capacidade instalável, com metade em aproveitamentos localizados na Amazônia).

Devido às suas características, o Setor Elétrico Brasileiro (SEB) possui alta complexidade no que diz respeito ao seu funcionamento. O problema de coordenação e operação do SEB requer a execução de várias etapas de planejamento onde o objetivo da cadeia de planejamento do sistema é proporcionar

a execução de uma política de operação econômica e confiável para o sistema de geração, transmissão e distribuição de energia. O resultado do planejamento deve prover uma seqüência de decisões que minimizem o custo da operação garantindo o atendimento da demanda. Para que o objetivo das etapas de planejamento seja alcançado, é essencial que os sistemas de geração, transmissão e distribuição estejam operando em perfeita harmonia dentro de seus limites operacionais. No caso brasileiro, o setor elétrico adota as seguintes etapas para executar o planejamento do parque gerador/transmissor de energia elétrica:

1. Planejamento da Operação: com horizontes de até cinco anos, o objetivo desta etapa é estabelecer o comportamento do sistema para um horizonte de operação de alguns anos à frente. Esta etapa deve promover o aproveitamento racional dos recursos, garantindo-se a qualidade e segurança no atendimento à demanda e a factibilidade das restrições operativas do sistema hidrotérmico.
2. Programação da Operação: o objetivo principal da programação da operação de curto prazo do sistema hidrotérmico é compatibilizar a operação do sistema hidráulico e elétrico ao longo de horizontes de curto prazo (de alguns dias até uma semana), respeitando as metas energéticas estabelecidas pelo planejamento da operação realizada em horizonte de médio prazo. Devido à sua proximidade da operação em tempo real, requer-se uma representação das restrições elétricas na programação da operação, as quais são ignoradas no planejamento da operação em horizonte de médio ou longo prazo.

No planejamento de longo e médio prazo, considera-se uma discretização mensal ou semanal para os horizontes de estudo. Como o sistema brasileiro é constituído de grandes reservatórios, com grande capacidade de regularização, utilizam-se horizontes de planejamento plurianuais. Como o grau de incerteza das afluências é alto, a representação da estocasticidade das afluências deve ser considerada.

A programação da operação visa obter um cronograma para as próximas semanas compatível com as metas traçadas pelo planejamento da operação, e servir como uma referência para a operação em tempo real do sistema.

Nesse contexto, é forte a relação da programação da operação com os aspectos operativos do sistema, uma vez que a programação da operação deve definir o número de máquinas, quanto essas devem gerar em cada intervalo de hora da próxima semana e também qual será o carregamento nas linhas de transmissão. Portanto, no cálculo desse programa de operação devem ser levados em conta diversas restrições, tais como: características operativas dos sistemas de geração e transmissão, requisitos de carga, fatores de segurança e redução de custos. A representação funcional do sistema de transmissão é fundamental para assegurar a viabilidade da operação do sistema elétrico. A operação do sistema de transmissão constitui um dos aspectos mais críticos para a operação em tempo real do sistema.

Do ponto de vista da operação de curto prazo, é importante detalhar a operação das unidades geradoras, definindo a configuração dessas unidades ao longo da próxima semana e seus respectivos pontos de operação, as restrições de operação do sistema hidrelétrico, restrições de uso múltiplo da água, restrições ambientais e as restrições de operação do sistema termelétrico.

Um problema que está fortemente relacionado com a programação da operação é a previsão de carga a curto prazo, uma vez que é em função do mercado que se determina a política de operação de cada unidade. A precisão na previsão de carga é importante, pois grandes desvios em relação à carga prevista podem levar o sistema a situações críticas. A demanda de carga é função dos requisitos do mercado, e muitos fatores influem neste comportamento, entre eles a hora do dia, o dia da semana, a temperatura e o índice de luminosidade. A previsão de curto prazo também é importante principalmente no intervalo de demanda de pico em que há grandes variações da carga em curto espaço de tempo. A previsão de carga a curto prazo auxilia no planejamento da operação no que se refere ao equilíbrio entre a geração e o consumo de potência ativa, cujo desequilíbrio pode ocasionar variações no nível da tensão, ou seja, a previsão de curto prazo pode atuar no planejamento de estratégias de controle de tensão. Na operação *on-line*, a previsão proporciona mais segurança e economia.

## A.2 O Problema de Previsão de Carga

A preocupação com o problema de estimação da carga num dado instante vem do fato da previsão ser um insumo básico ao planejamento e operação de sistemas elétricos de potência. Dentre as suas aplicações pode-se citar: *fluxo de potência ótimo, análise de estabilidade e segurança, despacho econômico, planejamento da produção, controle e operação de redes de transmissão/distribuição, entre outras.*

Do ponto de vista econômico, com a abertura do mercado de energia, em consequência da desregulamentação dos sistemas de potência, a eletricidade tem se tornado uma *commoditie*, gerando grande competição no mercado energético. Neste cenário, é fundamental maximizar o retorno dos processos de compra e venda de energia; para isso é essencial conhecer com a máxima exatidão o nível de demanda. Esta informação é importante para proporcionar a compra da quantidade correta de energia necessária, evitando as penalidades contratuais (Vehviläinen e Keppo, 2003).

Para ter um boa estimativa do consumo futuro, é essencial realizar uma previsão de carga de maneira eficiente, pois grandes erros na previsão podem gerar encargos adicionais e consequentemente afetar de forma significativa os preços das tarifas elétricas (Vehviläinen e Keppo, 2003) e (Watts e Alvarado, 2004).

De forma geral, se o mercado de eletricidade utilizar um sistema de previsão de demanda de carga que execute esta tarefa com erros reduzidos, este mercado terá uma maximização em seus lucros e com isso reduzirá suas possíveis perdas, pois o sistema estará apto a desenvolver estratégias apropriadas de forma a operá-lo (Stoft, 2002) e (Shahidehpour e ans Z. Li, 2002).

Em uma outra ótica, a previsão de carga é importante para a auxiliar a execução dos processos de controle responsáveis pela operação de um sistema elétrico de potência. Para que a empresa atue de maneira eficiente (fornecendo energia de maneira segura e econômica), ela precisa dispor de ferramentas que proporcionem um bom planejamento, evitando a ocorrência de vários problemas técnicos e operacionais. Para que o planejamento do sistema seja eficaz, deve

haver um monitoramento completo do sistema, desde a geração da energia até a entrega ao consumidor final (Sullivan, 1977).

### A.2.1 Série de Potência Elétrica

Quando um aparelho elétrico é conectado à rede de energia este aparelho passa a fazer parte do circuito elétrico. Se sua chave está na posição “ligado”, inicia-se um fluxo de uma corrente elétrica que, juntamente com a tensão associada, consomem a potência elétrica. De uma maneira geral, os aparelhos elétricos são dispositivos que transformam energia elétrica em outras formas de energia. Por exemplo: em um motor elétrico, a energia elétrica é transformada em energia mecânica de rotação do motor; em um aquecedor, a energia é transformada em calor; em uma lâmpada incandescente, a energia elétrica é transformada em energia luminosa. O tipo de conversão energética depende do objetivo e utilização de cada aparelho.

Uma corrente elétrica realiza trabalho fazendo funcionar um motor, aquecendo um fio entre outras maneiras. Tomando como base a corrente alternada, pode-se dizer que o trabalho que ela realiza por segundo, depende de sua intensidade e da voltagem. Um WATT (W) é a potência de uma corrente de 1 ampère, quando a diferença de potencial é 1 volt. Para calcular a potência elétrica usa-se equação  $P = U.i$ . Sendo que,  $U$  é a a diferença de potencial entre os terminais ou voltagem, e  $i$  a corrente que atravessa a resistência elétrica do aparelho.

O **consumo elétrico** é a energia consumida num intervalo de tempo, ou seja o produto da potência (W) da carga pelo tempo (horas, minutos ou segundos) em que esteve ligada. Uma **série de potência elétrica ou série de carga elétrica** representa uma série temporal contendo as medições de consumo elétrico em uma determinada discretização. As medições que compõem a série de potência podem ser realizadas com vários intervalos e discretizações; o intervalo de medição varia de acordo com o tipo de controle e operação a ser realizada.

A Figura A.1 ilustra a formação da série de consumo através de um exemplo simples onde três lâmpadas coloridas de 100W/h, permanecem ligadas

em paralelo, em distintos intervalos de tempo, totalizando um período de 3 horas. Neste contexto simples, nota-se que o consumo total é de 600W que é dado pela integral da potência consumida durante o tempo em que as lâmpadas permaneceram ligadas. A série de potência, neste caso, é formada pelos consumos em cada intervalo de tempo.

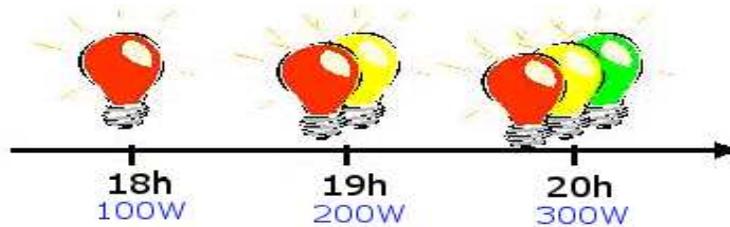


Figura A.1: Formação da Série de Potência Elétrica.

Como a série de potência elétrica é composta pela ligação simultânea de milhares de aparelhos e dispositivos, ela apresenta tendências que podem ser estatisticamente previstas. Por exemplo, no Brasil, o horário das 19 as 20h é considerado um horário de carga pesada, no qual o carregamento da linha atinge seu pico. Isto acontece devido ao padrão de comportamento brasileiro de utilizar o chuveiro elétrico no intervalo de 19 a 20h. A tendência e o comportamento da série de carga é influenciada por fatores que interferem em sua forma. Caracterizar a carga elétrica significa conhecer a forma como os clientes utilizam a energia, pois a carga é uma variável muito dependente de seu consumidor, seja ele residencial, comercial ou industrial. Em geral, a carga sofre influências de muitos fatores como: eventos televisivos, econômicos, dentre outros, ou seja, pode variar com o tempo.

No Brasil o SEB geralmente fornece energia elétrica para diferentes tipos de clientes e consumidores. Tais clientes podem ser classificadas como: clientes residenciais, comerciais e industriais. Nestas classes de consumidores podem-se observar algumas características:

1. Residencial → carga sensível às condições meteorológicas, a mudanças econômicas e tarifárias.
2. Comercial → carga sensível à sazonalidade, como em datas comemorativas, condições meteorológicas, e mudanças econômicas.

3. *Industrial* → carga bem específica, definida pelo número de turnos de operação útil. Geralmente tem curvas de cargas suaves e constantes, indicando pouca variabilidade.

Normalmente, o perfil de cada classe descrita acima é influenciado pelo comportamento típico de cada padrão. Os fatores que influenciam a carga residencial dependem, basicamente, do consumo individual e familiar. Os consumos comercial e industrial dependem do grau de venda e produção, respectivamente. Estes setores são fortemente influenciados pela economia do país.

#### **A.2.1.1 Fatores que Influenciam a Carga**

Existem vários fatores que influenciam o perfil da curva de carga. O maior ou menor consumo de energia está diretamente ligado a variáveis que proporcionam mudanças no hábito e comportamento dos clientes. Os fatores que têm maior influência sobre o comportamento de consumo energético, influenciando a curva de carga, podem ser classificados como:

**Fatores climáticos:** mudam o padrão de consumo em um curto espaço de tempo. Neste tipo de variável destacam-se: temperatura, velocidade do vento, neblina, umidade relativa do ar, chuvas, descargas elétricas, entre outros. De todos os fatores mencionados, a temperatura é uma variável que influencia diretamente o consumo de energia elétrica, delimitando o maior ou menor uso de aparelhos de condicionadores de ar, aquecedores, refrigeradores (Gross e Galiana, 1987), (Vehviläinen e Keppo, 2003) e (Watts e Alvarado, 2004).

**Fatores econômicos e demográficos:** ocorrem a longo prazo e possuem importância fundamental na evolução da carga. Exemplos: crescimento da área demográfica (rural, residencial, industrial), desenvolvimento industrial, aparecimento de novas indústrias, variação na agricultura, tendências econômicas, variação nos preços de eletricidade (Gross e Galiana, 1987), (Vehviläinen e Keppo, 2003) e (Watts e Alvarado, 2004).

**Fatores de calendário:** Influenciam a carga através de datas comemorativas de comportamentos com efeitos sazonal. No comportamento sazonal, observa-se a

variação da carga nos acontecimentos em determinados períodos do ano: férias, feriados, início do ano letivo, natal, ano novo, entre outros (Kim et al., 1995) e (Gross e Galiana, 1987).

**Fatores isolados:** Fatores aleatórios que causam perturbações na carga, tais como: eventos esportivos, programas de televisão, paralisação das indústrias, início ou parada de eventos onde a carga elétrica é alta (Gross e Galiana, 1987).

### A.2.2 Modelos Previsão de Carga

Em uma visão pragmática, o problema de previsão de carga pode ser classificado como um problema de predição de séries temporais, onde o histórico de dados utilizado é formado por medições de séries de carga, conforme descrito anteriormente.

A previsão de séries temporais é um problema no qual o principal fator é encontrar um modelo que represente de maneira fiel o comportamento da série ao longo do tempo. A Figura A.2 retrata o esquema clássico de um modelo de previsão de séries temporais, com várias entradas em instantes anteriores e uma saída que representa a previsão no instante  $t$ .

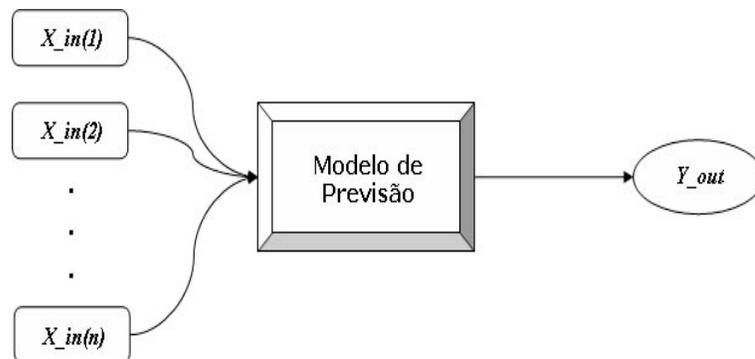


Figura A.2: Modelo de Previsão Simples.

A previsão de séries temporais de carga elétrica é um problema que possui uma solução não-trivial, haja visto que uma série de carga, como visto anteriormente, pode ter diversos padrões, e tais comportamentos podem não ser tratados de maneira conjunta em um único modelo de previsão. Outro fator

relevante é que o comportamento da série de carga geralmente apresenta característica não-linear, o que dificulta o aprendizado dos modelos de previsão. A complexidade do problema pode variar de acordo com o período e número de séries a serem previstas.

Na literatura, existem diversas técnicas para a previsão de carga a curto prazo. Alguns autores utilizam métodos estatísticos tradicionais, tais como os métodos baseados em alisamento exponencial (Hesterberg, 1989) e modelos autorregressivos (Gross e Galiana, 1987). Atualmente, tem sido intensificado o uso de abordagens alternativas para a previsão de cargas, baseadas no conceito de inteligência artificial, particularmente, as Redes Neurais Artificiais (RNAs), cuja vantagem está no fato do conhecimento ser extraído da base de dados sem a necessidade do conhecimento prévio do modelo das cargas (Srinivasan et al., 1991) e (Park et al., 1991). Contudo, RNAs também têm mostrado alguns obstáculos devido à sua estrutura genérica. Duas desvantagens comumente citadas são que os modelos neurais usualmente requerem a estimação de um grande número de parâmetros para atingir bons resultados e que normalmente é necessário projetar *a priori* uma topologia de rede além de ter um conhecimento prévio sobre a série analisada.

As redes neurais nebulosas (*redes neurofuzzy*) vêm sendo aplicadas para sistemas de identificação não-linear, controle de processos, reconhecimento de padrões e previsão de séries temporais (Ballini e Gomide, 2001) e (Kadowaki et al., 2002). Esta rede utiliza as características de RNA e lógica nebulosa, resultando em um sistema integrado onde a aprendizagem e o poder computacional dos modelos de RNA e a capacidade de representação e raciocínio da lógica nebulosa são combinados.

Atualmente, os modelos de previsão de carga têm se baseado também em modelos híbridos que utilizam abordagens de aprendizado de máquina (*Support Vector Machines - SVMs*). (Bo-Juen et al., 2004) utilizou a ferramenta SVMs para realizar a previsão da carga máxima durante os 31 dias de um determinado mês. O modelo utilizou como dado de entrada informações climáticas; os resultados do modelo foram previsões acuradas para os 31 valores desejados.

Os trabalhos de (Salgado, Pereira, Ohishi, Ballini, Lima e VonZuben, 2006), (Salgado, Pereira, Ohishi e Ballini, 2006) e (Pereira et al., 2006) também utilizaram SVMs para previsão um passo a frente da curva de carga horária (próximo dia). Os resultados encontrados nestes trabalhos são promissores.

Comumente existem dois tipos de previsão de carga pesquisadas na literatura: **Previsão de carga global ou individual** e **previsão de carga por barramento ou modular**. A previsão de carga global/individual preocupa-se em realizar a previsão em uma única série temporal de carga global. A previsão de carga por barramento preocupa-se em prever um conjunto de séries temporais onde cada série representa a demanda de um barramento do sistema. Esta característica faz com que a complexidade do problema de previsão de carga por barramento seja proporcional ao número de barramentos do sistema.

### A.2.2.1 Horizontes de Previsão de Carga

A classificação do tipo de previsão de carga varia de acordo com o período em que a carga é prevista. Na literatura especializada existem quatro horizontes de previsão de cargas (Gross e Galiana, 1987), (Wood e Woolenber, 1984), (Al-Kandari et al., 2004) and (Rahman, 1990):

1. **Previsão de Carga a Longo Prazo:** este tipo de previsão é realizada principalmente para o planejamento da expansão da capacidade de sistemas de potência. Essa previsão envolve um período de 10 a 20 anos. Esses tipos de previsões não consideram os dados de carga elétrica diária ou semanal, somente a tendência do consumo e variáveis econômicas.
2. **Previsão de Carga a Médio Prazo:** é feita para o planejamento de suprimento de combustível, programas de manutenção, planejamento de produção a médio prazo, planejamento da operação de reservatórios e intercâmbios. Abrange o período de poucas semanas, meses ou até mesmo alguns anos.
3. **Previsão de Carga a Curto Prazo:** é utilizada na programação de operações diária, transferência de energia e gerenciamento da demanda. A previsão é

feita com intervalo de discretização de 30 minutos até 1 semana à frente. A previsão de carga a curto prazo estima a carga para cada hora do dia, pico de carga diária.

4. **Previsão de Carga a Curtíssimo Prazo:** são essencialmente usadas para a operação e controle *on-line* da produção de energia elétrica. A previsão varia num intervalo de poucos segundos até 15 minutos.

## ***APÊNDICE B - Modelagem - Banco de Dados SysPrev***

Este capítulo trata sobre abordagens de armazenamento de informações, com ênfase ao modelo de representação de dados entidade-relacionamento (ER). É feita uma descrição da ferramenta de banco de dados utilizada para armazenar os dados do sistema, mostrando suas características e vantagens. Destaca-se neste capítulo a proposta da modelagem desenvolvida para armazenamento dos dados de carga elétrica e variáveis relevantes, visando facilitar o acesso à base de dados utilizada para validar os modelos de mineração de dados e previsão.

### **B.1 Análise Metodológica**

#### **B.1.1 Arquitetura de Banco de Dados**

Atualmente, a informação é um dos principais insumos que geram e alimentam as transações em qualquer nível em uma corporação. Quando se fala no problema de operação do sistema elétrico de potência deve-se pensar na qualidade da informação bem como na sua disponibilidade em um curto espaço de tempo. Disponibilizar informações de maneira rápida e confiável é fundamental, pois uma falha no envio da informação correta no momento em que esta foi solicitada pode levar o sistema elétrico ao caos, gerando apagões e prejuízos não mensuráveis (Gulutzan e Pelzer, 2002).

Na medida em que as empresas informatizam os seus processos, as aplicações evoluem para atender as exigências operacionais. Este crescimento

atinge diretamente as bases de dados das organizações, que cada vez tornam-se maiores e mais complexas. Por esse motivo, a cada dia aumenta-se a preocupação com a velocidade dos bancos de dados, isto é, o rápido armazenamento e recuperação das informações (Suehring, 2002).

A solução para o problema de armazenamento e recuperação de informações tem sido encontrada nos Sistemas Gerenciadores de Banco de Dados (SGBDs). Esta abordagem é adotada para armazenar e gerenciar dados em grandes organizações no mundo, inclusive no setor elétrico brasileiro. Estes SGBDs são responsáveis por (Date, 2003):

- Controlar a concorrência (i.e., múltiplas conexões ao banco simultaneamente);
- Manter a integridade dos dados armazenados;
- Otimizar o caminho de busca de uma informação;
- Gerenciar as permissões de usuários;
- Reindexar as tabelas de acordo com os índices criados à medida que os dados são modificados.

### **B.1.2 Sistemas Gerenciadores de Banco de Dados**

Os SGBDs são um marco na história da tecnologia em armazenamento de dados. Através deles, passou a existir uma estrutura que fornece suporte ao programador, sem a necessidade de preocupação com várias etapas do processo de manipulação dos dados.

A história dos SGBDs começou antes mesmo dos computadores, com os registros das bibliotecas, as técnicas de armazenamento de documentos e com os índices dos livros. Ao entender isso, fica fácil perceber que o uso de índices para busca de informações em bancos de dados não se trata de algo novo, mas sim de um método já existente há muito tempo que foi ajustado para o uso no ambiente computacional (Codd, 1972).

No final da década de 60, foi proposto o modelo de dados relacional; tal modelo caracterizou um marco no modo de pensar em relação ao banco de dados, e desde então este sistema se tornou um padrão (Codd, 1972). Nessa mesma década foram lançados os primeiros protótipos de sistemas relacionais. Um pouco mais tarde foi proposto o modelo de Entidade-Relacionamento, ou simplesmente modelo ER. Esse modelo possibilita que o projetista concentre-se apenas na utilização dos dados, sem se preocupar com a estrutura lógica das tabelas (Chen, 1977).

O modelo relacional caracteriza-se por uma coleção de tabelas, cada qual designada por um nome único. Uma *tupla* em uma tabela representa um relacionamento entre um conjunto de valores. Uma vez que uma tabela é uma coleção de relacionamentos, existe uma correspondência entre o conceito de tabela e o conceito matemático de relação. Por essa correspondência entre tabela e relação, originou-se o nome “modelo relacional” (Codd, 1972).

Na década de 80, a linguagem estruturada de consulta, ou simplesmente SQL, se tornou um padrão mundial, transformando e dando vida à sistemática de armazenamento de dados (ANSI, 1986).

Os SGBDs possuem algumas definições na literatura: sistema de manutenção de registros via computador (Date, 2003), sistemas de coleção de objetos que mantêm e manipulam dados (Gulutzan e Pelzer, 2002) ou sistemas que gerenciam uma coleção de uma ou mais tabelas de informações (Suehring, 2002). Os SGBDs têm como diferencial o controle de integridade dos dados, pois as suas tabelas estão relacionadas, permitindo um controle rápido e seguro. Estes sistemas são responsáveis por (Date, 2003):

- Controlar a concorrência: quando duas ou mais sessões tentam acessar e/ou manipular os mesmos dados simultaneamente, o SGBD tem a responsabilidade de permitir o acesso eficiente para todas as sessões, mantendo rigorosamente a integridade dos dados;
- Manter a integridade referencial: o SGBD é totalmente responsável por manter a integridade referencial definida em seu esquema, sem precisar em nenhum momento do auxílio do programa aplicativo;

- Escolher o menor caminho para a busca de uma informação: todo SGBD possui um mecanismo chamado de otimizador, que é responsável por gerar um plano de acesso à base de dados sempre que uma instrução SQL é executada.
- Gerenciar as permissões de usuários: o SGBD é responsável por bloquear o acesso a objetos do banco de dados que não estão autorizados para determinados usuários e habilitar o seu acesso a quem for configurado dessa forma, protegendo assim a segurança dos dados;
- Atualizar os índices: o uso dos índices é de imensa importância para um bom desempenho em um banco de dados.

Existem vários SGBDs disponíveis no mercado. Alguns desenvolvidos por grandes corporações e outros desenvolvidos com base na filosofia *open-source*; estes produtos mantêm todas as características apresentadas anteriormente. Neste trabalho, optou-se por utilizar o SGBD MySQL - ©1995-2008 MySQL AB, 2008-2009 Sun Microsystems, Inc. Este gerenciador de dados se tornou o mais popular banco de dados *open-source* do mundo porque possui consistência, alto desempenho, confiabilidade e é de fácil utilização. Atualmente, é usado em mais de 6 milhões de instalações em todos os continentes, desde instalações em grandes corporações à aplicações específicas. Na seção abaixo são descritas algumas características do SGBD MySQL.

#### **B.1.2.1 MySQL**

O MySQL é um sistema gerenciador de bancos de dados relacional rápido, desenvolvido pela MySQL AB. Faz parte do grupo dos SGBDs desenvolvidos como software livre, tendo a característica de ser rápido e enxuto. Foi desenvolvido em linguagem C/C++ e possui versões habilitadas a operar os diversos sistemas operacionais.

Hoje o MySQL está classificado entre SGBDs mais rápidos e robustos do mercado. No item segurança, o MySQL fornece um sistema de privilégios e

senhas que é muito flexível, seguro e que permite verificação baseada em estações/máquinas, sendo que todo o tráfego de senhas é criptografado quando o usuário conecta ao servidor.

O sistema MySQL é distribuído sob a GNU, *General Public License - (GPL)* podendo ser usado gratuitamente para as mais variadas aplicações.

Pelas razões descritas anteriormente, o MySQL foi definido como repositório de dados padrão para o desenvolvimento do subsistema de banco de dados neste projeto. É importante destacar que os comandos SQL utilizados na manipulação das informações existentes na base de dados (seleção, gravação, atualizações, entre outros) seguem o formato ANSI (ANSI, 1986) que é padronizado em todos os SGBDs existentes no mercado. Assim, o sistema em desenvolvimento tem a flexibilidade de “migrar” de um SGBD para outro SGBDs sem grandes dificuldades.

## **B.2 Projeto de Banco de Dados**

Sistematizar as informações e variáveis envolvidas no problema de previsão de carga em uma base de dados sólida não é uma tarefa trivial; existem diversos processos que devem ser analisados para garantir a consistência e funcionalidade do modelo de dados abordado. Não basta apenas conhecer a arquitetura de armazenamento, deve-se principalmente compreender o significado da informação a ser armazenada. Quando há uma boa integração entre o conhecimento da arquitetura de armazenamento e os dados a serem guardados, o resultado é uma base dinâmica, flexível e de fácil acesso.

Projetar um banco de dados não é uma tarefa realizada apenas por profissionais da área de computação, pois existe a necessidade de conhecimentos especializados para garantir a integridade da informação. O objetivo da modelagem de dados é transmitir e apresentar uma representação única, não redundante e resumida dos dados de uma aplicação (Maciaszek, 1990).

Para se conhecer as necessidades de informação de uma realidade, precisa-se de um modelo que mostre como as informações pertinentes estão rela-

cionadas. Espera-se que, com base no modelo criado, o analista possa interagir com o sistema, extraindo seu máximo desempenho e validando seus procedimentos.

A utilização de uma abordagem correta de metodologia orientada a banco de dados envolve a estruturação em etapas definidas para a criação de um projeto de banco de dados. Nesta ótica, existem três etapas fundamentais para o bom funcionamento da arquitetura de armazenagem definidos como elementos de abstração: **Modelo Conceitual**, **Modelo Lógico** e **Modelo Físico** (Date, 2003).

O **Modelo Conceitual** representa e descreve a realidade do ambiente definido pelo problema, constituindo-se em uma visão global dos principais dados e relacionamentos, independente das restrições de implementação. O objetivo desta etapa é descrever as informações contidas no mundo real e que deverão estar armazenadas na base de dados. É uma descrição de alto nível, que tem a preocupação de captar e retratar toda a realidade de um problema. No contexto do problema em análise, esta etapa visa descrever quais serão os dados relevantes que devem fazer parte da base de dados para resolver o problema de previsão.

No **Modelo Lógico** são descritas todas as estruturas que estarão contidas no banco de dados, de acordo com as possibilidades e permissões dadas pela abordagem adotada. Esta fase é realizada levando em consideração as informações obtidas no modelo conceitual.

O **Modelo Físico** irá a partir dos modelos anteriores descrever as estruturas físicas de armazenamento, tais como: tamanho de campos, índices, tipos de preenchimento, entre outras informações. Este modelo detalha o estudo dos métodos de acesso do SGBD, para elaboração dos índices de cada informação inserida nos modelos conceitual e lógico (Gulutzan e Pelzer, 2002).

### **B.2.1 Modelagem Proposta**

Neste tese de doutoramento, um dos objetivos foi projetar e definir um subsistema gerenciador de dados que facilite a utilização de informações relevantes na previsão de carga elétrica. Para atender este requisito várias abordagens

de modelagem foram avaliadas, buscando sempre atender os objetivos maximizando os resultados.

Quando se trata do problema de previsão de carga, a primeira pergunta que surge, geralmente, diz respeito ao tipo de informação que deve ser levada em consideração para estudar o fenômeno de previsão e obter resultados satisfatórios. Na revisão da bibliografia, observou-se que os autores são unânimes ao destacar os fatores que influenciam significativamente a curva de carga elétrica e, conseqüentemente, a precisão nos resultados de previsão. Entre as variáveis citadas pode-se afirmar que na previsão de carga a curto prazo, a temperatura, luminosidade e os dias do calendário são os principais fatores que fazem com que o comportamento da carga seja modificado, dificultando os estudos de previsão (Gross e Galiana, 1987).

#### **B.2.1.1 Modelo Conceitual**

A Figura B.1 apresenta o modelo conceitual do banco de dados proposto para a abordagem deste problema. Este modelo foi desenvolvido avaliando as principais informações que influenciam os resultados da previsão de carga. Desta forma, é desejável que a base de dados contenha todas as informações descritas no modelo conceitual. A disponibilidade destas variáveis na base de dados aumenta a probabilidade de obter uma previsão mais acurada.

Como pode ser observado, ao construir o modelo conceitual no problema de previsão de carga, deve-se ter a preocupação em armazenar as seguintes variáveis: **medições de carga** - armazenadas na menor discretização possível, **dados climáticos** e **dados de calendário** - armazenando todos os tipos de datas especiais que a priori forem conhecidas. As variáveis de cunho econômico num primeiro plano não são extremamente necessárias, principalmente quando se trata de problemas de previsão de carga a curtíssimo e curto prazo, onde tendências econômicas não têm grande influência sobre o comportamento da carga. A mesma análise é feita para as variáveis de cunho esporádico. Apesar das mesmas influenciarem significativamente a carga, é impossível saber quando estas irão acontecer. Logo, sua utilização se torna imprópria na previsão, sendo neces-

sária apenas para explicar a existência de *outliers*.

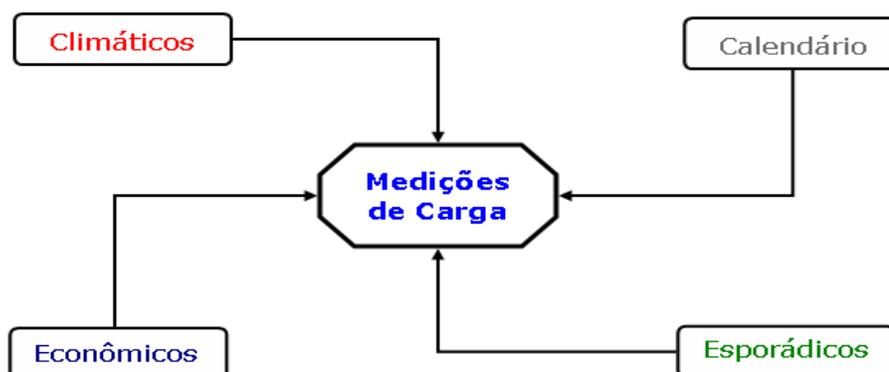


Figura B.1: Modelo Conceitual - Banco de Dados.

No problema de previsão de carga a curto prazo por barramento, além de pensar em armazenar as variáveis descritas anteriormente, deve-se também definir os barramentos aos quais os valores estão associados. Nesta visão, é importante inserir um identificador dentro do modelo para que este possa discernir qual é o barramento associado aos dados que estão sendo processados pelo sistema.

### B.2.1.2 Modelo Lógico

A implementação do modelo lógico do banco de dados do sistema compreende a criação de um modelo ER (entidade-relacionamento) formado por tabelas e relacionamentos que fazem referência entre as informações inseridas em diversas tabelas.

O esquema apresentado na Figura B.2 mostra a diagramação desenvolvida para representar as informações que serão acessadas pelo sistema. Observa-se que as tabelas estão divididas por quatro blocos, onde cada um caracteriza tipos de informações semelhantes. Estes blocos de informação representam tipos de dados que caracterizam o seu conteúdo e estão divididas em: **Sistemas**, **Barramentos\_Cargas**, **Datas** e **Climática**.

A região **Sistemas** armazena as informações sobre o sistema interligado nacional (SIN) através de duas tabelas: *SIN\_Regional* e *Sist\_Transmissao*.

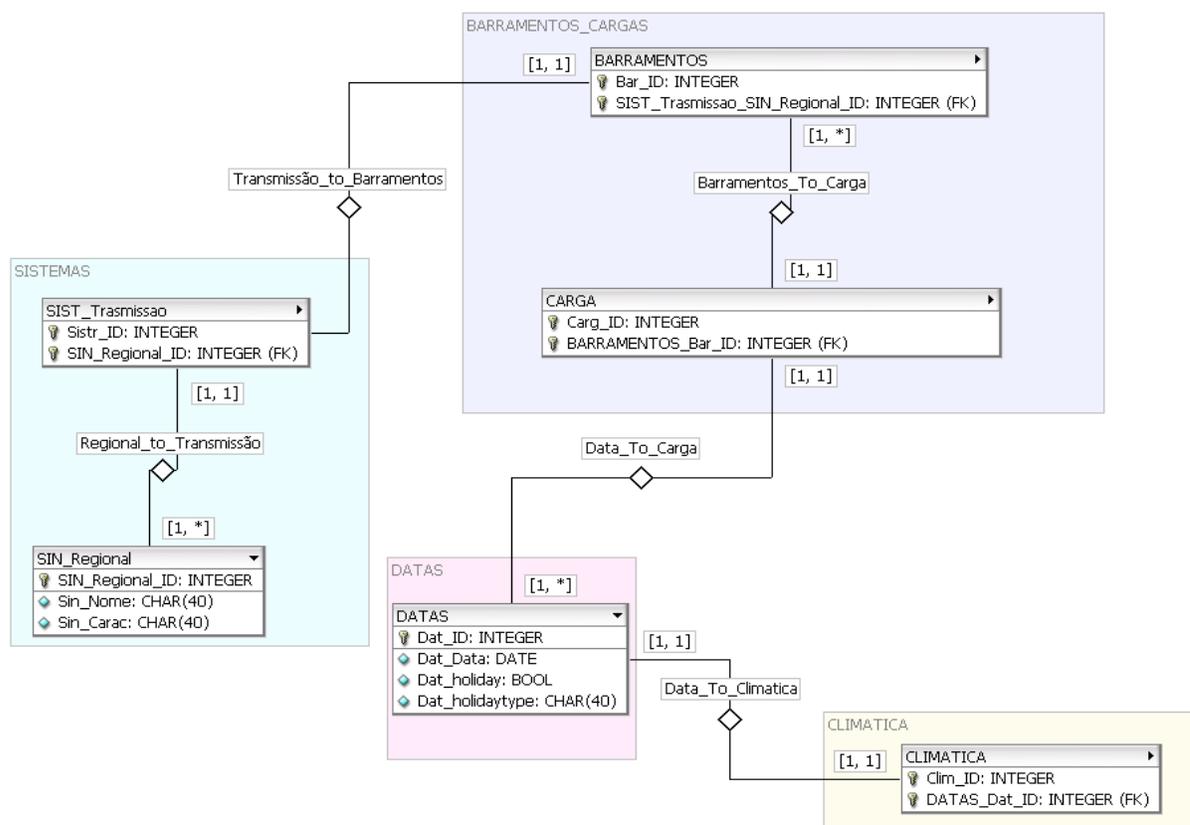


Figura B.2: Modelo Lógico - Banco de Dados.

A tabela *SIN\_Regional* armazena as divisões do SIN, de acordo com o Operador Nacional do Sistema (ONS). Nesta tabela tem-se os subsistemas regionais: **Norte, Nordeste, Sul e Sudeste/Centro-Oeste**. A tabela *Sist\_Transmissao* armazena os sistemas de transmissão, divididos por área de concessão, pertencentes a cada um dos sistemas regionais.

A região **Barramentos\_Cargas** contém informações sobre os barramentos e suas respectivas cargas por meio de duas estruturas: *BARRAMENTOS* e *CARGA*. A tabela *BARRAMENTOS* armazena informações sobre o número de barramentos que cada sistema de transmissão (tabela *Sist\_Transmissao*) possui em sua rede elétrica. A tabela *CARGA* contém as medições de potência ativa, discretizadas em base horária, para cada informação da tabela *BARRAMENTOS*. Pode-se dizer que esta tabela contém as principais e mais ricas informações de toda a base de dados.

As regiões **DATAS** e **CLIMATICA** guardam as informações de calendário e dados climáticos nas tabelas **DATAS** e **CLIMATICA**, respectivamente. Na tabela **DATAS** estão armazenadas as informações de feriados, datas específicas e tipos de dias especiais. A tabela **CLIMATICA** contém as informações de temperatura, luminosidade, cobertura, estação do ano, entre outras variáveis relativas a cada elemento expresso na tabela **DATA**.

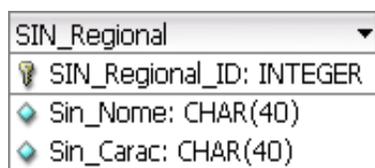
### B.2.1.3 Tabelas e Relacionamentos

#### A – Descrição do Conteúdo: Tabelas

As Figuras B.3 a B.8 mostram as tabelas que compõem o banco de dados projetado para armazenar os dados para o problema de previsão de carga por barramento. Nas descrições abaixo não serão levadas em consideração as chaves primárias, que descrevem os índices de cada elemento da tabela.

Na Figura B.3 observa-se todos os componentes da tabela *SIN\_Regional*. Esta tabela contém as informações dos sistemas regionais dispostas em 2 atributos:

- Sin\_Nome ⇒ Retrata o nome do sistema regional pertencente ao SIN. Por exemplo: N - Norte, NO - Nordeste, S - Sul, SE/CO - Sudeste/Centro-Oeste.
- Sin\_Carac ⇒ Descreve algumas características de cada sistema regional.



SIN_Regional
🔑 SIN_Regional_ID: INTEGER
🔹 Sin_Nome: CHAR(40)
🔹 Sin_Carac: CHAR(40)

Figura B.3: Tabela Sistema Regional - Banco de Dados.

A representação da tabela *SIN\_Regional*, no banco de dados, é mostrada na Tabela B.1:

A Figura B.4 mostra a modelagem da tabela *Sist\_Transmissao*. Nesta estrutura observa-se a existência de 4 atributos que caracterizam sua estrutura.

Tabela B.1: Exemplo: Tabela *SIN\_Regional*.

<b>SIN_Regional_ID</b>	<b>Sin_Nome</b>	<b>Sin_Carac</b>
<b>1</b>	Sistema S	SIN - Ramificação: Sul
<b>2</b>	Sistema N	SIN - Ramificação: Nordeste
<b>3</b>	Sistema NO	SIN - Ramificação: Norte
<b>4</b>	Sistema SE/CO	SIN - Ramificação: Sudeste/Centro-Oeste

Existe também 1 atributo herdado da tabela *SIN\_Regional* mostrando que existe um relacionamento entre as duas estruturas. As informações são expressas de acordo com os seguintes índices:

- Sistr\_Nome ⇒ Descreve o nome do sistema e/ou empresa de transmissão;
- Sistr\_Num\_Barras ⇒ Aponta o número de barramentos que compõe o sistema de transmissão;
- Sistr\_Caract ⇒ Mostra características do sistema de transmissão.
- Sistr\_Inf\_Extras ⇒ Mostra informações extras relativas ao sistema em análise.

SIST_Transmissao	
🔑	Sistr_ID: INTEGER
🔑	SIN_Regional_ID: INTEGER (FK)
🔹	Sistr_Nome: CHAR(40)
🔹	Sistr_Num_Barras: INTEGER
🔹	Sistr_Caract: CHAR(100)
🔹	Sistr_Inf_Extras: CHAR(100)
📁	SIST_REGIONAL_FKIndex1
🔑	SIN_Regional_ID

Figura B.4: Tabela Sistema Transmissão - Banco de Dados.

A Tabela B.2 representa o formato da tabela *Sist\_Transmissao* na base de dados.

Tabela B.2: Exemplo: Tabela *Sist\_Transmissao*.

Sistr_ID	SIN_Regional_ID	Sistr_Nome	Sistr_Num_Barras	Sistr_Caract	Sistr_Inf_Extras
1	2	Sist_A	12	[13.8 - 69 Kv]	Transmissão
2	2	Sist_B	22	[1 - 13.8Kv]	Distribuição

A Figura B.5 mostra a estruturação da tabela *BARRAMENTOS*, onde é possível observar a existência de 4 atributos que caracterizam as informações de cada barramento e 2 atributos oriundas das tabelas *SIN\_Regional* e *Sist\_Transmissao*. As duas colunas adicionais evidenciam a existência de relacionamentos entre as estruturas tabulares *BARRAMENTOS*, *SIN\_Regional* e *Sist\_Transmissao*. Na tabela *BARRAMENTOS*, as informações são expressas pelos seguintes itens:

- Bar\_Nome ⇒ Descreve o nome do barramento;
- Bar\_Volt ⇒ Aponta a tensão operativa do barramento;
- Bar\_Loc\_Geog ⇒ Apresenta a localização geográfica do barramento;
- Bar\_Carac\_Elet ⇒ Mostra as características elétricas do barramento;

BARRAMENTOS	
Bar_ID	INTEGER
SIST_Trasmissoao_SIN_Regional_ID	INTEGER (FK)
SIST_Trasmissoao_Sistr_ID	INTEGER (FK)
Bar_Nome	CHAR(40)
Bar_Volt	FLOAT
Bar_Loc_Geog	CHAR(100)
Bar_Carac_Elet	CHAR(100)
BARRAMENTOS_FKIndex1	
SIST_Trasmissoao_SIN_Regional_ID	
SIST_Trasmissoao_Sistr_ID	

Figura B.5: Tabela Barramentos - Banco de Dados.

A Tabela B.3 representa o formato da tabela *BARRAMENTOS* no interior da base de dados.

Tabela B.3: Exemplo: Tabela *BARRAMENTOS*.

Bar_ID	SIN_Regional_ID	Sistr_ID	Bar_Nome	Bar_Volt	Bar_Loc_Geog	Bar_Carac_Elet
<b>1</b>	2	1	Barra_A	69.0	Regiao_A	ND
<b>2</b>	2	1	Barra_B	13.8	Regiao_B	ND

A Figura B.6 mostra a montagem da tabela *CARGAS*. Nesta tabela encontram-se todas as medições relativas aos dados de carga do sistema. Esta estrutura está definida por 24 atributos, que apresentam todas as cargas discretizadas em base horária e também outros atributos que mostram os relacionamentos da tabela *CARGAS* com as demais estruturas tabulares do sistema. Como esta tabela contém a principal informação do sistema, é natural que haja diversos relacionamentos que facilitem a busca de informações nesta base. Os seguintes itens compõem a estrutura desta tabela principal:

- *Carg\_hor1* ⇒ Armazena a carga da hora 1 em todos os barramentos do sistema;
- *Carg\_hor2* ⇒ Armazena a carga da hora 2 em todos os barramentos do sistema;
- ...
- *Carg\_hor24* ⇒ Armazena a carga da hora 24 em todos os barramentos do sistema;

A Tabela B.4 mostra o formato da tabela *CARGA* na base de dados. Um comentário importante é que o modelo utilizado para armazenar a base de dados, com destaque para tabela *CARGA*, permite o acesso a qualquer medida de carga em qualquer barramento, utilizando comandos simples na estrutura SQL. Isto faz com que seja possível selecionar qualquer tipo de dado com extrema facilidade, fornecendo ao sistema maior flexibilidade na consulta aos dados para previsão.

A Figura B.7 mostra a estruturação da tabela *DATAS*, onde é possível observar a existência de 3 atributos que caracterizam as informações. Na tabela *DATAS* as informações são expressas pelos seguintes itens:

CARGA	
🔑	Carg_ID: INTEGER
🔑	BARRAMENTOS_Bar_ID: INTEGER (FK)
🔑	BARRAMENTOS_SIST_Trasmissoa_SIN_Regional_ID... (FK)
🔑	BARRAMENTOS_SIST_Trasmissoa_Sistr_ID: INTEGER (FK)
🔑	DATAS_Dat_ID: INTEGER (FK)
◆	Carg_hor1: FLOAT(10,4)
◆	Carg_hor2: FLOAT(10,4)
◆	Carg_hor3: FLOAT(10,4)
◆	Carg_hor4: FLOAT(10,4)
◆	Carg_hor5: FLOAT(10,4)
◆	Carg_hor6: FLOAT(10,4)
◆	Carg_hor7: FLOAT(10,4)
◆	Carg_hor8: FLOAT(10,4)
◆	Carg_hor9: FLOAT(10,4)
◆	Carg_hor10: FLOAT(10,4)
◆	Carg_hor11: FLOAT(10,4)
◆	Carg_hor12: FLOAT(10,4)
◆	Carg_hor13: FLOAT(10,4)
◆	Carg_hor14: FLOAT(10,4)
◆	Carg_hor15: FLOAT(10,4)
◆	Carg_hor16: FLOAT(10,4)
◆	Carg_hor17: FLOAT(10,4)
◆	Carg_hor18: FLOAT(10,4)
◆	Carg_hor19: FLOAT(10,4)
◆	Carg_hor20: FLOAT(10,4)
◆	Carg_hor21: FLOAT(10,4)
◆	Carg_hor22: FLOAT(10,4)
◆	Carg_hor23: FLOAT(10,4)
◆	Carg_hor24: FLOAT(10,4)
📁	CARGA_FKIndex1
🔑	BARRAMENTOS_Bar_ID
🔑	BARRAMENTOS_SIST_Trasmissoa_SIN_Regional_ID
🔑	BARRAMENTOS_SIST_Trasmissoa_Sistr_ID
📁	CARGA_FKIndex2
🔑	DATAS_Dat_ID

Figura B.6: Tabela Cargas - Banco de Dados.

Tabela B.4: Exemplo: Tabela CARGA.

<b>Carg_ID</b>	Bar_ID	SIN_Regional_ID	Sistr_ID	DATAS_ID	Carg_hor1	...	Carg_hor24
<b>1</b>	1	2	Barra_A	01/06/2001	69.0	...	65.7
<b>2</b>	1	2	Barra_A	02/06/2001	13.8	...	12.6

- Dat\_Data ⇒ Armazena as datas relativa a cada medição de carga;
- Dat\_holiday ⇒ Identificador booleano que detecta se a data é ou não feriado;
- Dat\_holidaytype ⇒ Caso a data em análise seja feriado, este campo informa o tipo de data comemorativa;

DATAS	
🔑	Dat_ID: INTEGER
🔹	Dat_Data: DATE
🔹	Dat_holiday: BOOL
🔹	Dat_holidaytype: CHAR(40)

Figura B.7: Tabela Datas - Banco de Dados.

O exemplo mostrado na Tabela B.5 apresenta o formato da tabela *DATAS* na base de dados.

Tabela B.5: Exemplo: Tabela *DATAS*.

<b>Dat_ID</b>	Dat_Data	Dat_holiday	Dat_holidaytype
<b>1</b>	14/11/2001	Nao	-
<b>2</b>	15/11/2001	Sim	Proclamação da República

A Figura B.8 mostra a estruturação da tabela *CLIMATICA*, onde é possível observar a existência de 5 atributos que compõe informações que influenciam a carga. Na tabela *CLIMATICA* as informações são compostas pelas seguintes variáveis:

- Clim\_Temp ⇒ Armazena a temperatura máxima do dia relativo à medição de carga;

- Clim\_Lum ⇒ Armazena a luminosidade média do dia;
- Clim\_Rad\_sol ⇒ Armazena a radiação solar média do dia;
- Clim\_Cobertura\_dia ⇒ Mostra o nível médio de cobertura do dia;
- Clim\_Est\_ano ⇒ Mostra a estação do ano para cada dia do histórico.

The screenshot shows the table definition for 'CLIMATICA'. It lists the following fields and their data types:
 

- Clim\_ID: INTEGER (Primary Key)
- DATAS\_Dat\_ID: INTEGER (FK)
- Clim\_Temp: FLOAT(10,4)
- Clim\_Lum: FLOAT(10,4)
- Clim\_Rad\_sol: FLOAT(10,4)
- Clim\_Cobertura\_dia: CHAR(40)
- Clim\_Est\_ano: CHAR(40)

 Additionally, there is a foreign key constraint named 'CLIMATICA\_FKIndex1' on the 'DATAS\_Dat\_ID' field.

Figura B.8: Tabela Climática - Banco de Dados.

O exemplo mostrado na Tabela B.6 apresenta o formato da tabela *CLIMATICA* na base de dados.

Tabela B.6: Exemplo: Tabela *CLIMATICA*.

Clim_ID	Dat_ID	Clim_Temp	Clim_Lum	Clim_Rad_sol	Clim_Cobertura_dia	Clim_Est_ano
1	1	27.9	78	155	Parcialmente coberto	Verão
2	2	30.2	25	95	Coberto	Verão

## B – Análise: Relacionamentos entre Tabelas

Após a análise das estruturas tabulares que compõe o banco de dados é fundamental realizar um estudo sobre os relacionamentos que fazem ligação e concatenam as informações de todas as tabelas do banco.

O banco de dados proposto contém 6 tabelas ligadas por 5 tipos de relacionamentos. Quatro tabelas possuem 2 relacionamentos e duas tabelas possuem apenas uma ligação relacional.

Analisando a Figura B.2 pode-se ver claramente a estrutura relacional que forma a base de dados. A lógica de criação deste modelo relacional foi desenvolvida segundo o seguinte princípio: “Avaliar a possibilidade de uma variável pertencer a vários conjuntos, evitando a redundância de elementos”. Esse princípio pode ser compreendido pela análise abaixo.

Na Figura B.2 o relacionamento *Regional\_to\_Transmissão* que une as tabelas *SIN\_Regional* e *Sist\_Transmissao* expressa a seguinte lógica relacional: Cada elemento pertencente a tabela *SIN\_Regional* pode estar associado a  $n$  elementos na tabela *Sist\_Transmissao*. Isto é, cada subsistema regional do SIN pode ter  $n$  sistemas de transmissão, ou seja há um relacionamento de 1 para  $n$ .

Analogamente, a ligação relacional *Transmissão\_To\_Barramentos* entre as estruturas *Sist\_Transmissao* e *BARRAMENTOS*, também expressa o tipo de relacionamento de 1 para  $n$ . Assim, esta relação mostra que cada sistema de transmissão pode possuir  $n$  barramentos em sua rede elétrica. O relacionamento *Barramentos\_To\_Carga*, entre as tabelas *BARRAMENTOS* e *CARGA* mostra que cada barramento pode ter várias medições de carga, caracterizando outra ligação relacional de 1 para  $n$ .

O relacionamento *Data\_to\_Carga* é interessante, pois como as cargas de todos os barramentos estão armazenadas na tabela *CARGA* é natural que barramentos distintos tenham diferentes medições lidas no mesmo dia e horário. Esta característica faz com que vários elementos da tabela *CARGA* estejam associados a um único elemento, ou seja, a uma única data, na tabela *DATAS*, gerando uma relação de 1 para  $n$ , da tabela *DATAS* para a tabela *CARGA*.

Entre as tabelas *DATAS* e *CLIMATICA* há um simples relacionamento de 1 para 1, pois de acordo com a forma em que a tabela *CLIMATICA* foi projetada cada elemento na tabela *DATAS* está associado a apenas 1 valor climático.

#### **B.2.1.4 Avaliação - Base de Dados**

O processo de cadastramento dos dados de carga na base de dados foi realizado utilizando as medições de carga elétrica disponíveis para resolver o problema de previsão de carga por barramento. Os dados de medição de carga

disponíveis representam medições feitas no **Sistema NE** (Sistema Interligado Nacional - Ramificação Nordeste).

As medições armazenadas contém dados de carga de 74 barramentos pertencentes a 6 empresas de distribuição de energia. As cargas têm discretização horária e foram medidas no período de 01 de junho de 2001 a 02 de fevereiro de 2002 (período de racionamento de energia no Brasil).

Para demonstrar a facilidade de manipulação dos dados que formam o banco de dados do sistema, foram feitas várias buscas nas tabelas da base de dados. Os resultados das buscas evidenciam a praticidade e mostram que o modelo implementado é eficiente e rápido para armazenar as informações que serão utilizadas no sistema.

Na Figura B.9 é realizado um “*select*” completo, buscando todas as informações gravadas na tabela *SIN\_Regional*. Como resultado pode-se ver os 4 subsistemas regionais que compõe o sistema interligado nacional.

```
mysql> select *from sin_regional;
```

SIN_Regional_ID	Sin_Nome	Sin_Carac
1	Sistema S	Sistema Interligado Nacional - Ramificacao: Sul
2	Sistema NE	Sistema Interligado Nacional - Ramificacao: Nordeste
3	Sistema N	Sistema Interligado Nacional - Ramificacao: Norte
4	Sistema SE/CO	Sistema Interligado Nacional - Ramificacao: Sudeste/Centro-Oeste

```
4 rows in set (0.00 sec)
```

Figura B.9: Exemplo: Select - SIN\_Regional

Observando a Figura B.10 nota-se que o “*select*” foi mais específico, buscando mostrar as datas que estão num intervalo determinado. Esta facilidade funcional, proposta pela linguagem SQL, é essencial ao projeto, pois torna o sistema capaz de buscar e manipular os dados utilizando comandos simples, que estão encapsulados no sistema. Para o usuário, a única exigência é que este defina o intervalo de seleção e o tipo de dados para que o sistema realize a busca na base de dados.

```
mysql> select *from Datas where dat_id>=99 and dat_id<=134;
```

Dat_ID	Dat_Data	Dat_holiday	Dat_holidaytype
99	2001-09-07	Sim	Independencia do Brasil
100	2001-09-08	Nao	---
101	2001-09-09	Nao	---
102	2001-09-10	Nao	---
103	2001-09-11	Nao	---
104	2001-09-12	Sim	---
105	2001-09-13	Nao	---
106	2001-09-14	Nao	---
107	2001-09-15	Nao	---
108	2001-09-16	Nao	---
109	2001-09-17	Nao	---
110	2001-09-18	Nao	---
111	2001-09-19	Nao	---
112	2001-09-20	Nao	---
113	2001-09-21	Nao	---
114	2001-09-22	Nao	---
115	2001-09-23	Nao	---
116	2001-09-24	Nao	---
117	2001-09-25	Nao	---
118	2001-09-26	Nao	---
119	2001-09-27	Nao	---
120	2001-09-28	Nao	---
121	2001-09-29	Nao	---
122	2001-09-30	Nao	---
123	2001-10-01	Nao	---
124	2001-10-02	Nao	---
125	2001-10-03	Nao	---
126	2001-10-04	Nao	---
127	2001-10-05	Nao	---
128	2001-10-06	Nao	---
129	2001-10-07	Nao	---
130	2001-10-08	Nao	---
131	2001-10-09	Nao	---
132	2001-10-10	Nao	---
133	2001-10-11	Nao	---
134	2001-10-12	Nao	N. S. Aparecida

```
36 rows in set (0.02 sec)
```

Figura B.10: Exemplo: Select - DATAS

A Figura B.11 mostra a seleção realizada na tabela *BARRAMENTOS*; a estrutura deste comando foi mais específica, onde o objetivo foi buscar os barramentos que pertencem ao segundo sistema de transmissão. O resultado mostra que 25 barramentos pertencem a este sistema. Devido à linguagem SQL, é possível fazer qualquer tipo de busca na tabela de barramentos apenas usando as chaves que especificam os seus relacionamentos com as outras tabelas do sistema.

Um fator a ser destacado é que o tempo de resposta em todas as pesquisas realizadas na base de dados foram extremamente baixos, da ordem de milésimos de segundos. Foram realizadas várias consultas buscando dados com várias grandezas, e o SGBD adotado neste projeto mostrou-se robusto e eficiente, fornecendo os dados com baixo tempo de resposta.

```
mysql> select *from barramentos where sist_transmissao_sistr_id=2;
```

Bar_ID	SIST_Transmissao_SIM_Regional_ID	SIST_Transmissao_Sistr_ID	Bar_Nome	Bar_Volt	Bar_Loc_Geog	Bar_Carac_Elet
17	2	2	JZD	0	ND	ND
18	2	2	SNB	0	ND	ND
19	2	2	IRE69	69	ND	ND
20	2	2	IRE138	138	ND	ND
21	2	2	BJS	0	ND	ND
22	2	2	BRA	0	ND	ND
23	2	2	CMD69	69	ND	ND
24	2	2	CMD238	238	ND	ND
25	2	2	CTG	0	ND	ND
26	2	2	CTU13	13	ND	ND
27	2	2	CTU69	69	ND	ND
28	2	2	STJ	0	ND	ND
29	2	2	MTT11	11	ND	ND
30	2	2	MTT69	69	ND	ND
31	2	2	OLD	0	ND	ND
32	2	2	PTU	0	ND	ND
33	2	2	JCR	0	ND	ND
34	2	2	ENP	0	ND	ND
35	2	2	FNL138	138	ND	ND
36	2	2	FNL138_Pedra	138	ND	ND
37	2	2	FNL13	13	ND	ND
38	2	2	GUM69	69	ND	ND
39	2	2	TMB	0	ND	ND
40	2	2	CCD	0	ND	ND
41	2	2	PAF	0	ND	ND

25 rows in set (0.00 sec)

Figura B.11: Exemplo: Select - BARRAMENTOS

### B.3 Comentários

Além da preocupação na escolha da melhor SGBDs um fator essencial é criar uma modelagem dinâmica que proporcione facilidades nas consultas e gravações de informações bem como facilidades no entendimento, no caso de futuras manutenções na base. Nesta ótica, a modelagem proposta anteriormente é eficaz, com um alto grau de compreensão mesmo para usuários que não tem domínio das técnicas de modelagem de dados. Nos procedimentos de consultas ao banco, pode-se afirmar que a modelagem desenvolvida para o aplicativo de previsão foi eficiente proporcionando consultas rápidas, através de instruções extremamente simples.