

UNIVERSIDADE DO VALE DO RIO DOS SINOS – UNISINOS  
CIÊNCIAS EXATAS E TECNOLÓGICAS  
PROGRAMA INTERDISCIPLINAR DE PÓS-GRADUAÇÃO  
EM COMPUTAÇÃO APLICADA

Rodrigo Marques de Figueiredo

UM SISTEMA COMPUTACIONAL PARA PREVISÃO  
DE CARGA EM SISTEMAS DE ENERGIA ELÉTRICA  
BASEADO EM REDES NEURAS ARTIFICIAIS

São Leopoldo, 2009.

UNIVERSIDADE DO VALE DO RIO DOS SINOS  
CIÊNCIAS EXATAS E TECNOLÓGICAS  
PROGRAMA INTERDISCIPLINAR DE PÓS-GRADUAÇÃO  
EM COMPUTAÇÃO APLICADA

Rodrigo Marques de Figueiredo

UM SISTEMA COMPUTACIONAL PARA PREVISÃO  
DE CARGA EM SISTEMAS DE ENERGIA ELÉTRICA  
BASEADO EM REDES NEURAIS ARTIFICIAIS

Dissertação para Obtenção do Título de Mestre em Computação Aplicada

Orientador  
Prof. Dr. José Vicente Canto dos Santos

São Leopoldo, 2009

F475s

Figueiredo, Rodrigo Marques de.

Um sistema computacional para previsão de carga em sistemas de energia elétrica baseado em redes neurais artificiais / Rodrigo Marques de Figueiredo. – 2008.

109 f.: il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa Interdisciplinar de Pós-Graduação em Computação Aplicada, 2008.

“Orientador, Prof. Dr. José Vicente Canto dos Santos”.

1. Redes neurais (Computação). 2. Sistemas de energia elétrica. I. Título.

CDD 006.32

CDU 004.032.26

Rodrigo Marques de Figueiredo

Um Sistema Computacional para Previsão de Carga em Sistemas de Energia Elétrica Baseado em  
Redes Neurais Artificiais

Monografia apresentada à Universidade do Vale do Rio dos Sinos como requisito parcial  
para obtenção do título de Mestre em Computação Aplicada.

Apresentado em março de 2009.

BANCA EXAMINADORA

---

Professor Dr. José Vicente Canto dos Santos – Orientador

PIPCA – Universidade do Vale do Rio dos Sinos - UNISINOS

---

Professor Dr. Thair Ibrahim Abdel Hamid Mustafa

DEET – Universidade Regional de Blumenau- FURB

---

Professor Dr. Luiz Paulo Luna de Oliveira

## AGRADECIMENTOS

Um sonho pessoal, isso é o que significa este mestrado pra mim. Este sonho tive que sonhar com os pés na realidade, realidade esta dura e às vezes até cruel, pois ao longo do curso houveram alguns percalços. Por outras vezes sonhei sozinho, sonhei com este momento, em que estava escrevendo os agradecimentos, finalizando minha dissertação. Pois é, cheguei aqui e finalmente posso me orgulhar de mim mesmo, sim eu posso.

A explicação de porque eu posso ser orgulhoso de minha própria pessoa nunca poderá ser expressa em palavras, pois assim como a pior dor é a que se sente, os sentimentos nobres também são assim. Só sentindo. Antes de agradecer a quem me ajudou agradeço aos que me dificultaram o meu caminho até aqui, com ou sem intenção. O meu muito obrigado a vocês, pois se me colocaram pedras no caminho ou me achavam forte o suficiente para removê-las ou me deixaram forte para tanto. Nessa caminhada aprendi a ser grato aos que dificultam, desdenham e não entendem. Isso é talvez o meu grande aprendizado no âmbito pessoal.

Mas não teria tido forças de avançar sobre o terreno mais inóspito, se não fossem as pessoas que me ajudaram. Não falo de ajuda direta, mas sim de gestos e palavras simples, tão simples que estas pessoas talvez nem saibam que estavam me dando um grande impulso em direção a minha conquista. Obrigado a vocês, que de alguma forma sabem que estou agradecido.

Tenho o dever de agradecer minha família, que mesmo que pequena e dispersa, por este ou aquele motivo, está unida em meu coração, e por vocês, pra vocês eu tive forças pra não ter sono, não ter descanso e não ter dor. Obrigado ao meu pai e a minha mãe que criaram a mim e meu irmão como dois homens de caráter, com defeitos como qualquer um, mas com um caráter reto assim como eles. Minha pequena e nova família, uma família de dois, Carina e eu, ou três se contar

com a Kika, agradeço por existir, pois se algo dá força a um homem este algo é a família. Esta família que tento sobremaneira deixar em condições de ser estável e feliz em todos os aspectos. Minha companheira, parceira e amante Carina obrigado por me agüentar esses dois anos, tudo que tenho e sou devo a ti.

Por fim e não menos importante agradeço ao meu orientador e amigo José Vicente, pela paciência, pela confiança e principalmente pela força dada a mim nesta empreitada, mesmo antes dela ser oficialmente iniciada. Vicente muito obrigado por aceitar a me orientar!

“Se o conhecimento pode criar problemas, não é através da ignorância que podemos solucioná-los” .

Isaac Asimov

## RESUMO

Este trabalho insere-se na área de modelagem computacional para problemas de previsão em sistemas de energia elétrica. A sociedade moderna possui uma dependência muito grande da utilização de energia elétrica, uma vez que grande parte da tecnologia atual utiliza de alguma forma este tipo de energia. Este fato justifica plenamente os estudos realizados na área para melhorar ou facilitar o trabalho no que se refere aos sistemas de energia elétrica. Atualmente existem diversos estudos na área que abordam todos os campos de sistema de energia elétrica. Uma importante parte do processo tanto de produção como de transmissão e distribuição de energia elétrica é o planejamento, que entre outros fatores baseia-se fortemente em uma previsão de carga elétrica. Esta previsão deve ser confiável, possuir uma alta acuracidade, pois a partir desta são tomadas decisões importantes nos âmbitos técnico e econômico da empresa de geração, transmissão ou distribuição de energia. O presente trabalho apresenta um sistema computacional para previsão de carga em sistemas de energia elétrica, através da utilização de uma nova abordagem para o uso da integração de modelos neurais de previsão. Com isto busca-se integrar as informações da própria rede elétrica (carga elétrica) com variáveis externas ao sistema, sendo elas variáveis meteorológicas e macroeconômicas. Para validar o sistema proposto, serão apresentados resultados de testes realizados com cenários reais fornecidos pela empresa fomentadora do projeto ao qual a dissertação neste documento está inserida, a RGE e órgãos como INPE e INMET.

## **ABSTRACT**

This work is inserted in the forecasting computational modeling for electrical power systems area. The modern society has a great dependency of electrical power, since the current technology uses this type of energy to many ends. This fact justifies the studies in that area to bettering or make easy to work with this type systems. Currently there are many studies in this áreas that broaches all the fields of electrical power. An important part of the process of production, transmission and distribution of electrical energy is the planning, that between others factors is strongly based in a load forecasting. This load forecasting should be reliable, and to have a high accuracy, because since that forecast important decisions are maked in technical and economical ambit of electrical system enterprises. This work presents a computational system for electrical load forecasting, through the using of a new neural model for forecasting approach. With this new model is tried integrate the electrical network information (electrical load) with external system variables, being that meteorological and macroeconomic variables. To validate the proposed system will be presents the tests results with real data, these data will come from RGE, the sponsor of this work, and from INPE and INMET.

## LISTA DE FIGURAS

|   |    |
|---|----|
| Figura 2-1: Sistema Elétrico de Potência.....   | 20 |
| Figura 2-2: Modelo não-linear de um neurônio artificial.....  | 24 |
| Figura 2-3: Função Limiar (Heaviside).....  | 25 |
| Figura 2-4: Função Linear por Partes .....  | 26 |
| Figura 2-5: Função Sigmóide .....   | 27 |
| Figura 2-6: Função Limiar Deslocada.....  | 28 |
| Figura 2-7: Função Tangente Hiperbólica .....   | 29 |
| Figura 2-8: Camadas das RNA.....  | 30 |
| Figura 2-9: Rede de Camada Única Alimentada Adiante .....   | 30 |
| Figura 2-10: Rede Recorrente.....   | 31 |
| Figura 2-11: Aprendizagem Correção de Erro (Diagrama de Blocos).....                                | 33 |
| Figura 2-12: Dinâmica de um método de <i>Cross-Validation</i> .....                                 | 36 |
| Figura 2-13: Apresentação da dinâmica do método de <i>Direct Validation</i> .....                   | 37 |
| Figura 2-14: Exemplo de uma Correlação Gráfica. ....  | 40 |
| Figura 2-15: Exemplo de uma verificação por Sobreposição de Curvas. ....                            | 41 |
| Figura 3-1: Áreas de concessão do estado do Rio Grande do Sul. ....                                 | 55 |
| Figura 3-2: Sistema de Distribuição da RGE.....   | 57 |
| Figura 3-3: Regiões geoeletricas da área de concessão da RGE.....                                   | 57 |
| Figura 3-4: Modelo Neural de Longo Prazo.....   | 60 |
| Figura 3-5: Modelo Neural de Curto Prazo.....   | 61 |
| Figura 3-6: Integração dos modelos neurais de longo e curto prazos. ....                            | 61 |
| Figura 3-7: Modelo Neural Integrado.....  | 62 |
| Figura 3-8: Arquitetura de Sistema Computacional Proposto. ....                                     | 63 |
| Figura 4-1: Distribuição de classes de consumidores por regiões geoeletricas.....                   | 65 |
| Figura 4-2: Comportamento de previsão esperado do sistema computacional.....                        | 67 |
| Figura 4-3: Arranjo temporal das variáveis do modelo neural. ....                                   | 67 |
| Figura 4-4: Região geoeletrica de Gravataí (em destaque).....                                       | 68 |
| Figura 4-5: Resposta para curto prazo - Gravataí - <i>Ten-Fold Cross-Validation</i> .....           | 70 |
| Figura 4-6: Correlação gráfica - curto prazo - Gravataí - <i>Ten-Fold Cross-Validation</i> .....    | 70 |
| Figura 4-7: Resposta para longo prazo - Gravataí - <i>Ten-Fold Cross-Validation</i> .....           | 72 |
| Figura 4-8: Correlação gráfica - longo prazo - Gravataí - <i>Ten-Fold Cross-Validation</i> .....    | 72 |
| Figura 4-9: Resposta para curto prazo - Gravataí - <i>Direct Validation</i> .....                   | 73 |
| Figura 4-10: Correlação gráfica - curto prazo - Gravataí - <i>Direct Validation</i> .....           | 74 |
| Figura 4-11: Resposta para longo prazo - Gravataí - <i>Direct Validation</i> .....                  | 75 |
| Figura 4-12: Gráfico de erro do previsor de longo prazo - Gravataí - <i>Direct Validation</i> ..... | 76 |

|   |    |
|---|----|
| Figura 4-13: Correlação - longo prazo - Gravataí - <i>Ten-Fold Cross- Validation</i> .....            | 76 |
| Figura 4-14: Região geométrica de Taquara (em destaque).....  | 77 |
| Figura 4-15: Resposta para longo prazo - Taquara - <i>Ten-Fold Cross-Validation</i> .....             | 78 |
| Figura 4-16: Correlação gráfica - curto prazo - Taquara - <i>Ten-Fold Cross- Validation</i> .....     | 79 |
| Figura 4-17: Resposta para longo prazo - Taquara - <i>Ten-Fold Cross-Validation</i> .....             | 80 |
| Figura 4-18: Correlação gráfica - longo prazo - Taquara - <i>Ten-Fold Cross- Validation</i> .....     | 80 |
| Figura 4-19: Resposta para curto prazo - Taquara - <i>Direct Validation</i> . .....                   | 81 |
| Figura 4-20: Correlação gráfica - curto prazo - Taquara - <i>Direct Validation</i> .....              | 82 |
| Figura 4-21: Resposta para curto prazo - Taquara - <i>Direct Validation</i> . .....                   | 83 |
| Figura 4-22: Correlação gráfica - longo prazo - Taquara - <i>Direct Validation</i> .....              | 83 |
| Figura 4-23: Região geométrica de Passo Fundo (em destaque).....                                      | 84 |
| Figura 4-24: Resposta para curto prazo - Passo Fundo - <i>Ten-Fold Cross-Validation</i> .....         | 85 |
| Figura 4-25: Correlação gráfica - curto prazo - Passo Fundo - <i>Ten-Fold Cross- Validation</i> ..... | 86 |
| Figura 4-26: Resposta para longo prazo - Passo Fundo - <i>Ten-Fold Cross-Validation</i> . .....       | 87 |
| Figura 4-27: Correlação gráfica - longo prazo - Passo Fundo - <i>Ten-Fold Cross- Validation</i> ..... | 88 |
| Figura 4-28: Resposta para curto prazo - Passo Fundo - <i>Direct Validation</i> . .....               | 89 |
| Figura 4-29: Correlação gráfica - longo prazo - Passo Fundo - <i>Direct Validation</i> .....          | 89 |
| Figura 4-30: Resposta para longo prazo - Passo Fundo - <i>Direct Validation</i> .....                 | 90 |
| Figura 4-31: Correlação gráfica - longo prazo - Passo Fundo - <i>Direct Validation</i> .....          | 91 |

## LISTA DE TABELAS

|  |    |
|--|----|
| Tabela 3-1: Lista de variáveis selecionadas para o modelo.....                               | 59 |
| Tabela 4-1: Resposta dos erros para Ten-Fold Cross-Validation para curto prazo.....          | 69 |
| Tabela 4-2: Resposta dos erros para Ten-Fold Cross-Validation para longo prazo. ....         | 71 |
| Tabela 4-3: Resposta dos erros para Direct-Validation para curto prazo.....                  | 73 |
| Tabela 4-4: Resposta dos erros para Direct-Validation para longo prazo. ....                 | 74 |
| Tabela 4-5: Resposta dos erros para <i>Ten-Fold Cross-Validation</i> para curto prazo.....   | 78 |
| Tabela 4-6: Resposta dos erros para <i>Ten-Fold Cross-Validation</i> para longo prazo. ....  | 79 |
| Tabela 4-7: Resposta dos erros para <i>Direct Validation</i> para curto prazo. ....          | 81 |
| Tabela 4-8: Resposta dos erros para <i>Direct Validation</i> para longo prazo.....           | 82 |
| Tabela 4-9: Resposta dos erros para <i>Ten-Fold Cross-Validation</i> para curto prazo.....   | 85 |
| Tabela 4-10: Resposta dos erros para <i>Ten-Fold Cross-Validation</i> para longo prazo. .... | 86 |
| Tabela 4-11: Resposta dos erros para <i>Direct Validation</i> para curto prazo. ....         | 88 |
| Tabela 4-12: Resposta dos erros para <i>Direct Validation</i> para longo prazo.....          | 90 |

## LISTA DE ABREVIATURAS

|        |  |
|--------|--|
| ANEEL  | <i>Agência Nacional de Energia Elétrica</i>                          |
| ARMCRN | <i>Auto-Regressive Multi-Contect Recurrent Neural Network</i>        |
| ASNN   | <i>Analyzable Structured Neural Network</i>                          |
| BE     | <i>Backward Elimination</i>  |
| BNN    | <i>Bayesian Neural Network</i>                                       |
| CG     | <i>Conjugate Gradient</i>  |
| DEC    | <i>Duração Equivalente de Interrupção por Unidade Consumidora</i>    |
| FEC    | <i>Frequência Equivalente de Interrupção por Unidade Consumidora</i> |
| FS     | <i>Forward Selection</i>   |
| INMET  | <i>Instituto Nacional de Meteorologia</i>                            |
| INPE   | <i>Instituto Nacional de Pesquisas Espaciais</i>                     |
| IPA-OG | <i>Índice de Produto por Atacado – Oferta Global</i>                 |
| IPEA   | <i>Instituto de Pesquisa Econômica Aplicada</i>                      |
| ME     | <i>Mercado Atacadista de Energia</i>                                 |
| MAE    | <i>Mean Absolute Error</i>   |
| MAPE   | <i>Mean Absolute Percentage Error</i>                                |
| MCMC   | <i>Markov Chain Monte Carlo</i>                                      |
| MCT    | <i>Ministério da Ciência e Tecnologia</i>                            |
| MLP    | <i>Multi Layer Perceptron</i>  |
| PLF    | <i>Peak Load Forecasting</i>   |
| RGE    | <i>Rio Grande Energia</i>  |
| RMSE   | <i>Root Mean Square Error</i>  |
| RNA    | <i>Rede Neural Artificial</i>  |
| SNNS   | <i>Stuttgart Neural Network Simulator</i>                            |

# SUMÁRIO

|            |  |           |
|------------|--|-----------|
| <b>1</b>   | <b>INTRODUÇÃO .....</b>                                      | <b>16</b> |
| <b>2</b>   | <b>CONCEITOS BÁSICOS .....</b>                               | <b>19</b> |
| <b>2.1</b> | <b>Sistemas Elétricos de Potência .....</b>                  | <b>20</b> |
| 2.1.1      | Geradores .....  | 20        |
| 2.1.2      | Linhas de Transmissão.....                                   | 21        |
| 2.1.3      | Sistemas de Distribuição .....                               | 21        |
| 2.1.4      | Características do Sistema Elétrico de Potência .....        | 21        |
| <b>2.2</b> | <b>Redes Neurais Artificiais .....</b>                       | <b>22</b> |
| 2.2.1      | Modelo de um Neurônio.....                                   | 23        |
| 2.2.2      | Função de Ativação.....                                      | 25        |
| 2.2.2.1    | <i>Função de Limiar</i> .....                                | 25        |
| 2.2.2.2    | <i>Função Linear por Partes</i> .....                        | 26        |
| 2.2.2.3    | <i>Função Sigmóide:</i> .....                                | 26        |
| 2.2.2.4    | <i>Função Ímpar</i> .....                                    | 27        |
| 2.2.3      | Arquiteturas de RNAs .....                                   | 29        |
| 2.2.3.1    | <i>Redes Alimentadas Adiante com Camada Única</i> .....      | 30        |
| 2.2.3.2    | <i>Rede Alimentadas Adiante com Múltiplas Camadas</i> .....  | 30        |
| 2.2.3.3    | <i>Redes Recorrentes</i> .....                               | 31        |
| 2.2.4      | Aprendizagem em Redes Neurais Artificiais.....               | 31        |
| 2.2.4.1    | <i>Aprendizagem por Correção de Erro</i> .....               | 32        |
| 2.2.4.2    | <i>Aprendizagem Baseada em Memória</i> .....                 | 33        |
| 2.2.4.3    | <i>Aprendizagem Hebbiana</i> .....                           | 33        |
| 2.2.4.4    | <i>Aprendizagem Competitiva</i> .....                        | 34        |
| 2.2.4.5    | <i>Aprendizagem de Boltzmann</i> .....                       | 34        |
| <b>2.3</b> | <b>Métodos de Validação de Previsores.....</b>               | <b>35</b> |
| 2.3.1      | Cross-Validation .....                                       | 35        |
| 2.3.1.1    | <i>Leave-One-Out Cross-Validation</i> .....                  | 36        |
| 2.3.1.2    | <i>K-Fold Cross-Validation</i> .....                         | 37        |
| 2.3.2      | Direct Validation.....                                       | 37        |
| <b>2.4</b> | <b>Métodos de avaliação de Desempenho de Previsores.....</b> | <b>37</b> |
| 2.4.1      | Erro Médio Absoluto.....                                     | 38        |
| 2.4.2      | Erro Médio Quadrático .....                                  | 39        |
| 2.4.3      | Correlação Gráfica .....                                     | 39        |
| 2.4.4      | Sobreposição de Curvas.....                                  | 40        |

|            |  |            |
|------------|--|------------|
| <b>2.5</b> | <b>Métodos de Seleção de Variáveis .....</b>   | <b>41</b>  |
| 2.5.1      | Forward Selection.....   | 42         |
| <b>2.6</b> | <b>Modelos de Previsão.....</b>  | <b>44</b>  |
| 2.6.1      | Modelos de Previsão em Sistemas de Energia Elétrica.....                             | 45         |
| 2.6.2      | Modelos de Previsão de Carga .....   | 46         |
| 2.6.2.1    | <i>Modelos de Previsão de Carga Elétrica Utilizando RNAs</i> .....                   | 47         |
| 2.6.2.2    | <i>Modelos de Previsão de Carga Elétrica Utilizando RNAs e Outras Técnicas</i> ..... | 52         |
| <b>3</b>   | <b>SISTEMA COMPUTACIONAL PROPOSTO .....</b>  | <b>55</b>  |
| <b>3.1</b> | <b>Modelos Propostos .....</b>   | <b>56</b>  |
| 3.1.1      | Seleção das Variáveis do Modelo .....  | 59         |
| 3.1.2      | Modelo de Longo Prazo .....  | 59         |
| 3.1.3      | Modelo de Curto Prazo .....  | 60         |
| 3.1.4      | Integração entre os Modelos.....   | 61         |
| <b>3.2</b> | <b>Arquitetura do Sistema Computacional Proposto .....</b>                           | <b>62</b>  |
| <b>4</b>   | <b>TESTES E RESULTADOS .....</b>   | <b>65</b>  |
| <b>4.1</b> | <b>Treinamento e Validação do Modelo Neural.....</b>                                 | <b>66</b>  |
| <b>4.2</b> | <b>Teste I (Carga Predominante: Industrial) .....</b>                                | <b>68</b>  |
| 4.2.1      | Resultados Teste I – Ten-Fold Cross-Validation – Curto Prazo.....                    | 69         |
| 4.2.2      | Resultados Teste I – Ten-Fold Cross-Validation – Longo Prazo.....                    | 71         |
| 4.2.3      | Resultados Teste I – Direct Validation – Curto Prazo .....                           | 73         |
| 4.2.4      | Resultados Teste I – Direct Validation – Longo Prazo .....                           | 74         |
| <b>4.3</b> | <b>Resultados do Teste II (Carga Predominante: Residencial) .....</b>                | <b>77</b>  |
| 4.3.1      | Resultados Teste II – Ten-Fold Cross-Validation – Curto Prazo .....                  | 77         |
| 4.3.2      | Resultados Teste II – Ten-Fold Cross-Validation – Longo Prazo .....                  | 79         |
| 4.3.3      | Resultados Teste II – Direct Validation – Curto Prazo .....                          | 81         |
| 4.3.4      | Resultados Teste II – Direct Validation – Longo Prazo .....                          | 82         |
| <b>4.4</b> | <b>Resultados do Teste III (Cargas Equilibradas).....</b>                            | <b>84</b>  |
| 4.4.1      | Resultados Teste III – Ten-Fold Cross-Validation – Curto Prazo .....                 | 85         |
| 4.4.2      | Resultados Teste III – Ten-Fold Cross-Validation – Longo Prazo .....                 | 86         |
| 4.4.3      | Resultados Teste III – Direct Validation – Curto Prazo.....                          | 88         |
| 4.4.4      | Resultados Teste III – Direct Validation – Longo Prazo.....                          | 90         |
| <b>4.5</b> | <b>Análise dos Resultados .....</b>  | <b>91</b>  |
| <b>5</b>   | <b>CONCLUSÃO.....</b>  | <b>93</b>  |
|            | <b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>  | <b>95</b>  |
|            | <b>APÊNDICE A - ARTIGOS GERADOS A PARTIR DA DISSERTAÇÃO.....</b>                     | <b>100</b> |



# 1 INTRODUÇÃO

Este trabalho insere-se na área de modelagem computacional para problemas de previsão, mais precisamente no problema de previsão de carga em sistemas de energia elétrica. O sistema de energia elétrica é talvez o sistema tecnológico ao qual a sociedade moderna está mais dependente, pois grande parte da tecnologia atual depende desta forma de energia. Este nível de dependência tão elevado, da sociedade frente ao sistema de energia elétrica, leva organismos como o Banco Mundial a medir o grau de desenvolvimento de um país através da aferição da demanda por energia elétrica existente no mesmo. Também se pode verificar a presença da energia elétrica em praticamente todos os setores produtivos.

A energia elétrica é o único produto que é consumido no momento em que é gerado, ou seja, possui consumo instantâneo. Outra característica importante é que não se pode fazer o sistema armazenar energia excedente, e nem mesmo sobrecarregar o sistema para produzir mais energia do que o suportado por este. Isto dá uma idéia de como é complexo o planejamento de produção racional de energia elétrica. Porém a estas restrições intrínsecas, ou seja, as restrições dadas pelo próprio sistema físico somam-se ainda fatores externos que influem sobremaneira na produção de energia elétrica. Esses fatores externos podem ser classificados em dois grandes grupos, os meteorológicos e os macroeconômicos. O grande desafio para os pesquisadores no momento da modelagem do sistema é mensurar a influência desses fatores no sistema.

As profundas transformações que ocorreram no setor elétrico brasileiro na metade da década passada abriram um leque de oportunidades e obrigações aos agentes deste setor, com a privatização do setor. Este processo criou as áreas de concessão de energia elétrica, onde empresas, especialmente as de distribuição estão aptas a gerir determinadas áreas [REIS, 2006]. A definição de novos parâmetros para negócios envolvendo energia elétrica como produto, fez necessário um maior conhecimento desse mercado, introduzindo novas competências e buscando novos instrumentos para a análise de suas possibilidades [GUILLEN, 2005]. Entre os novos

instrumentos para análise do mercado de energia elétrica estão os sistemas computacionais de previsão. Estes sistemas de previsão podem ser divididos em dois grandes grupos: I) os que fazem uma previsão do preço da energia elétrica [LORA, 2007], onde uma análise focada no mercado é realizada e II) os que realizam a previsão de consumo de energia elétrica [ARDIL, 2007], que faz uma análise mais aprofundada em todo o sistema. Este último analisa desde as questões econômicas, passando pelas variáveis climáticas e também as questões técnicas que envolvem a rede elétrica em si.

Esta privatização deflagrou o atual processo de comercialização de energia elétrica no Brasil, com a criação do ME (Mercado Atacadista de Energia) é uma importante motivação para as previsões do comportamento do mercado de energia elétrica [GUILLEN, 2005], sejam de curto ou de longo prazo. Para tanto é necessário que o sistema computacional de previsão de carga elétrica possua uma precisão adequada, onde este é o objetivo principal de um sistema de previsão.

Existem diversos esforços da sociedade científica para criar sistemas computacionais de apoio à previsão de consumo de energia elétrica, ou simplesmente previsão de carga, nos quais se pode incluir este trabalho. Estes sistemas visam dar ao usuário, ou a empresa de geração, transmissão ou de distribuição de energia, subsídios para o planejamento de geração ou de compra e venda de energia elétrica. Desta forma o usuário tem um panorama do comportamento futuro do sistema, e pode ter tomada de decisões mais seguras e com base científica.

O foco do trabalho é criar um sistema computacional para determinar com elevada acuracidade de previsão de carga elétrica, de curto e longo prazo, para uma determinada região consumidora de uma empresa de distribuição de energia elétrica, no caso a RGE (Rio Grande Energia). Para tanto recorreu-se à literatura para que uma análise de quais alternativas estão sendo usadas pelos pesquisadores para sistema computacionais de previsão. Foi dada uma atenção maior ao que se refere à previsão de carga elétrica. Existem diversos métodos para aplicar-se e obter a previsão de carga elétrica, desde modelagens matemáticas, caras do ponto de vista computacional, até os métodos mais modernos que lançam mão de modelos neurais. A utilização de redes neurais recorrentes se mostra um dos métodos mais interessantes e por este motivo é essa a ferramenta a ser utilizada no sistema computacional aqui desenvolvido.

Como contribuição científica este trabalho busca uma nova proposta de integração de dois horizontes de previsão. Serão desenvolvidos dois modelos distintos, sendo um para longo e outro para curto prazo. Nesta nova proposta os modelos são integrados em nível topológico, de maneira que se espera diminuir eventuais influências não desejadas entre os modelos desenvolvidos. Um subproduto desta contribuição é a possibilidade de através de um único modelo, derivado da integração de dois modelos distintos, apresentar duas respostas de previsão com apenas uma rodada do sistema. Computacionalmente falando está-se duplicando a eficiência do sistema, pois

com apenas um conjunto de treinamento pode-se esperar uma resposta equivalente a de dois modelos.

Descrevendo a organização deste documento, tem-se que após esta introdução, o Capítulo 2 que apresenta ao leitor os conceitos básicos necessários para o entendimento do trabalho desenvolvido, bem como uma extensa revisão bibliográfica dos problemas de previsão, com maior atenção para sistemas de previsão aplicados a sistemas de energia elétrica. O Capítulo 3 apresenta o sistema computacional proposto. Neste capítulo será realizada uma descrição completa da proposta do sistema, apresentando a concepção e desenvolvimento de seus modelos neurais. Os testes e resultados realizados e apresentados pelo sistema desenvolvido, com suas metodologias e discussões são apresentados neste documento sob a forma do Capítulo 4. Seguem-se a conclusão nos Capítulos 5, onde será dado um fechamento ao trabalho. Neste capítulo as considerações que são presumidamente relevantes ao entendimento dos resultados do sistema proposto são apresentadas, e por final as referências bibliográficas.

## 2 CONCEITOS BÁSICOS

As noções conceituais básicas necessárias para o bom entendimento desta dissertação estão apresentadas nesta seção. Nela são abordadas questões sobre sistemas elétricos de potência, redes neurais artificiais, métodos para avaliação de desempenho de modelos e modelos de previsão. É importante lembrar que estes assuntos aqui apresentados são muito amplos de maneira que esta seção não tem a ambição de tratar estes em toda a sua amplitude, mas sim em trazer ao leitor que possui pouca ou nenhuma familiaridade com o assunto o seu entendimento.

Primeiramente são apresentados os conceitos dos sistemas elétricos de potência, bem como suas características e elementos. É interessante lembrar que este é um campo da engenharia que ganhou muita importância nas últimas décadas e a partir deste tiveram início muitos estudos sobre análise de falhas, performance e principalmente de previsão para este tipo de sistema. Nestes estudos a utilização de ferramentas computacionais tornou-se uma prática comum entre os pesquisadores.

Para cada um destes estudos existe uma, ou mais, ferramenta computacional a ser utilizada. No que diz respeito ao objetivo desta dissertação, que é a previsão de carga elétrica de curto e longo prazo, esta ferramenta é a rede neural artificial. Os conceitos sobre redes neurais artificiais apresentados nesta seção trazem a base da teoria necessária para o entendimento da prática implementada. O mesmo ocorrendo para os conceitos apresentados para avaliação de desempenho de modelos.

Aos modelos de previsão foi dada uma atenção especial, pois ao contrário dos demais assuntos este não é uma ferramenta, mas sim o assunto principal a ser abordado na dissertação proposta. O objetivo da dissertação de criar um modelo integrado de dois previsores, estes de curto e longo prazos, tornou necessária uma pesquisa bibliográfica mais abrangente antes de focar no assunto previsão de carga elétrica.

## 2.1 Sistemas Elétricos de Potência

Um sistema elétrico de potência é constituído por três tipos principais de elementos, sendo eles as estações geradoras, as linhas de transmissão e os sistemas de distribuição. As linhas de transmissão são responsáveis pela conexão das estações geradoras aos sistemas de distribuição, [STEVENSON, 1974]. Já os sistemas de distribuição ligam todas as suas cargas individuais de uma determinada área às linhas de transmissão. A figura 2.1 mostra de maneira mais intuitiva esta relação entre os três principais elementos.

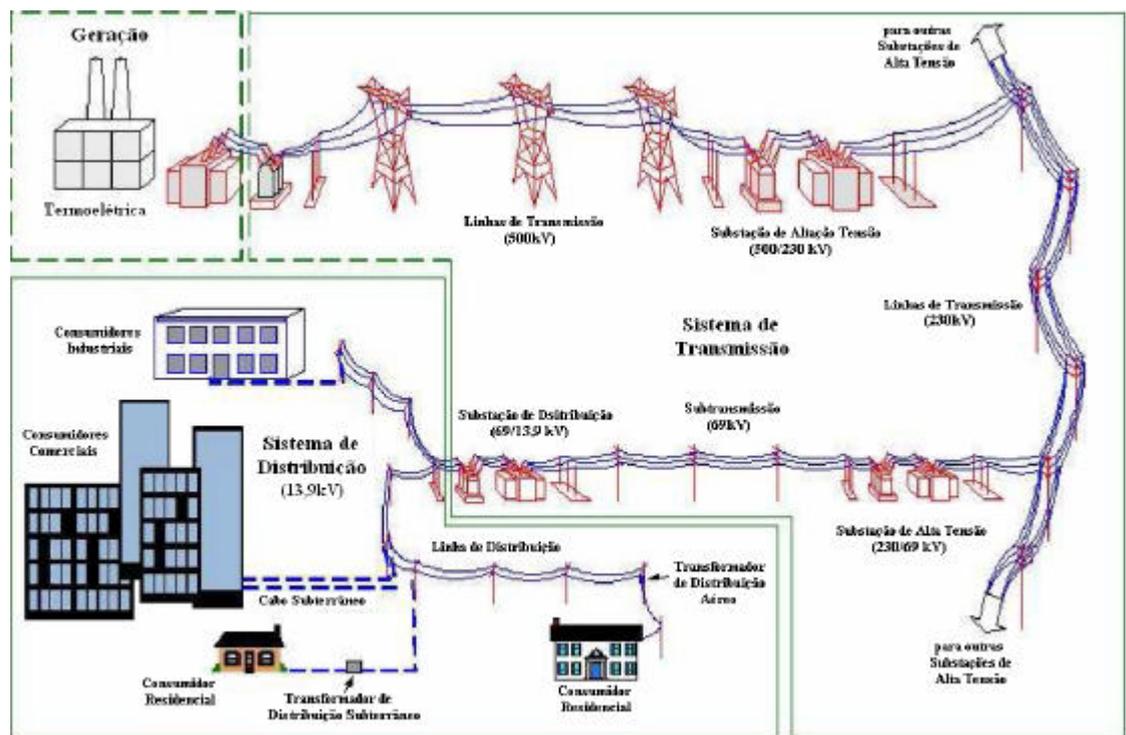


Figura 2-1: Sistema Elétrico de Potência

### 2.1.1 Geradores

Basicamente existem três tipos de elementos geradores, os hidrelétricos, eólicos e os termoeletricos. Os elementos geradores hidrelétricos, ou usinas hidrelétricas são dependentes da geografia da região já que necessitam da presença de rios para que possam ser construídas as suas barragens. Estas represam a água para que esta possa ser utilizada para mover as turbinas que geram a energia elétrica. Já as usinas termoeletricas utilizam algum combustível para aquecer a água presente em seu sistema, que normalmente é fechado, até transformá-la em vapor. Este vapor irá alimentar a turbina que está acoplada ao gerador. O combustível utilizado para aquecer a água pode ser desde biomassa, que são restos de grãos, passando por carvão e até mesmo energia nuclear. Quando deste último caso a usina termoeletrica é chamada de usina nuclear. Este elemento gerador, por não ter nenhuma dependência geográfica é mais flexível quando ao seu local de construção,

sendo geralmente construídos próximos dos grandes centros. Os geradores eólicos utilizam a força eólica para girar grandes pás em formato de hélice que ao girar alimentam os geradores. Estes geradores também são de certa maneira dependentes da geografia da região, pois sua implantação só é justificada em regiões que possuam ventos perenes e com certa intensidade.

### **2.1.2 Linhas de Transmissão**

As linhas de transmissão como visto anteriormente são as responsáveis pela conexão dos elementos geradores com os sistemas de distribuição. São compostas basicamente de torres, chamadas de torres de transmissão e subestações de alta tensão. Neste componente do sistema elétrico de potência a tensão varia entre 230 kV até 750 kV. Quanto maior a distância percorrida pela linha de transmissão maior a tensão utilizada por esta linha. A conversão de tensões ao longo da linha de transmissão e na entrada do sistema de distribuição é realizada pelas subestações.

### **2.1.3 Sistemas de Distribuição**

É neste componente do sistema elétrico de potência que a energia elétrica é entregue ao consumidor final. Normalmente cada sistema de distribuição possui apenas uma companhia de eletricidade que atende uma dada região geográfica. Este fato leva a falsa impressão de que não há concorrência entre as empresas do setor de distribuição. Porém estas empresas disputam grandes consumidores negociando tarifas vantajosas para estes consumidores.

Nesse sistema a tensão é de 13,8 kV na distribuição e de 127/220V nos consumidores residenciais e comerciais e 220/380V para as indústrias. No sistema de distribuição estão presentes os transformadores de baixa tensão, ou transformadores BT, que realizam a conversão de 13,8 kV para a tensão contratada pelo consumidor final.

### **2.1.4 Características do Sistema Elétrico de Potência**

Diz-se que um sistema elétrico de potência está bem projetado quando este compreende um grande número de estações geradoras interligadas de modo que a energia total produzida por este conjunto possa ser utilizada em toda a região coberta pelo sistema. Esta definição de sistema bem projetado provém de três características dos sistemas elétrico de potência que influenciam de maneira marcante no modo de operação do sistema [WEEDY, 1973].

1. A eletricidade não pode ser armazenada e o fornecedor (operador do elemento gerador) tem pouca informação sobre a carga instantânea. Portanto se for gerada mais

energia elétrica do que a necessidade haverá um desperdício de geração, porém se gerada menor energia que a demanda de carga haverá a sobrecarga no sistema.

2. Existe um contínuo aumento na demanda de energia, que é ainda mais aparente em países em desenvolvimento como o Brasil. Com isso cada vez mais carga é agregada ao sistema, sendo os circuitos ampliados periodicamente, ao invés de serem projetados e mantidos inalterados.

3. A transmissão da energia é um fator de suma importância uma vez que principalmente em se tratando de hidrelétricas, a geração fica longe dos centros consumidores.

Essas características, principalmente as duas primeiras tornam os sistemas elétricos de potência em sistemas extremamente complexos. No que diz respeito a distribuição de energia, as empresas que atuam neste setor necessitam de ferramentas computacionais eficientes para auxiliarem no planejamento de suas ações dentro do mercado de energia. Esse planejamento é dado sobre tendências e informações futuras, portanto as ferramentas computacionais envolvidas são ferramentas de previsão.

## 2.2 Redes Neurais Artificiais

Uma rede neural artificial, ou simplesmente RNA, é uma ferramenta computacional amplamente utilizada na indústria e como objeto de pesquisa no meio acadêmico. O sucesso das RNAs nesses meios se deve aos benefícios trazidos por estas. Sua estrutura maciçamente paralelamente distribuída e sua capacidade de aprendizado, por consequência, sua capacidade de generalizar.

Simon Haykin define em seu livro [HAYKIN, 2001] uma RNA como um processador maciçamente paralelamente distribuído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Sendo o conhecimento adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem. E as forças de conexão entre os neurônios, conhecidas como processos sinápticos, são utilizados para armazenar o conhecimento adquirido.

O processo de aprendizagem de uma RNA é dado pelo algoritmo de aprendizagem, o qual altera os pesos sinápticos distribuindo-os de maneira ordenada na rede para alcançar o objetivo de projeto desejado. Através desse processo as RNAs possuem as seguintes características [HAYKIN, 2001], no que se diz respeito a implementação computacional:

1. *Não-Linearidade*: Uma RNA pode ser linear ou não-linear. Caso esta seja constituída por conexões de neurônios não-lineares, a rede será não-linear, e, caso seja

constituída por neurônios lineares a rede será linear. Esta característica é muito importante, pois desta forma a RNA pode atender aos estímulos de entrada sendo esta linear ou não-linear.

2. *Mapeamento de Entrada-Saída*: Consiste em fornecer exemplos a RNA, cada exemplo é constituído de um padrão de entrada e um padrão de saída, ou seja, um padrão da resposta da RNA. A cada exemplos os pesos sinápticos são alterados para que a haja uma aproximação da resposta da rede com a resposta desejada, até esta aproximação esteja estabilizada. Assim a rede aprende com os exemplos realizando um mapeamento de entrada-saída para o exemplo (problema) dado como padrão para a RNA.

3. *Adaptabilidade*: As RNAs têm uma capacidade de adaptação inata proveniente da característica de alteração dos pesos sinápticos. Uma RNA treinada para operar em um ambiente específico pode ser facilmente novamente treinada para agregar novas informações ao modelo de um ambiente alterado.

4. *Resposta a Evidências*: Em classificação de padrões uma RNA pode não só fornecer a informação sobre qual padrão selecionar, mas também informar sobre a confiança sobre a decisão tomada. Isto faz com que escolha entre respostas ambíguas seja facilitada.

5. *Informação Contextual*: O conhecimento é representado por toda a estrutura da RNA. Como cada neurônio é afetado potencialmente pelos demais que compõe a rede, a informação contextual é tratada de maneira natural pela RNA.

### 2.2.1 Modelo de um Neurônio

Em seu livro Haykin [HAYKIN, 2001] define um neurônio artificial como uma unidade de processamento de informação fundamental para a operação de uma rede neural artificial. A figura 2.7 mostra de maneira visual o modelo de um neurônio artificial não-linear. Nesta figura pode-se observar três elementos básicos do modelo de um neurônio:

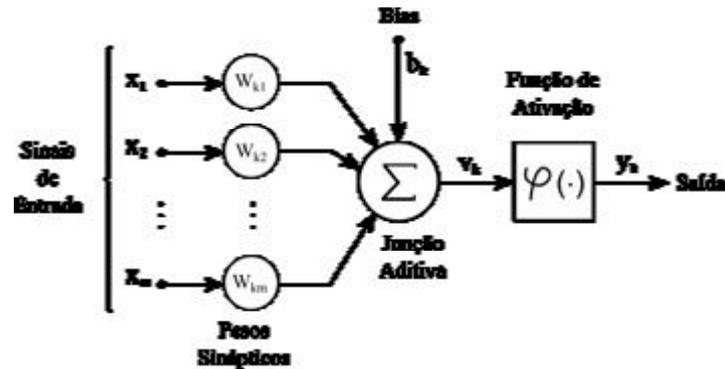


Figura 2-2: Modelo não-linear de um neurônio artificial

1. *Conjunto de Sinapses*: Cada caracterizada por um peso próprio. Para cada entrada ( $x_j$ ) existe uma conexão sináptica ( $j$ ) associada a um peso sináptico ( $w_{kj}$ ), que multiplica sua respectiva entrada. Essas ligações são responsáveis pela interligação dos neurônios em rede.
2. *Somador*: Soma os sinais de entrada já ponderados pelos seus respectivos pesos sinápticos. Este somador nada mais é que um combinador linear.
3. *Função de Ativação*: Esta função restringe a amplitude da resposta do neurônio, por isso também chamada de *Função Restritiva*, já que limita o intervalo permissível de amplitude do sinal de saída a um valor finito. Tipicamente este intervalo permissível é normalizado em um intervalo fechado  $[0,1]$  ou alternativamente  $[-1,1]$ .
4. *Bias*: um fator aplicado ao somador do neurônio. A função do *bias* é aumentar ou reduzir a entrada para a função de ativação.

A descrição matemática de um neurônio artificial pode ser dada pelas seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j, \quad (2.1)$$

$$v_k = u_k + b_k$$

e

$$y_k = \mathbf{j} \cdot (v_k)$$

onde:

$x_j$  : sinais de entrada;

$w_{kj}$  : pesos sinápticos do neurônio;

$u_k$  : saída do somador (combinador linear) sem a adição do *bias*;

$b_k$  : sinal de *bias*;

$v_k$  : saída do somador com a adição do *bias*;  
 $\mathbf{j}(\cdot)$  : função de ativação;  
 $y_k$  : sinal de saída do neurônio.

## 2.2.2 Função de Ativação

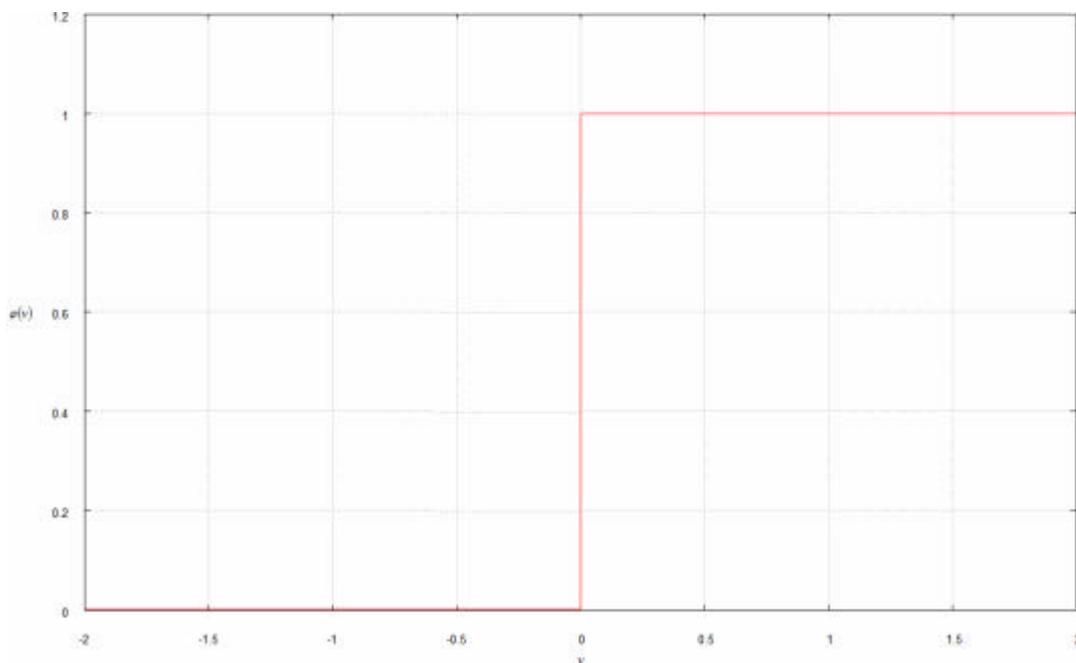
A função de ativação,  $\mathbf{j}(v)$  define a saída de um neurônio em termos do campo induzido  $v$ . Existem três tipos básicos de funções de ativação, sendo elas:

### 2.2.2.1 Função de Limiar

Este tipo de função também conhecido nas engenharias como função de *Heaviside*, ou ainda como função degrau, é descrita a seguir:

$$\mathbf{j}(v) = \begin{cases} 1 & \text{se } v \geq 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (2.2)$$

A figura 2.8 mostra o gráfico desta função:



**Figura 2-3: Função Limiar (Heaviside)**

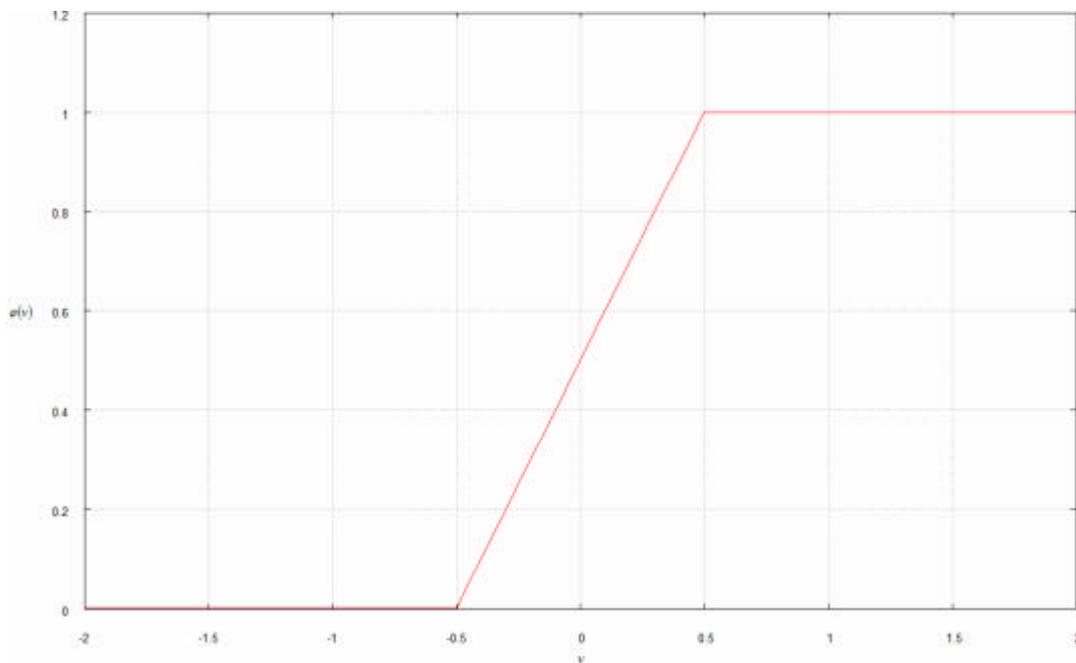
Esta função foi proposta por McCulloch, em seu artigo [MCCULLOCH, 1943]. Com esta função de ativação os valores negativos tem sua saída zerada e os valores de entrada positivos são *setados* para o valor 1 (um).

### 2.2.2.2 Função Linear por Partes

A função linear por partes assume um fator de amplificação unitário dentro da região linear. A descrição matemática desta função é dada pelo sistema a seguir:

$$\mathbf{j}(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases} \quad (2.3)$$

A figura 2.9 mostra de maneira gráfica esta função de ativação:



**Figura 2-4: Função Linear por Partes**

Portanto esta função de ativação funciona como um amplificador não-linear, e desta forma pode-se observar esta função em dois casos especiais:

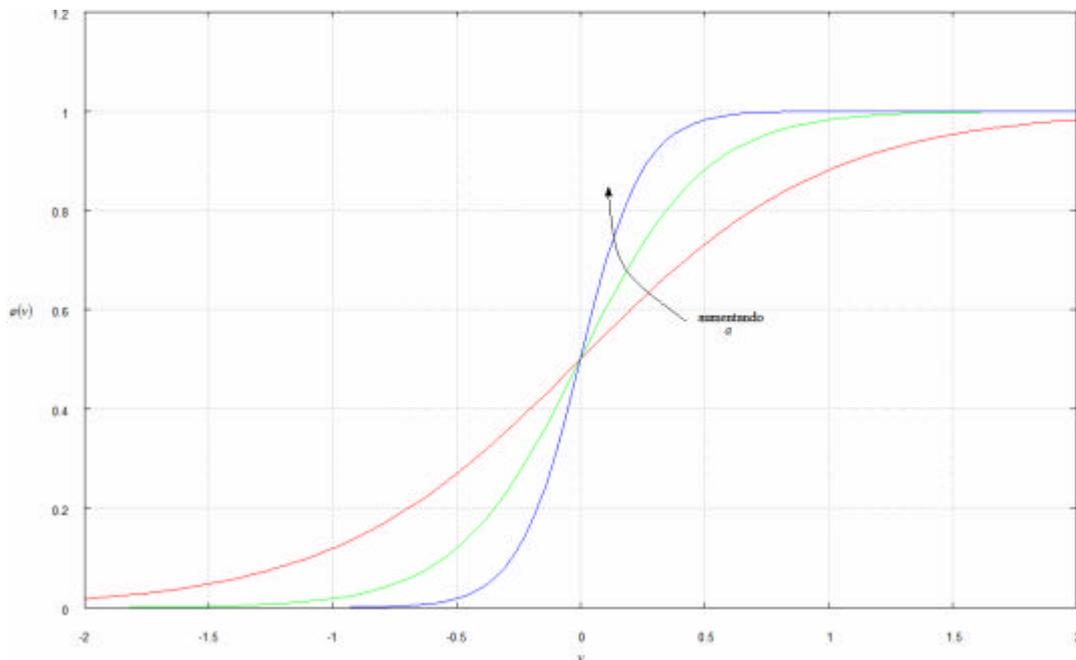
- Se a região de operação é mantida sem entrar em saturação, tem-se um combinador linear;
- A função linear por partes pode ser vista como a redução da função limiar quando o fator de amplificação tende ao infinito.

### 2.2.2.3 Função Sigmóide:

Esta função é a mais comumente utilizada como função de ativação para implementação de RNAs. É definida como uma função estritamente crescente, que possui um balanceamento adequado entre comportamento linear e não-linear. A *função logística* é um exemplo de uma função sigmóide. A descrição matemática abaixo representa esta função:

$$j(v) = \frac{1}{1 + \exp(-av)} \quad (2.4)$$

Como pode ser visto na figura 2.10, o parâmetro  $a$  define a inclinação da função sigmóide. Quando este parâmetro tende ao infinito a função sigmóide torna-se uma função limiar. Comparando as funções sigmóide com a limiar nota-se que para a função limiar os valores assumidos na saída desta são 0 (zero) ou 1 (um), e para a sigmóide os valores assumidos pela saída ficam num intervalo entre 0 (zero) e 1 (um).



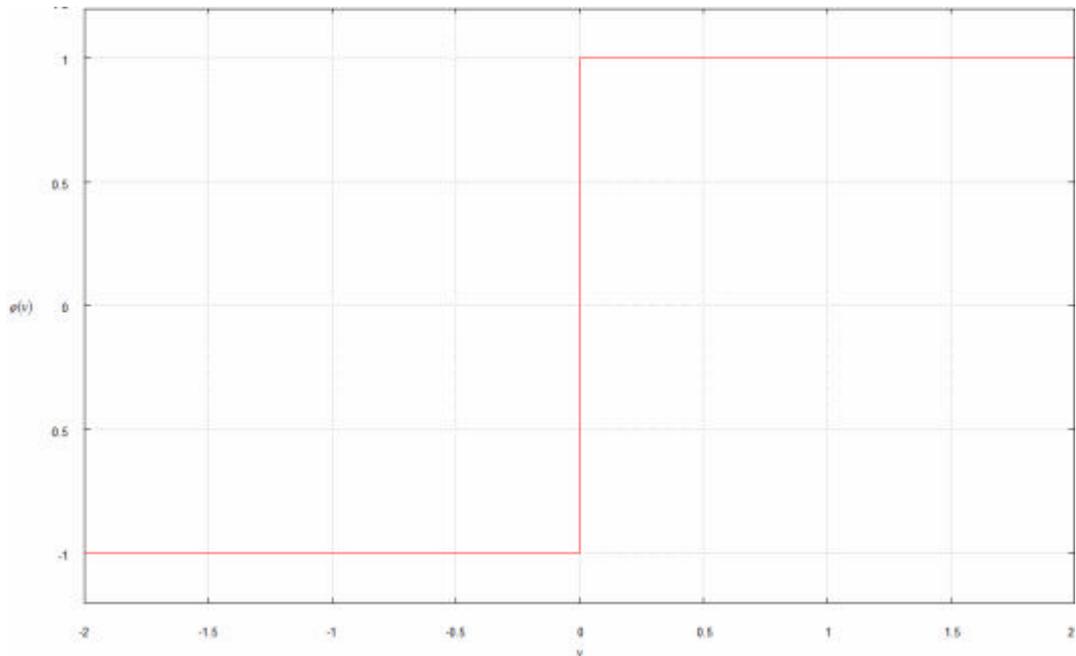
**Figura 2-5: Função Sigmóide**

#### 2.2.2.4 Função Ímpar

As funções de ativação até agora apresentadas apresentam um intervalo de operação de  $[0, 1]$ , porém para algumas aplicações pode ser necessário um intervalo que se estenda de  $[-1, 1]$ , assumindo uma forma anti-simétrica em relação a origem. Desta forma se tem uma função de ativação ímpar do campo local induzido. Para se utilizar este intervalo para uma função limiar estende-se o intervalo conforma a descrição matemática a seguir:

$$\mathbf{j}(v) = \begin{cases} 1, & \text{se } v > 0 \\ v, & \text{se } v = 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (2.5)$$

A figura 2.11 mostra o gráfico desta função:

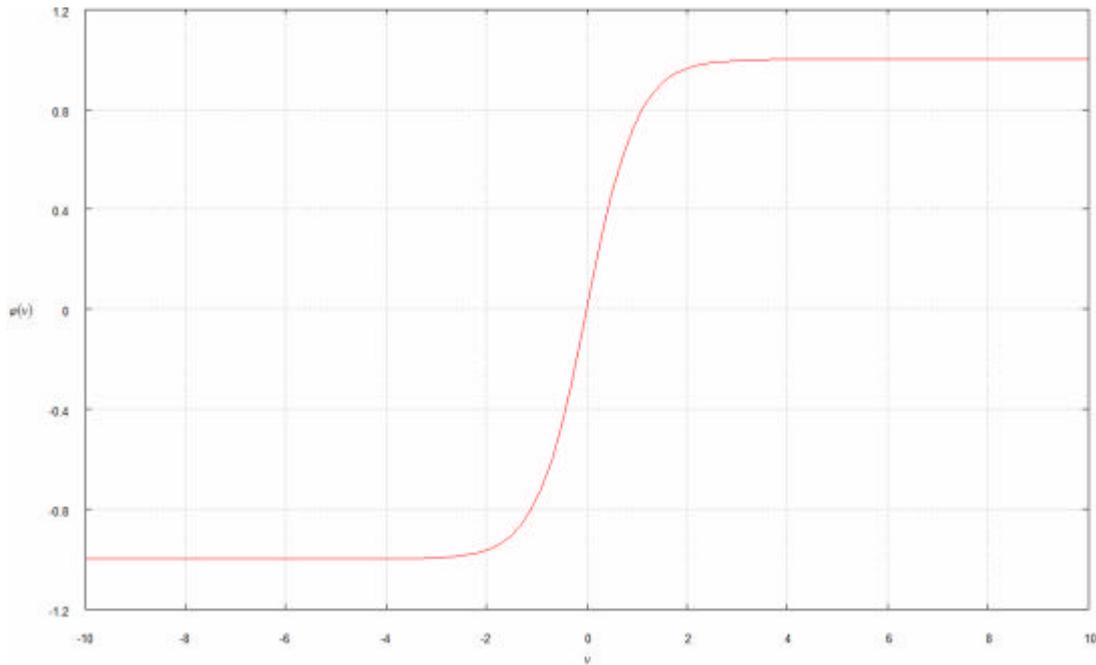


**Figura 2-6: Função Limiar Deslocada**

Caso queira-se aplicar este intervalo  $[-1, 1]$  a uma função correspondente a função sigmóide, utiliza-se a *Função Tangente Hiperbólica*, definida por:

$$\mathbf{j}(v) = \tanh(v) \quad (2.6)$$

A figura 2.12 apresenta o gráfico da função tangente hiperbólica:



**Figura 2-7: Função Tangente Hiperbólica**

### 2.2.3 Arquiteturas de RNAs

Segundo Haykin, [HAYKIN, 2001], a organização dos neurônios na estrutura de uma RNA está intimamente ligada ao algoritmo de aprendizagem usado para treinar esta RNA. Pode-se falar, portanto, que os algoritmos, ou regras, de aprendizagem na implementação de RNAs são estruturados. Existem três arquiteturas de RNAs fundamentalmente diferentes, das quais derivam-se outras, porém estas contêm a base conceitual sobre a arquitetura de uma RNA. A seguir serão abordadas estas arquiteturas.

As RNAs são comumente distribuídas em camadas, sendo que existem três camadas ditas básicas, como mostra a figura 2.13, sendo elas: I) camada de entrada, na qual localizam-se os neurônios que realizam a interface com os sinais provenientes do sistema em que a rede está inserida; II) camada escondida (ou intermediária), onde estão os neurônios que posicionam-se entre a interface de entrada e saída da rede; e III) camada de saída, na qual estão os neurônios pelos quais se dá a saída da resposta da RNA.

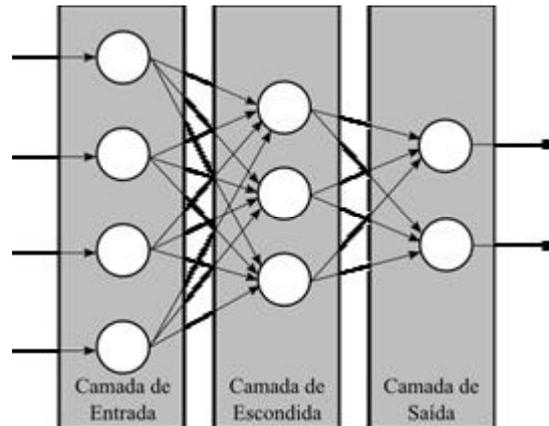


Figura 2-8: Camadas das RNA

### 2.2.3.1 Redes Alimentadas Adiante com Camada Única

A forma mais simples de uma rede em camadas é a rede em que as sinapses se dão no sentido camada de entrada para a camada de saída, ou seja, a rede é estritamente alimentada adiante (acíclica). A figura 2.14 mostra uma rede deste tipo. Nela nota-se que os neurônios de entrada são ligados aos neurônios da camada de saída. Diz-se que esta é uma rede de camada única, pois só há computação nos neurônios da camada de saída.

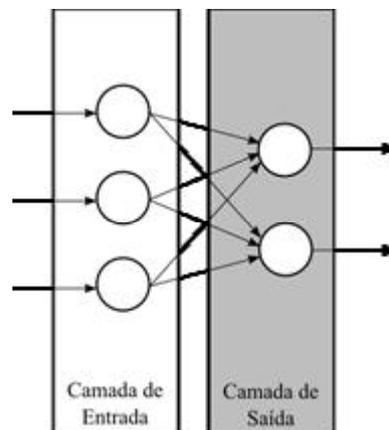


Figura 2-9: Rede de Camada Única Alimentada Adiante

### 2.2.3.2 Rede Alimentadas Adiante com Múltiplas Camadas

Ainda na linha de redes alimentadas adiante, as redes alimentadas adiante com múltiplas camadas, diferem-se do tipo de rede apresentado anteriormente pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de neurônios ocultos. A função destes

neurônios é intervir entre os neurônios da camada de entrada e saída de maneira útil ao objetivo da rede. Quando estas camadas são adicionadas a uma RNA esta passa a ser capaz de extrair estatísticas de ordem elevada. Apesar de sua conectividade local a rede adquire uma perspectiva global dada pela relação destas sinapses. Esta habilidade é bastante útil particularmente quando o número de entradas é elevado. A figura 2.13 é um exemplo de uma rede alimentada adiante com múltiplas camadas.

Este tipo de rede pode ser totalmente conectada, quando todos os neurônios possuem sinapses entre si. Porém existem aplicações em que não se quer que existam conexões entre todos os neurônios, e para estes casos a rede é dita parcialmente conectada.

### 2.2.3.3 Redes Recorrentes

A terceira arquitetura de RNA dita básica é a de redes recorrentes. Neste tipo de rede existe pelo menos um laço de realimentação. A rede recorrente pode consistir em uma única camada com cada um desses neurônios realimentando para a sua entrada. Uma variação desta arquitetura são redes que possuem neurônios ocultos a saídas destes realimentadas para a entrada da RNA, como mostra a figura 2.15:

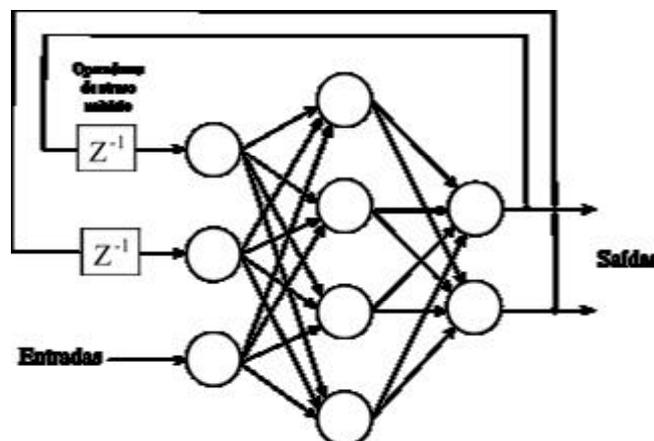


Figura 2-10: Rede Recorrente

A presença dos laços de realimentação nesta arquitetura de RNA tem um profundo impacto na capacidade de aprendizagem da rede. Estes laços de realimentação envolvem o uso de ramos particulares compostos representados por  $Z^{-1}$  (elementos de atraso unitário), o que resulta num comportamento dinâmico não-linear, admitindo-se que a RNA contenha unidades (neurônios) não-lineares.

### 2.2.4 Aprendizagem em Redes Neurais Artificiais

A propriedade das RNAs de importância primordial é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho através da aprendizagem. Essa melhoria ocorre com o tempo de acordo com uma medida preestabelecida. O aprendizado acerca do ambiente de uma RNA se dá através de um processo iterativo de ajustes dos pesos sinápticos e níveis de *bias*. De maneira ideal uma RNA se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem.

Haykin define em sua obra [HAYKIN, 2001] a aprendizagem de uma RNA como o processo pelo qual os parâmetros livres da rede são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre. Esta definição implica numa sequência de eventos listada a seguir:

1. Estímulo através de um ambiente;
2. Modificação dos parâmetros livres da RNA como resultado do estímulo anteriormente mencionado;
3. Uma nova maneira de resposta da RNA ao ambiente devido a modificação dos parâmetros acima mencionado.

A seguir serão brevemente apresentadas as cinco regras básicas de aprendizagem: aprendizagem por correção de erro, baseada em memória, hebbiana, competitiva e de boltzmann.

#### **2.2.4.1 Aprendizagem por Correção de Erro**

A aprendizagem por correção de erro se dá através de um conjunto de padrões de entrada e saída esperada pra cada uma das entradas. Cada passo  $n$  representa um conjunto de entrada  $x(n)$  que é processado pelo conjunto respectivo de neurônios  $k$ , gerando uma saída  $y_k(n)$  que é comparada com o padrão de saída  $d_k(n)$  esperado para este conjunto  $n$  de entrada. Esta comparação se dá por meio de uma diferenciação e o resto desta é o erro  $e_k(n)$  ao qual é buscada a minimização a cada iteração. A figura 2.16 mostra o diagrama de blocos desta regra de aprendizagem.

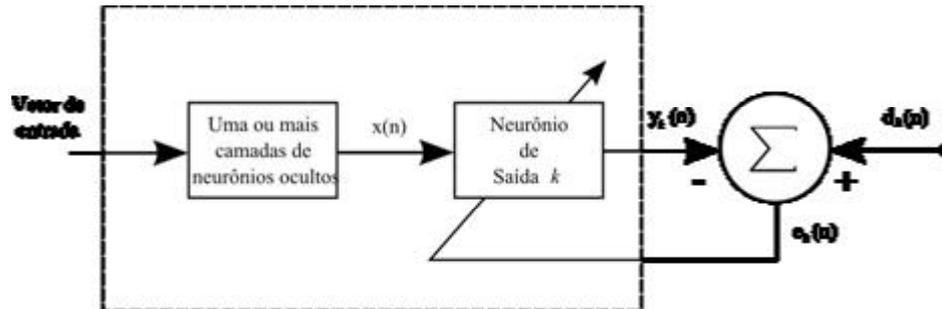


Figura 2-11: Aprendizagem Correção de Erro (Diagrama de Blocos)

#### 2.2.4.2 Aprendizagem Baseada em Memória

Nesta regra, todas ou a maioria das experiências passadas pela RNA são armazenadas em uma grande memória de maneira explícita. Nessa memória os dados são organizados de maneira que  $\{(x_i, d_i)\}_{i=1}^N$ , onde  $x_i$  representa um valor de entrada e  $d_i$  a resposta correspondente desejada. Todos os algoritmos de aprendizagem baseados em memória possuem duas características essenciais:

1. Critério para definir a vizinhança local do vetor de teste;
2. Regra de aprendizagem aplicada aos exemplos de treinamento na vizinhança local.

#### 2.2.4.3 Aprendizagem Hebbiana

A aprendizagem Hebbiana é a mais famosa e antiga regra de aprendizagem. Sua denominação provém em homenagem ao neuropsicólogo Hebb, que em seu livro [HEBB, 1949] cita:

*Quando um axônio da célula A está perto o suficiente para excitar uma célula B e participa do seu disparo repetida ou persistentemente, então algum processo de crescimento ou modificação metabólica acontece em uma das células ou em ambas, de tal forma que a eficiência de A como uma das células que dispara B é aumentada.*

Esta regra que estava num campo neurobiológico, foi extrapolada como uma regra em duas partes [STENT, 1973] e [DANCHIN, 1976]:

1. Se dois neurônios em ambos os lados de uma sinapse são ativados simultaneamente, então a força daquela sinapse é seletivamente aumentada;

2. Se dois neurônios em ambos os lados de uma sinapse são ativados assincronamente, então aquela sinapse é seletivamente enfraquecida ou eliminada.

#### 2.2.4.4 Aprendizagem Competitiva

Para esta regra é estabelecida uma competição entre os neurônios de saída da RNA em questão para se tornarem ativos. Ao contrário da regra de aprendizagem Hebbiana apresentada anteriormente, em que vários neurônios podem estar ativos simultaneamente, na regra de aprendizagem competitiva apenas um neurônio pode estar ativo em um determinado instante. É esta característica que torna a aprendizagem competitiva atraente para a descoberta de características estatisticamente salientes para a classificação de padrões.

Existem três características básicas em uma regra de aprendizagem competitiva:

1. Conjunto de neurônios iguais entre si, exceto por alguns pesos sinápticos distribuídos de maneira aleatória, e que desta forma respondem de maneiras diferentes a um conjunto de padrões de entrada;
2. Limite imposta sobre a *força* de cada neurônio;
3. Mecanismo que permita a competição por parte do neurônio pelo direito de responder a um determinado conjunto de entradas, de forma que apenas um neurônio seja ativo na saída.

#### 2.2.4.5 Aprendizagem de Boltzmann

É assim denominada em homenagem a Ludwig Boltzmann. Esta regra de aprendizagem é um algoritmo estocástico derivado de idéias da mecânica estatística. Uma RNA projetada com base na regra de aprendizagem de Boltzmann é denominada de *Máquina de Boltzmann*. Em uma *Máquina de Boltzmann*, os neurônios constituem uma estrutura recorrente e operam de maneira binária. A máquina é determinada por uma *função de energia*,  $E$ , cujo valor é determinado pelos estados particulares ocupados pelos neurônios individuais da máquina e é descrita por:

$$E = -\frac{1}{2} \sum_j \sum_k w_{kj} \cdot x_k \cdot x_j, \text{ para } j \neq k \quad (2.7)$$

onde:

$x_j$  : é o estado do neurônio  $j$  ;

$w_{kj}$  : é o peso sináptico da conexão do neurônio  $j$  com o neurônio  $k$  .

A desigualdade  $j \neq k$  indica nenhum neurônio possui auto-realimentação. A máquina opera então escolhendo um neurônio ao acaso, trocando o estado deste neurônio. Portanto se a máquina escolheu o neurônio  $k$  que se encontra no estado  $x_k$  e passa para o estado  $-x_k$  que possui uma pseudotemperatura (alusão ao processo de têmpera da mecânica estatística) probabilística  $T$ . Essa probabilidade é dada por:

$$P(x_k \rightarrow -x_k) = \frac{1}{1 + \exp(-\Delta E_k/T)} \quad (2.8)$$

onde  $\Delta E_k$  é a variação de energia (da máquina) resultando da troca de estados do neurônio. Se aplicada repetidamente a regra atingirá o equilíbrio (equilíbrio térmico).

Os neurônios da máquina de Boltzmann podem ser divididos em dois grupos funcionais, sendo eles os visíveis e os ocultos. Os ditos visíveis criam a interface entre a RNA e o ambiente em que ela está inserida, ao passo que os ocultos sempre operam livremente. Há ainda dois modos de operação a serem considerados:

1. Condição presa: os neurônios visíveis estão todos presos a estados específicos determinados pelo ambiente;
2. Condição de operação livre: todos os neurônios (visíveis e ocultos) podem operar livremente.

## 2.3 Métodos de Validação de Previsores

O processo de validação de um modelo de predictor é o passo mais importante na concepção deste. Isto se deve ao fato da validação ser o ponto de retorno da interação no desenvolvimento do modelo, pois dependendo da resposta dada a validação o modelo do predictor será descartado, modificado ou dado como concluído. Desta forma o modo como a validação é realizada e analisada é a diferença entre um modelo errôneo e um modelo confiável.

Em se tratando de predictores neurais dois métodos destacam-se como mais utilizados e aceitos, cada um destes com seus focos de avaliação. A robustez do predictor é avaliada através do método de validação cruzada, ou *Cross-Validation* que consiste no particionamento e cruzamento da massa de dados utilizada para treinar e testar o predictor. Já a acuracidade do predictor é avaliada com a chamada validação direta, ou *Direct Validation*, na qual a massa de dados é dividida entre treinamento e validação sem nenhum outro tipo de manipulação. A seguir estes métodos de validação são apresentados de maneira detalhada.

### 2.3.1 Cross-Validation

A validação dada por este tipo de método é a indicada quando se quer aferir a robustez de um modelo. No caso específico de um modelo de previsão esta informação é também utilizada para indicar a confiabilidade do modelo. Essa relação entre robustez e confiabilidade pode ser feita neste caso, pois o sistema previsto pode apresentar um comportamento fora do padrão e estando o modelo robusto o suficiente sua resposta é confiável.

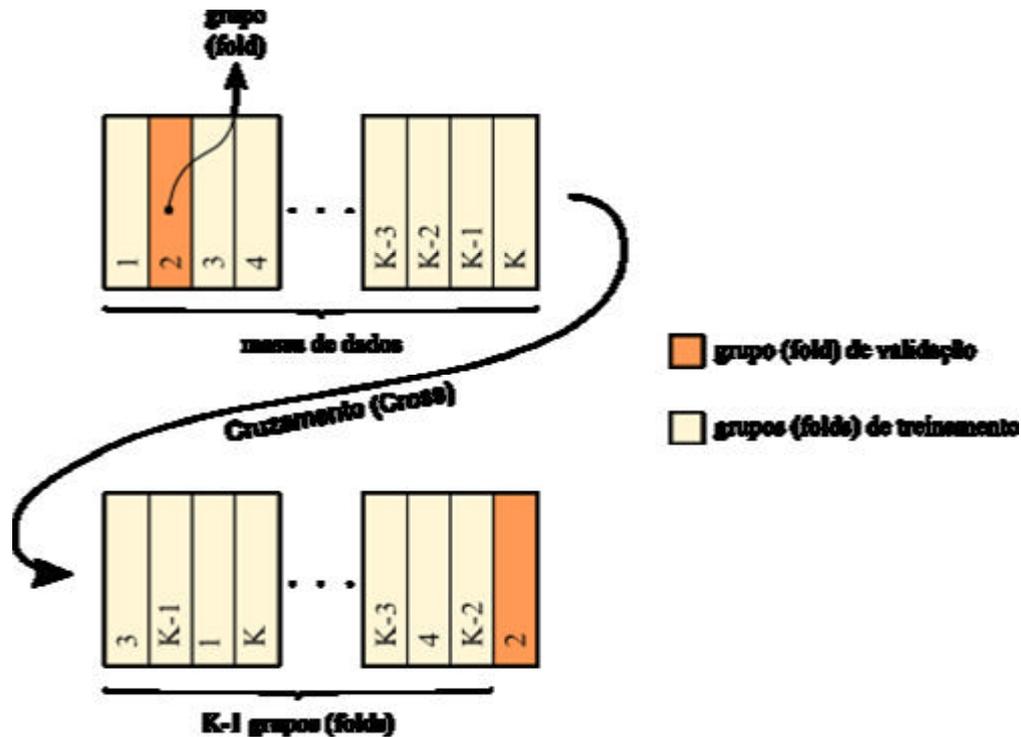


Figura 2-12: Dinâmica de um método de *Cross-Validation* .

O método de *Cross-Validation* define, de maneira geral, um particionamento da massa de dados em  $K$  grupos (*folds*) e o cruzamento dos mesmos de maneira a criar um grupo para treinamento e outro para teste, ou seja, a validação propriamente dita. Qualquer tipo de validação que utilize estes preceitos pode ser dita como parte do grupo dos métodos de *Cross-Validation*. Dos tipos comuns de *Cross-Validation* destacam-se o *Leave-One-Out Cross-Validation* e o *K-Fold Cross-Validation*.

### 2.3.1.1 Leave-One-Out Cross-Validation

Este método, que também é chamado pela abreviação *LOOCV*, divide a massa de dados em  $K$  grupos, onde são comuns a utilização de  $K$  entre 3 (três) e 10 (dez). Estes grupos, ou *folds*, são cruzados onde  $K - 1$  é utilizado para validação e um único grupo utilizado para a validação propriamente dita.

### 2.3.1.2 K-Fold Cross-Validation

O particionamento da massa de dados em  $K$  grupos (*folds*). Destes grupos  $K-1$  são utilizados de maneira cruzada para treinamento do previsor, tal como no *LOOCV*, e o grupo que restou utilizado para a validação. Este processo é repetido  $K$  vezes até que todos os  $K$  *folds* tenham sido utilizados para validação. Os  $K$  resultados podem ser apresentados ou em forma de uma média destes, ou combinados, sendo a última a mais corriqueira. O valor de  $K$  igual a dez é mais utilizado, sendo considerado praticamente uma convenção para validação de modelos neurais. Deste valor surge o nome do teste de validação *Ten-Fold Cross Validation*.

### 2.3.2 Direct Validation

Quando o objetivo da validação é a acuracidade do modelo testado o método de *Direct Validation* é o indicado. O método *Direct Validation* consiste primeiramente na definição do instante inicial de validação, ou seja, escolhe-se o primeiro ponto do modelo de previsão a ser validado, como o observado na **figura 2-13**. A massa de dados então é separada em um grupo de treinamento e um de validação e então estes são aplicados ao modelo.



**Figura 2-13:** Apresentação da dinâmica do método de *Direct Validation*.

Qualquer de validação de modelos necessita de uma métrica, ou ainda um método para a avaliação quantitativa e qualitativa destes. Portanto os métodos apresentados nesta seção necessitam ser quantificados e qualificados para que passem a ser úteis. Esses métodos são apresentados logo a seguir no presente texto.

## 2.4 Métodos de avaliação de Desempenho de Previsores

A avaliação do desempenho de previsores possui dois métodos básicos para a avaliação de desempenho de previsores, sendo quantitativo e outro qualitativo. Os métodos quantitativos são baseados em métricas numéricas que relacionam a resposta do previsor com os valores esperados,

quantificando geralmente o erro gerado pelo previsor. Já os métodos qualitativos fazem a mesma relação entre os valores previstos e esperados, porém os apresentam na forma gráfica. Para todos estes métodos os valores de entrada para análise, tanto os de previsão como os dos valores reais devem estar devidamente normalizados. A normalização para análise estatística, que é o caso da maioria destes métodos é dada por:

$$n_{(i)} = \frac{x_{(i)} - \bar{x}}{s_x} \quad (2.9)$$

onde:

|           |   |                                     |
|-----------|---|-------------------------------------|
| $n_{(i)}$ | : | valor normalizado;                  |
| $x_{(i)}$ | : | valor a ser normalizado;            |
| $\bar{x}$ | : | valor a ser normalizado;            |
| $s_x$     | : | média dos valores não normalizados; |

Existem diversos métodos quantitativos para a representação numérica da performance de previsores, porém os mais utilizados e aceitos pela comunidade científica são a *Mean Absolute Error* (MAE) e *Root Mean Squared Error* (RMSE), em português Erro Médio Absoluto e Erro Médio Quadrático respectivamente. O mesmo ocorre para os métodos qualitativos onde existe uma ampla gama de métodos e métricas a serem utilizadas para sua representação. Os mais utilizados são a Correlação Gráfica e a de Sobreposição de Curvas. Esses métodos, tanto quantitativos como qualitativos mais aceitos são apresentados no texto que segue.

#### 2.4.1 Erro Médio Absoluto

O uso da métrica do Erro Médio Absoluto, MAE, em análise de previsores tem por objetivo obter-se uma medida de quão próximo está o valor previsto do valor real. A equação que rege esta métrica é dada por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_{(i)} - x_{(i)}| \quad (2.10)$$

onde:

|           |   |   |
|-----------|---|---|
| $n$       | : | número de instantes analisados;         |
| $f_{(i)}$ | : | valor previsto para o i-ésimo instante; |
| $x_{(i)}$ | : | valor real do i-ésimo instante.         |

O MAE é uma análise sobre os valores previstos de maneira absoluta, confrontando os valores previstos com os valores reais um a um. Esta abordagem analisa o resultado da previsão de

maneira linear, desta forma esta métrica é menos exigente ao apresentar o erro do que a do Erro Médio Quadrático.

### 2.4.2 Erro Médio Quadrático

Esta é a métrica mais utilizada para a avaliação de erro em modelos de previsão. Isto se deve ao fato desta ser uma análise quadrática, a qual é capaz de analisar as tendências do erro a cada observação. A avaliação do Erro Médio Quadrático (RMSE) de um previsor informa a variância do erro no intervalo de observação dado para essa análise. A equação que define o Erro Médio Quadrático é dada a seguir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_{(i)} - x_{(i)})^2} \quad (2.11)$$

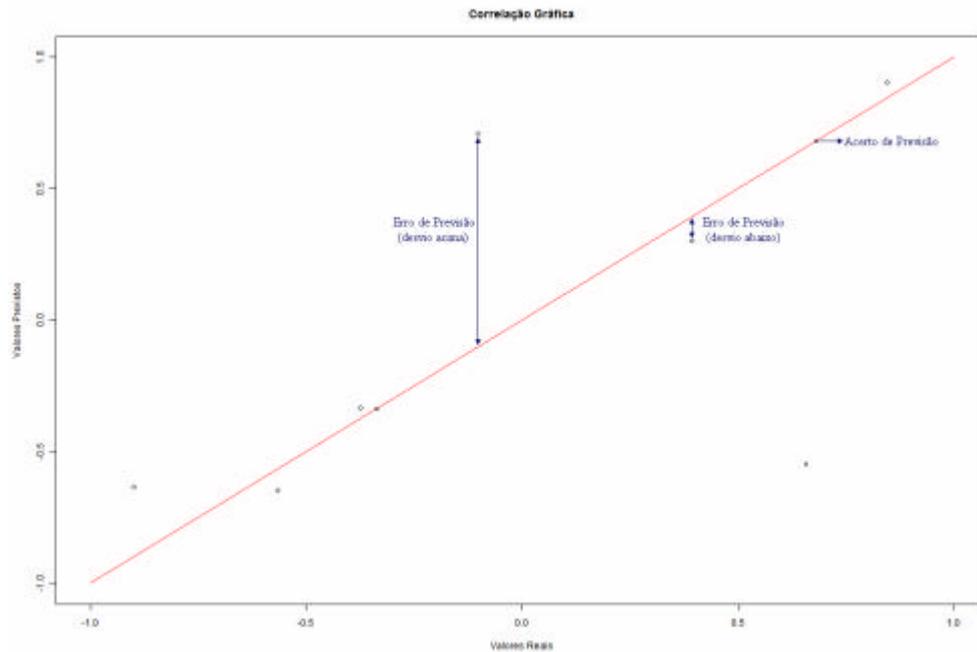
onde:

|           |   |  |
|-----------|---|--|
| $n$       | : | número de instantes analisados;            |
| $f_{(i)}$ | : | valor previsto para o $i$ -ésimo instante; |
| $x_{(i)}$ | : | valor real do $i$ -ésimo instante.         |

A definição de RMSE, principalmente a matemática, dada é muito importante para o entendimento da aplicação prática do sistema desenvolvido que é apresentado nesta dissertação. Nesta aplicação o RMSE é ferramenta básica para sua análise de resultados e de desempenho.

### 2.4.3 Correlação Gráfica

Ao contrário dos métodos até agora apresentados a correlação gráfica é um método não-estatístico. Este método simplesmente correlaciona dois intervalos de dados, no caso de interesse, um intervalo de previsão e outro de valores reais. A única exigência do método é que esses intervalos tenham a mesma dimensão, ou seja, o mesmo comprimento. A perfeita aderência dos dados a diretriz  $x = y$ , ou seja, valores reais iguais aos valores previstos indicam a ausência de erro de previsão, quanto maior a distância dos pontos em relação à diretriz, maior o erro associado ao instante de previsão por ele representado. Este comportamento pode ser melhor observado na figura a seguir:

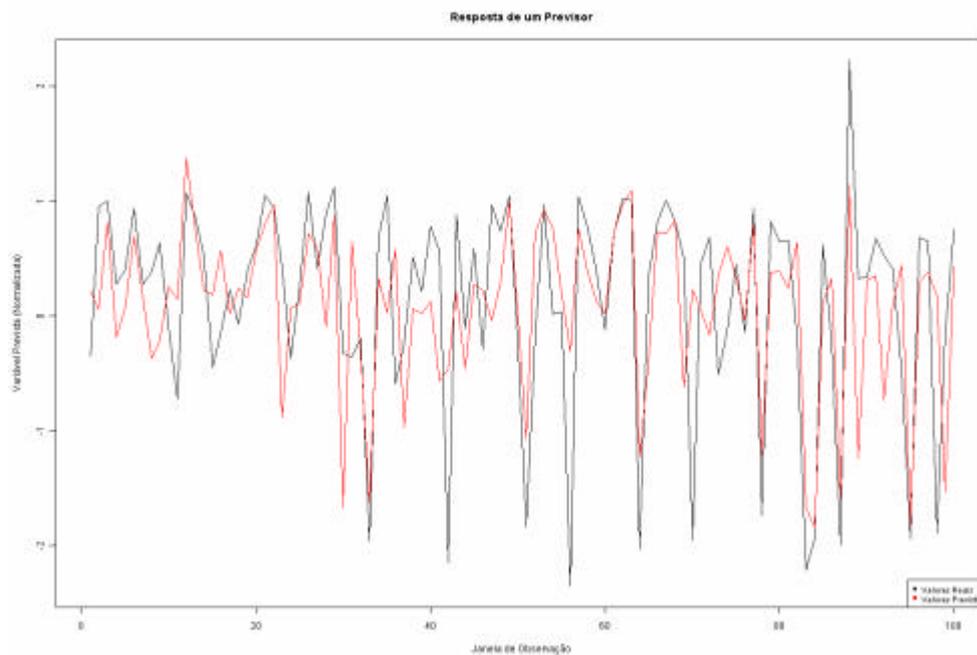


**Figura 2-14: Exemplo de uma Correlação Gráfica.**

Portanto para medidas qualitativas e de fácil e rápida interpretação este método é interessante. Exemplos da utilidade do uso da Correlação Gráfica podem ser vistos em duas diferentes fases do projeto de um previsor. Tanto na fase de validação do previsor para um retorno visual de como está a resposta da ferramenta, como na fase verificação quando o previsor é testado para um determinado intervalo de tempo analisando sua resposta quanto a correlação entre valores reais (esperados) e previstos (gerados pelo previsor).

#### **2.4.4 Sobreposição de Curvas**

Outro método não-estatístico e qualitativo, porém bastante útil é o da Sobreposição de Curvas. Este método é bastante simples, sendo bastante direto em sua proposta. Assim como o método da Correlação Gráfica, este é baseado no uso de dois conjuntos de dados com mesma dimensão (comprimento).



**Figura 2-15: Exemplo de uma verificação por Sobreposição de Curvas.**

Um dos conjuntos diz respeito ao intervalo de tempo contendo os dados reais (esperados) e o outro aos dados previstos (gerados pelo previsor), que ao serem desenhados juntos mostram como a previsão está aderindo aos valores reais. Quando as curvas se sobrepõem perfeitamente indica que a previsão corresponde exatamente ao valor real esperado. Portanto de maneira rápida e direta tem-se um retorno do comportamento do sistema. Para testes funcionais este é o método qualitativo mais interessante, pois traduz visualmente o comportamento do sistema.

## 2.5 Métodos de Seleção de Variáveis

Os métodos de seleção de variáveis fazem parte de uma área de estudo chamada de redução de dados. Esta seleção é realizada com base em um modelo, onde a inclusão ou exclusão de variáveis afetam a qualidade da resposta do modelo, dado um método quantitativo de avaliação. Com a redução conseguida com a esta seleção eliminam-se as variáveis redundantes e irrelevantes, melhorando o desempenho da resposta do modelo [GUEDES et al, 1999].

Pode-se dividir os métodos de seleção de variáveis em duas classes, a classe dos métodos manuais e a dos automáticos. O método manual é dependente de um profundo entendimento do sistema, ou seja, do modelo ao qual as variáveis pertencem. Já o método automático implica em uma busca em todo o espaço de variáveis, o que significa uma busca extensiva com  $2^n$  possibilidades dado  $n$  variáveis. Isso torna para a grande maioria dos casos práticos uma busca extensiva inviável sendo necessária uma busca baseada em heurística.

Como via de regra quando se quer aplicar um método de seleção de variáveis o modelo não é de todo conhecido, a aplicação de um método de seleção automático. Dos métodos de seleção de

variáveis baseados em heurísticas os mais difundidos são o *Forward Selection* baseado em seleção [SEEGER, 2003] e o *Backward Elimination* baseado em eliminação, [HONG, 2004]. Dentre estes o mais indicado para sistemas com grande número de variáveis é o *Forward Selection*, sendo esta característica melhor explicada a seguir.

### 2.5.1 Forward Selection

O algoritmo que implementa o método de *Forward Selection* é ao mesmo tempo simples e eficiente, como pode ser visto no **quadro 1**. Isto porque este é de fácil entendimento e trás bons resultados. O método consiste em adicionar variáveis uma a uma ao modelo e analisar seu impacto na resposta deste. O modelo é dinâmico, pois a cada iteração este contará com mais uma variável até que seu critério de parada seja atingido.

```

programa ForwardSelection ()
inicio
  err_var1_min = VALOR_ALTO;
  err_var2_min = VALOR_ALTO;
  err_var3_min = VALOR_ALTO;
  iter_min1 = 0;
  iter_min2 = 0;
  iter_min3 = 0;

  para idx1 de 1 a NUM_RESULTADOS faca
    err = modelo( x(t-idx1), x(t) )
    se err < err_var1_min entao
      err_var1_min = err;
      iter_min1 = idx1;
    fim se
  fim para

  para idx2 de 1 a NUM_RESULTADOS faca
    err = modelo( [x(t-iter_min), x(t-idx2)], x(t) )
    se e < err_var2_min e j≠i entao
      err_var2_min = err;
      iter_min2 = idx2;
    fim se
  end para

  para idx3 de 1 a NUM_RESULTADOS faca
    err = modelo( [x(t-iter_min1), x(t-iter_min2), x(t-idx3)], x(t) )
    se err < err_var3_min e idx3 ≠ idx1 e idx3 ≠ idx2 entao
      err_var3_min = err;
      iter_min3 = idx3;

```

**Quadro 1: Pseudocódigo do método de seleção de *Forward Selection*.**

Em sistemas de previsão normalmente é utilizado como critério de parada um limite aceitável de erro na resposta do modelo. Ou ainda quando após um dado número de iterações sua resposta não apresente melhoria ou esta não seja significativa frente ao critério de avaliação. A

avaliação do erro, ou seja, do desempenho do previsor é dada por um ou mais dos métodos de avaliação de desempenho apresentados anteriormente.

Com a aplicação de um método de seleção de variáveis, como o *Forward Selection*, acelera-se o processo de aprendizagem computacional, pois o espaço de variáveis é reduzido drasticamente. Outro impacto positivo provocado pela seleção das variáveis é o aumento do desempenho preditivo do modelo final, pois as redundâncias e irrelevâncias são excluídas, aumentando o foco nas variáveis realmente importantes a definição do modelo de previsão.

### 3 MODELOS DE PREVISÃO

Em sistemas que envolvam tomadas de decisões não raro tem-se a implicação de que eventos futuros (estimativas) sejam determinantes para a tomada de decisão. Desta maneira estes eventos que ainda não ocorreram precisam ser previstos para que a decisão possa ser tomada de maneira adequada. Não pode deixar-se de levar em conta que estes fatos precisam ser previstos com acuracidade e tempo de resposta aceitáveis. A acuracidade do sistema está ligada à complexidade do modelo, conforme mostra estudo de [KORZYK, 1997]. Já o tempo de resposta do sistema está relacionado diretamente com a ferramenta computacional de predição, ou ainda, com a maneira como a ferramenta computacional é utilizada. Sendo estas ferramentas e seu uso, na atualidade o principal alvo de estudos dos pesquisadores no que se trata de sistemas com problemas de previsão.

Problemas de previsão sempre foram de interesse científico, pois a capacidade de prever eventos ainda por ocorrer pode ser ou é determinante para diversas áreas do conhecimento. Esta capacidade dá ao operador do sistema, ou ao ente nele inserido, a capacidade de tomar decisões e agir de maneira antecipada, antes que o evento que normalmente provocaria a ação ocorra. Modelos de previsão são utilizados nas mais diversas áreas de conhecimento, como em segurança de redes de comunicação, [PIKOULAS *et al*, 2001] na previsão de ataque de invasores, em análises econômicas [RIETZ, 2007], agricultura [ALLEN, 1994] buscando a previsão de produção e preços de produtos agrícolas, [GAIO, 2007] em modelo para bolsa de valores. Também em previsões climáticas [TORRÓ, 2001] apresenta o estudo de um modelo para estimar o comportamento diário da temperatura do ar, [XIE, 2006] um modelo de previsão para superfície de ventos em furacões e [JORQUERA, 2002] modelo para previsão dos níveis de concentração de ozônio.

Nas engenharias dos ramos de telecomunicações e de sistemas de energia, ganham destaque atualmente no que se diz respeito à necessidade do uso de modelos e sistemas de

previsão. Estas áreas possuem grande apelo econômico por proverem ao consumidor produtos básicos do mundo moderno. Em se tratando de telecomunicações o principal objetivo é saber em que área investir em ampliações com a maior probabilidade de obter-se retorno. O trabalho de [ZONG, 2006] analisa a alocação de demanda de serviços em companhias telecomunicações. No que se diz respeito a sistemas de energia, a importância é muito grande, pois praticamente toda tecnologia atual é baseada em sistemas elétricos e/ou eletrônicos, o que impulsionou a criação de normas rígidas de regulamentação por parte dos governos de países desenvolvidos e em desenvolvimento. Este fato cria uma necessidade crescente por parte das empresas do setor em atender suas normas, e para tal muitos são os problemas de tomadas de decisão que devem ser atendidos, conforme será visto adiante.

### **3.1 Modelos de Previsão em Sistemas de Energia Elétrica**

Em sistemas de energia elétrica os problemas de decisão podem ser encontrados em todas as áreas, desde a gestão e administração até a operativa. Muitos são os esforços de pesquisadores e empresas do ramo em criar modelos e sistemas para uma previsão com alto nível de acuracidade. Anteriormente os estudos focavam na utilização de métodos determinísticos para modelar e criar os sistemas de previsão, como previsão de preços ou capacidades de sistemas de potência. Entretanto esta abordagem negligencia totalmente as incertezas da previsão intrínsecas ao sistema modelado [SWINDER, 2007]. Isto se deve ao fato de existirem variáveis exógenas relevantes, e que devem ser levadas em conta para a resposta deste modelo/sistema, sendo que em sua maioria estas variáveis tem um comportamento estocástico.

Esta característica está presente em dois dos principais problemas encontrados em sistemas de energia elétrica, que são previsão do preço e de carga de energia elétrica em um horizonte de tempo. Há um grande número de pesquisadores envolvidos na criação de modelos e sistemas de previsão para esses dois problemas. Em se tratando da previsão do preço da energia elétrica, eles podem ser vistos como uma análise de uma série temporal, muito parecida com as que se faz em sistemas econômicos. Segundo [CAÑIZARES, 2006] o conhecimento prévio das flutuações de preço no mercado de energia elétrica é essencial para ambos os lados, empresas e consumidores. Para as empresas geradoras de energia uma previsão com boa acuracidade as ajuda a criar uma oferta racional de energia em curto prazo. Para as empresas distribuidoras de energia o mesmo raciocínio pode ser feito, sendo que para estas a finalidade é a relação entre compra e venda de energia que serão ajustadas com a previsão de preço de energia.

No mercado competitivo de energia elétrica, as ferramentas de predição têm se tornado um importante meio para criação de estratégias de modo a maximizar o lucro com a negociação de energia [RAMOS, 2007]. Essa característica pode ser aplicada em todos os âmbitos do mercado de energia elétrica. Outra meta das empresas de geração de energia é verificar o comportamento do sistema com a integração de novas fontes de energia, como por exemplo, a verificação da política

ótima de integração de geração de energia por meio de hidrelétricas e termoelétricas [UDAYASEN, 1989]. Para todos os sistemas e modelos de previsão descritos anteriormente, de maneira direta ou indireta a carga do sistema é utilizada. Por este motivo a previsão de carga em sistemas de energia elétrica é um ponto muito importante. Uma ferramenta confiável de previsão de carga elétrica pode por si só ser muito útil para tomadas de decisões em sistemas de energia elétrica, mas também poderá servir como base para ferramentas que busquem outras previsões ou soluções.

### 3.2 Modelos de Previsão de Carga

Uma estratégia primordial para os sistemas elétricos é a previsão de carga, pois nela é baseado o planejamento e operações do sistema de forma confiável e segura [SENJYU, 2002]. Previsão de carga em sistemas de energia elétrica é uma tarefa muito importante para garantir-se a viabilidade econômica de operação do sistema [MIZUTANI et al, 2005]. Com a previsão de carga pode-se definir o consumo de energia em uma dada região com antecedência e assim projetar e/ou adequar o sistema elétrico para atender esta região. Para as empresas esta informação é de suma importância, pois determinadas ações, principalmente no que se referem às expansões de rede e negociações contratuais, a antecipação do comportamento da rede traz subsídios que irão determinar e guiar as ações, que por muitas vezes possuem implementações morosas e complicadas.

Em sua dissertação de mestrado Esteves [ESTEVES, 2003] cita que previsão de carga elétrica, tanto de curto, quanto de médio e longo prazo, tem se mostrado e desempenhado um papel muito importante no que tange a operação e planejamento das empresas concessionárias prestadoras de serviço. Esta previsão de consumo de energia elétrica evita o acontecimento de desperdício, escassez e a má alocação de recursos. Especificamente no caso da previsão de carga elétrica, Esteves destaca o objetivo da previsão de curto prazo, que pode variar entre dias ou horas de antecedência, que é auxiliar a definição da alocação das cargas de maneira eficiente para seus clientes. Para previsões de médio prazo, que variam entre semanas e meses, o objetivo é organizar as manutenções necessárias no sistema de energia, tanto na geração como na transmissão e distribuição. E finalmente para previsões de longo prazo, referentes a intervalos entre meses e anos, o objetivo é fazer um diagnóstico do mercado consumidor, buscando evidenciar a necessidade ou não, de investimentos, ocasionado por aumento ou diminuição da demanda do serviço.

Os estudos tanto dos modelos de previsão de carga elétrica passa pelo uso das ferramentas computacionais utilizadas para esta previsão. Fazendo-se uma revisão na literatura nota-se que uma das ferramentas computacionais mais utilizadas são as Redes Neurais Artificiais, ou simplesmente RNAs. Pechmann cita em sua dissertação de mestrado [PECHMANN, 2004], as diferentes classes de RNAs, sendo elas redes alimentadas adiante, redes alimentadas adiante com atraso e redes recorrentes. As redes recorrentes, também chamadas redes temporais, estão baseadas nas redes alimentadas adiante, porém com um comportamento mais complexo. Este tipo de rede é utilizado na modelagem e previsão de séries temporais.

### 3.2.1 Modelos de Previsão de Carga Elétrica Utilizando RNAs

Na literatura muitos são os trabalhos que utilizam RNAs como ferramenta para previsão de carga. Isto se deve a característica das RNAs temporais ser a classe de redes que melhor representa a natureza temporal dos sistemas dinâmicos, que é o caso do sistema elétrico. Mesmo que os autores utilizem praticamente em sua totalidade as RNAs temporais, como será visto nesta seção as implementações diferem quanto a maneira com que a base de dados é utilizada para treinar estas redes.

Em seu trabalho Botha, [BOTHÁ, 1998] admite que carga possa ser modelada como um sistema dinâmico, influenciado por uma série de variáveis climáticas e tempo. Ele também cita que as RNAs recorrentes pertencem a classe de modelos conexionistas, exibindo comportamento dinâmico intrínseco, que pode ser usado para construir modelos empíricos de sistemas dinâmicos. Por causa da natureza dinâmica não linear desses modelos, o comportamento da previsão de carga pode ser capturado em uma representação compacta e robusta. Neste mesmo trabalho Botha faz uma comparação dos resultados entre RNAs recorrentes e RNAs alimentadas simplesmente adiante. Nesta comparação verificou-se que as RNAs recorrentes capturam com sucesso o comportamento da curva de carga, com uma complexidade para treinamento não muito maior que as RNAs alimentadas simplesmente adiante.

Uma técnica de seleção ativa para dados de treinamento, empregando o conceito do vizinho mais próximo é apresentada em [DREZGA, 1999], como um conceito. Drezga mostra o conceito de simulação utilizado para determinar o número de unidades ocultas para as RNAs. Um conjunto de preditores locais das RNAs foi usado para produzir a última previsão, segundo o qual o processo iterativo de previsão utilizada uma média simples das RNAs implementadas. Os resultados obtidos utilizando dados de duas empresas do setor elétrico americano mostraram uma precisão de previsão comparáveis aos de técnicas semelhantes. Excelentes previsões de uma hora ou até de cinco dias de antecedência, com comportamento robusto, comportando grandes e súbitas mudanças climáticas, baixo índice de erro e previsões precisas de picos de carga são algumas das conclusões apresentadas pelo trabalho de Drezga.

A aplicação de RNAs para previsões de carga de curto prazo possui uma importância muito grande na revisão da bibliografia realizada. Em [SAAD et al, 1999] este fato é comprovado. A disponibilidade de dados históricos de carga na base de dados das empresas do sistema elétrico torna muito atrativo o uso de RNAs, já que o principal elemento computacional para uma RNA é uma base de dados suficientemente grande para que se tenha a capacidade de aprender com a relação de informações passadas, presentes e futuro, para variáveis climáticas e de curva de carga. Estas duas séries temporais são combinadas e aproximadas por aproximações regressivas. Uma ampla variedade de diferentes tipos de RNAs têm sido usadas para previsão de carga. Saad traz

uma RNA do tipo MLP que é normalmente usada para previsão, que foi treinada e validada com dados reais e obteve resultados muito satisfatórios. Saad também observou uma grande diferença entre o comportamento da carga do sistema em dias de semana e de finais de semana.

Uma abordagem para previsão de curtíssimo prazo utilizando a aplicação de RNAs para o modelo de carga dinâmica é apresentado no trabalho de [CHARYTONIUK, 2000]. O algoritmo proposto é mais robusto se comparado com a abordagem tradicional, onde valores de cargas reais são previstas e usadas como variáveis de entrada. Isto provê maior confiabilidade à previsão, segundo Charytoniuk, especialmente quando as condições climáticas são diferentes das apresentadas na base de dados de treinamento. Uma preocupação de Charytoniuk foi de dar tratamento diferente às bases de dados dos dias de semana e dos finais de semana, pois dessa maneira é possível diminuir o erro da previsão, pois existe uma sensível discrepância do comportamento de carga nestas duas situações. O método de Charytoniuk foi implementado com sucesso e utilizado para previsão *on-line* de carga em uma empresa do setor elétrico norte americano. Para garantir um desempenho robusto e tempos de treinamento aceitáveis, para atender as necessidades de um sistema *on-line*, este foi concebido como um conjunto de RNAs. A cada RNA foi atribuída a tarefa de previsão de um determinado período do dia, com um único padrão de carga dinâmica.

Funabashi utiliza em seu trabalho [FUNABASHI et al, 2002] como avaliador de aderência entre previsões de um dia e um dia seguinte, fatores ponderados através da norma euclidiana. Segundo Funabashi esta técnica é útil para avaliar a semelhança entre previsões. Dias com previsões similares foram selecionados conforme correspondência baseada nesta norma. Portanto, conforme a norma euclidiana diminui, melhor torna-se a avaliação da similaridade entre a previsão dos dias. Funabashi também estuda o coeficiente de correlação entre os dados meteorológicos e carga antes da aplicação da norma euclidiana, portanto uma seleção de semelhança entre dias considera uma tendência de carga e temperatura. Com isso a RNA utiliza desvio de dados para carga e temperatura como dados de aprendizado, o que possibilita a redução da estrutura e o tempo de aprendizado da RNA. Este método de previsão de carga usa RNA e adotando o aprendizado *on-line* através do uso do erro como dado para o aprendizado. Funabashi não trata os dias de semana e os finais de semana de maneira distinta, porém como o seu modelo cria previsões para dias similares, onde foram separados em dez grupos de dias, esta situação acaba por ser contemplada de maneira automática.

O foco do trabalho de Fukuyama é a implementação de um método que utiliza redes neurais estruturadas analisáveis, ou ASNN do inglês *analyzable structured neural network*. Uma ASNN é utilizada em [FUKUYAMA et al, 2002], com a finalidade de fazer uma previsão do pico de carga diária e ainda explicar ou dar indicações sobre a previsão realizada. Este tipo de rede é constituída por duas unidades ocultas, onde uma delas realiza as conexões entre a camada oculta e

um grupo de unidades de entrada e a outra conecta as unidades ocultas a todas as unidades de entrada, sendo que cada uma dessas conexões possui um peso relacionado gerado a partir do treinamento da RNA. O primeiro grupo de unidades ocultas permite explicar a previsão realizada, já o segundo e último grupo garante a performance da previsão. As diferenças entre dias de semana e finais de semana estão contempladas no modelo, mais precisamente na arquitetura da rede implementada por Fukuyama, na qual a primeira camada de unidades ocultas liga-se a unidades de entrada (variáveis de entrada) específicas, responsáveis por um dado comportamento. A efetividade do treinamento proposto pelo método de Fukuyama foi validada através da simulação de dois casos, em um deles o cenário de previsão é a primavera e o outro é o verão. No primeiro caso Fukuyama observou uma relação quadrática entre a temperatura e o pico de carga, já no segundo caso, o verão, a constatação foi que há uma relação diretamente proporcional entre temperatura e consumo de energia elétrica, conseqüentemente aumento da carga elétrica. Fukuyama apresenta uma detalhada apresentação de sua implementação de uma ASNN.

Saber o pico de carga elétrica diária é muito importante para as empresas do setor elétrico, portanto a previsão do pico de carga elétrica ou PLF, do inglês *peak load forecasting*, é alvo do trabalho de pesquisadores. Soni utilizou uma rede neural alimentada adiante baseada no gradiente conjugado (CG) como métodos de retro-propagação [SONI, 2002], incorporando o efeito, de 11 parâmetros meteorológicos, a informação do pico de carga do dia anterior, bem como o tipo de dia, para criar um sistema de previsão de pico de carga. Para evitar que a rede fique em um estado de mínimos locais, Soni lançou mão de um método de otimização com parâmetros definidos pelo usuário, sendo estes, a aprendizagem e a taxa de erro aceitável. O grupo de dados para treinamento da RNA foi selecionado utilizando conceito de janelamento crescente de dados e redução conforme a da natureza do dia e da época em que a previsão será realizada. Para eliminar redundância nas variáveis de entrada, a redução do número de variáveis de entrada é realizada pela análise do componente principal, método do fator de extração, onde os dados resultantes são utilizados para a formação de uma RNA de três camadas. Para aumentar a velocidade da aprendizagem, Soni inicializa os pesos e tolerâncias, de acordo com o método Nguyen e Widrow.

Uma técnica alternativa para o uso de RNAs é apresentada em trabalho [ABDEL-AAL, 2004] publicado por Abdel-Aal, onde são mostradas as vantagens do modelo proposto. Segundo Abdel-Aal o modelo apresenta vantagens quanto à simplicidade, à automação de síntese do mesmo, e modelos de entrada e saída analíticos que selecionam automaticamente as entradas mais significativas, permitindo a comparação entre modelos estatísticos e empíricos. Para teste e validação do modelo proposto foi utilizada uma base de dados de cinco anos com informações horárias de temperatura e carga, onde estas foram aplicadas a 24 modelos de previsão de carga horária para o próximo dia. Os resultados da validação, previsão de carga horária para o ano seguinte ao final da base de dados, apresentou uma média de erro percentual absoluta, ou simplesmente MAPE (do inglês *mean absolute percentage error*) de 2,67%, para previsões

diárias. Quando os modelos foram utilizados para previsões de até uma hora, o MAPE apresentado foi de 1,14%. Os dois métodos apresentam resultados semelhantes, porém o método proposto por Abdel-Aal possui maior simplicidade no modelo.

Algoritmos para previsão de carga de curto prazo, especialmente dentro do horizonte de uma hora, pertencem a um grupo de metodologias que ajudam a tornar as ações de planejamento, operação e controle do sistema elétrico, mais efetivos. Em [MENDES et al, 2006] é apresentada uma metodologia baseada em RNAs, a qual necessita, entre outras coisas prover a escolha das variáveis de entrada do modelo, evitar o *overtraining* e a criação de um vetor de entradas. Isto é possível através da tentativa de diminuir a arbitrariedade nas escolhas de variáveis endógenas. Em primeiro momento Mendes aplicou técnicas matemáticas para o processo de reconstrução através de um processo estocástico que modela o sistema. Já em um segundo estágio o conceito de tendência de dias semanas anteriores é utilizado. A inclusão de variáveis climáticas no vetor de entradas traz ao modelo, proposto por Mendes, a possibilidade de torná-lo sensível às variações climáticas. Mendes ainda apresenta em seu estudo a modelagem de um sistema real.

Previsões de longo prazo para carga em sistemas elétricos também ganham destaque na literatura pesquisada, Quintanilha em seu trabalho aborda este tipo de previsão [QUINTANILHA et al, 2005]. Nele Quintanilha propõe um modelo hierárquico híbrido para previsão de pico de carga em longo prazo. O modelo proposto possui duas redes mapeadas uma sobre a outra, sendo que estas redes se auto-organizam, ou auto-ajustam, possuindo cada uma delas apenas uma camada de *perceptron* (*single layer perceptron*). Segundo Quintanilha a informação do contexto da aplicação aos quais, os eventos estão vinculados é abordada pela primeira rede, ou seja, pela primeira regra. O modelo de Quintanilha foi comparado com RNAs com *perceptrons* de múltipla camada, onde ambos modelos, hierárquicos (proposto no trabalho em questão) e de *perceptrons* de múltiplas camadas foram testados e validados por dados reais de uma companhia de energia elétrica norte americana. Aos modelos foi requerido uma vez a cada semana ou mês o pico de carga elétrica para os dois anos seguintes. Os resultados dos experimentos mostrados pelo autor, modelo hierárquico híbrido, foram muito melhores que os apresentados pelo modelo de RNAs com *perceptrons* de múltiplas camadas. A performance superior mostrada pelo modelo justifica o uso deste, e levando-se em conta ainda que este modelo à época da publicação do trabalho ainda permanecia em desenvolvimento, ou seja, ainda não estava esgotada sua capacidade, e segundo o próprio autor ajustes finos ainda deveriam ser feitos no modelo. Estes ajustes deveriam ser feitos principalmente nos parâmetros de pré-processamento. A comparação dos dois modelos utilizando janelamento não foi realizada. Por este motivo o comportamento do modelo hierárquico não é conhecido aplicado junto a tal técnica. Como esta é muito utilizada para previsões de carga de curto prazo, Quintanilha propõe como futuro trabalho utilizar o janelamento para previsões de longo prazo e analisar seu comportamento aplicado junto à técnica por ele desenvolvida.

Uma tendência apresentada pelas publicações mais recentes abordando previsão de carga é o enfoque em previsões de curto prazo. Gleeson comprova esta tendência e em seu trabalho [GLEESON et al, 2006] abordando justamente um modelo para previsão de carga de curto prazo utilizando RNAs recorrentes. Gleeson apresenta um modelo de rede auto-regressiva chamada de *Auto-Regressive Multi-Context Recurrent Neural Network*, ou simplesmente a sigla ARMCRN. Esta rede auto-regressiva é uma combinação de redes recorrentes e não-recorrentes, através desta relação à ARMCRN quando alimentada com dados climáticos e históricos de carga elétrica, na mesma rede produz um resultado com maior acuracidade para previsão de carga. Isto se deve ao fato da relação existente entre as variáveis históricas e variáveis internas e externas, que quando agrupadas e relacionadas aumentam a acurácia do sistema, e é exatamente isso que uma rede do tipo ARMCRN faz, cria esta relação. Gleeson define também as etapas de um sistema de predição, sendo elas: adquirir e analisar dados históricos, pré processar e normalizar os dados, escolher os grupos de dados para serem utilizados como treinamento e como teste, escolher um algoritmo de aprendizagem adequado e por fim implementar o sistema. Gleeson em seu modelo criou três redes distintas para contemplar as diferenças entre dias normais de semana, feriados e finais de semana. Essa abordagem dada pelo autor diferencia-se das demais, pois ele aborda feriados como tendo comportamento diferente dos finais de semana e acaba por criar uma terceira rede para abordar esta diferença.

Ainda seguindo na linha de previsões de curto prazo, Shirvany faz um estudo de aplicações de RNAs em sistemas de previsão de carga de curto prazo [SHIRVANY, 2007]. A base de dados utilizada para teste possui três anos e foi retirada de uma localidade a oeste do Iran, chamada Ilam. A arquitetura utilizada por Shirvany é a de perceptrons de múltiplas camadas, ou MLPs, do inglês *Multi Layer Perceptron*. Shirvany destaca que a verdadeira vantagem, que as redes neurais têm para serem utilizadas é a sua habilidade para representar relações lineares e não lineares. Além disso, ele também destaca a capacidade de aprendizado das RNAs aprenderem as relações entre as variáveis do modelo diretamente do mesmo. Os testes realizados para a validação do modelo deram conta que a arquitetura de redes MLPs teve um resultado satisfatório para o sistema em questão.

Carga em sistemas elétricos depende de vários fatores, o que torna sua previsão um processo em que se deve ajustar o modelo de tal forma que este utilize as variáveis realmente significativas do sistema modelado. Ardil propõe um modelo utilizando uma rede MLP com um algoritmo de aprendizado baseado em retropropagação modificado. A principal constatação de Ardil em seu trabalho [ARDIL et al, 2007], foi a observação da existência de 4 (quatro) tipos de carga, que devido a seus comportamentos distintos, devem possuir tratamentos distintos. Ardil definiu estes quatro tipos de carga como 1) Carga Residencial; 2) Carga Comercial; 3) Carga Industrial; 4) Outras Cargas. O comportamento do tipo de Carga residencial é mais constante e possui uma sazonalidade clara e muita sensibilidade às variações climáticas, já a Carga Comercial tem grande influência sazonal e baixa influência climática. Cargas Industriais possuem características

muito próximas das de Cargas Comerciais, porém com variações muito mais bruscas devido aos picos de consumo ser bem diferentes. Ainda neste trabalho Ardil lança quatro questões a serem respondidas futuramente, que dizem respeito aos fatores, ou variáveis que devem ser levadas em consideração por determinado modelo para descrever o sistema de maneira adequada. Estas questões são: 1) Deve o pico de demanda servir para prever energia e fatores de carga, ou devem ser previstos de maneira separada? 2) Deve a previsão de carga total ser dada através da associação de previsões de específicas para cada um dos componentes, ou deve este ser dada através da análise e uso do histórico de carga total? 3) As condições climáticas a serem utilizadas devem levar em conta uma média ou condições extremas? E por fim: 4) Devem ser utilizados métodos e modelos simples para previsão de carga ou modelos com maior formalidade matemática devem ser investigados? O autor ainda faz um detalhado estudo da implementação do modelo apresentado no trabalho. Este trabalho se destaca dos demais pelo nível de detalhamento e pela atenção do autor a detalhes que nos demais trabalhos apresentados nesta revisão bibliográfica não haviam sido levados em consideração

A revisão bibliográfica realizada até aqui contempla as formas e técnicas de uso de RNAs para previsão de carga. Observa-se claramente que o uso de RNAs é muito importante para a solução de problemas de previsão, como o de previsão de carga elétrica. As técnicas utilizadas, vão desde uma simples remodelagem das ligações internas da RNA, passando por novas arquiteturas de RNAs, até a implementação de sistemas híbridos com o uso de mais de uma RNA para melhorar o desempenho da RNA. Técnicas híbridas envolvendo RNAs e outras técnicas também podem ser encontradas na literatura, sendo que a próxima seção da revisão trata justamente desta gama de trabalhos e publicações.

### **3.2.2 Modelos de Previsão de Carga Elétrica Utilizando RNAs e Outras Técnicas**

O desenvolvimento de sistemas computacionais híbridos têm sido muito pesquisada nas mais diversas aplicações, principalmente em problemas de otimização. Essas pesquisas têm comprovado que, desde que bem utilizado e implementado, tais técnicas unem o melhor que as técnicas utilizadas possuem. No caso de problemas de previsão, e principalmente em se tratando de previsão de carga elétrica, o hibridismo começou a ser explorado. Na revisão bibliográfica realizada foi observado que as técnicas híbridas em sua grande maioria têm um componente em comum que são as RNAs. Portanto nesta seção serão apresentados os sistemas que utilizam RNAs e outras técnicas.

A execução *on-line* e os resultados de um sistema de previsão híbrido de curto prazo para carga elétrica são apresentados no trabalho de Chan, onde também é avaliada a capacidade do sistema desenvolvido, [CHAN et al, 1999]. O sistema de predição implementado por Chan emprega uma abordagem envolvendo em paralelo lógica difusa e sistema especialista, em que se

utiliza o mapa auto-organizado de Kohonen com recurso para classificação de padrões de carga diária. O processamento das saídas da rede neural é realizado com um sistema especialista *fuzzy* que corrige os desvios de carga causados pelos efeitos do tempo e dados de dias de feriado e finais de semana. A questão de diferença de comportamento de carga entre dias de semana, feriados e finais de semana é tratada em sua totalidade pelo sistema especialista, onde há a seleção do grupo a que a base de dados pertence. No caso dos feriados existe um refinamento a mais que é a indicação de sua influência na carga, que Chan subdividiu em três categorias: sem efeito, normal e especial. Na categoria sem efeito o comportamento é tratado como um dia de semana normal, se a classificação for normal o tratamento dado será de um final de semana e quando classificado como especial é tratado como um feriado. Portanto Chan utiliza três redes distintas, mas consegue tratar cinco situações diferentes com a utilização do sistema especialista classificando as mesmas. O sistema apresentado tem alta automatização, com pouca interferência humana necessária durante o processo de previsão de carga. Uma comparação feita entre este modelo com um baseado em regressão foi usada em um centro de controle, onde demonstrou uma melhoria significativa nos resultados de previsão de carga.

O uso de um método estocástico para auxiliar no treinamento de uma rede neural é o que busca Pacheco em seu trabalho, [PACHECO et al, 1999]. Nesta publicação Pacheco apresenta uma aplicação de redes neurais bayesianas, ou BNN (do inglês *bayesian neural network*) para previsão de carga. Os métodos bayesianos utilizados por Pacheco foram a aproximação gaussiana e Cadeia de Markov Monte Carlo, ou MCMC (do inglês *Markov Chain Monte Carlo*). Como as BNNs possuem características de modelar o conhecimento, Pacheco utilizou uma BNN para modelar o conhecimento da série temporal da base de dados que estava a sua disposição. Como em uma aproximação bayesiana os pesos são calculados a partir de uma distribuição de probabilidade, e isto gera um espaço de possíveis respostas grande, deve-se utilizar segundo Pacheco, um método numérico para auxiliar neste cálculo, onde ele utilizou o método de aproximação gaussiana. Este método faz o mesmo papel da aplicação do MLE em aproximações com redes retropropagadas. O sistema desenvolvido por Pacheco foi testado e comparado com implementações de RNAs com retropropagação e obteve resultados satisfatórios e melhores em relação às implementações comparadas.

Bao define como os mais importantes fatores para previsão de carga em seu trabalho [BAO, 2002]. Primeiramente a base de dados histórica das curvas de carga, ou seja, a série temporal que descreve a carga historicamente, também é importante as informações de calendário, que são os dias de semana, finais de semana, feriados, estações do ano, entre outras. Finalmente o último fator são as informações climáticas, entre elas a temperatura instantânea, temperatura média, picos de temperatura, velocidade do vento, umidade, entre outras. Bao criou dois modelos de previsão, um para previsão de carga horária e outro para previsão de carga diária. As respostas desses modelos são analisadas separadamente, onde observa-se os padrões cíclicos da carga e a partir do

comportamento desses padrões cria-se um modelo de previsão de movimento para carga. Outra abordagem de Bao em seu trabalho é análise da correlação existente entre temperatura e carga através de regressões lineares.

Uma proposta de modelagem pelo método gráfico para seleção das variáveis de entrada de um sistema de previsão de carga é apresentada por Mori em seu trabalho [MORI, 2007]. O método gráfico determina as variáveis de entrada apropriadas para o modelo de RNA para previsão de carga. A vantagem efetiva da seleção das variáveis de entrada de maneira apropriada é a exclusão da pseudo-correlação entre algumas das variáveis de entrada, que geram erros no valor da predição final. Essa exclusão é possível devido ao método observar a correlação parcial que valida a correlação real entre as variáveis de entrada e de saída. O método gráfico utiliza a teoria de campo de Markov, e apresenta duas características muito importantes: 1) seleção da combinação ótima das variáveis de entrada e 2) facilidade de entender a relação entre as variáveis de entrada e de saída via expressão gráfica das mesmas. Mori aplica o método gráfico para selecionar as variáveis de entrada para alimentar uma rede MLP. Os testes de Mori utilizaram 2047 combinações de 11 variáveis de entrada, onde a utilização do método gráfico apresentou melhorias da média de erros e de erros máximos em 7,5% e 15,5% respectivamente, em relação aos métodos tradicionais, como modelos adaptativos e métodos de regressão.

A busca por modelos baseados em RNAs para previsão de carga elétrica é um campo a ainda ser muito explorado, pois apesar de haver muitas publicações nesse sentido ainda existem áreas a serem investigadas. Existem publicações que levam em conta variáveis climáticas e macroeconômicas, assim como as que tratam da integração de modelos de RNA recorrentes de curto e longo prazo para previsão de carga elétrica, porém em nenhum dos trabalhos estudados ou analisados estas características aparecem juntas. Portanto a abordagem proposta neste trabalho, tal como em [CECHIN et al, 2008] não foi encontrada na literatura especializada.

## 4 SISTEMA COMPUTACIONAL PROPOSTO

No estado do Rio Grande do Sul foram definidas três zonas principais de concessão, como mostra a **figura 3-1**. Uma quarta zona de concessão diz respeito a cooperativas com áreas mais restritas. A zona de concessão em que é está focado o desenvolvimento, testes e aperfeiçoamento deste trabalho esta apresentado é a região Norte-Nordeste, correspondente a RGE.

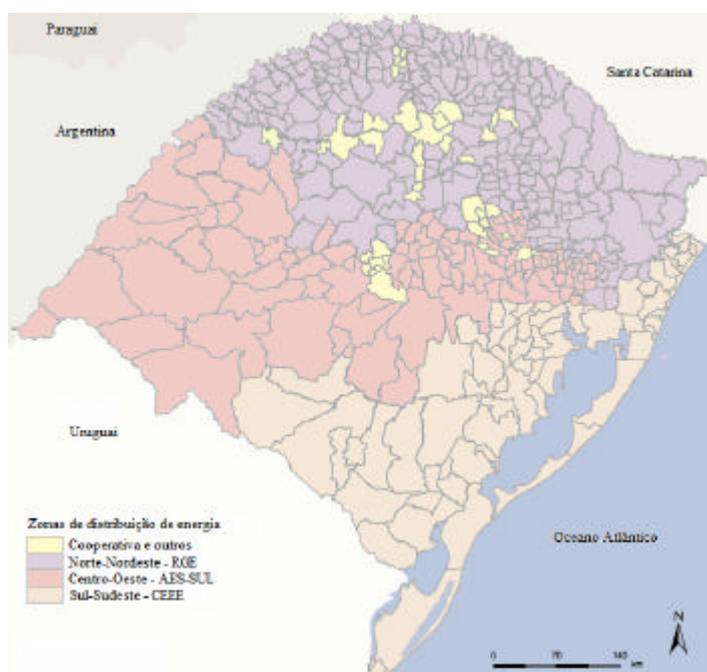


Figura 4-1: Áreas de concessão do estado do Rio Grande do Sul.

Para esta zona de concessão foi realizado uma análise computacional sobre as variáveis relevantes para os modelos de previsão criados para a mesma. Isto se deve ao fato de que uma

habilidade importante de sistema de previsão computacional é a capacidade de escolher as variáveis relevantes para previsão. Estas idealmente são listadas indicando seus respectivos níveis de importância. Esta escolha, ou seleção, se faz necessária, pois um sistema de previsão de carga elétrica é um sistema multivariável e complexo, e portanto há um grande número de variáveis que podem influir em sua previsão.

Outra importante definição é seu horizonte de previsão. Esta definição incorre sobre outras dentro do projeto do modelo de previsão a ser construído. Um exemplo desta influência é que a partir desta definição algumas variáveis podem deixar de ser relevantes ao projeto, por terem resolução diferente. Variáveis com frequência menor que a resolução dada pelo horizonte de previsão não podem fazer parte do modelo. Por outro lado se a variável em questão tiver uma dinâmica muito pequena frente ao horizonte de previsão esta será vista como uma constante por este. Portanto a escolha do horizonte de previsão além de determinar o ponto temporal que se deseja prever, também determina uma nova restrição na modelagem do sistema de previsão.

O sistema proposto nesta dissertação busca a previsão de dois horizontes possíveis, um de longo e outro de curto prazo. Foi definido como previsão de curto prazo um horizonte de um dia e longo prazo um horizonte de um mês. Para os dois horizontes foram desenvolvidos dois modelos de previsão distintos. Outra definição de projeto e também a principal contribuição desta dissertação é integração entre os dois modelos de previsão. Desta forma têm-se dois modelos de previsão integrados em um único previsor. Com apenas um previsor todas as contingências computacionais são dadas apenas uma vez, o que reduz o custo computacional, melhorando assim o tempo de resposta do sistema.

O previsor será criado com base em RNAs, que como visto no capítulo anterior são excelentes ferramentas para sistemas de previsão. Estas serão utilizadas para que as informações das séries temporais de curvas de carga, variáveis climáticas e variáveis macroeconômicas sejam correlacionadas. Desta mesma forma serão integrados os modelos para os diferentes horizontes de previsão. A seguir será explanado com mais detalhes a forma com que os modelos do sistema computacional proposto foram desenvolvidos.

#### 4.1 Modelos Propostos

O projeto do previsor baseia-se em dois modelos neurais, inicialmente independentes, sendo um para longo e outro para curto prazo. As variáveis, ou parâmetros, que formam o modelo são relativo à área de concessão da empresa distribuidora de energia Rio Grande Energia, a RGE, que pode ser vista no mapa apresentado na **figura 3-2**. Nesta mesma figura podem ser observadas

as subestações de alta tensão, em vermelho, e suas linhas de transmissão na mesma cor. Também são vistas as subestações de baixa tensão e as suas linhas de distribuição nas demais cores.

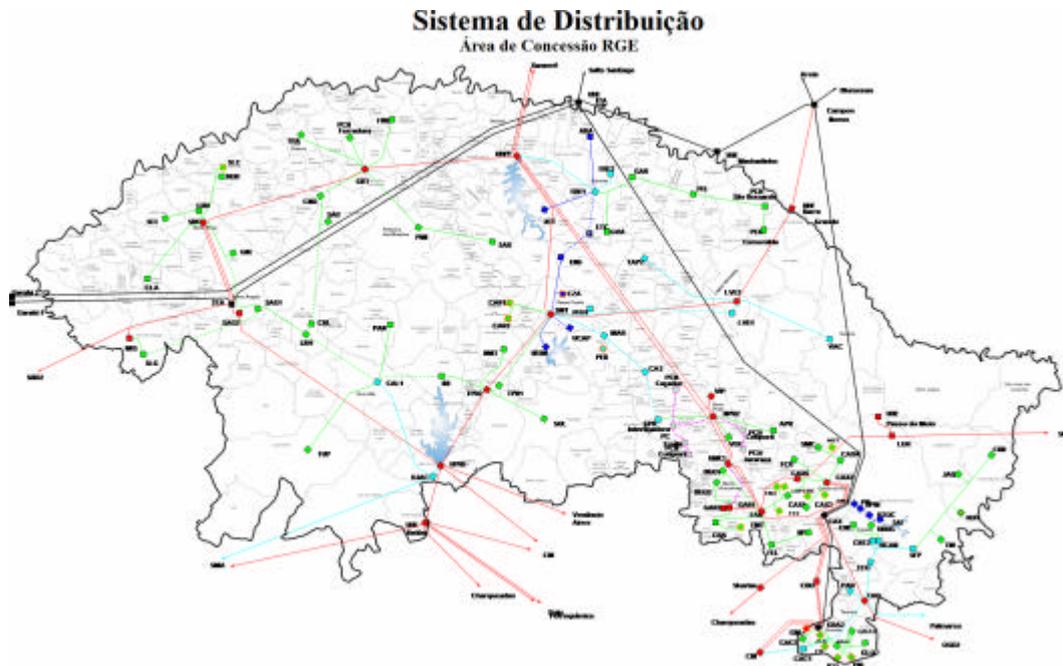


Figura 4-2: Sistema de Distribuição da RGE.

A área de concessão da RGE corresponde a região Norte-Nordeste do Rio Grande do Sul, porém para a empresa esta área é ainda dividida em sete regiões geoeletricas como mostrado na **figura 3.3**. Entende-se por região geoeletrica uma zona geográfica que compartilha as mesmas características elétricas, que podem ser desde o compartilhamento de subestações ou até mesmo a classe de consumidor predominante.



Figura 4-3: Regiões geoeletricas da área de concessão da RGE.

Ambos os modelos são compostos por três parâmetros básicos [CECHIN et al, 2008], sendo eles I) séries temporais de curvas de carga, II) variáveis climáticas e III) variáveis macroeconômicas. Sendo as séries temporais de curvas de carga medidas do consumo de carga ao longo de um dado período de tempo. Estes dados são obtidos através de medidores localizados em pontos estratégicos (cidades), que registram o consumo de energia elétrica em um determinado instante de tempo. Estas medidas são muito importantes, pois relatam de maneira direta o comportamento do consumo de carga. Por este motivo é importante ter-se uma grande base de dados de curva de carga, pois desta forma se têm dados suficientes para determinar as tendências do sistema ao longo do tempo.

As variáveis climáticas serão recolhidas nas mesmas cidades (pontos estratégicos) onde são adquiridos os dados que perfaz as séries temporais de consumo de carga [SONI, 2002], para se ter uma maior correlação entre estas variáveis. É medidas temperaturas, umidade relativa do ar e pressão atmosférica, ponto de orvalho com as medidas máxima, mínima e média. Também são informações pertencentes à classe das variáveis climáticas a velocidade do vento, direção e rajada, radiação solar e quantidade de chuva.

Variáveis macroeconômicas trazem informações do comportamento do consumidor de uma dada cidade ou região. Um exemplo desse tipo de variável são as classes de consumidores, sendo eles consumidores divididos em residenciais, comerciais e industriais [ARDIL, 2007]. Esta classificação além de indicar qual tipo de contrato existe entre distribuidora de energia elétrica e consumidor, mostra o comportamento deste quanto ao consumo de energia, no que diz respeito ao horário de pico máximo de consumo de energia elétrica e sazonalidade. Existem ainda classificações dentro destes três tipos de consumidores que levam a um refinamento ainda maior sobre o comportamento dos consumidores [MOTA, 2004]. Portanto as variáveis macroeconômicas são muito importantes para uma boa resposta do sistema de previsão.

Utilizando como base esses três parâmetros de entrada de dados, serão criados os modelos que contemplam os objetivos de projeto do sistema proposto. Estes modelos serão integrados de maneira a fornecer uma maior robustez à previsão advinda dos mesmos. A interação entre os modelos será dada em nível topológico, ou seja, as RNAs irão ser integradas através do compartilhamento de neurônios e ligações sinápticas.

As séries temporais de curvas de carga, bem como as variáveis climáticas e macroeconômicas serão utilizadas como base de dados para o treinamento da RNA. Esta rede neural gerará um modelo não-linear e multivariável do consumo de energia elétrica. Os modelos gerados representarão as séries temporais utilizadas no treino da RNA não de forma a simplesmente repeti-la, mas sim de maneira a espelhar os fenômenos subjacentes ao processo de distribuição de energia elétrica. O treino da RNA tem como objetivo obter a resposta dos modelos integrados de

maneira que estes espelhem com alta precisão os fenômenos, de longo e curto prazo, envolvidos na distribuição de energia elétrica.

#### 4.1.1 Seleção das Variáveis do Modelo

O espaço de variáveis que modela um sistema elétrico é extremamente grande e complexo, porém o primeiro grande corte neste espaço de variáveis é dado pela disponibilidade de informações sobre os sistema. Ainda pode-se fazer uma triagem baseado em conhecimento prévio sobre os sistema modelado. No caso do modelo neural realizado neste trabalho além desta triagem baseado no conhecimento do sistema foi aplicado o método de seleção de variáveis, o *Forward Selection*, anteriormente detalhado.

A triagem das variáveis baseada no conhecimento do sistema foi realizada em reuniões para troca de informações com especialistas de operação do sistema de distribuição de energia da RGE. Nessas reuniões foram abordados alguns pontos relevantes para uma triagem das variáveis, onde destaca-se a relação entre temperatura e umidade para o comportamento de curto prazo da carga. Para o comportamento de longo prazo da carga do sistema é muito importante as informações das diferentes classes consumidoras. Portanto foram entregues a avaliação do método *Forward Selection* as seguintes variáveis apresentadas na **Tabela 3-1**, separadas pelos horizontes de previsão. Sendo destacas as variáveis selecionadas pelo método.

| Variáveis - Curto Prazo    | Variáveis - Longo Prazo                         |
|----------------------------|---|
| Curvas de carga            | Curvas de carga                                 |
| Temperatura média          | Temperatura média                               |
| Temperatura máxima         | Umidade média                                   |
| Temperatura mínima         | Velocidade do vento média                       |
| Umidade média              | Insolação média                                 |
| Umidade máxima             | Índice Pluviométrico média                      |
| Umidade mínima             | Carga Industrial média                          |
| Velocidade do vento média  | Carga Comercial média                           |
| Velocidade do vento máxima | Carga Residencial média                         |
| Velocidade do vento mínima | Capacidade instalada da indústria média         |
| Insolação média            | Número de equipamentos elétricos vendidos média |
| Carga Industrial média     | Cotação do dólar                                |
| Carga Comercial média      | Crescimento da econômico                        |
| Carga Residencial média    | Capacidade de geração de energia do país        |

**Tabela 4-1: Lista de variáveis selecionadas para o modelo.**

#### 4.1.2 Modelo de Longo Prazo

O principal objetivo do modelo de longo prazo é fornecer ao modelo de curto prazo a tendência do comportamento da carga elétrica ao longo do tempo, auxiliando este em sua

acuracidade de previsão. Para tanto, é necessário realizar uma avaliação sobre as variáveis utilizadas para a criação do modelo. Essa análise de quais são as variáveis relevantes do sistema para a previsão de longo prazo é dada através de um método de seleção de variáveis. A avaliação é realizada através da obtenção de um valor numérico para cada uma das variáveis em termos de sua importância para a resposta do sistema dada uma redução do erro da resposta advinda do modelo.

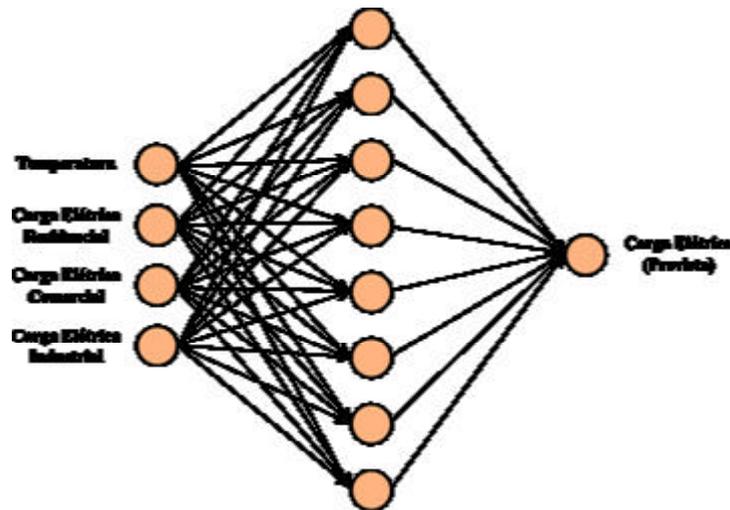


Figura 4-4: Modelo Neural de Longo Prazo.

Uma definição importante na obtenção das possíveis variáveis a serem utilizadas no modelo de longo prazo é a utilização de variáveis com comportamentos dinâmicos mais lentos. As variáveis que se julgam mais favoráveis a esse sistema são as macroeconômicas que possuem um comportamento temporal senão igual muito próximo do mensal. A partir da seleção do *Forward Selection* foi obtido o modelo neural de longo prazo apresentado na **Figura 3.1**.

#### 4.1.3 Modelo de Curto Prazo

Para o modelo de curto prazo a proposta desta dissertação é criação de um modelo que busque mimetizar o comportamento do consumo de energia elétrica no horizonte de um dia. Em outras palavras o objetivo deste modelo é descrever o comportamento do sistema elétrico modelado de acordo com suas características relevantes. Essas características relevantes, ou seja, variáveis relevantes serão incorporadas ao modelo aumentando assim sua acuracidade. É importante destacar que para a previsão de curto prazo serão levadas em conta variáveis diferentes das de longo prazo, visto que a sensibilidade do sistema como um todo será ampliada, quanto a variações mais rápidas das entradas.

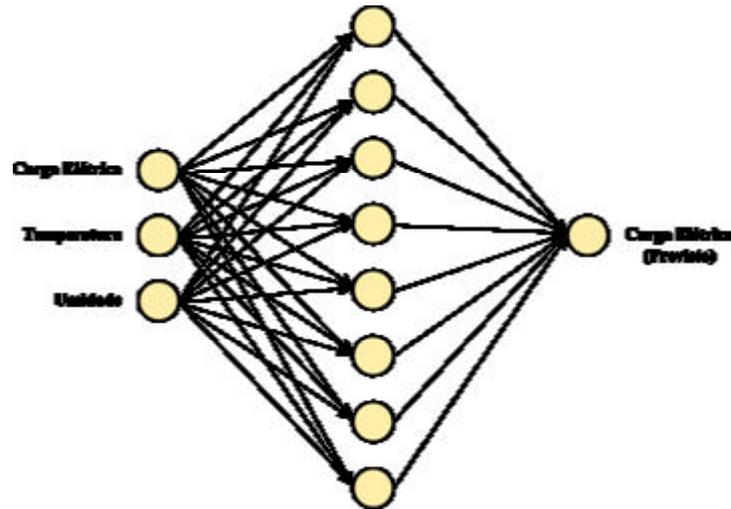


Figura 4-5: Modelo Neural de Curto Prazo.

Analisando as características do sistema pode-se perceber que as variáveis macroeconômicas tendem a ser monótonas para um sistema de previsão com resolução de um dia. Desta forma os esforços para encontrar as variáveis relevantes a este modelo pode ser estreitada sobre as variáveis meteorológicas e elétricas (séries temporais de curva de carga). Aplicando-se o método de seleção de variáveis *Forward Selection* chegou-se ao modelo neural mostrado na Figura 3.2.

#### 4.1.4 Integração entre os Modelos

A integração de modelos neurais é um procedimento que deve ser realizado com o máximo cuidado. Apesar de não haverem regras pré-estabelecidas em relação a esta prática, algumas providências devem ser tomadas para que esta não venha a ser prejudicial para o funcionamento do modelo resultante. Criar uma cascata de RNAs dependentes é uma prática que para integração de previsores tende a ser ruim. Isto se deve ao fato de que cada RNA possuirá um erro associado e este será não só propagado para a seguinte, como será somado ao erro desta.

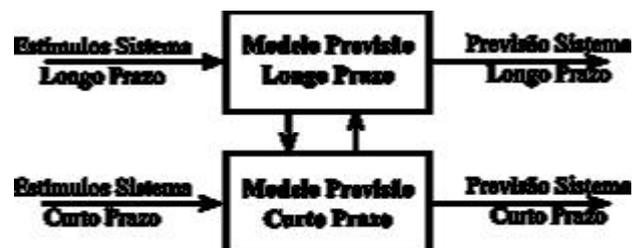


Figura 4-6: Integração dos modelos neurais de longo e curto prazos.

Esta dissertação tem como sua grande contribuição científica sua proposta de integração dos diferentes modelos de RNAs. A integração dos modelos em seu nível topológico, que é

apresentado neste trabalho, mostra uma vantagem importante sobre os demais tipos de integrações no que se refere a modelos para sistemas de previsão. Integrando os modelos no nível topológico conforme mostrado na **Figura 3.3**, cria-se a possibilidade de apenas a tendência de um modelo ser passada ao outro, sem que este tenha sua resposta distorcida. Logicamente que algumas precauções mínimas são necessárias para que isto seja verdade, porém esta possibilidade representa um grande avanço na modelagem de previsores integrados.

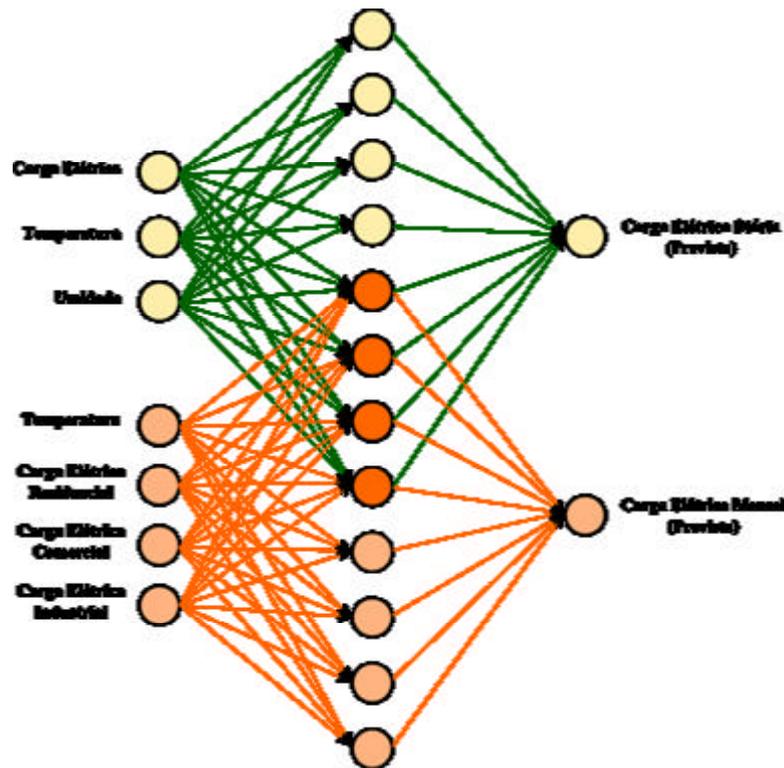


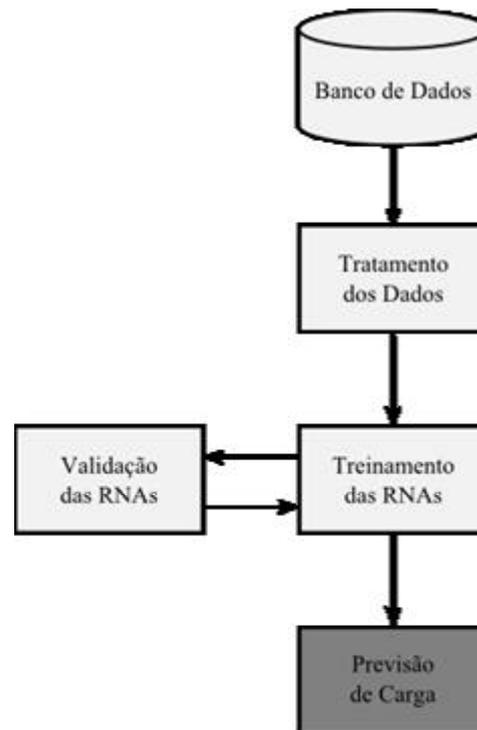
Figura 4-7: Modelo Neural Integrado.

O modelo neural mostrado na **Figura 3.4** é o resultado da integração dos modelos neurais para previsão de curto e longo prazo. Um ponto importante para o entendimento desta integração é saber que os estímulos de entrada de cada um dos modelos são ligados parcialmente aos neurônios da camada oculta. A camada oculta possui 12 neurônios, este número foi definido a partir da soma dos neurônios da camada oculta dos modelos para previsão de curto e longo prazo. Desses neurônios quatro foram selecionados para receberem os estímulos de entrada dos dois modelos. A mesma lógica é utilizada para a ligação com os neurônios estabelecem as saídas do modelo neural integrado. Somente os neurônios correspondentes ao modelo e os neurônios compartilhados serão ligados ao neurônio de saída que representa o modelo.

## 4.2 Arquitetura do Sistema Computacional Proposto

Um sistema computacional para previsão baseia-se principalmente em um histórico de eventos e acontecimentos. Estes são computacionalmente tratados como dados. Desta forma defini-

se o primeiro elemento básico do sistema, o banco de dados. Surge então a necessidade de requisitar estes dados de seu repositório e disponibiliza-los ao uso dos modelos, de onde se tem a definição do segundo elemento básico do sistema, o tratamento dos dados. O terceiro e quarto elementos a serem definidos surgem de maneira natural, pois estes juntos formam o modelo de previsão. Sendo então definidos o treinamento e validação das RNAs (modelos). A **Figura 3-8** apresenta de maneira visual a arquitetura básica do sistema computacional.



**Figura 4-8: Arquitetura de Sistema Computacional Proposto.**

O *Banco de Dados* armazena todas as informações meteorológicas, macroeconômicas e de séries temporais de curva de carga do sistema modelado. Este é o componente responsável pela organização dos dados classificando-os por tipo, posição temporal e resolução mínima. Essa classificação foi definida da seguinte forma:

- **Tipo de Dado:** classifica os dados como sendo meteorológicos, macroeconômicos ou elétricos (séries temporais de curva de carga);
- **Posição Temporal:** classifica os dados de acordo com o período coberto por sua base de dados;
- **Resolução Mínima:** classifica os dados através do período entre aquisições.

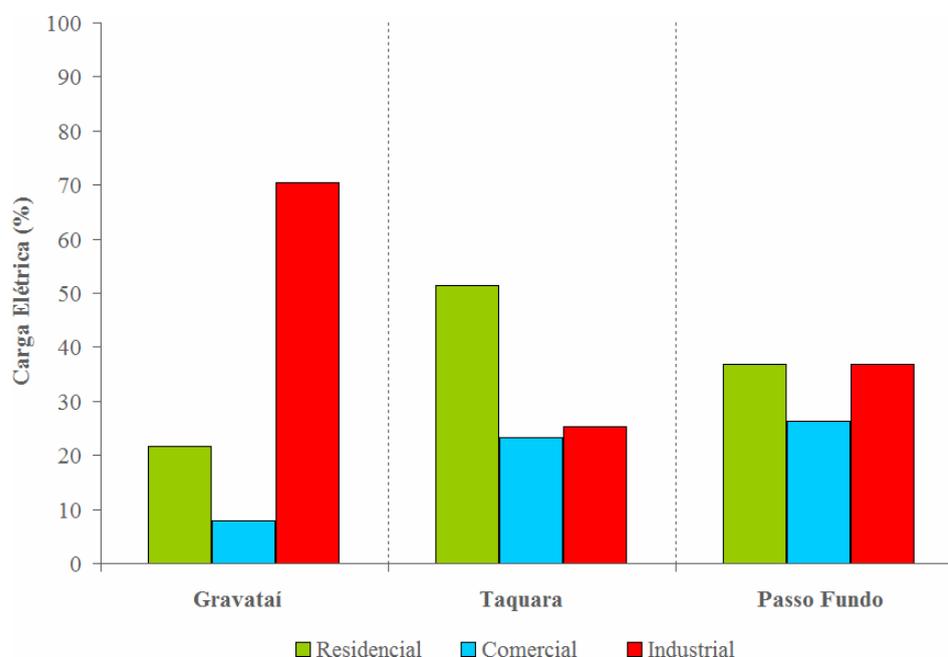
Com esta classificação dos dados a sua busca na base de dados é facilitada. Após este processo é necessário que os dados sejam tratados. Este tratamento se dá no componente de

*Tratamento de Dados*, que alinha os dados temporalmente de acordo com seu uso no modelo neural e os normaliza. O alinhamento temporal dos dados é necessário, pois apesar dos dados estarem classificados temporalmente, nem sempre há coincidência perfeita entre diferentes tipos de dados ou aquisições. Já a normalização é necessária para poderem-se colocar variáveis de diferentes grandezas unidas em um mesmo modelo.

Após o tratamento dos dados, estes estão prontos para serem entregues ao modelo neural. A RNA que descreve o modelo pode ser então treinada e validada. O componente de *Treinamento das RNAs* irá utilizar os dados já tratados e para treinar a RNA. Estes mesmos dados serão utilizados para a validação do treinamento, processo realizado pelo componente de *Validação das RNAs*. Os componentes descritos anteriormente perfazem o sistema computacional para o previsor de carga neural proposto neste trabalho.

## 5 TESTES E RESULTADOS

O teste do sistema computacional de previsão desenvolvido objetiva avaliar seu desempenho em três aspectos onde primeiramente está sua robustez, passando pela sua acuracidade e chegando finalmente a sua capacidade de generalização. A robustez do modelo é avaliada com a aplicação do *Ten-Fold Cross Validation*, e sua acuraciade analisada através do *Direct Validation*. Para a avaliação da capacidade de generalização são testados três regiões geoeletricas com características diferentes, no que se refere a classe de consumidor majoritária.



**Figura 5-1: Distribuição de classes de consumidores por regiões geoeletricas.**

Realizou-se uma análise das classes consumidoras para a determinação das regiões geoeletricas utilizadas nos testes. Nesta análise foram comparadas as classes residencial e industrial de três regiões, Gravataí, Taquara e Passo Fundo. Como pode ser visto na **Figura 4-1** a região

geométrica de Gravataí possui uma carga industrial muito expressiva, sendo que na região de Taquara isto ocorre com a classe consumidora residencial. Já na região de Passo Fundo existe um forte equilíbrio entre as cargas residencial, comercial e industrial.

A seguir é descrita a metodologia utilizada para cada etapa de teste do modelo neural de previsão. Inicialmente são apresentados os procedimentos para o treinamento e validação, onde estes procedimentos são comuns a todos os testes realizados. Posteriormente são apresentadas as respostas quantitativas e qualitativas de cada teste com suas devidas considerações.

### 5.1 Treinamento e Validação do Modelo Neural

Para o treinamento e validação do modelo neural foi desenvolvida uma ferramenta computacional que permite a automatização destes processos. Esta ferramenta baseia-se na integração de três softwares que servem como ferramentas básicas, sendo eles o simulador de redes neurais artificiais SNNS e o ambiente de computação estatística R script. Cada um destes softwares possui uma tarefa específica no funcionamento da ferramenta.

O simulador de redes neurais artificiais SNNS realiza toda a camada neural, desde onde a rede é treinada e tem seus pesos sinápticos ajustados, até sua validação onde o modelo neural já treinado é validado. Com o R script a ferramenta computacional tem toda sua camada de alto nível, com os parsers de dados para sua devida formatação e ajustes temporais. Este software é responsável ainda por fazer chamadas do SNNS rodando diretamente de seu ambiente os passos de treinamento e validação do modelo neural, onde os arquivos de padrões de treinamento e de valores reais (esperados) são gerados conforme o método de validação escolhido. Por fim, ainda no ambiente R script a resposta do simulador é avaliada segundo os métodos qualitativos e quantitativos anteriormente apresentados.

A base de dados utilizada para treinamento e validação conta com dados elétricos, meteorológicos e macroeconômicos desde janeiro de 2003 até dezembro de 2007. Os dados correspondentes a curvas de carga em intervalos horários do ano de 2003 possui falhas nas aquisições, portanto estes dados não são utilizados para os testes funcionais do modelo. Outra importante consideração sobre os dados é em relação a sua ordenação temporal. Como o modelo relaciona dois horizontes de previsão existe uma região limítrofe entre dados de previsão e dados previstos. Esta região é mostrada claramente no exemplo apresentado na **Figura 42**, onde a adequação entre os padrões de entrada de curto (diário) e longo (mensal) prazo devem ser adequados, de forma que com a passagem de um mês para o outro a previsão seja mantida de maneira coerente.

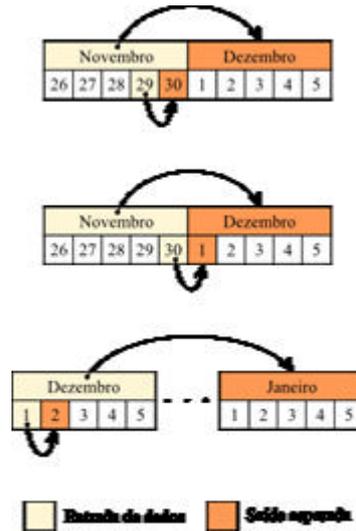


Figura 5-2: Comportamento de previsão esperado do sistema computacional.

Outra importante consideração é quanto disposição temporal dos dados para a previsão de curto e longo prazo a ser entregue ao modelo neural. Observando novamente a **Figura 4-2** nota-se que o mês previsto é sempre o mês seguinte ao correspondente aos padrões de entrada diária. Isto acarreta na necessidade de se fornecer a informação do mês atual para o preditor, o que é uma inconsistência. Para que esta situação não ocorra a informação do mês corrente vem do histórico deste mês no ano anterior, desta forma tem-se a disposição temporal dos dados de treinamento conforme mostrado na **Figura 4.3**. Tendo como referência o instante de previsão, mostrado no campo de padrões esperados, pode-se definir os deslocamentos dos padrões para os horizontes de curto e longo prazo. Os padrões de longo prazo estão deslocados no tempo em relação aos padrões esperados em exatamente um ano e um dia, pois desta forma a tendência do comportamento do mês em questão é mantida. Já no que tange aos padrões de curto prazo o deslocamento temporal relativo ao instante de previsão é de um dia.

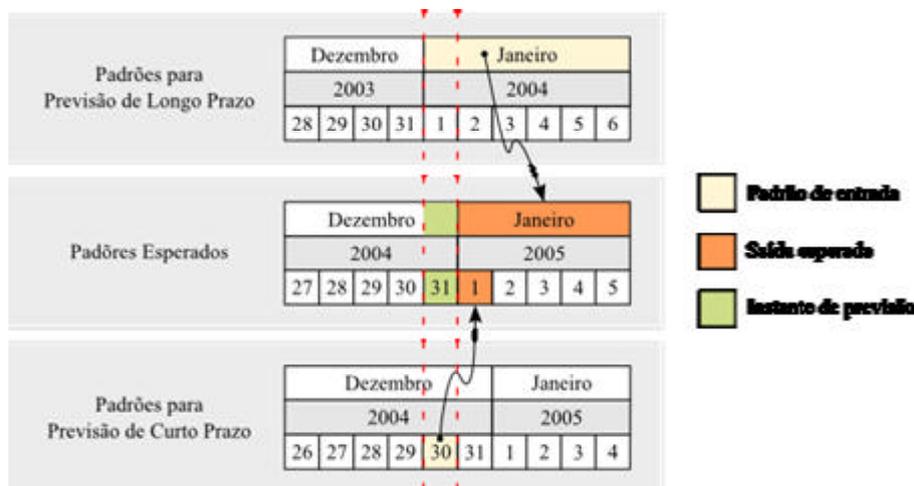
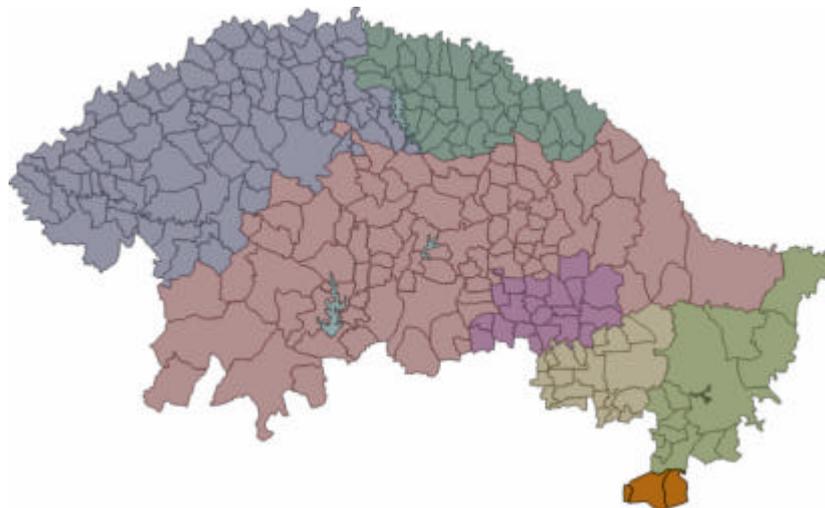


Figura 5-3: Arranjo temporal das variáveis do modelo neural.

Com estas definições tem-se então a relação entre os dados de entrada necessários para gerar uma saída válida. Portanto para se ter a previsão de carga para curto e logo prazo em  $t + 1$  deve-se entregar ao previsor as variáveis correspondentes ao curto prazo no instante  $t - 1$ , e as correspondentes ao longo prazo em  $t - 366$ . Essas variáveis de entrada foram definidas a partir da aplicação do método de seleção de variáveis, que é mostrado a anteriormente. Portanto com a utilização da metodologia acima descrita os experimentos a seguir descritos foram realizados, onde é importante lembrar que o sistema a partir de suas entradas entrega dois horizontes de previsão, sendo estes analisados com rigor individual.

## 5.2 Teste I (Carga Predominante: Industrial)

Para o primeiro teste escolheu-se uma região geoeletrica com predominância de carga industrial. Em se tratando do sistema elétrico de distribuição da RGE esta região é a de Gravataí, que apesar de geograficamente ser pequena, como pode ser observado na **Figura 4-4**, possui uma grande demanda de carga por ser um dos, senão o maior, parque industrial do estado do Rio Grande do Sul. Neste encontram-se empresas com plantas de grande porte, como Taurus, Dana, Parker, Digicom, Perto e principalmente a planta da GM (General Motors) que além de sua própria possui um parque que conta com diversas plantas industriais de empresas satélites. O comportamento da deste tipo consumidor de energia é menos dependente das condições meteorológica e muito mais dependente das condições econômicas do país ou do mercado em que esta está inserida.



**Figura 5-4: Região geoeletrica de Gravataí (em destaque).**

Esta característica é importante para determinar se o modelo é sensível o suficiente para absorver este tipo de comportamento de consumidor de energia elétrica, traduzindo isto através de uma previsão de boa acuracidade. Para tanto foram disponibilizados ao modelo dados elétricos, meteorológicos e macroeconômicos referentes a esta região.

Os dados elétricos são referentes à principal subestação da cidade de Gravataí, sendo que os dados macroeconômicos também se referem à cidade de Gravataí. Já os dados meteorológicos são referentes a Porto Alegre, isto porque não haviam dados disponibilizados pelo INMET de Gravataí. Como estas cidades são geograficamente próximas pode-se assumir que as condições meteorológicas também possuem comportamentos muito próximos. Com estes dados são realizados os testes para a validação e avaliação do sistema proposto começando pelo teste de *Ten-Fold Cross-Validation* e finalizando com o teste de *Direct Validation*, ou seja, uma análise do desempenho do sistema de modo prático.

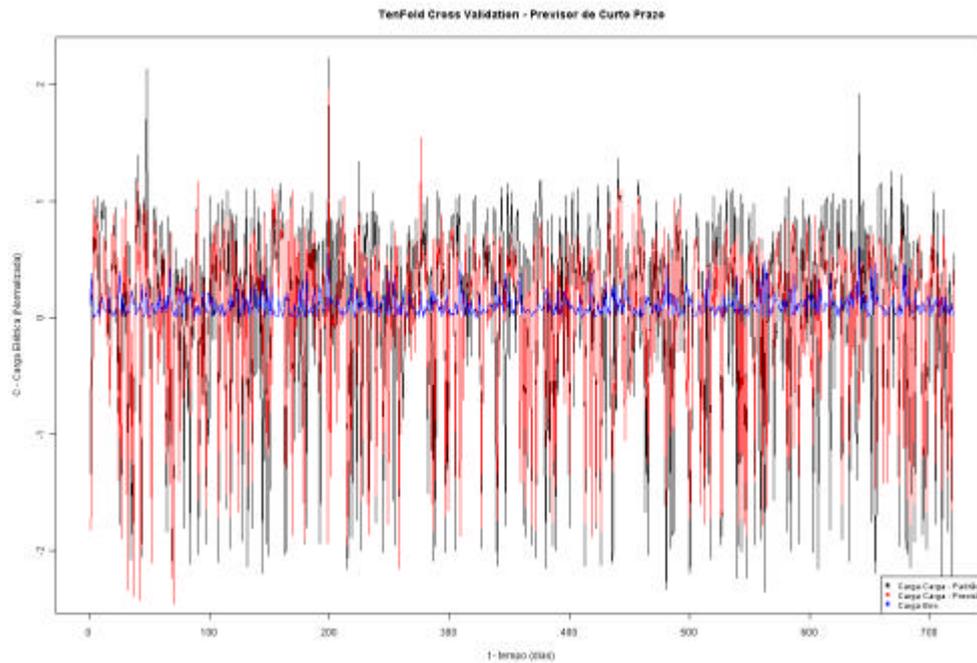
### 5.2.1 Resultados Teste I – Ten-Fold Cross-Validation – Curto Prazo

O método de validação *Ten-Fold Cross-Validation* como mencionado anteriormente fará uma validação da robustez do modelo do sistema computacional. A resposta deste método de validação é avaliada através dos métodos quantitativos e qualitativos também já mencionados no presente trabalho. As respostas quantitativas para a previsão de curto prazo deste teste estão apresentadas na **Tabela 4-1**. Nesta tabela estão disponibilizados os erros de **MAE** e **RMSE**, estes calculados com base no resultado de previsão do sistema computacional.

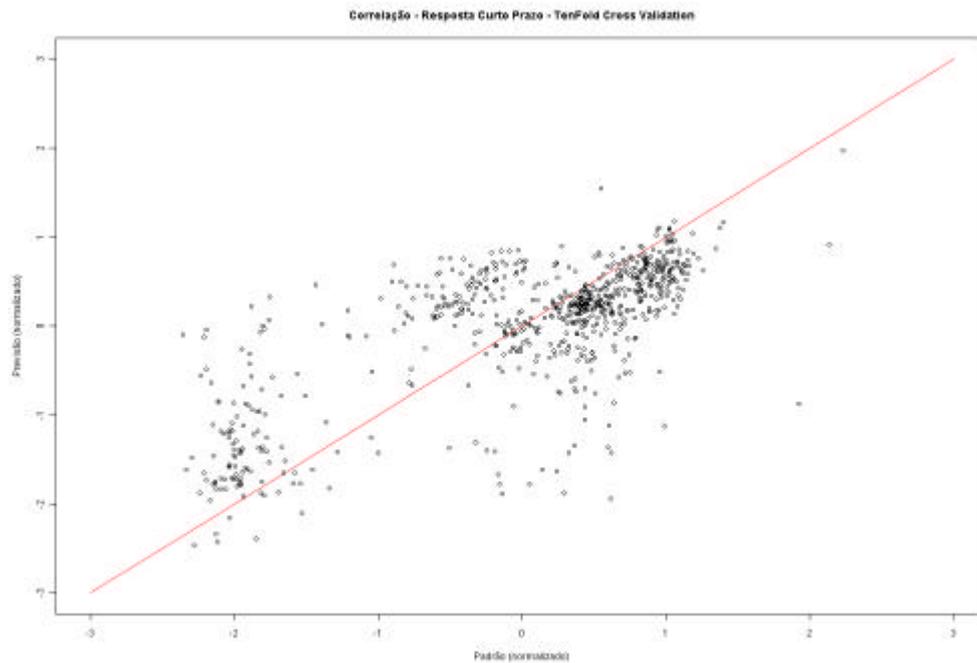
|      | Previsão de Curto Prazo |
|------|-------------------------|
| MAE  | 0,105140293229146       |
| RMSE | 0,132146508293125       |

**Tabela 5-1: Resposta dos erros para Ten-Fold Cross-Validation para curto prazo.**

Já a resposta qualitativa utilizando análise sobreposição de curvas para *Ten-Fold Cross-Validation* para previsão de curto prazo de um ponto da região geoeletrica de Gravataí pode ser visualizada na **Figura 4-5**. Em preto estão os padrões de carga esperado e em vermelho os valores previstos para a carga, ambos normalizados. Em azul está mostrado o erro absoluto para cada ponto da previsão.



**Figura 5-5: Resposta para curto prazo - Gravataí - *Ten-Fold Cross-Validation*.**



**Figura 5-6: Correlação gráfica - curto prazo - Gravataí - *Ten-Fold Cross-Validation*.**

Por ser tratar de uma validação cruzada os dados são disponibilizados ao modelo com maiores variações e por este motivo podendo dificultar sua visualização. Com vistas a avaliar melhor esta resposta é apresentada na **Figura 4-6** a correlação gráfica para este teste, nela pode-se avaliar de forma mais clara a dispersão dos dados no espaço de resposta bem como a aderência dos valores previstos aos valores esperados.

Com base nesses dois gráficos (**Figuras 4-5** e **Figura 4-6**) pode-se dizer que para curto prazo o sistema possui uma robustez aceitável, apesar de apresentar uma dispersão no espaço de respostas. Esta dispersão é também verificada nas respostas quantitativas de medidas de erro, pois a diferença entre as respostas de **MAE** e **RMSE** é dada pela variância do erro entre cada ponto de previsão, como pode ser visto na através da curva azul da **Figura 4-5** que representa o erro absoluto para cada ponto previsto.

### 5.2.2 Resultados Teste I – Ten-Fold Cross-Validation – Longo Prazo

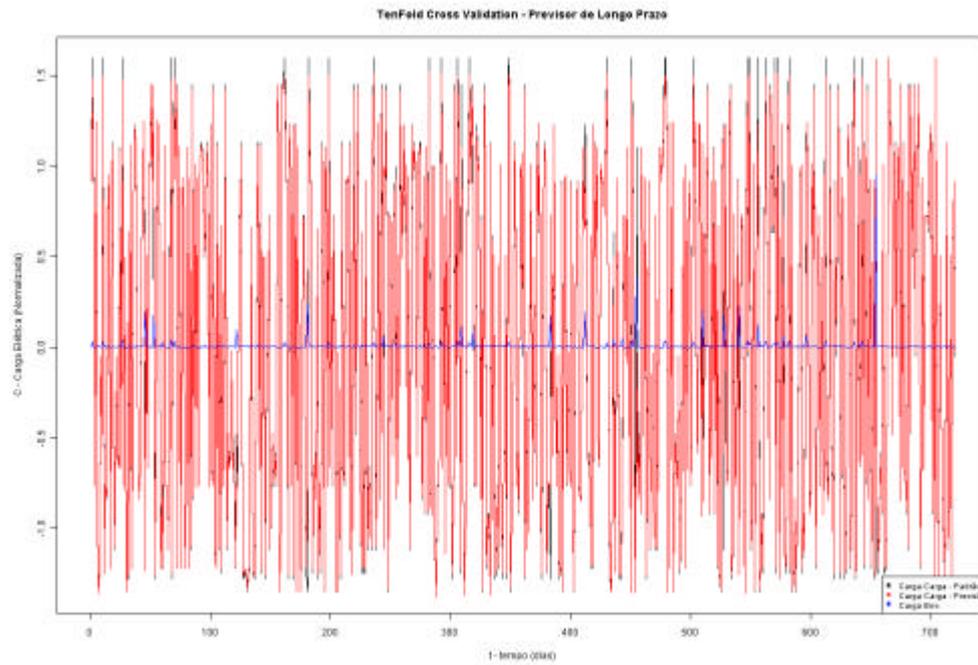
Para longo prazo o modelo do sistema computacional teve um comportamento mais robusto. Este comportamento por sua vez já era esperado, já que o comportamento do sistema elétrico é mais estável quando se aumenta sua janela de análise, já que a longo prazo o sistema possui uma média de comportamento estável. Com esta estabilidade a RNA que representa o modelo do sistema elétrico, o modelo neural propriamente dito, passa a mimetizar o comportamento de maneira mais fiel. Como pode ser visto através dos erros calculados apresentados na **Tabela 4-2**.

| Previsão de Longo Prazo |                   |
|-------------------------|-------------------|
| MAE                     | 0,011038784578930 |
| RMSE                    | 0,046070280804179 |

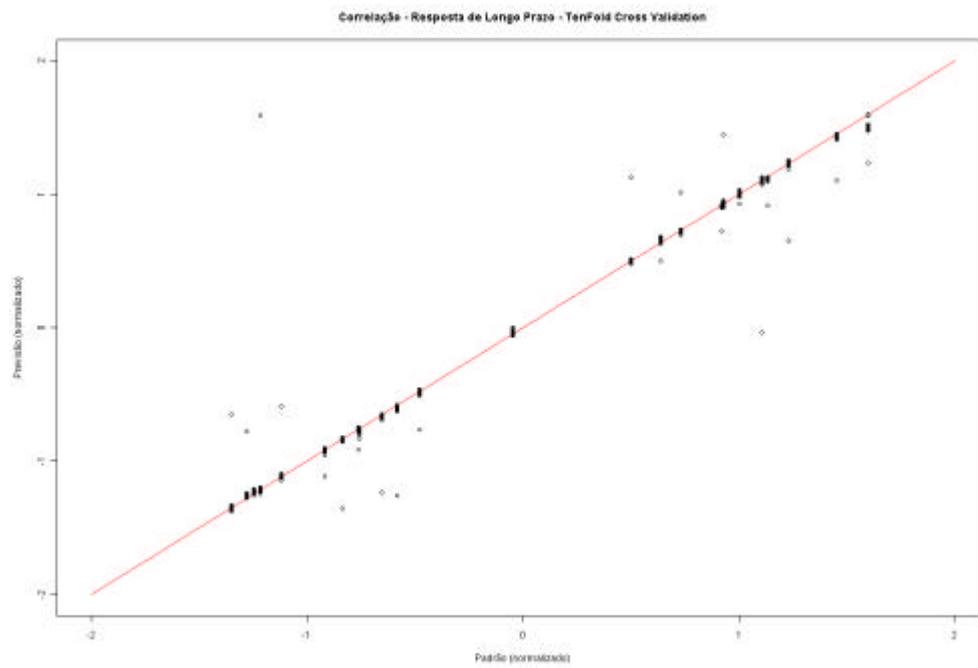
**Tabela 5-2: Resposta dos erros para Ten-Fold Cross-Validation para longo prazo.**

O mesmo pode ser verificado quando a resposta é analisada pelo método de sobreposição de curvas, **Figura 4-7**, onde nota-se uma maior precisão na previsão. A curva na cor preta que representa os valores esperados está praticamente sobreposta pela curva em vermelho, que representa os valores previstos. Esta boa precisão pode ser traduzida também pela observação da curva azul, que representa o erro absoluto para cada ponto de previsão, onde na grande maioria da janela de previsão manteve-se praticamente nula.

A correlação gráfica para este teste está mostrada na **Figura 4-8**, na qual nota-se uma dispersão muito pequena dos dados no espaço de respostas, com uma aderência muito boa dos valores previstos aos valores esperados. Traçando um comparativo entre a resposta da correlação gráfica da previsão de curto prazo (**Figura 4-6**) e de longo prazo (**Figura 4-8**) vê-se claramente que existe uma maior aderência das respostas de previsão de longo prazo ao seu padrão de saída em comparação as da previsão de curto prazo.



**Figura 5-7: Resposta para longo prazo - Gravataí - *Ten-Fold Cross-Validation*.**



**Figura 5-8: Correlação gráfica - longo prazo - Gravataí - *Ten-Fold Cross-Validation*.**

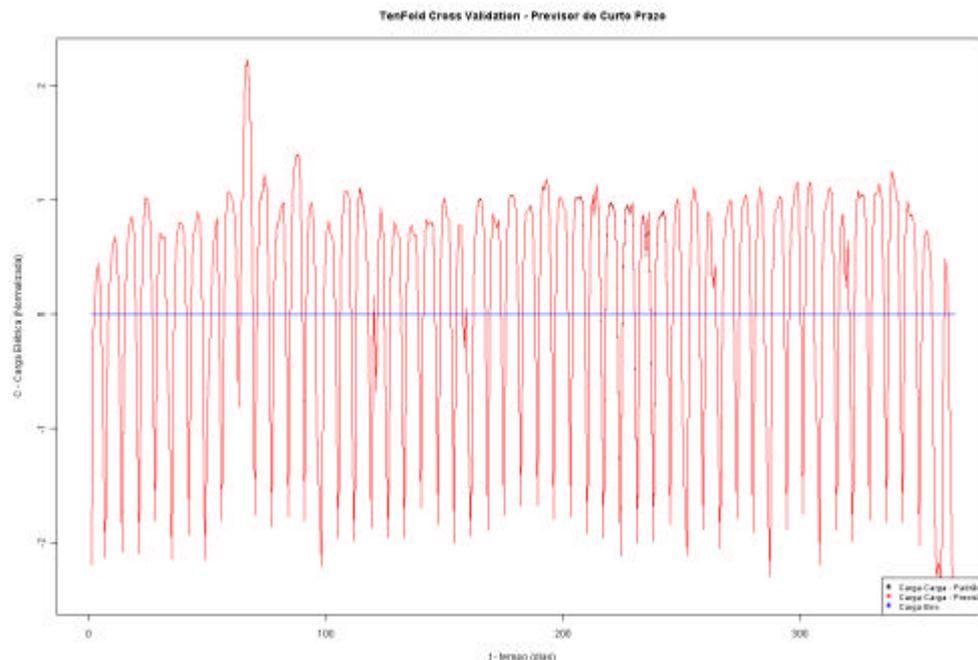
### 5.2.3 Resultados Teste I – Direct Validation – Curto Prazo

A acuracidade do sistema computacional é avaliada com a aplicação da validação *Direct Validation*, onde o sistema é confrontado com sua aplicação final, ou seja, com uma situação real de previsão. A janela de previsão selecionada foi de um ano, sendo RNA do modelo neural que descreve a rede elétrica é treinada com 1095 padrões (três anos) e testada com 365 padrões correspondente ao ano de 2007. A resposta gerada para esta previsão é apresentada na **Tabela 4-3**, esta mostra que os resultados de **MAE** e **RMSE** são valores realmente baixos. Valores de erros tão baixos para um teste funcional provam à excelente acuracidade alcançada pelo modelo neural para previsão de curto prazo.

| Previsão de Curto Prazo |                   |
|-------------------------|-------------------|
| MAE                     | 0,000005506849315 |
| RMSE                    | 0,000007457642949 |

**Tabela 5-3: Resposta dos erros para Direct-Validation para curto prazo**

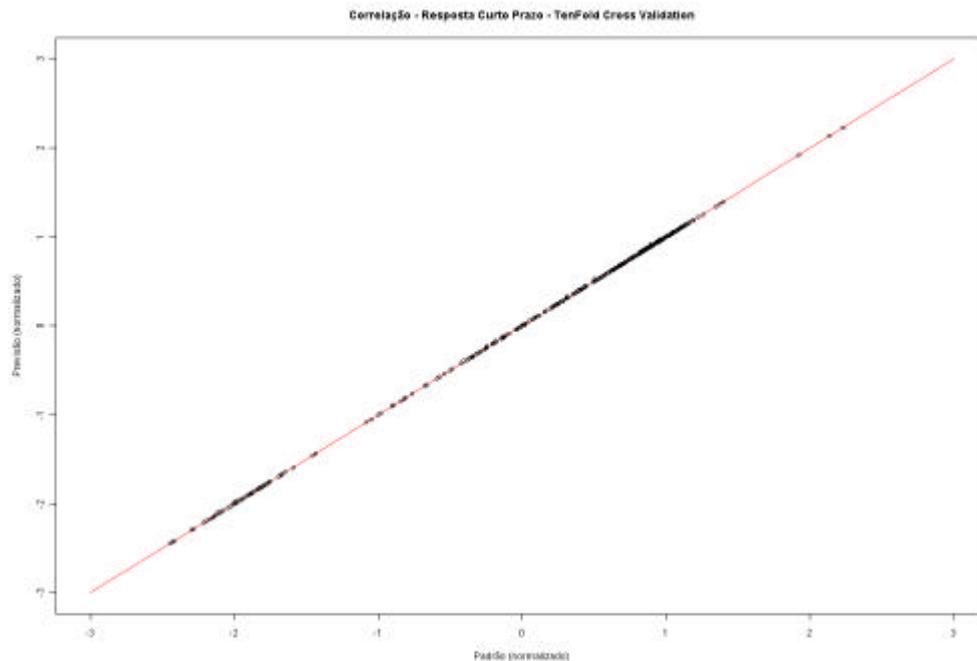
Utilizando a sobreposição de curvas nota-se claramente a excelente precisão alcançada pelo modelo, conforme é apresentado na **Figura 4-9**. Nesta a curva desenhada é preto, representando os valores de carga esperados, é praticamente totalmente sobreposta pela curva em vermelho, que representa os valores de carga previstos. O resumo desta acuracidade pode ser visto através da curva desenhada em azul, que representa o erro absoluto a cada instante de previsão.



**Figura 5-9: Resposta para curto prazo - Gravataí - Direct Validation**

Isto somado ao gráfico de correlação apresentado na **Figura 4-10**, que mostra a aderência praticamente perfeita das respostas do previsor aos valores esperados, indica que em

termos de acuracidade o previsor está plenamente satisfatório quanto ao seu comportamento em uma situação de aplicação real.



**Figura 5-10: Correlação gráfica - curto prazo - Gravataí - Direct Validation.**

#### 5.2.4 Resultados Teste I – Direct Validation – Longo Prazo

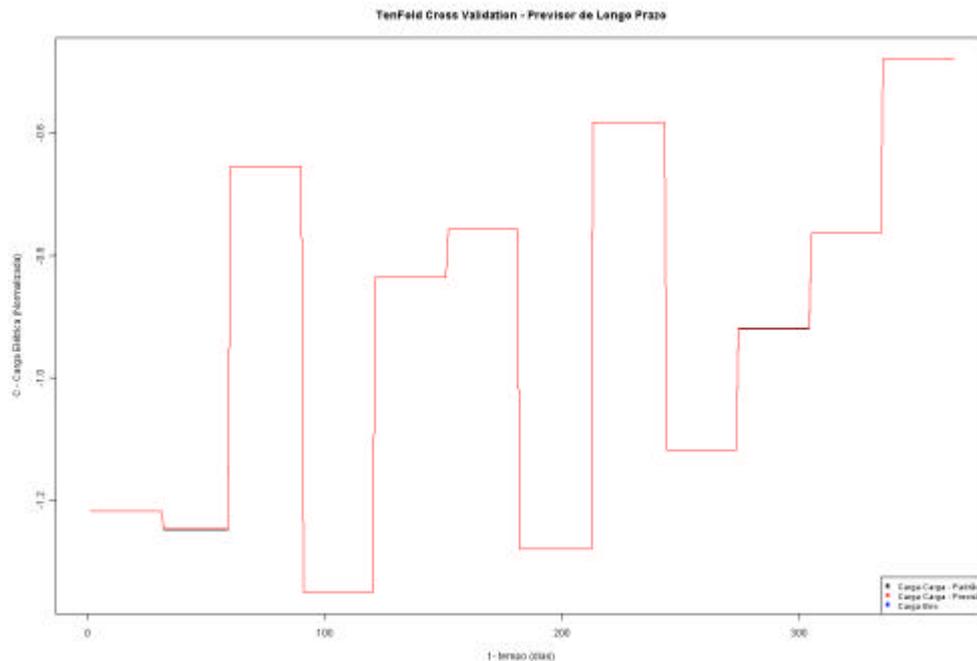
Utilizando o mesmo treinamento anteriormente descrito para o teste funcional com *Direct Validation* realizado para o previsor de curto prazo, por se tratar de um sistema integrado, tem sua resposta para longo prazo apresentada quantitativamente na **Tabela 4-4** através dos indicadores de erros de **MAE** e **RMSE**. Nesta nota-se quem o modelo possui uma resposta excelente para longo prazo, com erros inferiores a 2%. Um erro desta ordem para um horizonte mensal pode ser considerado excelente, visto que é inferior aos menores erros observados na literatura pesquisada que são da ordem de 5% para **RMSE** e de 3% para **MAE**.

| Previsão de Longo Prazo |                    |
|-------------------------|--------------------|
| <b>MAE</b>              | 0,0122012602739726 |
| <b>RMSE</b>             | 0,0184169731904808 |

**Tabela 5-4: Resposta dos erros para Direct-Validation para longo prazo.**

Esta excelente resposta pode ser melhor visualizada através do gráfico da resposta do previsor confrontado com o gráfico da resposta esperada para a janela de previsão, mostrada na **Figura 4-11**. Novamente é possível observar claramente que a curva em preto, que representa os

valores de carga esperados, está praticamente sobreposta pelos valores previstos para carga, representados pela curva em vermelho.



**Figura 5-11: Resposta para longo prazo - Gravataí - Direct Validation**

Neste caso os valores por serem normalizados ficaram deslocados para os valores negativos no eixo que representa a carga elétrica. Como o erro é absoluto sua curva é representada no intervalo de 0 a 1, esta necessitou ser traçada em um outro gráfico para poder ser devidamente observada e analisada. Este gráfico está apresentado na **Figura 4-12** onde a curva em azul representa o erro médio absoluto para esta previsão de longo prazo.

A correlação da resposta do modelo para longo prazo para sua validação funcional está apresentada na **Figura 4-13**. Nesta vê-se então a excelente aderência entre os valores previstos e esperados, com a dispersão no espaço de respostas sendo muito reduzida. A resposta de previsão de longo prazo tem-se também, assim como na resposta de previsão para curto prazo, uma resposta bastante satisfatória no que diz respeito à acuracidade do modelo neural.

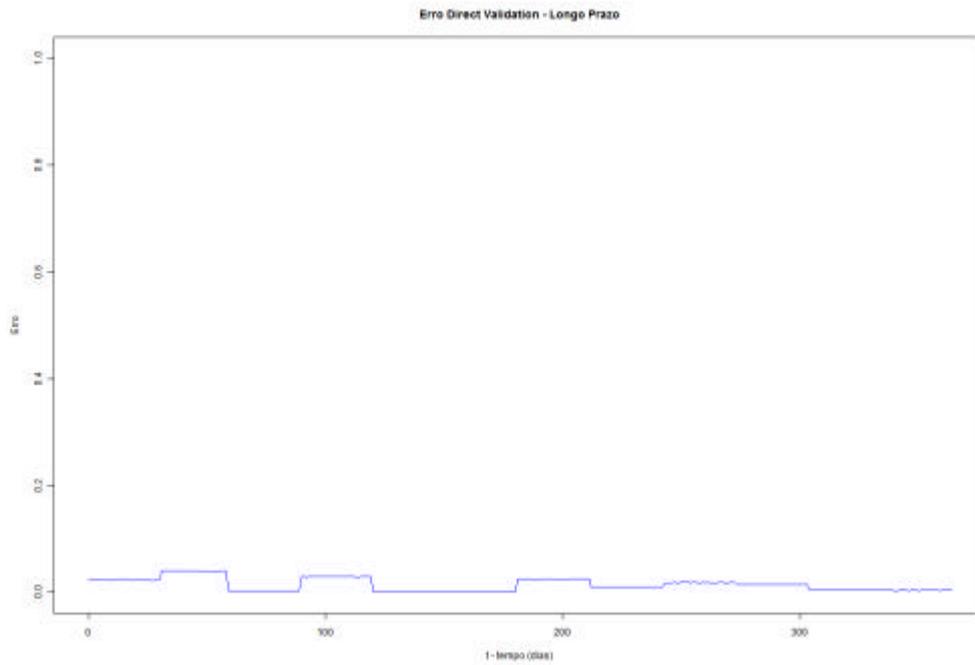


Figura 5-12: Gráfico de erro do predictor de longo prazo - Gravataí - *Direct Validation*.

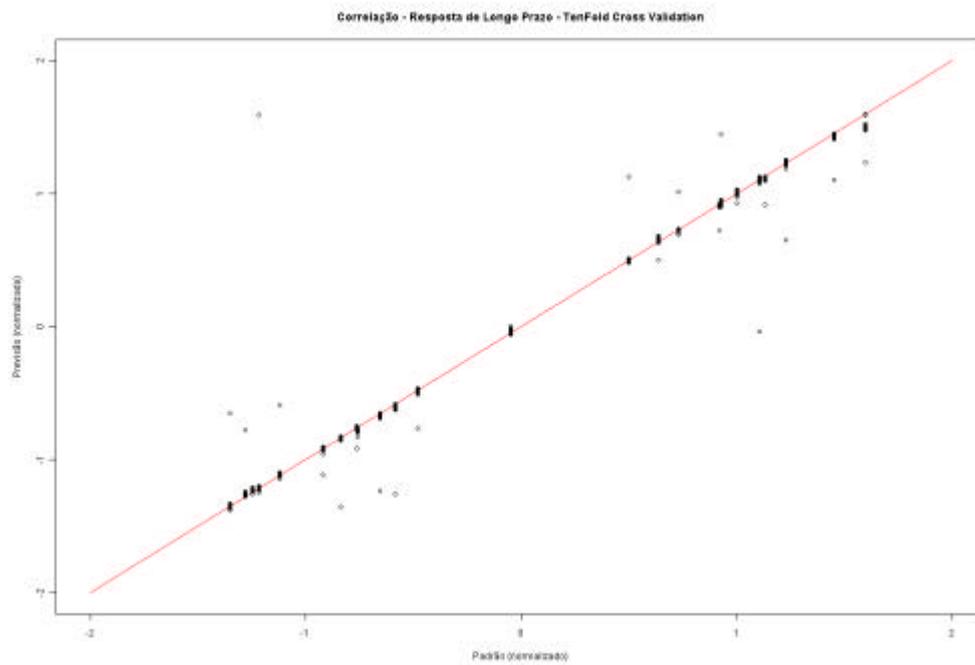
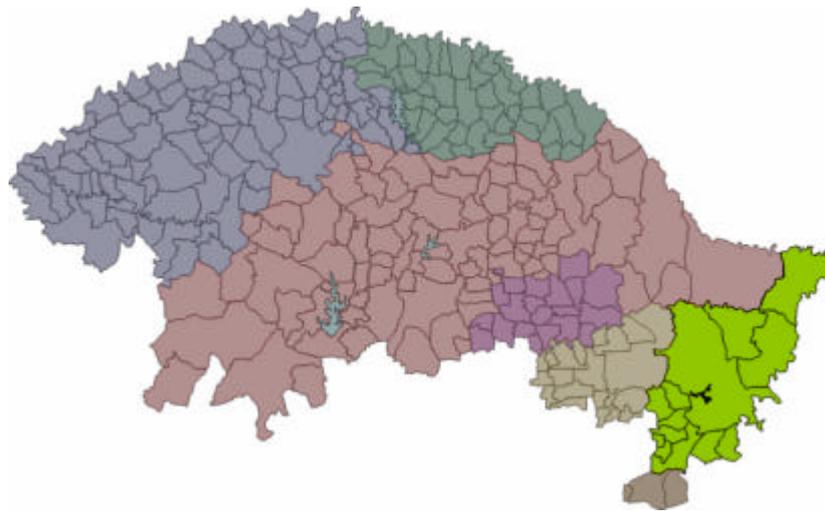


Figura 5-13: Correlação - longo prazo - Gravataí - *Ten-Fold Cross-Validation*.

### 5.3 Resultados do Teste II (Carga Predominante: Residencial)

Como segunda região geolétrica teste escolheu-se uma região com predominância de carga residência. Em se tratando do sistema elétrico de distribuição da RGE a que possui esta característica é a região de Taquara. Esta região é possui um tamanho geográfico moderado, como mostra a **Figura 414**, caracterizada por uma economia de setor de serviços e empresas com plantas pequenas. Com isso esta região geolétrica é o perfeito caso de uma região com predominância de consumidores residenciais para o teste do modelo neural.

Os consumidores residenciais são muito suscetíveis as alterações meteorológicas, pois quando muito frio utilizam aquecedores elétricos, quando com muito calor passam a utilizar mais os condicionadores de ar aumentando assim o consumo de energia. São consumidores que utilizam menos energia com temperatura amena e possuem uma característica sazonal bem definida, pois geralmente migram nas férias para localidades turísticas. Este tipo de consumidor também possui o comportamento mais estável quanto a situação econômica do país ou região a qual faz parte.



**Figura 5-14: Região geolétrica de Taquara (em destaque).**

Para esta região geolétrica assim como para a região de Gravataí tem-se a disposição dados de curvas de carga desde 2003 até 2007. Porém neste caso os dados estão todos íntegros, sendo os dados do ano de 2003 descartados para não compatibilizar o número de dados disponíveis para todos os experimentos. Desta forma os resultados podem ser analisados sem nenhum tipo de ressalva. Assim como no teste anterior são analisados os resultados de curto e longo prazo com vistas sua robustez e com vistas a sua acuracidade.

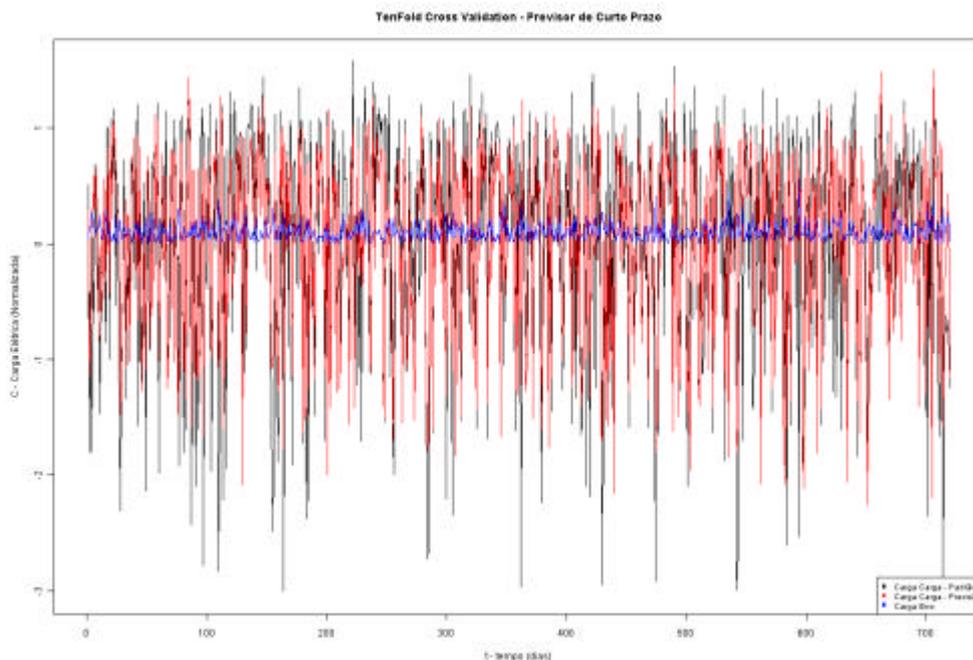
#### 5.3.1 Resultados Teste II – Ten-Fold Cross-Validation – Curto Prazo

Assim como no teste anterior a análise de robustez é realizada com a resposta do modelo para o método *Ten-Fold Cross-Validation*. Este teste apresentou resultados satisfatórios, mostrados na **Tabela 45**. Este modelo apresentando uma robustez satisfatória para uma região com predominância de consumidores residenciais é muito importante como subsídio para a análise de capacidade de generalização do modelo neural.

| Previsão de Curto Prazo |                   |
|-------------------------|-------------------|
| MAE                     | 0,104379603705723 |
| RMSE                    | 0,130831319999762 |

**Tabela 5-5: Resposta dos erros para *Ten-Fold Cross-Validation* para curto prazo.**

Fazendo-se uma análise qualitativa da resposta do modelo para curto prazo utilizando o método de sobreposição de curvas, mostrado na **Figura 4-15**, nota-se que existe uma boa relação entre os valores previstos e valores esperados. Os valores previstos estão representados no gráfico pela curva em vermelho e os esperados em preto. Curva desenhada em azul representa o erro absoluto em cada instante de previsão, mostrando que esta se mantém em um nível aceitável durante todo o intervalo de previsão. Uma consideração importante a ser feita é a diferença dada entre os valores de erro de **MAE** e **RMSE**, diferença essa que indica um nível de variância de erro entre os instantes de previsão.



**Figura 5-15: Resposta para longo prazo - Taquara - *Ten-Fold Cross-Validation***

Ao se fazer uma análise utilizando a correlação gráfica para a resposta do modelo para curto prazo, como mostrado na **Figura 4-16**, nota-se certa dispersão dos dados previstos no espaço de respostas. Apesar disto existe um comportamento em que os dados tendem a

concentrar-se a certa distância da diretriz, ou seja, manterem uma relação de erro máximo ao longo da janela de previsão.

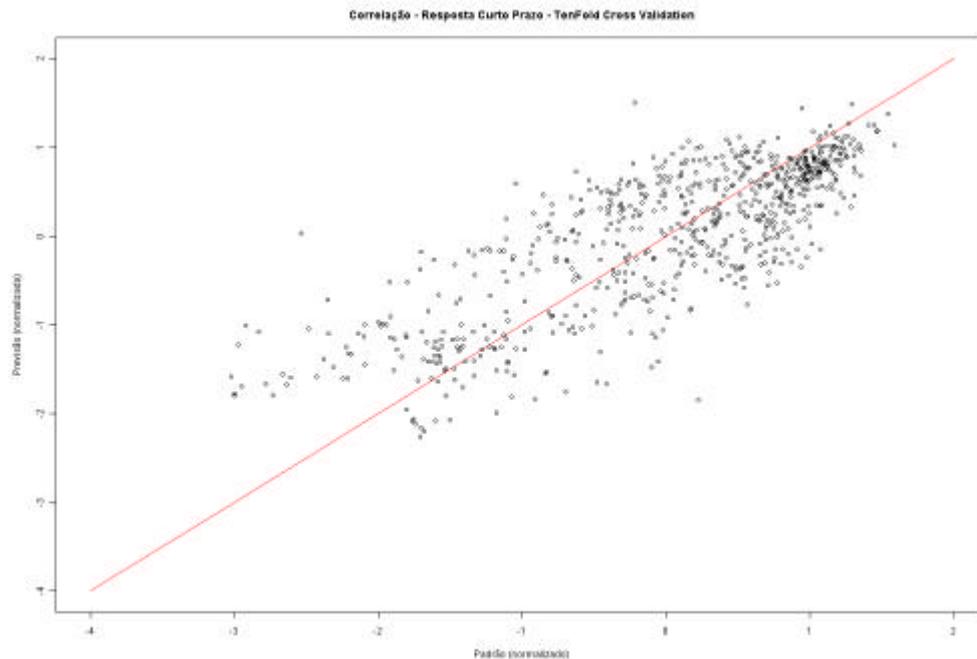


Figura 5-16: Correlação gráfica - curto prazo - Taquara - *Ten-Fold Cross- Validation*

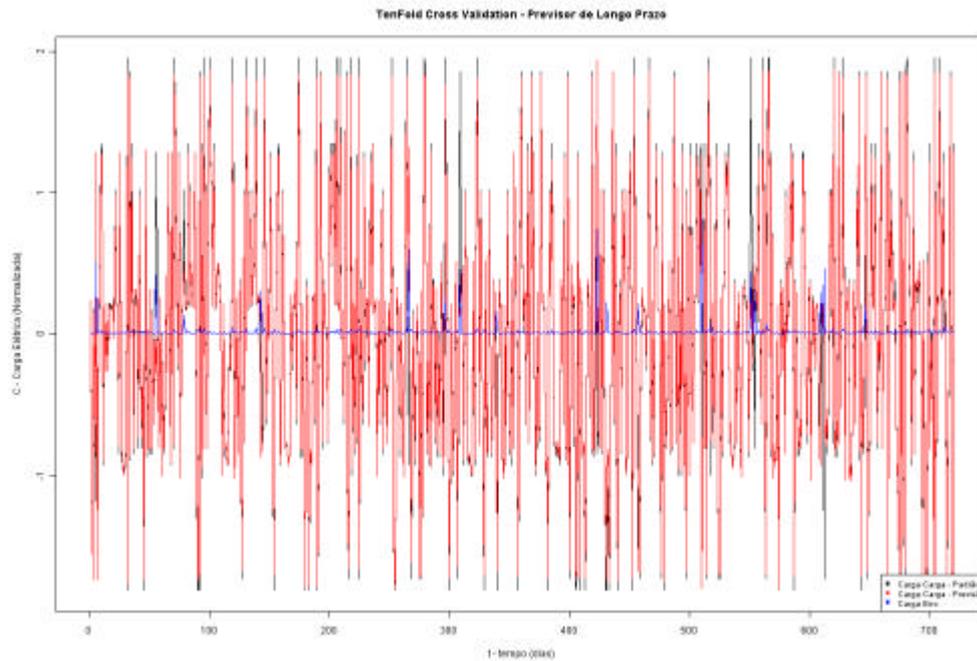
### 5.3.2 Resultados Teste II – *Ten-Fold Cross-Validation* – Longo Prazo

O teste de robustez para esta região geolétrica, em se tratando de sua previsão de longo prazo, apresentou resultados melhores do que os testes deste para curto prazo. Este comportamento foi o mesmo ocorrido para o teste anterior (Teste I), sendo a causa desta diferença a mesma anteriormente descrita. Os resultados quantitativos deste teste estão apresentados na **Tabela 4-6**, onde estão disponibilizados os resultados da análise realizados pelos métodos de avaliação MAE e RMSE.

|      | Previsão de Longo Prazo |
|------|-------------------------|
| MAE  | 0,0189565917266824      |
| RMSE | 0,0674664880923577      |

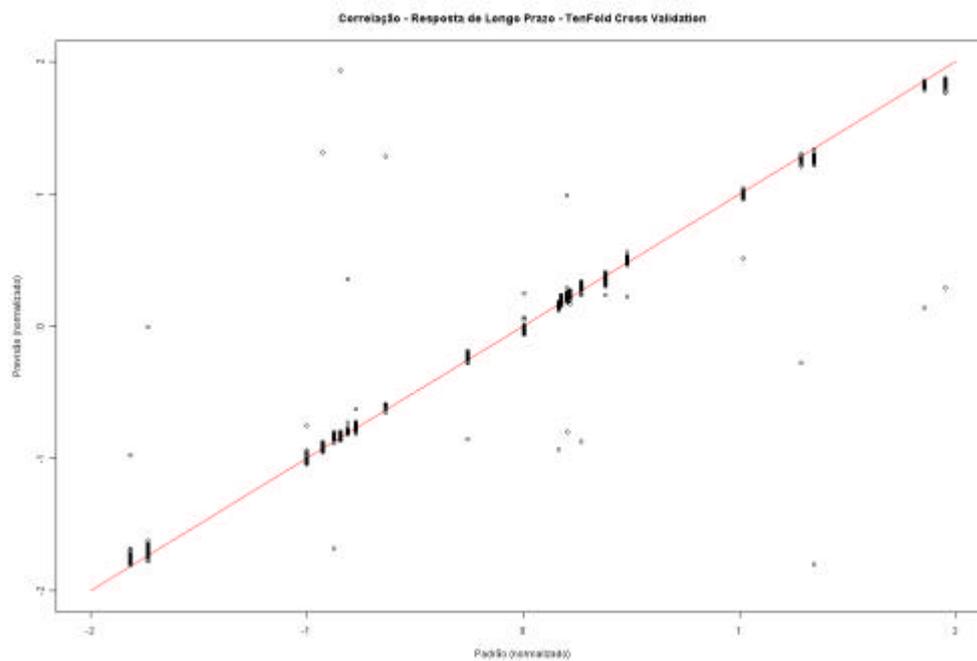
Tabela 5-6: Resposta dos erros para *Ten-Fold Cross-Validation* para longo prazo.

Este resultado mostra uma maior robustez do modelo para previsão de longo prazo, como notado na **Figura 4-17**. Nesta observa-se que a curva que representa os valores de carga elétrica esperados, em preto, está praticamente sobreposta pela curva vermelha, que representa os valores de carga previstos. A curva em azul representa o erro absoluto a cada instante de previsão e como é visto possui poucos picos de erros, mantendo-se durante grande parte da janela de previsão com valores próximos do nulo.



**Figura 5-17: Resposta para longo prazo - Taquara - Ten-Fold Cross-Validation.**

Este comportamento pode ser notado também na **Figura 4-18** que apresenta a correlação gráfica dos resultados de previsão para longo prazo do sistema. Nele se observa uma alta concentração de valores de previsão muito próximos dos valores esperados. Ainda que haja esta dispersão considera-se este resultado bastante satisfatório quanto à robustez do sistema para previsão de longo prazo.



**Figura 5-18: Correlação gráfica - longo prazo - Taquara - Ten-Fold Cross- Validation**

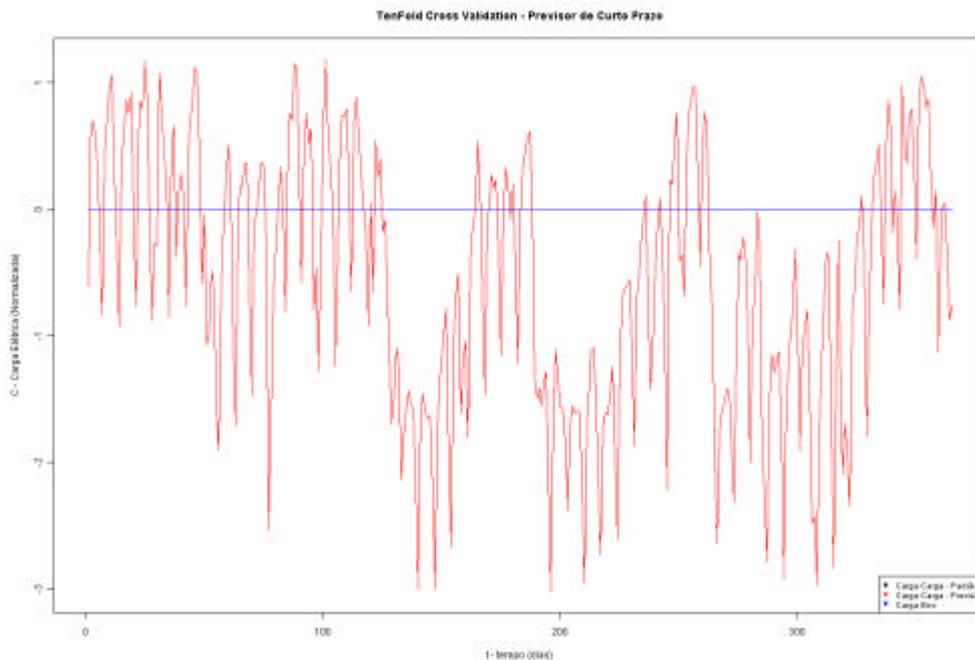
### 5.3.3 Resultados Teste II – Direct Validation – Curto Prazo

Uma avaliação do comportamento funcional do sistema para uma região geoeletrica com prevalência de consumidores residenciais é realizada aqui. Esta resposta somada a resposta do modelo para longo prazo formam a base para a análise da capacidade de generalização do sistema. Para fins de equalização de análises foram utilizados os mesmo número de padrões de treinamento e validação utilizados no teste anterior (Teste I). Os resultados deste teste estão apresentados na **Tabela 4-7**, onde se observa que os erros são muito baixos indicando excelentes resultados de previsão.

| Previsão de Curto Prazo |                   |
|-------------------------|-------------------|
| MAE                     | 0,000008904109589 |
| RMSE                    | 0,000002463567435 |

**Tabela 5-7: Resposta dos erros para *Direct Validation* para curto prazo.**

Os resultados quantitativos mostrados na **Tabela 4-7** somados aos qualitativos apresentados na Figura 4-19 mostram a excelente acuracidade alcançada pelo sistema sua para previsão de curto prazo. Nela a curva desenhada em preto, que representa os valores esperados praticamente não pode ser vista, pois está sobreposta pela curva vermelha, que representa os dados previstos. O baixíssimo erro também pode ser comprovado pelo traçado da curva em azul que é praticamente uma reta representando um valor nulo.



**Figura 5-19: Resposta para curto prazo - Taquara - *Direct Validation*.**

Utilizando o auxílio de uma análise por correlação gráfica, como mostra a **Figura 4-20**, se tem uma comprovação da perfeita aderência da curva de valores previstos com os valores

esperados. Logicamente os valores não são exatamente o mesmo, mas estão todos tão próximos que produzem um erro realmente muito baixo. Portanto em se tratando de acuracidade a previsão de curto prazo para uma região com predominância de consumidores residências o modelo está bem aprimorado.

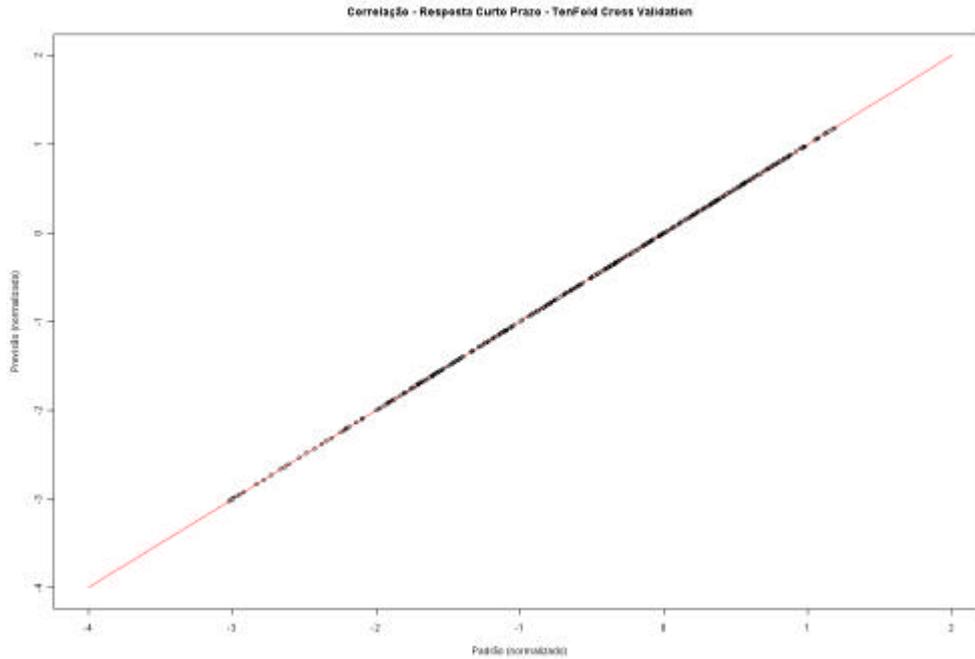


Figura 5-20: Correlação gráfica - curto prazo - Taquara - *Direct Validation*

### 5.3.4 Resultados Teste II – Direct Validation – Longo Prazo

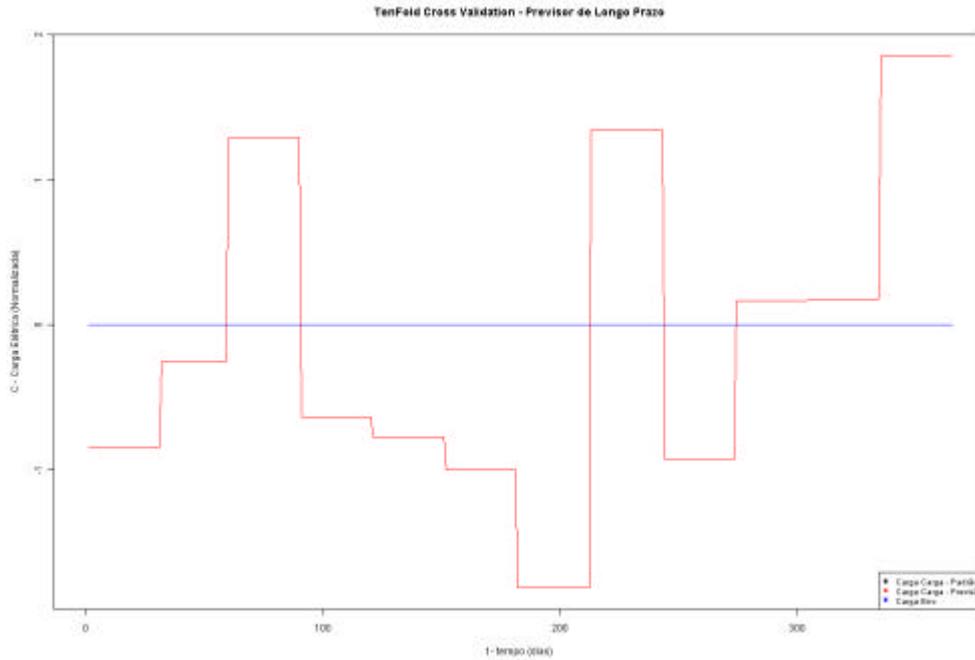
Este teste utiliza o mesmo conjunto de dados de treinamento e validação do teste de comportamento funcional para curto prazo. Sua resposta quantitativa é apresentada na **Tabela 4-8**, onde se observa valores de erros, **MAE** e **RMSE** muito pequenos. Apesar de estes erros serem apresentados com valores um pouco superiores aos relativos a previsão de curto prazo, ainda assim com estes valores de erros pode-se considerar o modelo como provendo alta acuracidade para o sistema de previsão aqui testado.

|      | Previsão de Longo Prazo |
|------|-------------------------|
| MAE  | 0,000513733166255678    |
| RMSE | 0,000950908642627066    |

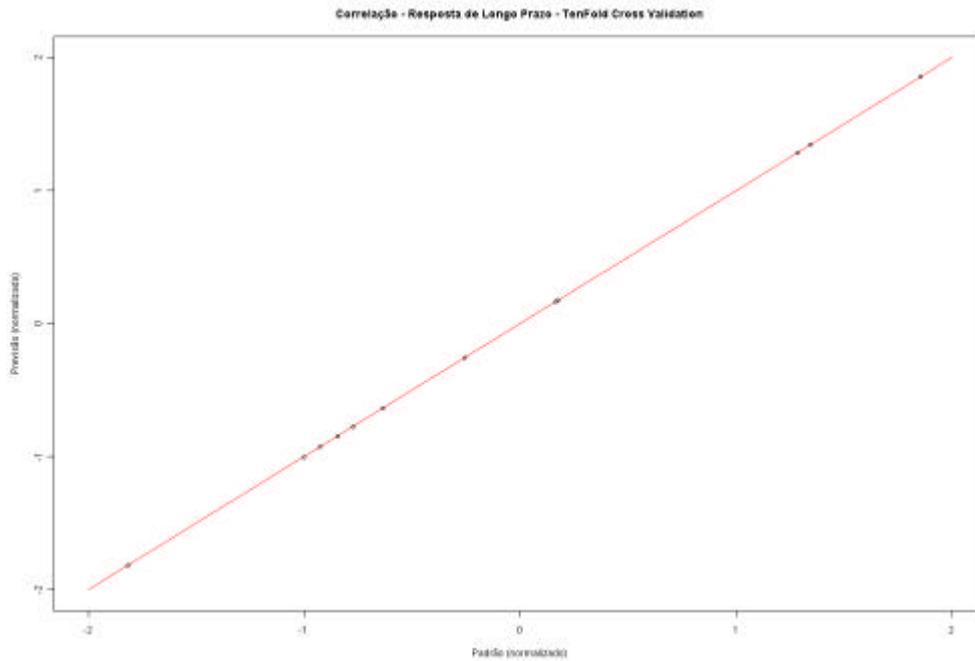
Tabela 5-8: Resposta dos erros para *Direct Validation* para longo prazo.

A tradução qualitativa destes excelentes resultados quantitativos é mostrada na **Figura 4-21**, onde estão sobrepostas as curvas de valores esperados, em preto, e de valores previstos, em vermelho. Também está traçada a curva que representa o erro absoluto para cara instante de previsão, apresentada em azul. Nota-se que as curvas estão em praticamente uma sobreposição

perfeita e a curva de erro apresenta-se com um traçado constante, pois o erro encontra-se em uma escala muito menor, não podendo ser observado na mesma escala.



**Figura 5-21: Resposta para curto prazo - Taquara - Direct Validation.**



**Figura 5-22: Correlação gráfica - longo prazo - Taquara - Direct Validation**

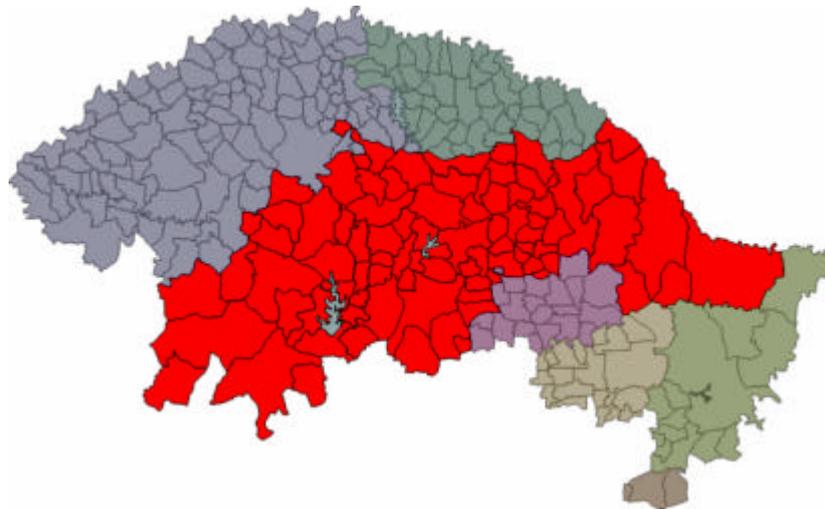
A excelente acuracidade do modelo para este teste de previsão de longo prazo pode ser também analisada através da correlação gráfica, apresentada na **Figura 4-22**. Nesta tem-se uma perfeita visualização da aderência dos valores resultantes da previsão com seus respectivos valores

esperados. Não há nenhuma dispersão de respostas em seu espaço, estando todos os resultados praticamente perfeitamente colocados sobre a diretriz. Os valores de desvio entre os valores previstos e esperados são tão pequenos que este não é notado na escala que comporta todos os valores da janela de previsão.

#### 5.4 Resultados do Teste III (Cargas Equilibradas)

A terceira região geolétrica escolhida para a validação do modelo neural do sistema computacional proposto é uma região elétrica que apresenta equilíbrio entre as classes consumidoras. A região do sistema de distribuição da RGE que apresenta esta característica é a região de Passo Fundo, mostrada em destaque na **Figura 4-23**. Esta é uma região geograficamente grande, representando boa parte do sistema de distribuição.

Como as classes consumidoras são realmente equilibradas como já mostrado na **Tabela 4-1**, é um excelente teste para verificar se o modelo possui capacidade para representar uma região com característica não definida. No caso desta região tanto que afetam o comportamento do consumo de energia elétrica inerentes aos consumidores residenciais, como os fatores meteorológicos de temperatura e umidade, como os fatores inerentes às classes industriais, como comportamento do mercado econômico, podem influenciar no sistema. Esta influência pode se dar em instantes diferentes como juntas, isto aumenta substancialmente a necessidade de um bom modelo para que a RNA que o descreve tenha um comportamento adequado.



**Figura 5-23: Região geolétrica de Passo Fundo (em destaque).**

Esta região geolétrica assim como para as regiões anteriormente utilizadas como estudo de caso, tem-se a disposição dados de curvas de carga desde 2003 até 2007. Os dados do ano de 2003 foram descartados para compatibilizar o número de dados disponíveis com os demais experimentos. Com este procedimento os resultados podem ser analisados igualmente, sem

nenhuma restrição. Da mesma forma que nos testes anteriores são analisados os resultados de curto e longo prazo buscando avaliar sua robustez e sua acuracidade.

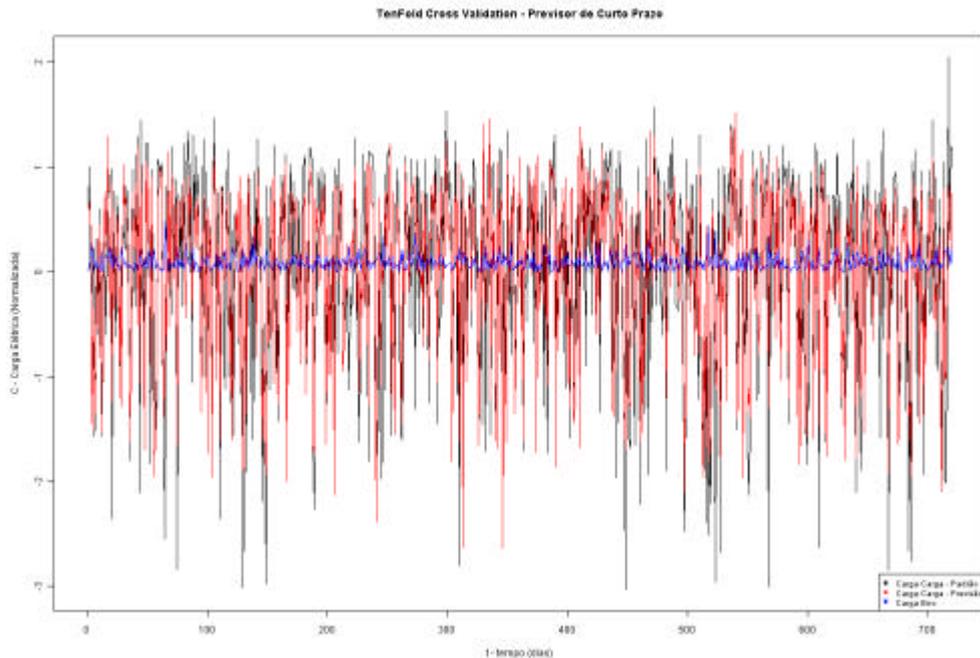
#### 5.4.1 Resultados Teste III – Ten-Fold Cross-Validation – Curto Prazo

A análise da robustez do modelo perante os padrões de uma região geoeletrica sem prevalência de classe consumidora, trará assim como para as demais regiões, subsídios para uma análise mais ampla do comportamento geral do previsor. A resposta do previsor para esta região está apresentada na **Tabela 4-9**, onde estão colocados as medidas de avaliação de performance MAE e RMSE.

| Previsão de Curto Prazo |                   |
|-------------------------|-------------------|
| MAE                     | 0,092588727780336 |
| RMSE                    | 0,117618366616970 |

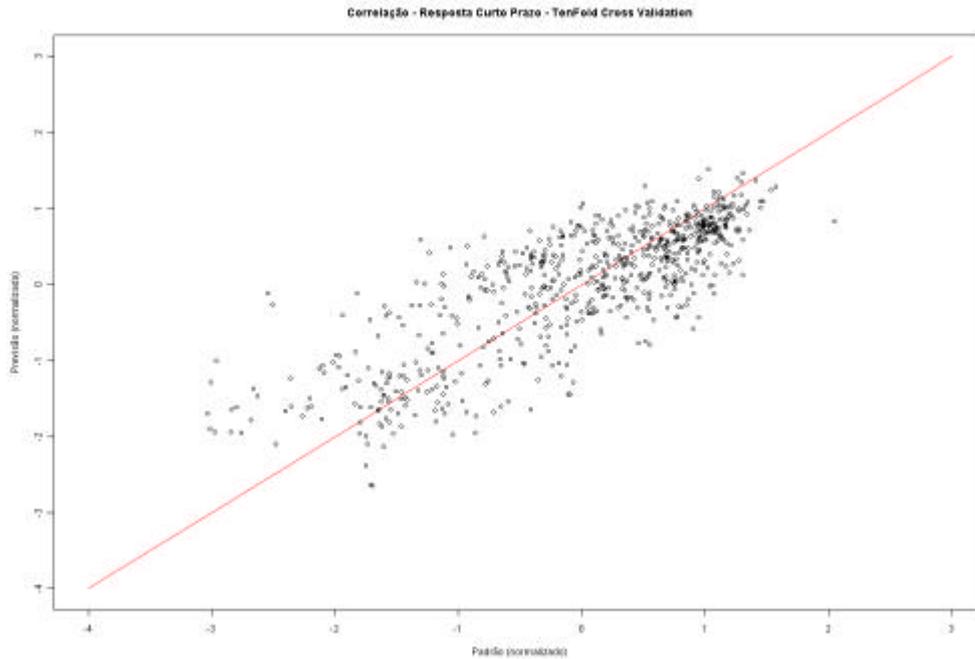
**Tabela 5-9:** Resposta dos erros para *Ten-Fold Cross-Validation* para curto prazo.

Graficamente o comportamento da resposta do previsor para este experimento pode ser considerada boa, como visto na **Figura 4-24**. A sobreposição de curvas nela apresentada traz os valores esperados, em preto, os valores previstos, em vermelho, e o erro absoluto para cada instante de previsão, traçado em azul. Nota-se a constância do erro ao longo da janela de previsão, respeitando sempre um grau máximo de erro ao longo desta.



**Figura 5-24:** Resposta para curto prazo - Passo Fundo - *Ten-Fold Cross-Validation*.

Fazendo uso da correlação gráfica para auxiliar nesta análise se observa que os valores de resposta do predictor apesar de possuírem certa dispersão comprovam a tendência de respeitar um nível máximo de erros, como mostrado na **Figura 4-25**. Com base nesta análise e somando as informações obtidas da análise anterior tem-se que o modelo neural de previsão possui um grau de robustez aceitável.



**Figura 5-25: Correlação gráfica - curto prazo - Passo Fundo - Ten-Fold Cross- Validation**

**5.4.2 Resultados Teste III – Ten-Fold Cross-Validation – Longo Prazo**

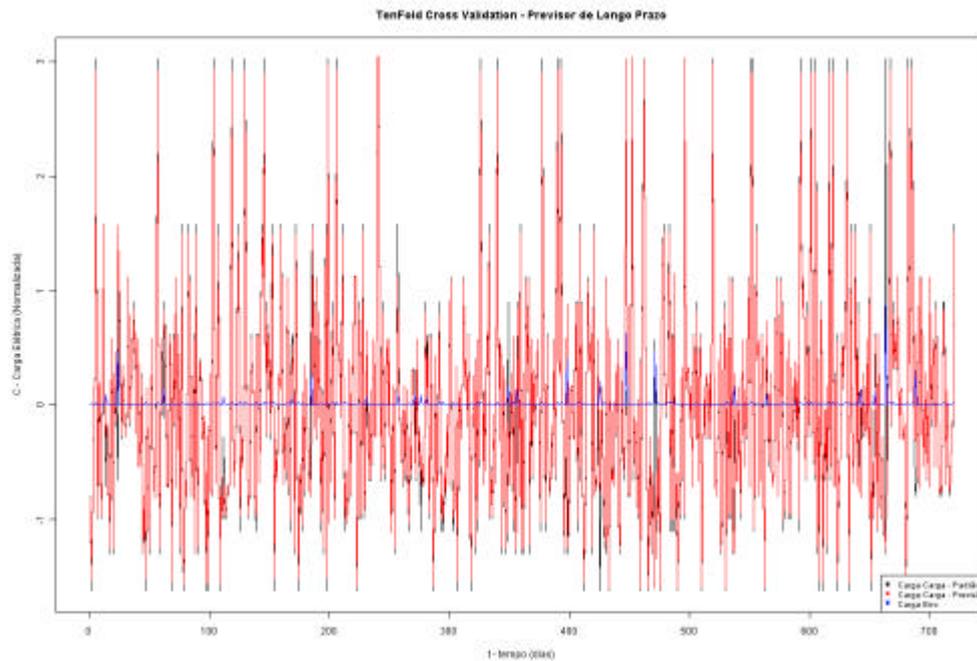
Analisando o modelo neural para uma previsão de longo prazo para uma região com classes consumidoras equilibradas, observa-se um comportamento deste muito parecido com o comportamento ocorrido com as demais regiões. A **Tabela 4-10** traz os erros calculados para este experimento, sendo estes o **MAE** e **RMSE**. São valores muito próximos para os testes de robustez, equivalentes, realizados anteriormente.

|      | Previsão de Longo Prazo |
|------|-------------------------|
| MAE  | 0,0140696449359025      |
| RMSE | 0,0556586053636449      |

**Tabela 5-10: Resposta dos erros para Ten-Fold Cross-Validation para longo prazo.**

O mesmo ocorre quando faz-se uma análise qualitativa da resposta do modelo para longo prazo, como visto na **Figura 4-26**. Nesta vê-se que o erro é substancialmente menor que o dado para o resultado de curto prazo, onde a curva em vermelho, representando os valores previstos

sobrepõe consideravelmente a curva em preto, que representa os valores esperados. Isto pode ser traduzido pela curva em azul, que representa o erro absoluto para cada instante de previsão.



**Figura 5-26: Resposta para longo prazo - Passo Fundo - Ten-Fold Cross-Validation.**

Verificando a correlação gráfica, apresentada na **Figura 4-27**, nota-se que esta resposta é realmente satisfatória. Apesar existir alguma dispersão das respostas do previsor em seu espaço de resultados também existe uma forte tendência das respostas convergirem para seus valores esperados correspondentes. Isto faz com que se conclua que existe uma boa robustez do modelo neural para previsão de longo prazo também para regiões geoeletricas com cargas equilibradas entre as classes consumidoras.

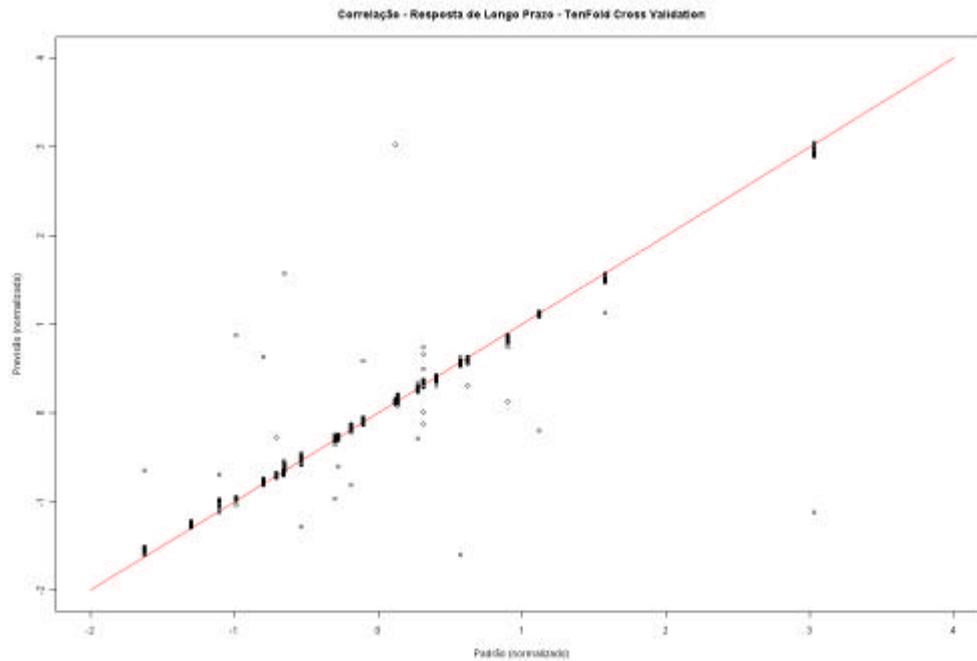


Figura 5-27: Correlação gráfica - longo prazo - Passo Fundo - *Ten-Fold Cross-Validation*

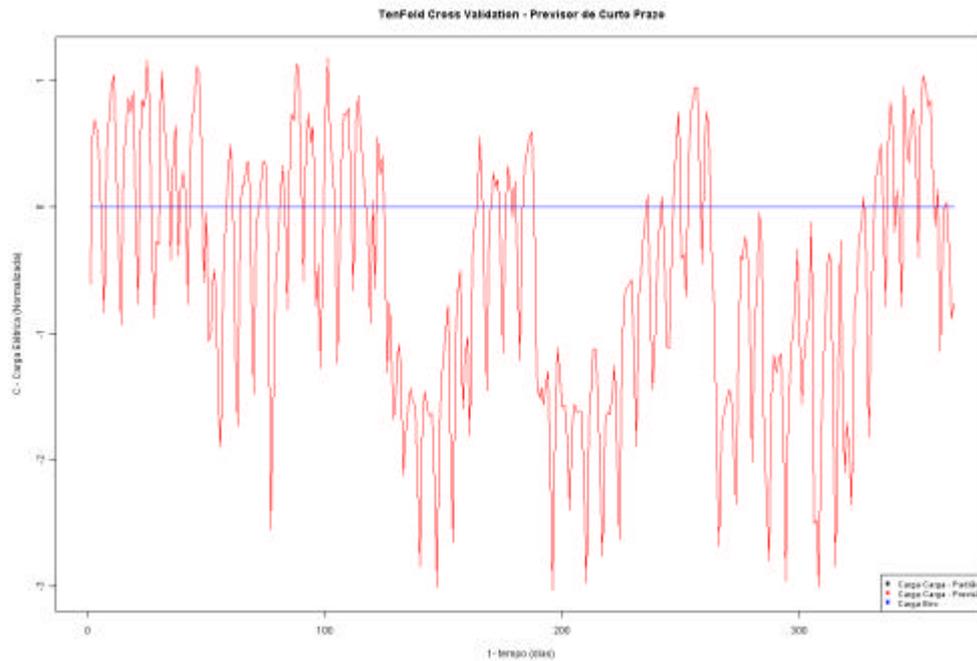
### 5.4.3 Resultados Teste III – Direct Validation – Curto Prazo

A validação funcional do sistema realizada através do método de *Direct Validation*, que visa avaliar o nível de acuracidade que o modelo neural desenvolvido pode oferecer é aqui apresentada. O teste utiliza o mesmo número de dados pra treinamento e mesma janela de previsão que são utilizados nos demais testes funcionais. O resultado dos erros para este teste é mostrado na **Tabela 4-11**, onde os erros são apresentados sob as métricas de **MAE** e **RMSE**.

| Previsão de Curto Prazo |                       |
|-------------------------|-----------------------|
| MAE                     | 0,0000112837512030464 |
| RMSE                    | 0,0000122304841668630 |

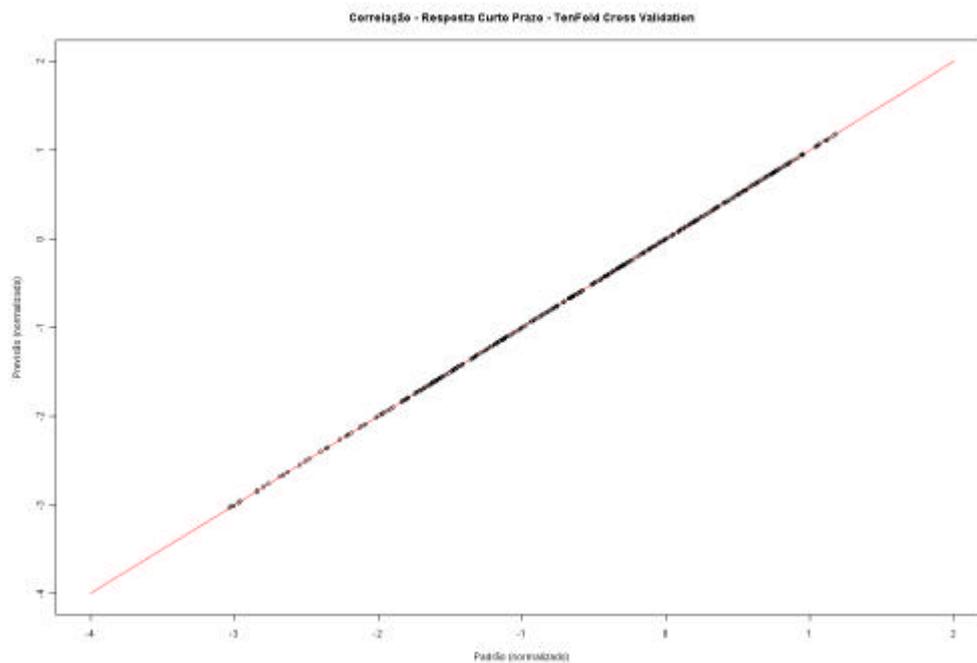
Tabela 5-11: Resposta dos erros para *Direct Validation* para curto prazo.

Os excelentes resultados quantitativos alcançados pelo modelo para previsão de curto prazo, mostrado na **Tabela 4-11**, é confirmado pelo teste qualitativo mostrado pela sobreposição de curvas apresentado na **Figura 4-28**. Nesta vê-se a clara sobreposição praticamente perfeita da curva traçada em vermelho, representando os valores previstos, sobre a curva que representa os valores esperados para carga, curva em preto. A curva traçada em azul representa o erro absoluto a cada instante de previsão, sendo este tão baixo que se comporta como uma reta muito próxima do valor nulo.



**Figura 5-28: Resposta para curto prazo - Passo Fundo - Direct Validation.**

A correlação gráfica que utiliza os valores previstos contra os valores esperados para previsão de curto prazo, apresentada na **Figura 4-29**, mostra uma excelente acuracidade provida pelo modelo neural. Os valores previstos estão praticamente iguais aos valores esperados, representados pela curva diretriz em vermelho.



**Figura 5-29: Correlação gráfica - longo prazo - Passo Fundo - Direct Validation**

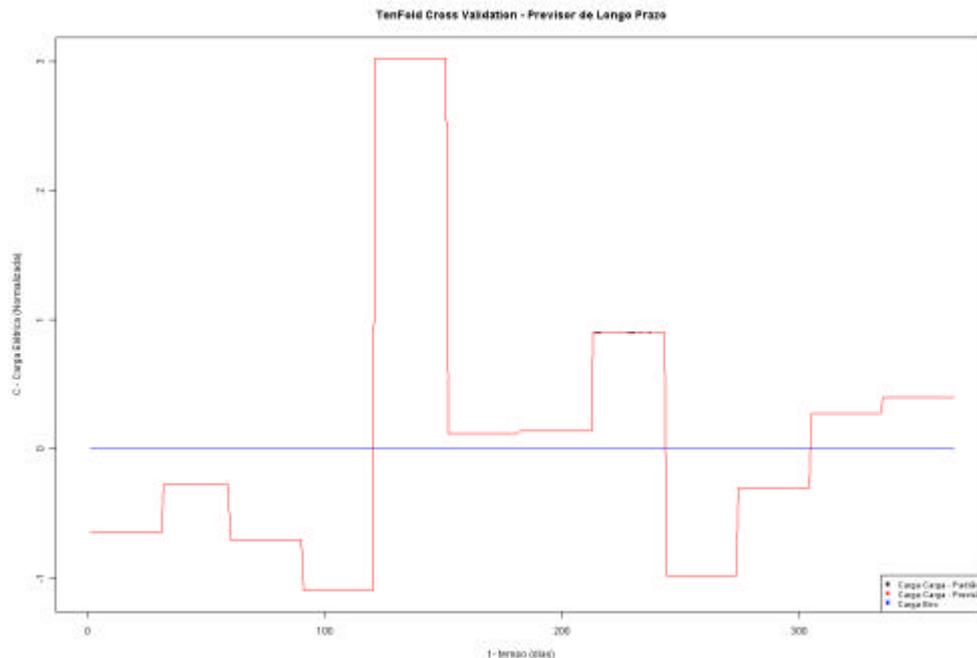
#### 5.4.4 Resultados Teste III – Direct Validation – Longo Prazo

Para a previsão de longo prazo com os estímulos de uma região sem prevalência de carga por classe consumidora têm suas respostas de erros apresentadas na **Tabela 412**. Nesta são colocados os erros **MAE** e **RMSE**, que possuem valores significativamente baixos, o que indica uma excelente acuracidade do modelo neural. Assim como o ocorrido para a previsão de curto prazo para este tipo de região geoeletrica, indicando que o modelo consegue uma excelente acuracidade para ambos os horizontes de previsão.

| Previsão de Longo Prazo |                      |
|-------------------------|----------------------|
| MAE                     | 0,000218637331939312 |
| RMSE                    | 0,000375742057167019 |

**Tabela 5-12:** Resposta dos erros para *Direct Validation* para longo prazo.

Graficamente tem-se a resposta do modelo para previsão de longo prazo para seu teste funcional apresentada na **Figura 4-30**. Nesta se observa a perfeita sobreposição das curvas que representam os valores esperados, em preto, e as que representam os valores previstos, em vermelho. Como resultado deste fato tem-se a curva que representa o erro absoluto a cada instante de previsão, em azul, que se apresenta como uma reta constante praticamente indicando um valor nulo.



**Figura 5-30:** Resposta para longo prazo - Passo Fundo - *Direct Validation*.

Outra análise que auxilia na comprovação da acuracidade do modelo neural é a correlação gráfica mostrada na **Figura 4-31**. Nela nota-se a perfeita aderência dos resultados apresentados pelo previsor de longo prazo com seus valores esperados. Este fato indica que realmente existe um

erro associado a cada instante de previsão muito baixo, ou seja, que há uma previsão com alta acuracidade gerada pelo previsor.

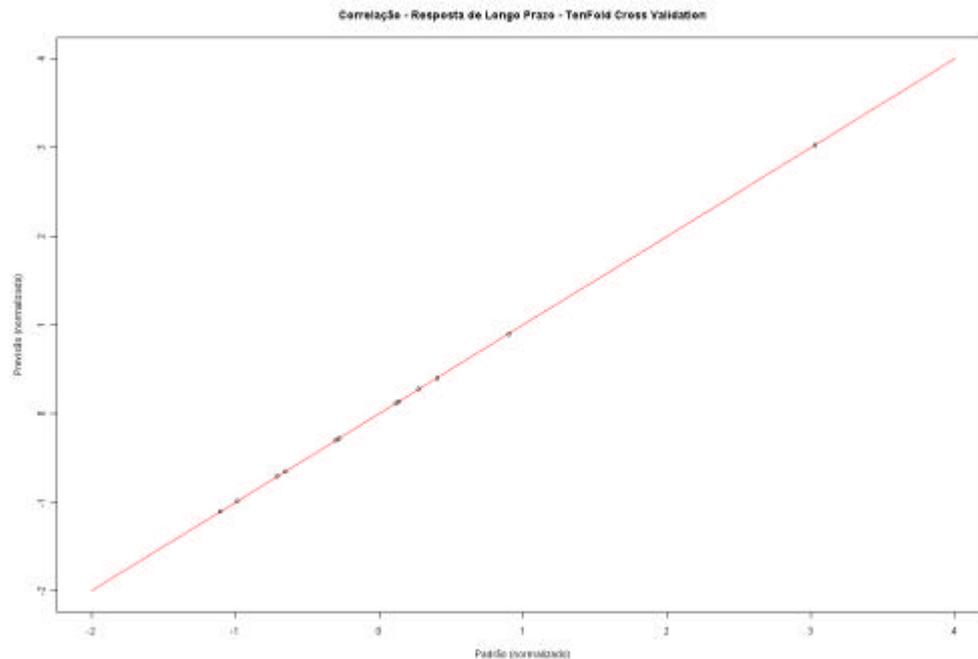


Figura 5-31: Correlação gráfica - longo prazo - Passo Fundo - *Direct Validation*

## 5.5 Análise dos Resultados

Os testes anteriormente descritos foram analisados de maneira pontual e específica, focando principalmente nos aspectos de robustez e acuracidade para o perfil de carga elétrica dos dados utilizados neste. Aqui busca-se realizar uma análise mais abrangente do sistema de previsão neural testado, fazendo esta análise levando em conta todo o contexto que envolve a previsão de carga por meio de um sistema computacional. Principalmente no que tange a capacidade de generalização do modelo utilizado para os diferentes perfis de carga.

Quanto a esta capacidade de generalização pode-se afirmar que o modelo utilizado pelo sistema neural responde adequadamente, pois os resultados foram muito próximos para os três testes realizados, cada um contando com dados de cargas de um perfil diferente. Estes diferentes perfis de carga exigem do sistema computacional, principalmente de seu modelo neural, uma capacidade de absorção de suas características muito grande, pois cada um deste possui diferentes aspectos que influenciam diretamente no consumo de energia elétrica.

A robustez do sistema manteve-se estável em todos os testes, sendo este robusto o suficiente para modelar todos os tipos de perfis de carga testados. Porém este foi o resultado menos satisfatório, em que se refere ao comportamento do modelo, o que pode ser explicado pelo pequeno número de padrões que principalmente para a previsão de curto prazo possui influência. O

previsor de curto prazo é mais afetado, pois com três padrões por ano, sendo que os feriados flutuam ano a ano, o que muda substancialmente o consumo de energia, causando assim certa dificuldade para a RNA conseguir gerar um padrão para estes dias especiais. Mesmo com esta conhecida dificuldade o sistema de previsão teve uma resposta para sua robustez aceitável.

O parâmetro de desempenho com melhores resultados foi o teste de acuracidade, obtido por meio de testes funcionais do previsor. Através destes testes funcionais pode-se ter uma idéia do comportamento do sistema computacional quando aplicado a um contexto real. As respostas para curto e longo prazos apresentaram um comportamento acima do esperado, com erros medidos pelos métodos clássicos de medidas erro, **MAE** e **RMSE**. Estes excelentes resultados também são vistos nas análises qualitativas com os gráficos dos valores previstos e esperados, onde os valores previstos aderiram muito bem aos valores esperados.

Por fim a capacidade do modelo neural utilizado pelo sistema computacional de integrar dois horizontes de previsão, diminuindo de maneira efetiva o tempo de treinamento e validação, é o principal atributo que torna este trabalho diferente dos demais trabalhos da área. Dentro do grande referencial bibliográfico pesquisado para este trabalho apenas um [SHYRVANY, 2007] cita integração de previsores, porém nenhum aprofunda este aspecto ou apresenta um modelo topologicamente integrado. Por este motivo acredita-se fortemente deste trabalho tratar-se de um trabalho inédito no que diz respeito a integração de horizontes de previsão de carga elétrica.

## 6 CONCLUSÃO

Deste o início o foco deste trabalho foi, além de atingir seus objetivos de criar um sistema computacional para previsão de carga, gerar um produto útil para aplicação na indústria de sistemas elétricos de potência. Para tanto foram desenvolvidos os modelos e sistema neurais com vistas em sua aplicação final, buscando o melhor resultado de previsão possível. Desta busca por um melhor sistema para a aplicação surgiu a idéia de integrar em um único modelo neural dois modelos distintos. A maneira de como integrar estes modelos foi vastamente estudada em sua literatura, porém somente uma abordava o tema, ainda que superficialmente, sobre a integração de modelos neurais de previsão.

A partir desta premissa em unir os modelos neurais, chegou-se a integração destes modelos em seu nível topológico. Os modelos foram desenvolvidos individualmente e depois integrados formando um terceiro modelo. No desenvolvimento de cada um destes modelos foram colocados em prática os conhecimentos sobre sistemas elétricos de potência, tornando assim estes modelos mais próximos da realidade.

O sistema computacional de previsão foi por sua vez quando submetido a testes com uma base de dados real respondendo de maneira muito satisfatória, sendo que comparativamente aos sistemas neurais de previsão de carga convencionais, obtiveram-se melhores resultados para o sistema proposto no presente trabalho. As análises dos resultados foram dadas segundo os métodos mais aceitos para este fim, tanto para RNAs como para sistemas de previsão. E amplamente discutidos no capítulo dedicado a testes e resultados, o **Capítulo 4**.

O sistema computacional desenvolvido nesta dissertação apresenta duas características relevantes que o tornam uma importante contribuição para a comunidade científica. A primeira delas é a integração de dois modelos neurais de previsão em um único. Implementações deste tipo ainda não haviam sido discutidas com a profundidade com que foi nesta dissertação, sendo esta uma

contribuição importante. A outra contribuição pode-se dizer que é um subproduto da primeira, pois com um sistema integrado tem-se a oportunidade de com apenas uma rodada de previsão do sistema se obter dois horizontes do comportamento de carga elétrica ao longo da janela de previsão. Este fato além de diminuir a menos a metade o custo computacional, permite ainda a simplificação de operação do sistema como ferramenta, e qualidade em sua resposta. Estas características são muito importantes em se tratando de aplicações na indústria, sendo todas estas embasadas nos resultados e as análises apresentadas no **Capítulo 4**, com maior detalhamento na **seção 4.5**.

Como perspectiva futura existe a intenção de dar continuidade ao trabalho tanto no meio acadêmico como na indústria. Pois existe ainda muito potencial a ser explorado para a técnica desenvolvida para a integração de modelos neurais de previsão em seu nível topológico. Há também melhorias a serem feitas nos modelos que serão integrados, pois na presente implementação não há distinção de previsão entre dias úteis, feriados e fins de semana. Sabidamente existem substanciais diferenças no comportamento do consumo de energia elétrica nestes diferentes casos. Estas alterações poderiam aumentar a robustez do sistema mantendo sua excelente acuracidade e capacidade de generalização. Por fim poder-se-ia ainda aumentar ainda mais a capacidade do modelo neural final aumentando o número de horizontes de previsão integrados, por exemplo, prevendo curto, médio e longo prazo.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABARBANEL, H. D. I; **Analysis of Observed Chaotic Data**, Institute of Nonlinear Science. Springer, First Edition, 1996.
- ABDEL-AAL, R. E.; **Short-Term Hourly Load Forecasting Using Abductive Networks**. IEEE Transactions on Power Systems, Vol. 19, No. 1, February 2004.
- ALLEN P.G. **Economic Forecasting in Agriculture**. International Journal of Forecasting, Pages 81 – 135, October 1994.
- ARDIL, C.; MANJUNATH, T. C.; MEHTA, H. A.; MEHTA, A. J.; **A Multi-Layer Artificial Neural Network Architecture Design for Load Forecasting in Power Systems**. International Journal of Applied Mathematics and Computer Sciences, Vol. 4, No. 4, 2007.
- BAO, J.; **Short-Term Load Forecasting Based on Neural Network and Moving Average**. IEEE Transactions on Power Systems, Vol. 8, No. 1, February 2002.
- BOTHA, E.C.; VERMAAK, J.; **Recurrent Neural Networks for Short-Term Load Forecasting**. IEEE Transactions on Power Systems, Vol. 13, No. 1 February 1998.
- CAÑIZARES, C. A.; BHATTACHARA, K.; ZAREIPOUR, H. **Forecasting the Hourly Ontario Energy Price by Multivariate Adaptive Regression Splines**. Power Engineering Society General Meeting, 2006. IEEE Volume 0, Issue 0, Page: 7 pp, 2006.
- CHAN, K; CHANG, C. S.; TAN, S. S.; SRINIVASAN, D.; **Parallel Neural Network-Fuzzy Expert System Strategy for Short-Term Load Forecasting: System Implementation and Performance Evaluation**. IEEE Transactions on Power Systems, Vol. 14, No. 3, August 1999.
- CHARYTONIUK, W.; CHEN, M. S.; **Very Short-Term Load Forecasting Using Artificial Neural Networks**. IEEE Transactions on Power Systems, Vol. 15, No. 1, February 2000.
- CECHIN, A. L.; **The Extraction of Fuzzy Rules from Neural Networks**. Tese (Doutorado em Informatik)-Universitaet Tuebingen (Eberhard-Karls), Alemanha, 1998.
- CECHIN, A. L; SANTOS, J. V. C; MACAGNAN, M. H; GÓMEZ, A. T; **Sistema de Previsão de Carga baseado em Cadeias de Markov extraídas de Redes Neurais Temporais**, Projeto de Pesquisa e Desenvolvimento – RGE, 2008.
- CECHIN, A. L.; SIMON, D. R. P.; **Representação do comportamento temporal de Redes Neurais Recorrentes em Cadeias de Markov**, VIII Brazilian Sym. on Neural Networks, 2004. 2004. v.1, p.1-10

- CECHIN, A. L.; SIMON, D. R. P.; STERTZ, K.: **State Automata Extraction from Recurrent Neural Nets Using k-Means and Fuzzy Clustering**, SCCC 2003, 2003, v.1, p.1-6.
- DREZGA, I.; RAHMAN, S.; **Short-Term Load Forecasting with Local ANN Predictors**. IEEE Transactions on Power Systems, Vol. 14, No. 3, August 1999.
- ESTEVEES, G. R. T.; **Modelos de Previsão de Carga de Curto Prazo**. Dissertação de Mestrado – Programa de Pós-graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUCRio, 2003.
- FUKUYAMA, Y.; MATSUI, T.; IIZAKA, T.; **A Novel Daily Peak Load Forecasting Method using Analyzable Structured Neural Network**. IEEE T&D Asia, October 2002.
- FUNABASHI, T.; UEZATO, K.; TAKARA, H.; SENJU, T.; **One-Hour-Ahead Load Forecasting Using Neural Network**. IEEE Transactions on Power Systems, Vol. 17, No. 1, February 2002.
- GAIO, L. E.; ROLIM, R. C. **Interferência dos Mercados Externos Sobre o IBOVESPA: Uma Análise Utilizando Autoregressão Vetorial Estrutural**. X SEMEAD, agosto de 2007.
- GLEESON, B.; KECHADI, M-T.; HUANG, B. Q.; RASHID, T.; **Auto-Regressive Recurrent Neural Network Approach for Electricity Load Forecasting**. International Journal of Computational Intelligence, Vol. 3 No. 1 2006.
- GUEDES, T. A.; IVANQUI, I. L.; MARTINS, A.B.; COCHIA, E. B.; **Seleção de Variáveis Categóricas Utilizando Análise de Correspondência e Análise Procrustes**. Acta Scientiarum. Technology, Vol. 21 1999.
- GUILLEN, O. T. C.; ISSLER, J. V.; ATHANASOPOULOS, G.; **Forecasting Accuracy and Estimation Uncertainty using VAR Models with Short and Long-Term Economic Restrictions: A Monte-Carlo Study**. Ensaios Econômicos da EPGE, No. 589, Abril 2005.
- HAYKIN, S.; **Redes Neurais Princípios e Prática**. Prentice Hall, Inc. 2ª Edição, 2001.
- HONG, X.; HARRIS, C.; BROWN, M.; CHEN, S.; **Backward Elimination Methods for Associative Memory Network Pruning**. International Journal of Hybrid Intelligent Systems, Vol. 1, Issue 1-2, Pages 90-98, April 2004.
- JORQUERA, H; PALMA, W; TAPIA, J. **A Ground-Level Ozone Forecasting Model for Santiago, Chile**. Journal of Forecasting, 21, 451-472, 2002.
- KORZYK, A. D.; VANDYKE, J.G. **A Forecasting Model for Internet Security Attacks**. 21st National Information Systems Security Conference, 1997.

- LORA, A. T.; SANTOS, J. M. R.; EXPÓSITO, A. G.; RAMOS, J. L. M.; RIQUELME, J. C.; **Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques**, IEEE Transactions on Power Systems, Vol. 22, No. 3, August 2007.
- MALIK, A.; NOVOVICOVA, J.; **Information-Theoretic Feature Selection Algorithms for Text Classification**. Proceedings of International Joint Conference on Neural Networks, 2005.
- MENDES, R. V.; MARTINS, J. F.; PIRES, A. J.; MARTINS, A. G.; SANTOS, P. J.; **Short-Term Load Forecast Using Trend Information and Process Reconstruction**. International Journal of Energy Research, Volume 30, Issue 10, Pages 811-822 February 2006.
- MIZUTANI, A.; YUKAWA, T.; NUMA, K.; KUZE, Y.; IIZAKA, T.; YAMAGISHI, T.; MATSUI, T.; FUKUYAMA, Y.; **Improvement of Input-Output Correlations of Electric Power Load Forecasting by Scatter Search**. IEEE Intelligent System Applications to Power Systems (ISAP), 2005.
- MORI, H.; KURATA, E.; **Graphical Modeling for Selecting Input Variables of Short-Term Load Forecasting**. IEEE PowerTech 2007.
- MOTA, L. T.; MOTA, A. A.; **Modelagem e Simulação de Cargas Residenciais Termostáticas para a Recomposição do sistema Elétrico a partir de uma Abordagem Orientada a Objetos**. SBA Controle & Automação Vol.15, No.2, 2004.
- PACHECO, M.; ZAVERUCHA, G.; VELLASCO, M.; TITO, E. H.; **Bayesian Neural Networks for Electric Load Forecasting**. 6th International Conference on Neural Information Processing, 1999. Proceedings. ICONIP. Vol. 1, Pages: 407 - 411, November 1999.
- PECHMANN, D. R.; **Extração de Conhecimento a partir de Redes Neurais Recorrentes**. Dissertação de Mestrado – PIPCA - Programa de Pós-Graduação em Computação Aplicada, 2004.
- PIKOULAS, J.; BUCHANAN, W.J.; MANNION, M.; TRIANTAFYLLOPOULOS, K. **An Agent-based Bayesian Forecasting Model for Enhanced Network Security**. Engineering of Computer Based Systems, 2001. ECBS 2001. Proceedings. Eighth Annual IEEE International Conference and Workshop on the Volume , Issue , 2001 Pages: 247 – 254.
- QUINTANILHA, P. S.; SOUZA, A. C. Z.; LEME, R. C.; CARPINTEIRO, O. A. S.; **A Hierarchical Hybrid Neural Model with Time Integrators in Long-Term Peak-Load Forecasting**. International Joint Conference on Neural Networks, 2005. IJCNN '05. Proceedings. 2005 IEEE. Vol. 5, Pages: 2960- 2965, August 2005.

- RAMOS, J. L. M.; EXPÓSITO, A. G.; SANTOS, J. M. R.; LORA, A. T.; SANTOS, J. C. R. **Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques**. IEEE Transactions on Power Systems, Vol. 22, N<sup>o</sup>. 3, August 2007.
- REIS, R. M.; PIRES, M. A.; TEIXEIRA, A. C.; **Os Benefícios da Privatização: Evidência no Setor Elétrico Brasileiro**. VI Congresso USP Controladoria e Contabilidade, 2006.
- RIETZ, T. A.; NELSON, F. D.; BERG, J. E. **Prediction Market Accuracy in the Long Run**. The International Journal of Forecastin, 2007.
- SAAD, M.; SOOD, V.; KANDIL, N.; **Use of ANNs for Short-Term Load Forecasting**. IEEE Canadian Conference on Electrical and Computer Engineering, May 1999.
- SEEGER, M.; WILLIAMS, C. K. I.; LAWRENCE, N. D.; **Fast Forward Selection to Speed Up Sparse Gaussian Process Regression**. Workshop on AI and Statistics, 2003.
- SENJYU, T.; TAKARA, H.; UEZATO, K.; FUNABASHI, T. **One-Hour-Ahead Load Forecasting Using Neural Network**. Power Systems, IEEE Transactions on Volume 17, Issue 1, Feb 2002 Page(s):113 – 118, 2002.
- SHIRVANY, Y.; HAYATI, M.; **Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region**. International Journal of Electrical, Computer, and Systems Engineering, Vol. 1 No. 2, 2007.
- SONI, M. K.; SAINI, L. M.; **Artificial Neural Network-Based Peak Load Forecasting Using Conjugate Gradient Methods**. IEEE Transactions on Power Systems, Vol. 17, No. 3, August 2002.
- STEVENSON, W., D.; **Elementos de Análise de Sistemas de Potência**. McGraw-Hill Book. Nova Iorque, 1974.
- SWINDER, D, J.; BARTH, R.; MEIBOM, P.; WEBER, C. **Changes of System Operation Costs Due to Large-Scale Wind Integration**. Business and Policy Track: Integrating wind in electricity markets, 2007.
- TORRÓ H; MENEU, V; VALOR, E. **Single Factor Stochastic Models with Seasonality Applied to Underlying Weather Derivatives Variables**, WP-EC, 2001.
- UDAYASEN, N.; MACBEAN, E. **Determination of Optimum Operating Policies for a Combined Hydro-Thermal Electric System**. Proceedings of the Baltimore Symposium, May 1989.
- XIE, L; BAO, S; PIETRAFESA, L. J.; FOLEY, K.; FUENTES, M.; **A Real-Time Hurricane Surface Wind Forecasting Model: Formulation and Verification**. AMS Journal May 2006.

WEEDY, B., M.; **Sistemas Elétricos de Potência**. John Wiley & Sons. Nova Iorque. 2ª Edição, 1973

ZONG, P; ANDERSON, B. **Modelling and Forecasting UK Telecommunications Expenditure Using Household Microdata**. Chimera Working Paper Number: 2006-14, 2006.

## **Apêndice A - Artigos Gerados a Partir da Dissertação**

Neste apêndice constam os artigos gerados a partir da presente dissertação de mestrado. O primeiro artigo aqui apresentado foi submetido e aceito para participar do IV Fórum de Inteligência Artificial da Região Sul, ocorrido entre os dias 21 e 22 de outubro de 2008. O segundo artigo refere-se a um artigo submetido ao 6th International Conference on Informatics in Control, Automation and Robotics – ICINCO, que ocorrerá de 2 a 5 de julho em Milão na Itália.

# Um Sistema Computacional para Previsão de Carga em Sistemas de Energia Elétrica Baseado em RNAs

Rodrigo M. Figueiredo<sup>1</sup>, J. V. Canto dos Santos<sup>1</sup>, Adelmo L. Cechin<sup>1</sup>

<sup>1</sup>PIPCA – Universidade do Vale do Rio dos Sinos (UNISINOS)  
CEP– 93022-000 - São Leopoldo - RS

rdgmarques@yahoo.com.br, jvcanto@unisinis.br, acechin@unisinis.br

**Abstract.** *This paper proposes a computational system to forecast electrical load through the use of techniques of artificial intelligence, specifically by the use of ANNs. It aims the information integration from the power grid (electric load) with external variables to the system, which are weather and macroeconomic variables. The validation of the proposed system will be given from real data provided by the project's promoting company.*

**Resumo.** *Este trabalho propõe um sistema computacional para previsão de carga elétrica, através da utilização de técnicas de inteligência artificial, mais precisamente do uso de RNAs. Busca-se integrar as informações da própria rede elétrica (carga elétrica) com variáveis externas ao sistema, sendo elas variáveis meteorológicas e macroeconômicas. A validação do sistema proposto, será dada a partir de dados reais fornecidos pela empresa fomentadora do projeto do qual este artigo é subproduto.*

## 1. Introdução

Energia elétrica é o único produto que consumido no momento em que é gerado, além disso, não se pode armazenar a energia excedente, e nem mesmo sobrecarregar o sistema para produzir mais energia do que o suportado por este [Weedy 1973]. Desta forma é importante se ter uma visão antecipada do comportamento do sistema para poder se tomar decisões com antecedência. Sistemas computacionais de apoio à previsão de carga, nos quais se inclui este trabalho, visam dar ao usuário esse poder. O principal objetivo deste trabalho é o desenvolvimento de um novo sistema computacional para previsão de carga em sistemas de energia elétrica utilizando RNAs. Para tanto foram desenvolvidos dois modelos de previsão, com horizontes de longo e curto prazo de maneira integrada.

## 2. Sistema Computacional

O sistema computacional proposto visa integrar dois horizontes de previsão distintos. Esta integração visa a troca de informação entre os modelos (de longo e curto prazos) a fim de melhorar sua acuracidade.

## 2.1. Modelo de Longo Prazo

O principal objetivo deste modelo é prover informações de tendências do comportamento do sistema ao longo do tempo, para o modelo de curto prazo através da sua integração, detalhada em seguida. Neste modelo o horizonte de previsão escolhido foi o mensal, visto que as informações mensais são importantes para as empresas do setor de energia [Quintanilha 2005]. A resposta do modelo deve possuir boa acuracidade, pois este modelo é de suma importância para a resposta global do sistema.

## 2.2. Modelo de Curto Prazo

Este modelo busca mimetizar o comportamento mais dinâmico do sistema. O horizonte de previsão para este modelo se dá em uma resolução diária. As variáveis que possuem uma variação mais freqüente que a do horizonte de previsão são potencialmente viáveis para o modelo. A definição anterior exclui a utilização das variáveis macroeconômicas, por estas possuírem praticamente nenhuma variação no que tange ao horizonte diário. Porém através da integração com o modelo de longo prazo, a seguir detalhada, estas informações serão incorporadas ao modelo de curto prazo.

## 2.3. Integração dos Modelos

A grande contribuição deste trabalho está na integração dos dois modelos com diferentes horizontes, como pode comprovar o trabalho de Shirvany [Shirvany 2007]. A integração proposta neste trabalho é dada no nível topológico, evitando-se assim eventuais acúmulos de erros devido a cascadeamentos RNAs. A figura 1 mostra a idéia básica de como é dada esta integração.

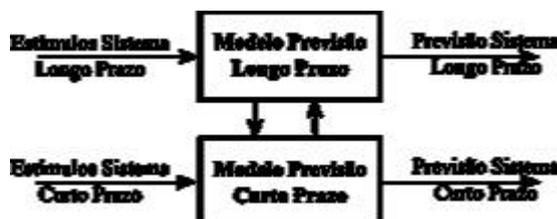


Figura 1. Integração topológica dos modelos

## 3. Metodologia

A base de dados foi organizada a partir de um dicionário de dados, o qual os classificou por classe, elétricos, meteorológicos e macroeconômicos, ou ainda temporalmente. Desta forma o banco de dados pode ser facilmente acessado para a busca das variáveis desejadas. Também foi utilizada uma biblioteca de *scripts* para o tratamento dos dados, treinamento e validação das RNAs. Estas ferramentas são a base que facilitam os testes com os modelos propostos.

### 3.1. Tratamento dos Dados

Os dados foram tratados pelos *scripts* de integração do sistema. Esses *scripts* além de integrar a base de dados com o simulador de RNAs alinha os dados temporalmente, também os normaliza. Entenda-se alinhar os dados temporalmente como organi-

### 3.1. Treinamento e Validação das RNAs

As RNAs foram treinadas utilizando o *software* SNNS, onde o *script* de integração faz a chamada do simulador por linha de comando. A validação foi realizada utilizando o algoritmo de validação *Tem-Fold Cross Validation* também implementado a partir do *script* de integração.

## 4. Resultados

A resposta do sistema para a região de Gravataí utilizando os anos de 2005 e 2006 para prever período do ano de 2006 apresentou bons resultados, como mostram os gráficos a seguir:

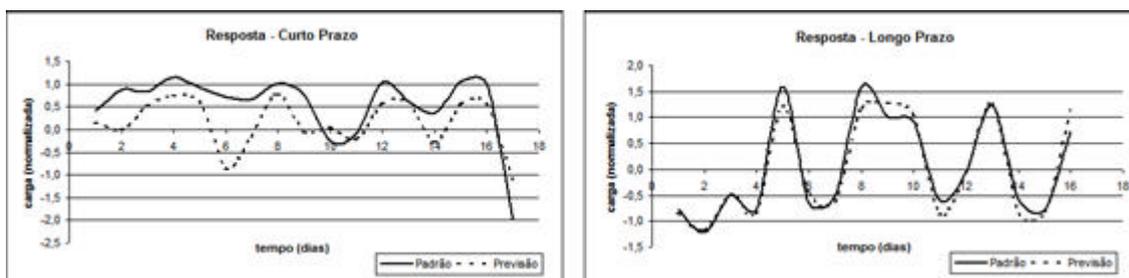


Figura 2. Resposta gráfica dos previsores de curto e longo prazo

O previsor de curto prazo apresentou RMSE de 0,15 e o previsor de longo prazo um RMSE de 0,06. A melhor performance do previsor de longo prazo deve-se principalmente a quantidade de parâmetros disponíveis para o treinamento da RNA.

## 5. Conclusão

Os resultados apresentados neste trabalho são bons e como os modelos ainda estão sendo aperfeiçoados tendem a melhorar. Porém mesmo com os resultados atuais este trabalho apresenta uma grande contribuição por dois aspectos. O primeiro é a apresentação de uma técnica para integração de horizontes de previsão, já a segunda deriva da primeira, pois com apenas uma RNA e um único treinamento pode-se ter a resposta de dois horizontes de previsão distintos, economizando principalmente tempo computacional.

## Referências

- Quintanilha, P., S., Souza, A., C., Z., Leme, R. C., Carpinteiro, O. A. S. (2005) “A Hierarchical Hybrid Neural Model with Time Integrators in Long-Term Peak-Load Forecasting”, International Joint Conference on Neural Networks, 2005. IJCNN '05. Proceedings. 2005 IEEE. Vol. 5, Pages: 2960- 2965.
- Shirvany, Y., Hayati, M.. (2007) “Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region”, International Journal of Electrical, Computer, and Systems Engineering, Vol. 1 No. 2, 2007..
- Weed, B., M. (1973) “Sistemas Elétricos de Potência”, John Wiley & Sons. Nova Iorque. 2ª Edição.

# A NEW NEURAL SYSTEM FOR LOAD FORECAST IN ELECTRICAL POWER SYSTEMS

## *A Topological Level Integration of Two Horizon Model Forecasting*

Rodrigo Marques de Figueiredo, José Vicente Canto dos Santos, Adelmo Luis Cechin  
*PIPCA - UNISINOS, Av. Unisinos 950, São Leopoldo, Rio Grande do Sul, Brazil*  
*rdgmarques@yahoo.com.br, jvcanto@unisinos.br, acechin@unisinos.br*

**Keywords:** Artificial Neural Networks, Electric Power Systems, Load Forecasting.

**Abstract:** This work presents a new integrated neural model approach for two horizons of load forecasting. First of all is presented a justification about the design of a computational neural forecasting model, explaining the importance of the load forecast for the electrical power systems. Here is presented the design of the two neural models, one for short and other for long term forecasting. Also is showed how these models are integrated in the topological level. A neural model that could integrate two forecasting horizons is very useful for electrical system enterprises. The computational system, here presented, was tested in three different scenarios, where each scenario has specific electrical load behaviour. At last the results is commented and explained.

## 1 INTRODUCTION

The electrical energy is the only one product that is consumed when it is produced. When it is produced in excess this energy can overload the electrical power system, being it could not be stored. When it has a scarcity production, the electrical power system has a fault (Weedy, 1973). This fact turns today the load forecasting in an important tool for enterprises of energy. The forecast for this system is subject to external variables, stochastic variables, like meteorological and macroeconomic variables. The first one has an imply in residential loads and the second an strong imply in industrial loads (Ardil et al, 2007).

These features also shows how complex is a a load forecast for an electrical power system. This system is non-linear and multivariable, too hard and computationally expensive to be given by a deterministic model. The solution is the use of approximate modelling approaches, where stands out neural models.

Many papers broaches this theme in various about the using of neural modeling for only one forecasting horizon. But neural modeling for two or more forecasting horizons, as in Shirvany (Shyrvany, 2007) is scare in the literature. The present paper propouses a new neural model for load

forecasting by the using of two integrated models, one for short term and other for long term load forecasting. The resulting model has the ability for short and long term load forecasting at the same time.

## 2 THE COMPUTATIONAL FORECASTING SYSTEM

The forecasting system consists in two neural models, one for short term and other for long term forecasting. These neural models are given by the artificial neural network application. The models were individually designed and validated to later be integrated. The data base of variables available to be used to design the models are given by the following types:

- Meteorological variables;
- macroeconomic variables;
- Electrical variables.

The variable space for an electrical system is too large, even when it is reduced for the three types showed above. For a better model response this space must be reduced (Guedes et al, 1999). Variable selection methods are the best way to reduce the variable space removing from model most of redundant and irrelevant variables.

## 2.1 Variable Selection

The variables were selected by the using of forward selection. In this method the neural model is constructed by its interaction, where in each interaction one variable is included in model. The criteria used to the model construction are the minor response error for a validation (Seeger, 2003). This algorithm runs until a stop criteria, in this paper case an error level minor than fifteen percent. For the two models, short and long term, this method is applied by individually manner.

Before the forward selection being applied a pre-selection of variables was made in according to its temporal behaviour. The meteorological variables have a faster temporal behaviour, which are relevant to use with short term model forecasting. But the behaviour of macroeconomic variables is different and it is relevant to the model to predict the long term. Electrical variables are relevant to both forecasting horizons because the focus of the forecast is the electrical load.

## 2.2 Long Term Model

The main objective of this model is to provide the behaviour information of the electrical system to short term model, through the topological integration. In this model the forecasting horizon chosen was the monthly horizon, because that information is very important for the business of the electrical energy sector enterprises (Quintanilha et al, 2005).

Through the using of forward selection method the variables were selected, and as resulting the neural model for long term forecasting is given in Figure 1. This model uses as input the monthly information of one year and one day ago. That information give to the long term model the monthly tendency of each month of the year with all seasonal influences. This fact makes the model more robust.

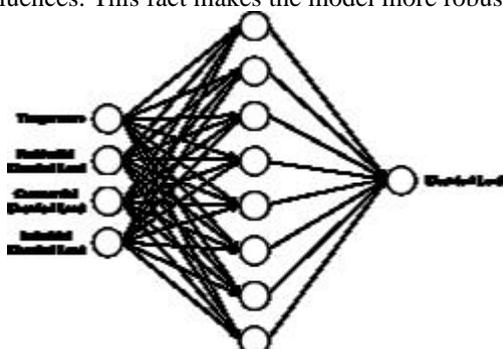


Figure 1: Long term forecast neural model.

## 2.3 Short Term Model

This model try, as main objective, mimetizes the electrical power system load behaviour. As like long term model, this model uses the forward selection to choose its variables. In this model case faster variables behaviour is relevant to it, like meteorological and electrical variables.

After the using of forward selection the neural model was constructed with the variables selected. This model showed below, in Figure 2, uses the temperature, humidity and electrical load as variables that can describes the short term behaviour of the electrical power system.

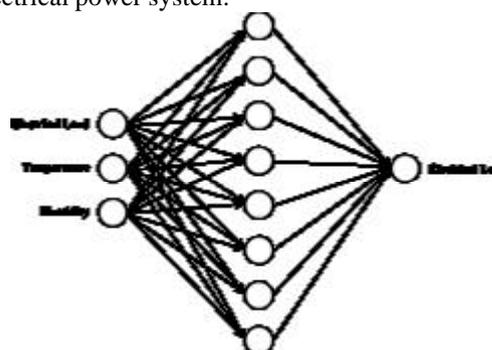


Figure 2: Short term forecast neural model.

## 2.4 Model Integration

The integration of the short and long term forecast models is the main step of the computational system design. Is important keep in mind that this integration is given in the topological level. With this type of integration only the tendencies of each model are passed to the other. In other types of integration the error also is integrated.

The neurons sharing guarantee the tendencies exchange between long and short term models without polluting yours responses (Figueiredo, 2008). But this is not a total share, only a parcel of these neurons is shared. Throughout tests this value was fixed at one third of the neurons. The others neurons are used exclusively by its respective model. The Figure 4 shows the shared neurons, highlighting the shared neurons in dark color. Also are showed the inputs and the out-puts of final model.

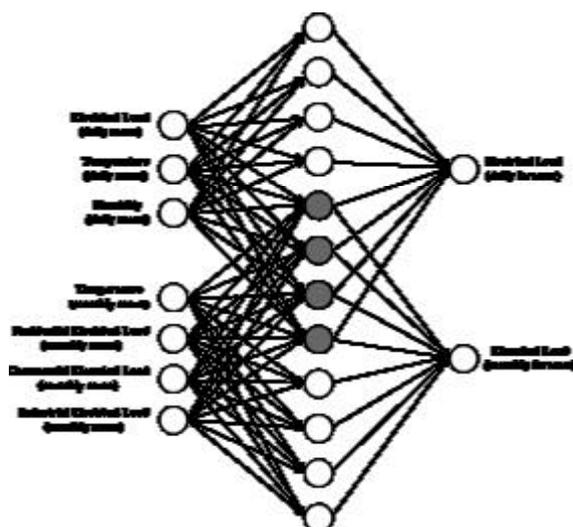


Figure 4: Neural model integration.

The final model uses twelve neurons in hidden layer, with four exclusively used by short term model, four for the long term model and four neurons being shared by the two models, unifying these models in only one.

## 2.5 System Architecture

The architecture of the computational system is given by three main parts, or modules. This architecture is showed in Figure 5:

- Database;
- Data Treatment;
- Neural Model.

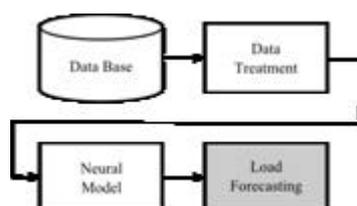


Figure 5: Computational system architecture.

Database contains all information about the electrical power system. For forecasting models is very important a large database as possible (Swinder et al, 2007). This module organizes the data by the temporal order and class (meteorological, macroeconomic and electrical).

The data treatment module is responsible to the data fetch from the database and its handling, that consists in temporal synchronization, data normalization and separation of data type. When the data

processing is complete they are ready to be delivered to the neural model.

The neural model uses data to learn the behaviour of electrical power system load. This learning occurs throughout the artificial neural network (ANN) training.

For the training a data set is delivered to the neural model, this data set is previously formatted by the data treatment module. The temporal data alignment of the data set is showed in Figure 6.

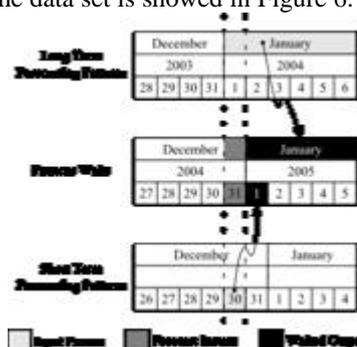


Figure 6: Data set temporal aligning.

In Figure 6 the forecast instant represents the moment when the computational forecasting system is executed. Note that data is aligned in different ways for short and long term parameters, that to avoid the need for not available data. That case occur when two forecasting horizons are used in the same model and one horizon is overridden by the other

## 3 TESTS AND RESULTS

To validate the computational neural system proposed in this paper tests were applied. These tests using three different scenarios:

- Industrial Load Region;
- Residential Load Region;
- Mixed Load Region.

Industrial load has a seasonal behaviour with strong dependence of macroeconomic factors. These economic factors indicates the production behaviour of the industry and per consequence its your electrical power consumption.

The residential load presents a different behaviour, it is not seasonal. This type of consumer has a behaviour closely liked to the meteorological conditions. In cold days the residential consumer uses their heaters, and in the hot days they use their air conditioner.

Mixed load consumer regions are areas where there is a balance between residential and industrial consumers. In those areas there is no definition about the load behaviour, because it follows the trend given by the industrial and residential load.

### 3.1 Validation and Analysis Methods

To validate the computational forecasting system are used two validation methods. As first method are used the Ten-Fold Cross Validation. This method was used to verify the robustness of the system. As second validation method are used the Direct Validation. This method verifies the accuracy of the system.

For analysing the results providing by the validation methods were used quantitative and qualitative analysis metrics. As quantitative metric used was the Root Mean Squared Error (RMSE), and as qualitative metric is used the graphical analysis of the pattern and forecasting curves in sobrepuestion. Other important information is the data set temporal organisation used to each validation method. For Ten-Fold Cross Validation is used the following temporal organisation:

Table 1: Ten-Fold Cross Validation data set, for training and validation.

| Forecast Horizon | Temporal Range  |
|------------------|-----------------|
| Long Term        | 2003 up to 2006 |
| Short Term       | 2004 up to 2007 |

For Direct Validation is used the temporal data set organisation as follow:

Table 2: Direct Validation data set, for training.

| Forecast Horizon | Temporal Range  |
|------------------|-----------------|
| Long Term        | 2003 up to 2005 |
| Short Term       | 2004 up to 2006 |

Table 3: Direct Validation data set, for validation.

| Forecast Horizon | Temporal Range |
|------------------|----------------|
| Long Term        | 2006           |
| Short Term       | 2007           |

This organisation is repeated for all test, with this action is granted the repeatability and the possibility to compare the results of each region test.

### 3.2 Industrial Load Region Test

For Ten-Fold Cross Validation the system has the following responses with 13% of RMSE for short

term forecasting and 4% for long term. The graph shows the response of the forecaster. The dashed line represents the patterns waits and the solid lines the forecasting values given by the forecasting system.

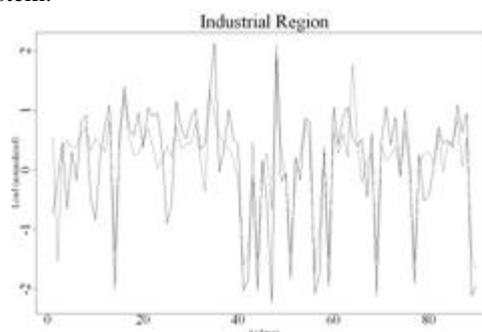


Figure 7: Short Term – Ten-Fold Cross Validation.

In Figure 7 is presented the short term response, with an acceptable behaviour and in Figure 8 is the long term result, better than the short term.

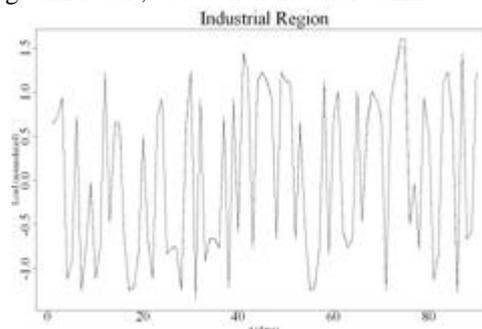


Figure 8: Long Term – Ten-Fold Cross Validation.

Using the direct validation the system has an excellent response. This validation tests the system in the real application situation. For this test the RMSE for short term was 0,07% and 1,8% for long term forecasting. These results are excellent and can be confirmed in Figures 9 and 10, which shows these responses in a graphical manner.

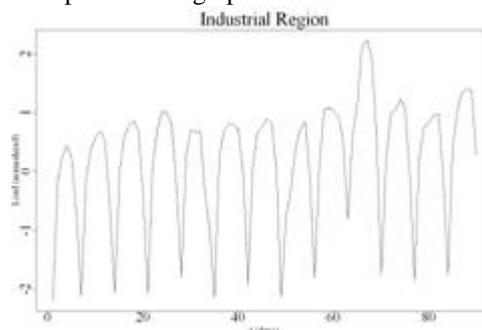


Figure 9: Short Term – Direct Validation.

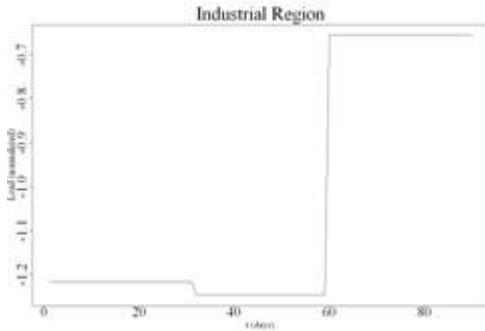


Figure 10: Long Term – Direct Validation.

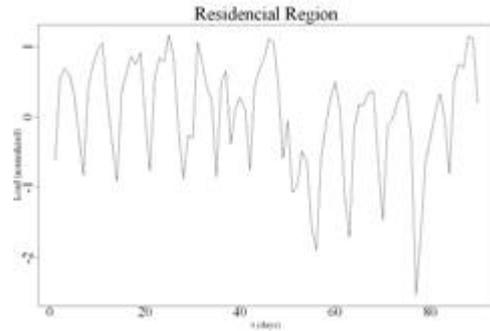


Figure 13: Short Term – Direct Validation.

### 3.2 Residential Load Region Test

The RMSE of the Ten-Fold Cross Validation for a residential load region has for short term forecasting with 13% and for long term forecasting with 6%. The Figures 11 and 12 show this in a visual manner:

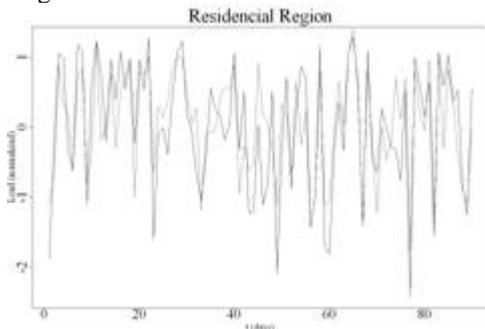


Figure 11: Short Term – Ten-Fold Cross Validation.

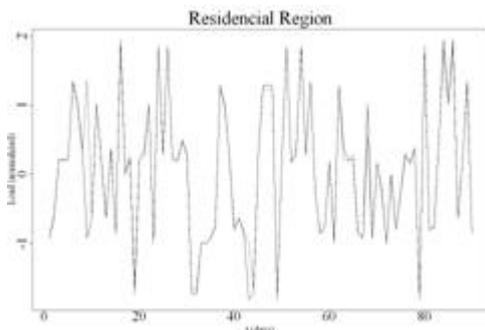


Figure 12: Long Term – Ten-Fold Cross Validation.

For direct validation this region has as RMSE results for short and long term 0,02% and 0,09% respectively. Those excellent results are showed in details in Figures 13 and 14 as follow.

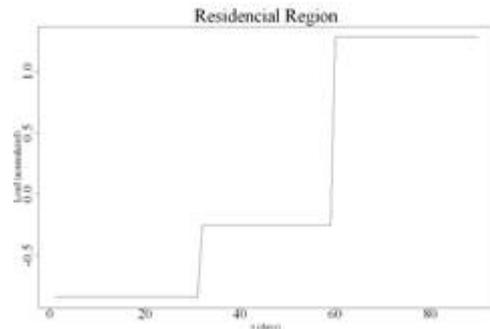


Figure 14: Long Term – Direct Validation.

### 3.3 Mixed Load Region Test

In mixed load region the Ten-Fold Cross Validation has for short term forecasting a RMSE with 12% and for long term forecasting a RMSE with 5%. This results has closely values as given by the others load regions test.

That system behaviour, constant for all tests, is very interesting and pretty good to the final system application. The next Figures 15 and 16 show this test results.

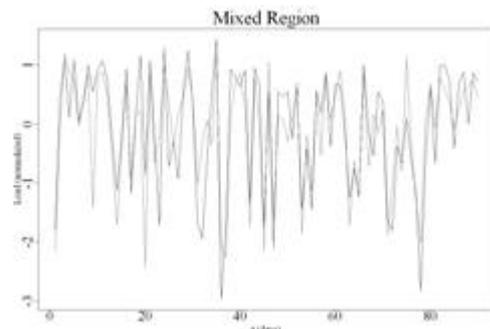


Figure 15: Short Term – Ten-Fold Cross Validation

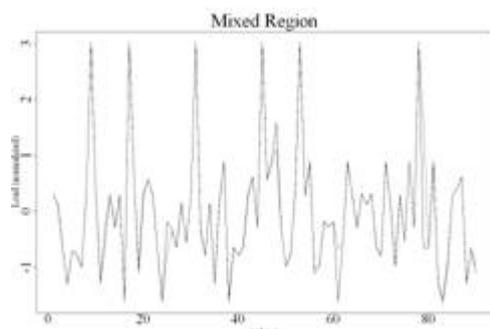


Figure 16: Long Term – Ten-Fold Cross Validation

For the direct validation there a RMSE for short term forecasting with 0,01% and for long term forecasting with 0,03%. Like happened with Ten-Fold Cross Validation, these test results has a closely behaviour as given in other load regions test. In the Figures 17 and 18 are presented the results of this tests in a graphical manner.

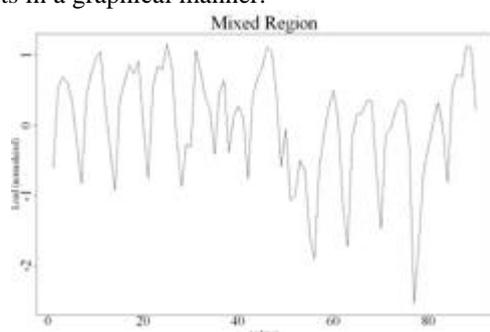


Figure 17: Short Term – Direct Validation

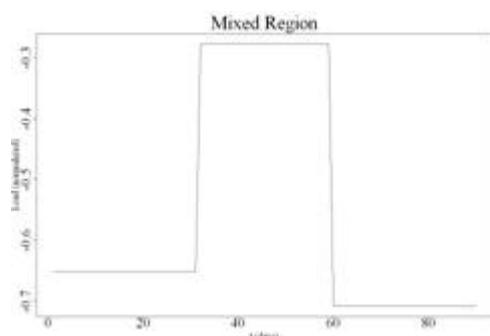


Figure 18: Long Term – Direct Validation

## 4 CONCLUSIONS

The results presented previously in section 3 shows the validation of the computational neural system. In this validation the system was submitted a two basics analysis. How robust it is, with applying the Ten-Fold Cross Validation, how accuracy it provi-

des, observing the direct validation response. and how in generic the model. Observing these results for the three tests, each one with a different electrical load feature, we could analyse how generic is the neural model of the system.

A generic forecasting system is a great advantage for commercial usage, because they could forecast many instances with only one model. Other important feature of the system developed in this paper is the accuracy, they presents a excellent accuracy for a real application, with errors minor than one percent.

Finally the great contribution of this work is presents a new neural model for load forecasting, by the topological level integration usage. With this integration, the computational system has proved flexible and capable to generating excellent results.

## REFERENCES

- Ardil, C., Manjunath, T., Mehta H., Mehta, A., 2007. *A Multi-Layer Artificial Neural Network Architecture Design for Load Forecasting in Power Systems*. International Journal of Applied Mathematics and Computer Sciences, Vol. 4, No. 4.
- Figueiredo, R., Santos, J., Cechin, A., 2008. *Um Sistema Computacional para Previsão de Carga em Sistemas de Energia Elétrica Baseado em RNAs*. IV Fórum de Inteligência Artificial da Região Sul.
- Guedes, T., Ivanqui, I., Martins, A., Cochia, E., 1999. *Seleção de Variáveis Categóricas Utilizando Análise de Correspondência e Análise Procrustes*. Acta Scientiarum. Technology, Vol. 21.
- Quintanilha, P., Souza, A., Leme, R., Carpinteiro, O., 2005. *A Hierarchical Hybrid Neural Model with Time Integrators in Long-Term Peak-Load Forecasting*. International Joint Conference on Neural Networks, 2005. IJCNN '05. Proceedings. 2005 IEEE. Vol. 5, Pages: 2960-2965.
- Seeger, M., Williams, C., Lawrence, N., 2003. *Fast Forward Selection to Speed Up Sparse Gaussian Process Regression*. Workshop on AI and Statistics.
- Shirvany, Y., Hayati, M., 2007. *Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region*. International Journal of Electrical, Computer, and Systems Engineering, Vol. 1 No. 2.
- Swinder, D., Barth, R., Meibom, P., Weber, C., 2007. *Changes of System Operation Costs Due to Large-Scale Wind Integration*. Business and Policy Track: Integrating wind in electricity markets, 2007.
- Weedy, B., 1973. *Sistemas Elétricos de Potência*. John Wiley & Sons. Nova Iorque. 2ª Edição.