

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

Previsão de carga multinodal utilizando redes neurais de  
regressão generalizada

**Kenji Nose Filho**

**Orientador:** Prof.<sup>a</sup> Dr.<sup>a</sup> Anna Diva Plasencia Lotufo

Ilha Solteira – SP  
Março/2011

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

Previsão de carga multinodal utilizando redes neurais de  
regressão generalizada

**Kenji Nose Filho**

**Orientador:** Prof.<sup>a</sup> Dr.<sup>a</sup> Anna Diva Plasencia Lotufo

Dissertação apresentada à Faculdade de Engenharia - UNESP – Campus de Ilha Solteira, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Ilha Solteira – SP  
Março/2011

## FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação  
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

N897p

Nose Filho, Kenji.

Previsão de carga multinodal utilizando redes neurais de regressão  
generalizada / Kenji Nose Filho. -- Ilha Solteira : [s.n.], 2010  
90 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de  
Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2010

Orientadora: Anna Diva Plasencia Lotufo  
Inclui bibliografia

1. Barramento. 2. Redes neurais (Computação).  
3. Regressão generalizada. 4. Previsão de carga de curto prazo.


**CERTIFICADO DE APROVAÇÃO**

**TÍTULO:** Previsão de carga multinodal utilizando redes neurais de regressão generalizada

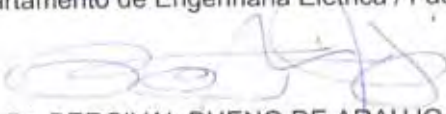
**AUTOR:** KENJI NOSE FILHO

**ORIENTADORA:** Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,  
Área: AUTOMAÇÃO, pela Comissão Examinadora:

  
Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Prof. Dr. PERCIVAL BUENO DE ARAUJO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

  
Prof. Dr. WALMIR DE FREITAS FILHO

Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas

Data da realização: 16 de fevereiro de 2011.

## Agradecimentos

*O Senhor é meu pastor, nada me faltará.*

*Em verdes prados ele me faz repousar. Conduz-me junto às águas refrescantes, restaura as forças de minha alma. Pelos caminhos retos ele me leva, por amor do seu nome.*

*Ainda que eu atravessasse o vale escuro, nada temerei, pois estais comigo. Vosso bordão e vosso báculo são o meu amparo.*

*Preparais para mim a mesa à vista de meus inimigos. Derramais o perfume sobre minha cabeça, e transborda minha taça.*

*A vossa bondade e misericórdia hão de seguir-me por todos os dias de minha vida. E habitarei na casa do Senhor por longos dias.*

*Salmo 22*

Agradeço primeiramente a Deus, no qual sempre depus a minha fé e a minha confiança. Agradeço especialmente a meus pais, Kenji e Mike, por todo o apoio e pela educação que me foi dada.

Agradeço às minhas irmãs, Michelle e Mirelli, meu cunhado Fábio e a todos os meus amigos que fiz durante os sete anos que estive em Ilha Solteira, por todos os momentos que passamos juntos, momentos estes que foram de grande importância para a minha formação pessoal e profissional.

Agradeço à minha orientadora, prof<sup>a</sup> Anna Diva Plasencia Lotufo, pelo carinho e pela confiança em mim depositado durante todos estes anos que estivemos trabalhando juntos. Ao meu co-orientador, prof. Carlos Roberto Minussi, pelos seus conselhos e pelas idéias que serviram de base para a realização deste trabalho. Também agradeço à professora Mara Lúcia Martins Lopes, pela ajuda fornecida durante todos estes anos.

Agradeço ao suporte financeiro concedido pelo CNPq.

## RESUMO

Neste trabalho, dá-se ênfase à previsão de carga multinodal, também conhecida como previsão de carga por barramento. Para realizar esta demanda, há necessidade de dispor de uma técnica que proporcione a precisão desejada, seja confiável e de baixo tempo de processamento. O conhecimento prévio das cargas locais é de extrema importância para o planejamento e operação dos sistemas de energia elétrica. Para realizar a previsão de carga multinodal foram empregadas duas metodologias, uma que prevê as cargas individualmente e outra que utiliza as previsões dos fatores de participação e a previsão de carga global. O principal objetivo deste trabalho é elaborar um modelo de previsor de carga de curto prazo, genérico e que pode ser aplicado na previsão de carga multinodal. Para tanto, utilizou-se redes neurais de regressão generalizada (GRNN), cujas entradas são compostas de variáveis exógenas globais e de cargas locais, sem a necessidade da inclusão de variáveis exógenas locais. Ainda, projetou-se uma nova arquitetura de rede neural artificial, baseada na GRNN, além de propor um procedimento para a redução do número de entradas da GRNN e um filtro para o pré-processamento do banco de dados de treinamento. Os dados, para testar as metodologias e as redes neurais artificiais, são referentes a um subsistema de distribuição de energia elétrica da Nova Zelândia composto por nove subestações.

**Palavras-chave:** Barramento. Multinodal. Previsão de Carga de Curto Prazo. Redes Neurais Artificiais. Regressão Generalizada.

# ABSTRACT

In this work, it is emphasized the multi-nodal load forecast, also known as bus load forecast. To perform this demand, there it is necessary a technique that is precise, trustable and has a short-time processing. The previous knowledge of the local loads is of extreme importance to the planning and operation of the electrical power and energy systems. To perform the multi-nodal load forecast is employed two different methodologies, one that forecast the loads individually and another that uses the participation factors forecasts and the global load forecast. The main objective of this work is to elaborate a generic model of a short-term load forecaster, which can be applied to the multi-nodal load forecast. For this, it was used general regression neural networks (GRNN), with inputs based on external global factors and local loads, without the need of external local factors. Still, it was developed a new architecture of an artificial neural network based on a GRNN and proposed a procedure to reduce the number of input variables of the GRNN and a filter for preprocessing the training data. The dataset, to test the methodologies and the artificial neural networks, refers to a New Zealand electrical distribution subsystem composed of nine substations.

**Keywords:** Artificial Neural Networks. Bus. Generalized Regression. Multinodal. Short-Term Load Forecast.

## LISTA DE ILUSTRAÇÕES

<b>Figura 3.1</b> - Conjuntos de variáveis independentes $x$ e de suas variáveis dependentes $y$ .	28
<b>Figura 3.2</b> - Função <i>radbas</i> para diferentes valores do parâmetro <i>spread</i> .	29
<b>Figura 3.3</b> - Arquitetura da GRNN.	30
<b>Figura 3.4</b> - Saídas das camadas da GRNN para a aplicação 1.	32
<b>Figura 3.5</b> - Curva real dada pelos pontos da Tabela 3.I (azul) e ponto aproximado pela GRNN (vermelho).	32
<b>Figura 3.6</b> - Arquitetura da GRNN modificada.	34
<b>Figura 3.7</b> - Saídas das camadas da GRNN modificada para a aplicação 2.	36
<b>Figura 3.8</b> - Curva real dada pelos pontos da tabela 3.I (azul) e ponto aproximado pela GRNN modificada (vermelho).	36
<b>Figura 4.1</b> - Sistema predictor de carga multinodal do tipo PCL.	41
<b>Figura 4.2</b> - Sistema predictor de carga multinodal do tipo PCL-FPCG.	42
<b>Figura 4.3</b> - a) Localização geográfica das subestações, b) diagrama elétrico.	43
<b>Figura 4.4</b> - Comportamento da carga global dos anos de 2007 e 2008.	46
<b>Figura 4.5</b> - Curvas de carga média dos dias da semana de 2007 e 2008.	47
<b>Figura 4.6</b> - Curvas de carga média dos dias da semana de 2007 e 2008 pertencentes e não pertencentes ao horário de verão.	47
<b>Figura 4.7</b> - Curvas de carga dos dias úteis dos anos de 2007 e 2008, dias normais em azul e dias atípicos e feriados em vermelho, a) segundas-feiras, b) terças-feiras, c) quartas-feiras, d) quintas-feiras, e) sextas-feiras.	50
<b>Figura 4.8</b> - Análise espectral das curvas de carga global dos anos de 2007 e 2008	51
<b>Figura 4.9</b> - Correlação entre os valores de cargas globais, médios, máximo e mínimos dos dias $d$ com os dias $d-1$ , dos anos de 2007 e 2008.	51
<b>Figura 4.10</b> - Modelo de predictor de carga local/global/fator de participação de carga global.	53
<b>Figura 4.11</b> - Filtro proposto, composto de uma GRNN e um filtro de média móvel.	54
<b>Figura 4.12</b> - Curvas de carga, original e típica.	56
<b>Figura 4.13</b> - Valor absoluto do erro entre a curva de carga original e típica e a tolerância.	56
<b>Figura 4.14</b> - Saídas do filtro GRNN, do filtro de média móvel (atrasada) e a carga filtrada (adiantada).	56



<b>Figura B.1</b> - Curvas de carga locais da subestação #01, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	80
<b>Figura B.2</b> - Curvas de carga locais da subestação #02, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	81
<b>Figura B.3</b> - Curvas de carga locais da subestação #03, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	82
<b>Figura B.4</b> - Curvas de carga locais da subestação #04, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	83
<b>Figura B.5</b> - Curvas de carga locais da subestação #05, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	84
<b>Figura B.6</b> - Curvas de carga locais da subestação #06, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	85
<b>Figura B.7</b> - Curvas de carga locais da subestação #07, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	86
<b>Figura B.8</b> - Curvas de carga locais da subestação #08, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	87
<b>Figura B.9</b> - Curvas de carga locais da subestação #09, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).	88
<b>Figura B.10</b> - Curvas de carga globais, reais e previstas pelos previsores tipo GRNN, GRNN-M e GRNN-MR.	89

# LISTA DE TABELAS

<b>Tabela 3.I -</b>	Conjunto de dados de treinamento da aplicação 1.	31
<b>Tabela 4.I -</b>	Nomenclatura dos sistemas previsores.	43
<b>Tabela 4.II -</b>	Especificações dos transformadores de cada subestação.	43
<b>Tabela 4.III -</b>	Divisão do banco de dados.	44
<b>Tabela 4.IV -</b>	Parâmetros do filtro.	55
<b>Tabela 5.I -</b>	MAPEs diários, médios e máximos, obtidos nas previsões das nove cargas locais.	59
<b>Tabela 5.II -</b>	Tempo médio gasto para o treinamento, a validação e a previsão de um dia por um predictor de carga local/fator de participação de carga global.	59
<b>Tabela 5.III -</b>	MAPEs diários, médios e máximos, obtidos nas previsões de carga global.	60
<b>Tabela 5.IV -</b>	Tempo médio gasto para o treinamento, a validação e a previsão de um dia pelos previsores de cargas globais.	60
<b>Tabela A.I -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN.	72
<b>Tabela A.II -</b>	Valores do parâmetro <i>spread</i> utilizados em cada predictor de carga local do sistema PCL GRNN.	72
<b>Tabela A.III -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN-M.	73
<b>Tabela A.IV -</b>	Valores do parâmetro <i>spread</i> utilizados em cada predictor de carga local do sistema PCL GRNN-M.	73
<b>Tabela A.V -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN-MR.	74
<b>Tabela A.VI -</b>	Valores do parâmetro <i>spread</i> utilizados em cada predictor de carga local do sistema PCL GRNN-MR.	74
<b>Tabela A.VII -</b>	Configuração de entrada dos previsores de cargas locais do sistema PCL GRNN-MR.	74
<b>Tabela A.VIII -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN.	75

<b>Tabela A.IX -</b>	Valores do parâmetro <i>spread</i> utilizados em cada previsor de fator de participação de carga global do sistema PCL-FPCG GRNN.	75
<b>Tabela A.X -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN-M.	76
<b>Tabela A.XI -</b>	Valores do parâmetro <i>spread</i> utilizados em cada previsor de fator de participação de carga global do sistema PCL-FPCG GRNN-M.	76
<b>Tabela A.XII -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN-MR.	77
<b>Tabela A.XIII -</b>	Valores do parâmetro <i>spread</i> utilizados em cada previsor de fator de participação de carga global do sistema PCL-FPCG GRNN-MR.	77
<b>Tabela A.XIV -</b>	Configuração de entrada dos previsores de fator de participação de carga global do sistema PCL-FPCG GRNN-MR.	77
<b>Tabela A.XV -</b>	MAPEs, diários, médios e máximos obtidos nas previsões de carga global.	78
<b>Tabela A.XVI -</b>	Valores do parâmetro <i>spread</i> utilizados pelos previsores de cargas globais.	78
<b>Tabela A.XVII -</b>	Configuração de entrada do previsor de carga global do sistema PCL-FPCG GRNN-MR.	78

## LISTA DE ABREVIATURAS E SIGLAS

<b>Adaline</b>	–	<i>Adaptive linear element</i>
<b>ANFIS</b>	–	<i>Adaptive Neuro-Fuzzy Inference System</i>
<b>ARIMA</b>	–	<i>Auto Regressive Integrated Moving Average</i>
<b>ART</b>	–	<i>Adaptive Resonance Theory</i>
<b>CDS</b>	–	<i>Centralised DataSet</i>
<b>CG</b>	–	Carga Global
<b>CL</b>	–	Carga Local
<b>CMOS</b>	–	<i>Complementary Metal Oxide Semiconductor</i>
<b>DST</b>	–	<i>Daylight Saving Time</i>
<b>EMAX</b>	–	Erro percentual máximo
<b>FASE</b>	–	<i>Forecasted-Aided State Estimator</i>
<b>FPCG</b>	–	Fator de Participação de Carga Global
<b>FPGA</b>	–	<i>Field Programmable Gate Array</i>
<b>GA</b>	–	<i>Gaussian ART</i>
<b>GR</b>	–	<i>Gaussian Regression</i>
<b>GRNN</b>	–	<i>General Regression Neural Network</i> / Rede Neural de Regressão Generalizada
<b>GRNN-M</b>	–	Rede Neural de Regressão Generalizada Modificada
<b>GRNN-MR</b>	–	Rede Neural de Regressão Generalizada Modificada com Redução de entradas
<b>HVPLN</b>	–	<i>Haryana Vidyut Prasaran Nigam Ltd.</i>
<b>LMS</b>	–	<i>Least Mean-Square</i>
<b>Madaline</b>	–	<i>Multiple adaline</i>

<b>MAPE</b>	–	<i>Mean Absolute Percentage Error</i>
<b>MLP</b>	–	<i>Multi Layer Perceptron</i>
<b><i>newgrnn</i></b>	–	Função do aplicativo MATLAB que cria uma GRNN.
<b>PCL</b>	–	Sistema previsor de cargas locais
<b>PCL-FPCG</b>	–	Sistema previsor de cargas locais por meio da previsão do FPCG e da CG
<b>PNN</b>	–	<i>Probabilistic Neural Network</i>
<b><i>radbas</i></b>	–	Função de base radial, do tipo gaussiana, do MATLAB.
<b>RBFNN</b>	–	<i>Radial Basis Function Neural Network</i>
<b>RLC</b>	–	Resistivo, Capacitivo e Indutivo
<b>RNA</b>	–	Redes Neurais Artificiais
<b>SCADA</b>	–	<i>Supervisory Control and Data Acquisition</i>
<b>SEC-WOA</b>	–	<i>Saudi Electricity Company, Western Operation Area</i>
<b>SEE</b>	–	Sistema de Energia Elétrica

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Organização</b>	<b>16</b>
<b>2</b>	<b>PREVISÃO DE CARGAS ELÉTRICAS</b>	<b>17</b>
<b>2.1</b>	<b>Tipos de previsão e aplicações</b>	<b>17</b>
<b>2.2</b>	<b>Variáveis de influência</b>	<b>18</b>
<b>2.3</b>	<b>Metodologias de previsão de cargas</b>	<b>19</b>
<b>2.3.1</b>	<i>Previsão de carga elétrica de curto prazo por redes neurais artificiais.</i>	<b>20</b>
<b>3</b>	<b>REDES NEURAIAS ARTIFICIAIS</b>	<b>25</b>
<b>3.1</b>	<b>Introdução</b>	<b>25</b>
<b>3.2</b>	<b>Rede Neural de Regressão Generalizada (GRNN)</b>	<b>27</b>
<b>3.2.1</b>	<i>Regressão Generalizada</i>	<b>27</b>
<b>3.2.2</b>	<i>Arquitetura</i>	<b>29</b>
<b>3.2.3</b>	<i>Aplicação 1</i>	<b>31</b>
<b>3.3</b>	<b>Rede Neural de Regressão Generalizada Modificada (GRNN-M)</b>	<b>33</b>
<b>3.3.1</b>	<i>Arquitetura</i>	<b>33</b>
<b>3.3.2</b>	<i>Aplicação 2</i>	<b>35</b>
<b>3.4</b>	<b>Processo de validação para determinação do parâmetro <i>spread</i> da GRNN</b>	<b>37</b>
<b>3.5</b>	<b>Procedimento para redução do número de entradas da GRNN</b>	<b>37</b>
<b>3.6</b>	<b>Conclusões</b>	<b>40</b>
<b>4</b>	<b>METODOLOGIA</b>	<b>41</b>
<b>4.1</b>	<b>Introdução</b>	<b>41</b>
<b>4.2</b>	<b>Estudos para elaboração das entradas das RNAs</b>	<b>44</b>
<b>4.3</b>	<b>Pré-processamento do banco de dados de treinamento</b>	<b>53</b>
<b>4.4</b>	<b>Conclusões</b>	<b>57</b>

<b>5</b>	<b>RESULTADOS</b>	<b>58</b>
<b>5.1</b>	<b>Introdução</b>	<b>58</b>
<b>5.2</b>	<b>Previsão de cargas locais</b>	<b>59</b>
<i>5.2.1</i>	<i>Resultados</i>	<i>59</i>
<i>5.2.2</i>	<i>Discussão</i>	<i>59</i>
<b>5.3</b>	<b>Previsão de carga global</b>	<b>60</b>
<i>5.3.1</i>	<i>Resultados</i>	<i>60</i>
<i>5.3.2</i>	<i>Discussão</i>	<i>60</i>
<b>6</b>	<b>CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS</b>	<b>62</b>
<b>6.1</b>	<b>Conclusões Gerais</b>	<b>62</b>
<b>6.2</b>	<b>Propostas para trabalhos futuros</b>	<b>63</b>
	<b>REFERÊNCIAS</b>	<b>64</b>
<b>Apêndice A</b>	<b>- TABELAS</b>	<b>71</b>
<b>A.1</b>	<b>Previsão de cargas locais</b>	<b>72</b>
<i>A.1.1</i>	<i>Previsão de cargas locais pelo sistema previsor PCL GRNN.</i>	<i>72</i>
<i>A.1.2</i>	<i>Previsão de cargas locais pelo sistema previsor PCL GRNN-M.</i>	<i>73</i>
<i>A.1.3</i>	<i>Previsão de cargas locais pelo sistema previsor PCL GRNN-MR.</i>	<i>74</i>
<i>A.1.4</i>	<i>Previsão de cargas locais pelo sistema previsor PCL-FPCG GRNN.</i>	<i>75</i>
<i>A.1.5</i>	<i>Previsão de cargas locais pelo sistema previsor PCL-FPCG GRNN-M.</i>	<i>76</i>
<i>A.1.6</i>	<i>Previsão de cargas locais pelo sistema previsor PCL-FPCG GRNN-MR.</i>	<i>77</i>
<b>A.2</b>	<b>Previsão de carga global</b>	<b>78</b>
<b>Apêndice B</b>	<b>FIGURAS</b>	<b>79</b>
<b>B.1</b>	<b>Previsão de cargas locais</b>	<b>80</b>
<b>B.2</b>	<b>Previsão de carga global</b>	<b>89</b>
<b>Apêndice C</b>	<b>- ARTIGOS SUBMETIDOS, ACEITOS E PUBLICADOS</b>	<b>90</b>
<b>C.1</b>	<b>Artigos aceitos e publicados</b>	<b>90</b>

# 1 INTRODUÇÃO

Alguns estudos e planejamentos em sistemas de energia elétrica (SEE) necessitam da previsão de cargas elétricas. Dentre eles, estão: despacho econômico, fluxo de potência, estabilidade transitória, compra e venda de energia elétrica, e o planejamento da geração, transmissão e distribuição. Para que o SEE opere de modo seguro, confiável e econômico é necessário o conhecimento prévio das cargas em vários pontos do sistema (HANDSCHIN; DÖRNEMANN, 1988).

Historicamente, encontram-se vários métodos para realizar a previsão de cargas, como: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado (GROSS; GALIANA, 1987), filtro de Kalman, métodos ARIMA de Box & Jenkins (BOX; JENKINS, 1976), entre outros. Estes métodos necessitam da modelagem prévia da carga para posteriormente serem aplicados.

Uma alternativa para a resolução do problema de previsão de cargas é a utilização de redes neurais artificiais (RNA) que não necessitam da modelagem prévia da carga. A modelagem é uma tarefa bastante dispendiosa e os métodos que necessitam da mesma nem sempre apresentam os melhores resultados. As RNAs são hábeis ferramentas, capazes de realizar a aproximação de funções não-lineares e a previsão de séries temporais a partir de um treinamento adequado, devido às suas capacidades de aprendizagem e generalização (HAYKIN, 2008).

Neste trabalho, dá-se ênfase à previsão de carga multinodal, também conhecida como previsão de carga por barramento (PYNE, 1974). Propõe-se então, efetuar uma abordagem que deixa de prever apenas a demanda de forma global, que é um procedimento comumente adotado na literatura, para a previsão em vários pontos da rede elétrica. Deste modo, consideram-se vários pontos da rede onde se observam diferentes tipos de consumidores (CHEN et al., 1996; SALGADO et al., 2010), constituindo-se num problema caracterizado por um grande volume de informação e de natureza complexa.



Para realizar esta demanda, há a necessidade de dispor de uma técnica que proporcione a precisão desejada, seja confiável e de baixo tempo de processamento. Neste caso, as redes neurais de regressão generalizada (GRNN), que são treinadas em apenas uma apresentação dos padrões de treinamento, são capazes de fornecer respostas rápidas e precisas, além da probabilidade de se cair em mínimos locais ser baixa.

Para diminuir ainda mais o tempo de resposta da GRNN convencional (SPECHT, 1991), foi proposto, neste trabalho, uma modificação em sua estrutura, criando-se assim uma nova arquitetura de RNA denominada rede neural de regressão generalizada modificada (GRNN-M).

As cargas locais são previstas por meio de duas metodologias diferentes, podendo ser previstas de forma individual ou a partir da previsão do fator de participação e da previsão de carga global. A segunda constitui-se em uma alternativa que pode ou não fornecer melhores resultados, pois em geral a previsão de carga global é realizada com maior precisão e o valor do fator de participação varia muito pouco.

Para realizar as previsões, é proposto um modelo de previsor de carga, de curto prazo, genérico, capaz de realizar previsões de carga global, local ou fator de participação por meio de GRNNs, convencionais e modificadas, cujas entradas são compostas apenas de variáveis exógenas globais e de cargas locais, sem a necessidade de variáveis exógenas locais. A não necessidade destas variáveis reduz a complexidade do problema da previsão de carga multinodal, pois não requer o estudo detalhado das cargas locais do sistema. A GRNN modificada também é uma proposta deste trabalho e foi desenvolvida com o intuito de reduzir o tempo gasto para realizar as previsões. Além disso, é proposto um procedimento para reduzir o número de entradas das RNAs, capaz de selecionar as entradas que são mais relevantes para cada caso, podendo melhorar a capacidade de generalização das RNAs utilizadas.

Para o pré-processamento do banco de dados de treinamento, foi desenvolvido um filtro capaz de diminuir ruídos, recuperar dados faltantes e substituir anormalidades do banco de dados de treinamento.

O SEE utilizado neste trabalho é um subsistema de distribuição da Nova Zelândia, composto por nove subestações. Os dados históricos de cargas locais são referentes aos valores de potência ativa processada por cada subestação, medidos de meia em meia hora, de janeiro de 2007 a março de 2009, extraídos do *Centralized Dataset* (CDS) disponibilizados

pelo *Electricity Commission* da Nova Zelândia (disponível em: <http://www.ea.govt.nz/industry/modelling/cds/>).

## 1.1 Organização

No capítulo 2 é elaborada uma revisão bibliográfica, contendo os principais trabalhos a respeito da previsão de cargas elétricas.

O capítulo 3 apresenta uma breve introdução a respeito das RNAs, também são apresentadas as arquiteturas da GRNN convencional e da modificada, o método utilizado para a determinação do parâmetro *spread* e o procedimento para redução do número de entradas das RNAs.

O capítulo 4 apresenta duas metodologias para a previsão de carga multinodal, a individual e a por meio da previsão dos fatores de participação. Também são apresentados os estudos realizados para a elaboração do modelo de previsor de carga, de curto prazo, genérico e o filtro para o pré-processamento do banco de dados de treinamento.

O capítulo 5 apresenta os resultados obtidos por cada sistema previsor.

No capítulo 6 são desenvolvidas algumas conclusões gerais a respeito do trabalho e algumas propostas para trabalhos futuros.

Os apêndices A e B contêm tabelas e figuras que ilustram os resultados obtidos por cada sistema previsor.

O apêndice C referencia os artigos submetidos, aceitos e publicados durante a realização deste trabalho.

## **2 PREVISÃO DE CARGAS ELÉTRICAS**

### **2.1 Tipos de previsão e aplicações**

A previsão de cargas elétricas pode ser efetuada a curto, médio e longo prazo. A de curto prazo consiste naquela de meia em meia hora ou horária, ou ainda picos de carga diários, de um período que pode variar de um dia a até uma semana (AQUINO et al., 2006; AL SHAREEF et al., 2008; AMJADY, 2007; CHEN et al., 1996; DA SILVA et al., 2001; FERREIRA; DA SILVA, 2005; FIDALGO; LOPES, 2005; GROSS; GALIANA, 1987; KIARTZIS et al., 1996; LOPES et al., 2010; LOTUFO; MINNUSSI, 1999; MALKI et al., 2004; NIU et al., 2005; NOSE-FILHO et al., 2009; PANDIAN et al., 2006; PYNE, 1974; SANO et al., 2005; SAINI, 2008; SAINI; SONI, 2002; SALGADO et al., 2010; SENJYU et al., 2005; SONG et al., 2005; TELBANY; KARMI, 2007; TOPALLI et al., 2006; TRIPATHI et al., 2008; VILLALBA; BEL, 2000; XIA et al., 2010; YALCINOZ; EMINOGLU, 2005; YAP et al., 2006; YUN et al., 2008). A de médio prazo consiste naquela de meia em meia hora ou horária, ou ainda picos de carga (diários ou semanais) de algumas semanas até um ano (AQUINO et al., 2006; AL-HAMADI; SOLIMAN, 2005; AMJADY; KEYNIA, 2008; MAHDAVI et al., 2008; PEDREGAL; TRAPERRO, 2010; XIA et al., 2010; YALCINOZ; EMINOGLU, 2005; ZHANG; LIU, 2010a, 2010b). A de longo prazo consiste na previsão de demanda para um determinado ano, ou picos de carga (mensais ou anuais) de um período que pode variar de alguns anos a algumas décadas (AL-HAMADI; SOLIMAN, 2005; EKONOMOU, 2010; KERMANSHAHI; IWAMIYA, 2002; XIA, et al., 2010).

A previsão de cargas elétricas de curto prazo é utilizada no planejamento e operação diário dos SEEs, para que os mesmos sejam seguros, confiáveis e econômicos. Já a de médio prazo é utilizada na programação de manutenções e coordenação das unidades geradoras, hidráulicas e térmicas. E ainda, a de longo prazo é utilizada no planejamento da expansão do SEE.

Pyne (1974) propõe a previsão de carga multinodal para o cálculo do fluxo de potência para estimar o nível de segurança do SEE.

Ranaweera et al. (1997) examinam o impacto econômico causado pelos erros obtidos na previsão de carga de curto prazo. Para isto são realizadas simulações de Monte Carlo utilizando diferentes valores de erros de previsão. Os resultados obtidos neste trabalho sugerem que as cargas sejam previstas com menos de 5% de erro.

No trabalho de Huang et al. (2005) os autores propõem uma metodologia para o restabelecimento de energia, após a ocorrência de uma contingência, em sistemas de distribuição, que leva em consideração a previsão de carga de curto prazo de cada zona de serviço.

Os trabalhos de Pyne (1974) e Huang (2005) propõem aplicações que necessitam das previsões de cargas elétricas em vários pontos do SEE. Nos trabalhos de Handschin e Dörnemann (1988), Amjady (2007) e Salgado et al. (2010) são realizadas as previsões de carga elétrica, por barramento, os dois últimos utilizam-se de RNAs. Todos estes trabalhos enfatizam a necessidade da previsão de carga em vários pontos do SEE, para que o mesmo possa ser planejado e operado de forma segura, confiável e econômica.

## 2.2 Variáveis de influência

As cargas elétricas de um SEE são influenciadas por vários fatores exógenos (GROSS; GALIANA, 1987), dentre eles:

- Fatores socioeconômicos: descritos pelos índices de renda média, taxa de emprego, distribuição da população por faixas salariais, padrão residencial, empregos por setor de atividade e escolaridade;
- Fatores demográficos: como índices de densidade demográfica (hab./km.<sup>2</sup>) e distribuição por faixas etárias;
- Fatores temporais: descritos pela hora, dia da semana, dia do mês, dia do ano, mês, ano e feriados;
- Fatores climáticos: podem ser descritos por medições ou previsões de temperatura, umidade, velocidade do vento, entre outros. Estes fatores exercem grande

influência sobre a carga, sendo o principal objetivo de estudo de alguns trabalhos, e.g. (LIN et al., 2005);

- Fatores aleatórios: podem ser descritos por interrupções no fornecimento de energia elétrica, manutenções não programadas, greves, tempestades, entre outros.

Os fatores socioeconômicos e demográficos não se modificam em curto prazo, exercendo grande influência nas previsões de médio e longo prazo. E.g. se a taxa de emprego de uma determinada região diminui é provável que o consumo diminua. Se a densidade demográfica de uma região aumenta, é provável que se aumente o consumo, pois mais cargas serão instaladas para suprir o aumento populacional.

Os fatores temporais, climáticos e aleatórios exercem grande influência nas previsões de curto e médio prazo, pois se modificam em curto prazo, e.g. se a temperatura aumenta, é provável que se aumente o consumo devido aos aparelhos de ar-condicionado, se a temperatura diminui muito é provável que o consumo também aumente devido aos aquecedores elétricos. Os fatores climáticos também exercem grande influência nas previsões de longo prazo.

Uma dificuldade encontrada na previsão de carga de curto prazo por RNAs é a influência que os fatores aleatórios podem causar no comportamento típico das cargas. O comportamento atípico destas cargas influencia negativamente, prejudicando a capacidade de aprendizagem e generalização das RNAs. Portanto, em alguns casos se faz necessário o uso de filtros e técnicas de reconstrução de dados para realizar o pré-processamento do banco de dados de treinamento.

## 2.3 Metodologias de previsão de cargas

Historicamente, encontram-se vários métodos para realizar a previsão de cargas, como: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado (GROSS; GALIANA, 1987), filtro de Kalman, métodos ARIMA de Box & Jenkins (BOX; JENKINS, 1976), entre outros.

Diversas outras metodologias para previsão de cargas foram propostas nas últimas duas décadas, como o uso de redes neurais artificiais, lógica *fuzzy*, sistemas híbridos, entre outros.

Os métodos estatísticos necessitam da modelagem prévia da carga para posteriormente serem aplicados, e.g. na regressão linear ou múltipla a carga pode ser descrita por (2.1), para determinar as entradas é necessário um estudo da correlação entre as variáveis de entrada e a variável de saída (LOTUFO; MINUSSI, 1999).

$$y(t) = a_0 + a_1x_1(t) + \dots + a_nx_n(t) + a(t) \quad (2.1)$$

Sendo:

$y(t)$  – carga elétrica.

$a_0, a_1, \dots, a_n$  – coeficientes de regressão.

$a(t)$  – ruído branco.

$x_1(t), x_2(t), \dots, x_n(t)$  – variáveis de correlação.

Já os métodos inteligentes, como as redes neurais artificiais, lógica *fuzzy* e sistemas híbridos, não necessitam da modelagem prévia da carga, ou seja, tais métodos não necessitam que as variáveis de entrada possuam correlação direta com a variável de saída, para estes, basta que os mesmos sejam fatores que influenciem no comportamento das cargas.

Na seção 2.3.1, dá-se ênfase aos trabalhos que realizam a previsão de carga de curto prazo por redes neurais artificiais.

### ***2.3.1 Previsão de carga elétrica de curto prazo por redes neurais artificiais.***

A previsão de carga de curto prazo pode ser por diferentes arquiteturas de RNAs, como as redes do tipo perceptron multicamadas (MLP, *Multilayer Perceptron*), redes da família ART (*Adaptive Resonance Theory*), GRNN, PNN (*Probabilistic Neural Network*), ANFIS (*Adaptive Neuro Fuzzy Inference System*), entre outros.

Nesta seção, é apresentada uma pequena revisão bibliográfica, com respeito à previsão de carga de curto prazo por RNAs, procurando especificar de cada trabalho, a arquitetura e a topologia da rede, a estratégia adotada, o banco de dados e os resultados obtidos.

No trabalho de Kiartzis et al. (1996), os autores propõem a previsão de carga horária de um SEE da ilha de Creta, Grécia, para o ano de 1995. Para isto é treinada uma RNA do tipo MLP com os dados referentes aos anos de 1990 a 1994. A topologia da rede é dada por três camadas, com 64, 48 e 24 neurônios em cada uma. Os dados de entrada são referentes a temperatura, dia da semana, dia do ano e cargas horárias de dois dias anteriores, totalizando 64 entradas. A saída é dada pelas 24 cargas horárias do dia seguinte. O erro obtido, MAPE (*Mean Absolute Percentage Error*) anual, foi de 2,52%. Neste trabalho foi realizado o pré-

processamento do banco de dados de treinamento, para a correção de possíveis irregularidades por meio da comparação das curvas de cargas com curvas de cargas típicas.

Chen et al. (1996) propõem a previsão de carga horária de três subestações de energia elétrica de Taiwan, as cargas previstas são referentes a um dia típico de verão e o banco de dados de treinamento é referente aos dias desta estação. A arquitetura das RNAs utilizadas é a de uma rede com uma camada de entrada, uma camada adicional, uma camada de base ortogonal, uma camada intermediária e uma camada de saída. São propostas diferentes topologias para a previsão das cargas dos dias da semana, dos sábados e dos domingos. As entradas são compostas por cargas passadas e dados de temperatura. O pré-processamento do banco de dados é realizado eliminando-se dados irregulares por meio de uma análise estatística. Os erros obtidos, MAPEs diários, para os dias da semana de cada uma das três subestações previstas, variam de 1,93% a 2,87%.

No trabalho de da Silva et al. (2001) é descrito um sistema neural utilizado pelas companhias de energia elétrica brasileiras para realizar a previsão de carga elétrica horária. Para isto é utilizado um modelo não paramétrico, baseado em um modelo linear acoplado a uma rede neural polinomial. O pré-processamento do banco de dados é realizado por meio de um previsor linear e um filtro passa baixa. Diferentes estratégias são adotadas para a previsão de feriados. O erro obtido, MAPE anual, foi de 2,26%.

Saini e Soni (2002) realizam a previsão de pico de carga, utilizando RNAs do tipo MLP, com três camadas. Para o treinamento são propostos diferentes algoritmos do tipo *backpropagation*, dentre eles os algoritmos do gradiente descendente, Levenberg-Marquardt, Broyden-Fletcher-Goldfarb-Shanno e *one-step secant*. As redes foram treinadas com dados históricos dos anos de 1997 a 1999, de uma subestação de energia elétrica de Haryana Vidyut Prasaran Nigam Ltd. (HVPNL), Índia. Foram obtidos resultados para as quatro estações do ano. A entrada é composta por dados de temperatura, tipo de dia e pico de carga do dia anterior. Os erros obtidos, MAPEs médios, foram de 2,38% a 2,87%.

No trabalho de Malki et al. (2004) os autores propõem a previsão de carga horária e de carga diária utilizando RNAs do tipo MLP. Para cada previsão é proposta uma estratégia diferente, que utiliza como entrada cargas passadas e dados de temperatura e umidade. O banco de dados utilizado é referente a um SEE de Berkley, Califórnia, dos anos de 1999 a 2001. O MAPE obtido nas previsões de cargas horárias variou de 2,39% a 8,33% e nas de cargas diárias variou de 1,13% a 1,89%.

Fidalgo e Lopes (2005) propõem a previsão de carga horária utilizando RNAs do tipo MLP. As cargas são referentes aos valores de potência ativa, reativa e de corrente de um SEE

de distribuição. Duas metodologias diferentes são adotadas neste trabalho, uma cuja saída é dada pela carga da hora seguinte e outra que fornece os valores das 24 cargas do dia seguinte. A primeira utiliza como variáveis de entrada indicadores do dia da semana e hora além de cargas passada, a segunda utiliza somente indicadores do dia da semana e cargas passadas. A RNA da primeira metodologia é composta por três camadas, 10 neurônios na camada de entrada, sete na intermediária e um na de saída. Já a RNA da segunda metodologia é composta por três camadas, 74 neurônios na camada de entrada, seis na intermediária e 24 na de saída. Para a previsão de feriados ou de dias que necessitem das cargas de feriados, diferentes estratégias são adotadas, onde os valores de determinadas cargas passadas podem assumir valores de outros dias, e.g. para a previsão de um dia que necessite dos valores de carga passada de uma quarta-feira, se esta quarta-feira for um feriado, serão utilizados valores de outra quarta-feira que não seja um feriado. Neste trabalho várias técnicas de filtragem de dados foram testadas, como o uso de filtros passa baixa, regras do tipo *IF-then* e filtragem por RNAs, destacando-se as duas últimas.

No trabalho de Ferreira e da Silva (2005) os autores propõem o uso de técnicas de regularização para lidar com o problema de *overfitting* das RNAs do tipo MLP na previsão de carga elétrica horária. O problema de *overfitting* ocorre quando há excesso de iterações no treinamento das redes. Para evitar isto os autores propõem o uso do treinamento bayesiano, técnica de controle de ganho e uso de máquinas de vetores suporte. O banco de dados utilizado é referente a um SEE Norte Americano. Os erros obtidos, MAPEs diários, variam de 5% a 8,41%.

Niu et al. (2005) propõem o uso de uma GRNN para a previsão de carga horária. Para a determinação do parâmetro *spread* desta rede é proposto uma técnica baseada em algoritmos evolutivos diferenciais. Os erros obtidos, MAPES diários, variam de 1,45% a 2,03%.

Em Yap et al. (2006) é proposto uma nova arquitetura de RNA, denominada *Gaussian Regression* (GR), baseada nas redes *Gaussian ART* (GA) e GRNN. Foram propostas duas metodologias diferentes, uma que prevê as cargas de meia em meia hora e outra que prevê as cargas do dia seguinte (48 valores de cargas), ambas utilizam como variáveis de entrada, valores de cargas passadas. O MAPE obtido foi de 1,65%.

Amjady (2007) propõe o uso de estimadores de estado (FASE, *Forecast-Aided State Estimator*) e RNAs do tipo MLP para a previsão de carga multinodal, de três subestações de energia elétrica iranianas. Os dados são referentes ao ano de 2005. As variáveis de entrada são compostas por cargas passadas que alimentam estimadores de estado, as saídas destes alimentam as RNAs e a saída da RNA fornece o valor de carga da hora seguinte. Os erros



obtidos para os dias convencionais, MAPEs semanais, variam de 1,42% a 7,88% e para os feriados, MAPEs diários, variam de 1,94% a 8,20%.

No trabalho de Al-Shareef et al. (2008) os autores propõem um modelo baseado em uma RNA do tipo MLP para a previsão de carga horária de um SEE da Arábia Saudita, *Regional Power Control Center of Saudi Electricity Company, Western Operation Area (SEC-WOA)*. Esta RNA possui três camadas com 22, 10 e um neurônio em cada camada. As entradas são compostas por indicadores de mês, ano, hora, dia da semana, feriados, além de variáveis climáticas como previsões de temperatura e umidade e cargas passadas. A saída é dada pela carga prevista da hora seguinte. Foram utilizados para o treinamento e teste, dados dos anos de 2003 a 2007 e os erros obtidos, MAPEs semanais, variam de 1,57% a 1,82%.

Em Saini (2008) são utilizados diferentes algoritmos de treinamento para RNAs do tipo MLP para a previsão de pico de carga diário, de um SEE indiano. Dentre eles estão o treinamento bayesiano, *resilient backpropagation* e *adaptive backpropagation*. Para a determinação dos parâmetros de entrada, dois procedimentos foram adotados, análise de correlação e a análise dos componentes principais. Dentre as variáveis de entradas possíveis estão diversas variáveis climáticas, indicadores de tempo e valores de cargas passadas. Os erros obtidos, MAPEs semanais, variam de 2,43% a 2,83%.

Tripathi et al. (2008) propõem uma estratégia capaz de prever o valor da carga da hora seguinte utilizando valores de preço de carga. Neste trabalho, são utilizadas duas arquiteturas diferentes de RNAs, a PNN e a GRNN. As variáveis de entrada são compostas por indicadores de hora e dia, valores de temperatura e de preço de carga. O banco de dados utilizado é referente a um SEE de Victória, Austrália. Os resultados obtidos, MAPEs diários, variam de 1,80% e 9,51%.

Em Nose-Filho et al. (2009) os autores propõem o uso de diferentes arquiteturas de RNAs para a previsão de cargas horárias de um SEE brasileiro do ano de 1998. Dentre elas estão as RNAs do tipo MLP treinadas pelos algoritmos do gradiente descendente com momento e o algoritmo de Levenberg-Marquardt, o ANFIS e a GRNN. As entradas são dadas por indicadores de hora e dia da semana além de cargas passadas. A saída é dada pela carga prevista da hora seguinte. Os erros obtidos, MAPEs diários, variam de 0,97% a 2,31%.

No trabalho de Lopes et al. (2010) os autores propõem a previsão de carga horária de um SEE brasileiro por meio de uma RNA da família ART, denominada *ART&ARTMAP fuzzy*. As entradas são dadas por indicadores de dia da semana e hora e cargas passadas. A saída é dada pela carga prevista da hora seguinte. O banco de dados utilizado é referente a um SEE brasileiro do ano de 1998. O erro obtido, MAPE diário, foi de 1,62%.

Em Salgado et al. (2010) os autores propõe a previsão de carga em vários barramentos de um SEE brasileiro, utilizando-se de RNAs do tipo MLP. Para isto, duas estratégias são utilizadas: uma que realiza a previsão das cargas dos barramentos de forma individual e outra que agrupa os barramentos com as mesmas características de carga em clusters. As entradas de cada modelo são determinadas por meio de uma análise de correlação entre a carga a ser prevista e valores de cargas passadas. A estratégia que prevê as cargas de forma agrupada chega a ser 14 vezes mais rápida que a estratégia de previsão individual. Os resultados obtidos, MAPEs diários, variam de 1,87% a 7,32%.

No trabalho de Xia et al. (2010) os autores realizam a previsão de carga de curto prazo por três diferentes arquiteturas de RNAs, uma RNA do tipo MLP, uma GRNN e uma rede neural do tipo base radial (RBFNN, *Radial Basis Function Neural Network*). Os resultados obtidos variam de 2,13% a 2,38%.

## 3 REDES NEURAIS ARTIFICIAIS

### 3.1 Introdução

As redes neurais artificiais (RNAs) (HAYKIN, 2008) têm como característica principal “simular” o funcionamento do cérebro humano, reproduzindo artificialmente a maneira como os estímulos são processados por nossos neurônios. As RNAs com seus mecanismos de associação, generalização e auto-organização conquistaram espaço dentro do mundo moderno.

As RNAs são capazes de resolver problemas complexos como a previsão de séries temporais, aproximação de funções e identificação de padrões, sem a necessidade da modelagem matemática do problema a ser resolvido.

O primeiro neurônio artificial foi descrito por McCulloch e Pitts (1943) em 1943. Em 1958, Rosenblatt (1958) apresentou o seu trabalho sobre o *perceptron*, uma das primeiras RNAs, com apenas um neurônio e aprendizagem supervisionada. Dois anos depois em 1960, Widrow e Hoff (1960) desenvolveram o algoritmo dos mínimos quadrados (LMS, *Least Mean-Square*) para o elemento linear adaptativo (Adaline, *Adaptive linear element*). Logo após, Widrow propôs a estrutura múltipla (Madaline, *Multiple adaline*). Nos anos 70 surgiram vários trabalhos a respeito dos mapas auto-organizáveis utilizando aprendizagem competitiva, com os trabalhos pioneiros de Willshaw e von der Marsburg (1976). Em 1976, surgem os primeiros trabalhos de Grossberg (1976a, 1976b) a respeito da teoria da ressonância adaptativa (ART, *Adaptive Resonance Theory*). No início dos anos 80 surgiram as redes de Hopfield e os mapas auto-organizáveis de Kohonen (1982). Em 1985 surgiu a máquina de Boltzmann, trabalho desenvolvido por Ackley et al. (1985), um exemplo de RNA de múltiplas camadas bem sucedido na época. Em 1986, Rumelhart et al. (1986) apresentam o algoritmo *backpropagation*, primeiramente proposto por Werbos (1974) em 1974. O algoritmo de treinamento *backpropagation* é um dos mais utilizados até hoje, inclusive como padrão de

referência. Em 1987, Grossberg (1987) apresenta a sua primeira rede baseada na teoria da ressonância adaptativa, conhecida como ART1.

Nos últimos 20 anos, várias outras redes foram desenvolvidas, novos algoritmos de treinamento surgiram e o uso de técnicas híbridas tem sido bastante estudado. Como exemplos estão as redes de função de base radial (RBFNN, *Radial Basis Function Neural Network*) (MOODY e DARKEN, 1989), a PNN e a GRNN introduzidas por Specht (1990, 1991), as redes ART *fuzzy*, ARTMAP e ARTMAP *fuzzy*, desenvolvidas por Carpenter et al. (1991a, 1991b, 1992), o ANFIS (*Adaptive Neuro-Fuzzy Inference System*) (JANG, 1993), e vários outros sistemas não menos importantes.

Nas últimas décadas vários trabalhos têm sido propostos utilizando RNAs. Pesquisas recentes vêm aplicando as RNAs em diagnósticos médicos, mapeamento do genoma humano, previsão do tempo, previsão de demanda de energia elétrica, previsão de preços de energia elétrica, classificação e detecção de faltas nos sistemas de energia elétrica, classificação de consumidores do setor elétrico, classificação de consumidores de lojas de varejo, entre outros.

As RNAs podem ser programadas tanto em *hardwares* quanto em *softwares*. Devido ao grande avanço tecnológico é possível implementar RNAs em circuitos RLC, FPGAs (*Field Programmable Gate Array*), microprocessadores e circuitos integrados utilizando tecnologia CMOS (*Complementary Metal Oxide Semiconductor*) (OKI, 1998), (LUCKS; OKI, 1999).

Em geral, as RNAs podem ser classificadas em recorrentes ou não recorrentes. As recorrentes possuem laços de realimentação, ou seja, as saídas dos neurônios de determinada camada realimentam a entrada desta mesma camada ou de camadas anteriores. As não recorrentes também conhecidas como *feedforward* não possuem laços de realimentação, ou seja, as saídas dos neurônios de uma camada só alimentam as entradas dos neurônios da camada seguinte.

A aprendizagem das RNAs ocorre na fase de treinamento (WASSERMAN, 1989). O treinamento realiza o ajuste dos pesos e *bias*, responsáveis pelo armazenamento de informações. O treinamento pode ser supervisionado, que utiliza os padrões de entradas e saídas desejadas, ou não supervisionado, que utiliza somente os padrões de entradas, em geral, trata-se de um processo auto-organizável.

Neste trabalho, foram utilizadas duas arquiteturas de RNAs para a previsão de carga multinodal, dentre elas a GRNN convencional, proposta por Specht (1991), e a GRNN modificada, detalhadas nas seções 3.2 e 3.3 respectivamente. O processo de validação para a escolha do parâmetro *spread* e o procedimento para redução do número de entradas das GRNNs são descritos nas seções 3.4 e 3.5.

## 3.2 Rede Neural de Regressão Generalizada (GRNN)

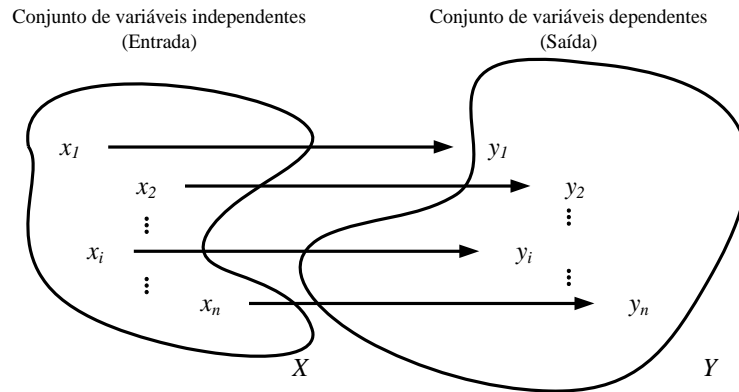
A GRNN, proposta por Specht (1991), é uma rede capaz de realizar a estimação de uma variável dependente a partir de uma independente por meio de um conjunto de variáveis finito. Seu treinamento é supervisionado, possui uma estrutura do tipo não recorrente e é realizado em apenas uma apresentação dos padrões de treinamento. Esta rede possui uma estrutura fixa, dada por uma camada de entrada, duas intermediárias e uma de saída, onde o número de neurônios de cada camada depende do número de padrões de treinamento, de entradas e saídas da rede. Sua capacidade de generalização é mantida até mesmo com o uso de dados esparsos e por ser baseada em uma função densidade de probabilidade, as chances de se cair em mínimos locais é muito baixa (NIU et al., 2005).

Esta rede tem sido bastante utilizada nos últimos anos, principalmente em problemas que envolvem a previsão de séries temporais, como a de cargas elétricas de curto prazo (NIU et al., 2005; NOSE-FILHO et al., 2009; TRIPATHI et al., 2008; XIA et al., 2010; YAP et al., 2006). Várias modificações têm sido propostas, com o intuito de melhorar a sua capacidade de generalização. No trabalho de Niu et al. (2005), os autores propõem a busca do parâmetro *spread* por meio de um algoritmo evolutivo diferencial modificado. Já o trabalho de Yap et al. (2006) combina o uso de redes baseadas na teoria da ressonância adaptativa (ART) com a GRNN.

A GRNN convencional foi programada com o auxílio dos *toolboxes* de RNAs do MATLAB (Manual *online* de utilização do MATLAB, disponível em <<http://www.mathworks.com/help/>>), por meio da função *newgrnn*.

### 3.2.1 Regressão Generalizada

A regressão consiste em estimar uma variável dependente  $y$  a partir de uma independente  $x$  por meio de um conjunto finito de variáveis  $x$  e  $y$ , que podem ser visualizados na Figura 3.1. Na teoria de sistemas, a variável dependente corresponde à saída e a independente corresponde à entrada e podem ser descritas por vetores, cujo número de elementos indica o número de entradas e saídas do sistema.



**Figura 3.1** - Conjuntos de variáveis independentes  $x$  e de suas variáveis dependentes  $y$ .

Considerando dois conjuntos finitos,  $X$  e  $Y$  de variáveis independentes (entradas) e dependentes (saídas) e sendo  $\hat{x}$  uma variável de entrada desconhecida, a saída  $\hat{y}$  pode ser estimada pela regressão de  $\hat{x}$  por meio das variáveis contidas nos conjuntos  $X$  e  $Y$ , conforme (3.1).

$$E(Y|\hat{x}) = \frac{\int_{-\infty}^{+\infty} yf(\hat{x}, Y)dy}{\int_{-\infty}^{+\infty} f(\hat{x}, Y)dy} \quad (3.1)$$

A função densidade de probabilidade  $f(\hat{x}, Y)$  pode ser obtida por meio dos conjuntos  $X$  e  $Y$ . A rede neural de regressão generalizada utiliza como função densidade de probabilidade a estimação de Kernel, também conhecida como janela de Parzen. A estimativa da variável  $\hat{y}$  dado uma variável desconhecida  $\hat{x}$  pode ser determinada por meio de (3.2), sendo  $n$  o número de amostras dos conjuntos  $X$  e  $Y$ ,  $y_i$  a variável dependente associada à independente  $x_i$  e  $a_i$  o valor da  $i$ -ésima distância euclidiana da variável desconhecida  $\hat{x}$  com as variáveis  $x_i$ , dada por (3.3).


$$\hat{y}(\hat{x}) = \frac{\sum_{i=1}^n y_i \exp\left(\frac{-a_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(\frac{-a_i^2}{2\sigma^2}\right)} \quad (3.2)$$

$$a_i = (\hat{x} - x_i)^T (\hat{x} - x_i) \quad (3.3)$$

A função de transferência da GRNN é uma função gaussiana dada por (3.4). O parâmetro  $\sigma$ , denominado *spread*, define a abertura desta função. A função de transferência utilizada pelo *toolbox* de RNAs do MATLAB é uma função do tipo gaussiana (*radbas*) dada por (3.5), ilustrada pela Figura 3.2.

$$f(a_i) = \exp\left(\frac{-a_i^2}{2\sigma^2}\right) \quad (3.4)$$

$$f(a_i) = \exp\left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right) \quad (3.5)$$



**Figura 3.2** - Função *radbas* para diferentes valores do parâmetro *spread*.


O valor do parâmetro *spread* define a área de vizinhança e conseqüentemente o número de padrões a serem levados em consideração para a estimação de uma variável. Quanto maior for este valor, maior será a área de vizinhança, e mais padrões serão levados em consideração. Quanto menor for este valor, menor será a área de vizinhança e menos padrões serão levados em consideração.

### 3.2.2 Arquitetura

A GRNN possui uma estrutura fixa, disposta em quatro camadas, uma de entrada, duas intermediárias e uma de saída, conforme Figura 3.3.

O número de neurônios de cada camada depende exclusivamente do número de entradas, saídas e de amostras do conjunto de dados de treinamento.

O padrão de entrada da rede é representado por um vetor coluna  $\hat{X}$ ,  $ne$ -dimensional e o padrão de saída é representado por um vetor coluna  $\hat{Y}$ ,  $ns$ -dimensional. O conjunto de dados de treinamento é representado por duas matrizes, uma matriz  $X_{ne \times n}$  contendo os padrões de entrada e outra matriz  $Y_{ns \times n}$  contendo os padrões de saída. O número  $n$  de colunas de cada matriz representa a quantidade de amostras do conjunto de dados de treinamento.



**Figura 3.3** - Arquitetura da GRNN.

A camada de entrada da GRNN é composta por  $ne$  neurônios. A primeira intermediária é composta por  $n$  neurônios. A segunda intermediária é composta por  $ns$  neurônios do tipo numerador e um neurônio do tipo denominador. A de saída é composta por  $ns$  neurônios de saída.

O algoritmo de treinamento e o algoritmo de diagnóstico/previsão da GRNN podem ser dados pelas seguintes etapas:

**Treinamento:**

1. Leitura das matrizes  $X$  e  $Y$  e do parâmetro *spread*.

**Diagnóstico/Previsão:**

1. Leitura do padrão desconhecido  $\hat{X}$ ;
2. Cálculo das distâncias euclidianas,  $a_i$  dadas por (3.6);
3. Cálculo dos níveis de pertinência,  $b_i$  dados por (3.7);
4. Cálculo das saídas dos neurônios do tipo numerador,  $c_j$  dadas por (3.8), e da saída do neurônio do tipo denominador,  $d$  dada por (3.9);
5. Cálculo das saídas estimadas,  $\hat{y}_j$  dadas por (3.10);
6. A saída  $\hat{Y}$  é dada por (3.11).

$$a_i = (\hat{X} - X_i)^T (\hat{X} - X_i), i = 1, \dots, n \quad (3.6)$$

$$b_i = \exp\left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right), i = 1, \dots, n \quad (3.7)$$



$$c_j = \sum_{i=1}^n y_{j,i} b_i, j = 1, \dots, ns \quad (3.8)$$

$$d = \sum_{i=1}^n b_i \quad (3.9)$$

$$\hat{y}_j = \frac{c_j}{d}, j = 1, \dots, ns \quad (3.10)$$

$$\hat{Y} = [\hat{y}_1 \cdots \hat{y}_j \cdots \hat{y}_{ns}]^T \quad (3.11)$$

### 3.2.3 Aplicação 1

Para entender o funcionamento da GRNN será realizada a aproximação de um ponto da função não linear (3.12). A entrada da rede neural é o valor de  $x$  e a saída é a estimativa de  $y$ .

$$y(x) = 0,1x + 0,2x^2 - 0,15x^3 \quad (3.12)$$

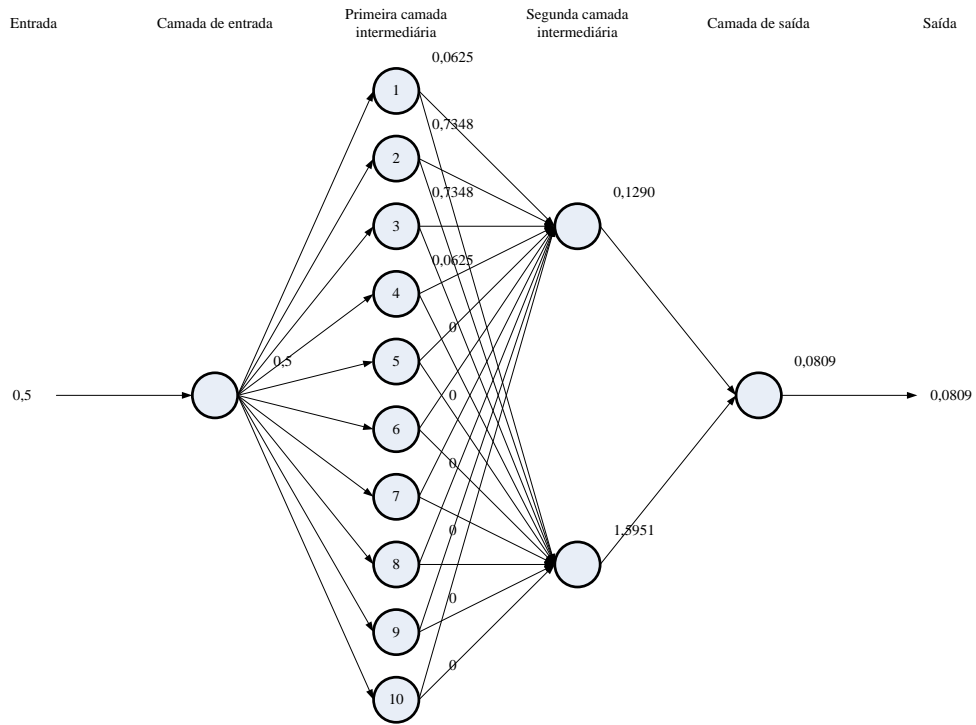
Para isto, a rede será treinada com 10 amostras de  $x$  e  $y$ , dados pela Tabela 3.I e parâmetro *spread*  $\sigma = 0,1$ .

**Tabela 3.I - Conjunto de dados de treinamento da aplicação 1.**

Amostra $i$	1	2	3	4	5	6	7	8	9	10
$x(i)$	0,2000	0,4000	0,6000	0,8000	1,0000	1,2000	1,4000	1,6000	1,8000	2,0000
$y(i)$	0,0268	0,0624	0,0996	0,1312	0,1500	0,1488	0,1204	0,0576	-0,0468	-0,2000

O ponto que se deseja aproximar é o ponto  $y = 0,0813$  dado por  $x = 0,5$ . As saídas de cada camada, produzida pela entrada  $x = 0,5$  podem ser vistas na Figura 3.4.

A saída da rede foi  $\hat{y} = 0,0809$  e o erro obtido foi de 0,4765%. A Figura 3.5 ilustra a curva dada pelos valores de  $x$  e  $y$  ilustrados pela Tabela 3.I, assim como a aproximação do valor de  $y$  dado  $x = 0,5$ .



$$a_i = (\hat{X} - X_i)^T (\hat{X} - X_i)$$

$$b_i = \exp\left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right)$$


$$i = 1, \dots, 10$$

$$c_1 = \sum_{i=1}^{10} y_{1,i} b_i$$

$$d = \sum_{i=1}^{10} b_i$$

$$\hat{y}_1 = \frac{c_1}{d}$$

**Figura 3.4 -** Saídas das camadas da GRNN para a aplicação 1.



**Figura 3.5 -** Curva real dada pelos pontos da Tabela 3.I (azul) e ponto aproximado pela GRNN (vermelho).

### 3.3 Rede Neural de Regressão Generalizada Modificada (GRNN-M)

O tempo de diagnóstico/previsão da GRNN é proporcional ao número de amostras do conjunto de dados de treinamento e do número de entradas da rede. Quanto mais amostras e/ou maior o número de entradas, maior será este tempo. O número de neurônios da primeira camada intermediária e o número de conexões entre esta e a segunda depende do número de amostras do conjunto de dados de treinamento, quanto mais neurônios e conexões, mais cálculos serão realizados na fase de diagnóstico/previsão e conseqüentemente maior será o tempo gasto nesta fase.

Uma forma de diminuir este tempo é reduzindo o número de neurônios da primeira camada intermediária, isto pode ser feito agrupando-se as amostras do conjunto de dados de treinamento por meio de técnicas de agrupamento, e.g. *k-means* (SPECHT, 1991) ou por meio de RNAs e.g. redes da família ART (YAP et al., 2006), porém o tempo de treinamento será maior que o convencional.


Outra forma de diminuir o tempo na fase de diagnóstico/previsão é a redução do número de conexões da primeira com a segunda camada intermediária. Deste modo é possível reduzir o número de cálculos, sem diminuir o número de neurônios da primeira camada intermediária e sem afetar o tempo de treinamento. Para isto foi desenvolvida uma GRNN modificada que utiliza um número reduzido de conexões entre a primeira e a segunda camada intermediária. Este número é fixado pelo usuário e independe do número de amostras do conjunto de dados de treinamento.

#### 3.3.1 Arquitetura

A arquitetura desta rede, ilustrada pela Figura 3.6, é basicamente a mesma que a da rede proposta por Spechth em 1991, com a diferença de um processo de redução de conexões entre a primeira camada intermediária e a segunda camada intermediária.

O padrão de entrada da rede é representado por um vetor coluna  $\hat{X}$ ,  $ne$ -dimensional e o padrão de saída é representado por um vetor coluna  $\hat{Y}$ ,  $ns$ -dimensional. O conjunto de dados de treinamento será representado por duas matrizes, uma matriz  $X_{ne \times n}$  contendo os padrões de entrada e outra matriz  $Y_{ns \times n}$  contendo os padrões de saída. O número  $n$  de colunas de cada

matriz representa a quantidade de padrões de entradas e saídas pertencentes ao conjunto de dados de treinamento.



**Figura 3.6** - Arquitetura da GRNN modificada.

O processo de redução funciona da seguinte maneira, as distâncias euclidianas  $a_i$ , são calculadas de acordo com (3.6). Feito isto são selecionadas as  $nmáx$  menores distâncias euclidianas e o valor do nível de pertinência  $b_i$ , passa a ser dado por (3.13).

$$b_i = \begin{cases} \exp\left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right), & i \in K; \\ 0, & i \notin K; \end{cases} \quad (3.13)$$

Sendo:  $K$  o conjunto que contém os índices das  $nmáx$  menores distâncias euclidianas.

Níveis de pertinência  $b_i$  iguais a zero, não possuem conexões ativas com a segunda camada intermediária, sendo assim o número de conexões entre as camadas intermediárias, que antes era de (3.14), passa a ser igual a (3.15), limitado por  $nmáx$ :

$$\text{Número de conexões entre as camadas intermediárias} = n \times (ns + 1) \quad (3.14)$$

$$\text{Número de conexões, reduzido, entre as camadas intermediárias} = nmáx \times (ns + 1) \quad (3.15)$$

As saídas dos neurônios do tipo numerador,  $c_j$  passam a ser dadas por (3.16), e a saída do neurônio do tipo denominador,  $d$  passa a ser dada por (3.17);

$$c_j = \sum_{i \in K} y_{j,i} b_i, j = 1, \dots, ns \quad (3.16)$$


$$d = \sum_{i \in K} b_i \quad (3.17)$$

### 3.3.2 Aplicação 2

Para entender o funcionamento da GRNN modificada será realizada a mesma aplicação da seção 3.2.3, com  $nmáx = 2$  e  $\sigma = 0,1$ .

As saídas de cada camada, produzidas pela entrada  $x = 0,5$  podem ser vistas na Figura 3.7, onde somente as conexões dos neurônios 2 e 3, da primeira camada intermediária, com os neurônios numeradores e denominadores, da segunda camada intermediária, foram mantidas, com isso teve-se uma redução de 20 conexões para 4 conexões, sem que o resultado fosse prejudicado.

A saída da rede, foi  $\hat{y} = 0,0810$  e o erro obtido foi de 0,3077%. A Figura 3.8 ilustra a curva dada pelos valores de  $x$  e  $y$  ilustrados pela Tabela 3.I, assim como a aproximação do valor de  $y$  dado  $x = 0,5$ .



$$a_i = (\hat{X} - X_i)^T (\hat{X} - X_i)$$


$$b_i = \begin{cases} \exp\left(\frac{-0.8326^2 a_i^2}{\sigma^2}\right) & i \in K \\ 0, & i \notin K \\ K = \{2,3\} \end{cases}$$

$$c_1 = \sum_{i=2,3} y_{1,i} b_i$$

$$d = \sum_{i=2,3} b_i$$

$$\hat{y}_1 = \frac{c_1}{d}$$

**Figura 3.7** - Saídas das camadas da GRNN modificada para a aplicação 2.



**Figura 3.8** - Curva real dada pelos pontos da tabela 3.I (azul) e ponto aproximado pela GRNN modificada (vermelho).

### 3.4 Processo de validação para determinação do parâmetro *spread* da GRNN

A determinação do valor do parâmetro *spread* das GRNNs, convencionais e modificadas, é realizada por meio do processo de validação.

O processo de validação para determinação do parâmetro *spread* de uma GRNN consiste em uma rotina de diagnósticos/previsões onde se varia o valor do parâmetro *spread*. No caso da previsão de cargas, é importante observar sempre o valor do *MAPE* (*Mean Absolute Percentage Error*), que corresponde à média aritmética dos erros percentuais absolutos, e o valor do erro percentual máximo obtido (*EMAX*). O parâmetro selecionado é aquele que fornece o menor *EMAX* com o menor *MAPE* possível. O algoritmo do processo de validação para a determinação do parâmetro *spread* é descrito por seis etapas:

#### Processo de validação para determinação do parâmetro *spread* da GRNN:

1. Cria-se um vetor contendo diferentes valores para o parâmetro *spread*.
2. Inicializam-se duas variáveis *MAPE\_MIN* e *EMAX\_MIN* com valores grandes, e.g. 100.
3. Treina-se a rede com um valor de *spread*.
4. Realiza-se o diagnóstico/previsão, o *MAPE* e o *EMAX* são calculados.
5. Se o *MAPE* for menor que o *MAPE\_MIN* e se o *EMAX* for menor que *EMAX\_MIN*, faz-se *MAPE\_MIN=MAPE* e *EMAX\_MIN=EMAX* e guarda-se o valor do parâmetro *spread* na variável *spread\_MIN*.
6. Repetem-se as etapas 3-5 até que todos os parâmetros *spread* criados sejam testados.

O parâmetro *spread* que será utilizado na fase de testes é dado pelo último valor armazenado na variável *spread\_MIN*.

### 3.5 Procedimento para redução do número de entradas da GRNN

A proposta deste procedimento é determinar uma configuração de entrada que seja capaz de produzir bons resultados, utilizando-se de menos variáveis de entrada.

Em geral, muitas entradas são capazes de produzir respostas específicas, enquanto que poucas entradas produzem respostas vagas. Dependendo da aplicação não é desejável respostas nem muito vagas e nem muito específicas, portanto, deve-se encontrar o número de

entradas da rede que seja ideal para a aplicação. Vale ressaltar que encontrar o número de entradas ideal é na verdade selecionar aquelas que são mais relevantes. Reduzindo-se este número, também se evitam o uso de entradas redundantes e de informações que possam confundir a rede.

No caso da previsão de cargas não é diferente, onde se espera que a RNA seja capaz de aprender o comportamento da carga com boa capacidade de generalização e diferenciação.

Para isto será proposto um procedimento capaz de determinar quais entradas são as mais relevantes para a rede.

Tal procedimento é aplicável em RNAs que possuam um tempo de treinamento e diagnóstico/previsão muito pequeno, e.g. as GRNNs, pois se trata de realizar diagnósticos/previsões para uma rede treinada várias vezes, cada vez com um número diferente de entradas.

O número de possibilidades  $p$  varia de acordo com o número de entradas  $ne$  da rede e é dado por (3.18).

$$p = 2^{ne} \quad (3.18)$$

Para aplicações práticas, onde o número de entradas é elevado, testar todas as possibilidades pode demandar muito tempo, o que o torna inviável. O procedimento proposto utiliza um número reduzido de possibilidades e os testes são realizados com os bancos de dados de treinamento e validação.

Para entender o procedimento proposto, será descrito uma aplicação para uma GRNN com número inicial de entradas igual a 10. Deseja-se que as entradas um e sete sejam mantidas e um número mínimo de seis entradas.

Neste caso, o número total de possibilidades é 1024, desconsiderando que as entradas um e sete devem ser mantidas e que se deve ter no mínimo seis entradas. A priori será testado o caso onde todas as entradas são consideradas e 63 possibilidades escolhidas aleatoriamente dentre as 1023 restantes.

Cria-se inicialmente uma matriz  $W$  de zeros e uns, dada por (3.19), contemplando todas as possibilidades. Cada coluna de  $W$  indica uma configuração de entrada diferente. As linhas com uns representam as entradas ativas e as linhas com zeros representam as entradas inativas, e.g. o vetor coluna  $W_k$ , dado por (3.20), indica que as entradas um, quatro, cinco, seis, sete e oito estão ativas e as entradas dois, três, nove e 10 estão inativas.



$$W = \begin{bmatrix} 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 1 & \dots & 0 & 0 \\ 1 & 1 & 0 & \dots & 0 & 0 \\ 1 & 0 & 1 & \dots & 1 & 0 \end{bmatrix} \quad (3.19)$$

$$W_k = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 0 \\ 0 \end{bmatrix} \quad (3.20)$$

O algoritmo de tal procedimento pode ser descrito pelas seguintes etapas:

**Procedimento para redução do número de entradas da GRNN:**

1. Cria-se uma matriz  $W$ , conforme (3.19), contemplando todas as 1024 possibilidades;
2. Inicializam-se as variáveis  $MAPE'$  e  $EMAX'$  com valores grandes, e.g. 100 e  $k = 1, K = 1$ ;
3. Cria-se uma matriz  $W'$  contendo a primeira coluna de  $W$  e mais 63 colunas escolhidas aleatoriamente;
4. Seleciona-se a coluna  $k$  da matriz de  $W'$  e verifica se as linhas um e sete são iguais a um e que a soma de todas as linhas é maior ou igual a seis;
5. Se sim, passe para a próxima etapa, caso contrário faça  $k = k + 1$  e volte para a etapa 4;
6. Realiza-se um processo de leitura das linhas da coluna  $k$  de  $W'$  e ativam-se somente as entradas dos bancos de dados de treinamento e validação correspondentes às linhas iguais a um. Ou seja, multiplica-se por 0 todas as linhas das matrizes de entrada de treinamento e validação correspondentes às linhas da coluna  $k$  de  $W'$  iguais a zero;
7. Treina-se a GRNN;
8. Inicia-se o processo de validação descrito em 3.4;
9. Armazenam-se o  $MAPE\_MIN$ , o  $EMAX\_MIN$  e o  $spread\_MIN$  da topologia selecionada em 3.4;
10. Se o  $MAPE\_MIN$  for menor que o  $MAPE'$  e se o  $EMAX\_MIN$  for menor que  $EMAX'$ , faz-se  $MAPE' = MAPE\_MIN, EMAX' = EMAX\_MIN, spread' = spread\_MIN$  e  $K = k$ ;
11.  $k = k + 1$ ;
12. Repetem-se as etapas 4-11 até  $k = 64$ .

A configuração de entrada vencedora é dada pela coluna  $K$  da matriz de  $W'$ . Esta configuração é a que será utilizada na fase de testes.

### 3.6 Conclusões

Neste capítulo, foram apresentadas as arquiteturas da GRNN convencional e modificada, o processo para determinação do parâmetro *spread* e o procedimento para redução do número de entradas de uma GRNN.

A GRNN convencional é treinada em apenas uma apresentação dos padrões de treinamento, apresentando um tempo de treinamento muito baixo. Além disso, esta rede é capaz de aproximar funções não-lineares e realizar a previsão de séries temporais com bastante precisão e rapidez. Por ser baseada em uma função densidade de probabilidade as chances de se cair em mínimos locais é muito baixa.

A GRNN modificada, proposta neste trabalho, possui as mesmas características da GRNN convencional, com a diferença de ter um número limitado de conexões entre a primeira e a segunda camada intermediária. Isto faz com que a estimação de uma variável dependente seja dada apenas com os padrões de treinamento mais relevantes, ou seja, àqueles cuja variável independente possua a menor distância euclidiana com os padrões de treinamento. Por meio desta modificação é possível obter resultados de qualidade em um menor tempo de processamento, para isto é necessário estabelecer o número máximo de conexões, definido pelo parâmetro  $nmáx$ . O valor deste parâmetro pode ser obtido realizando-se testes com o banco de dados de validação, por meio de um processo parecido com o proposto para determinação do parâmetro *spread*. Por meio de testes observou-se que, para as GRNNs modificadas treinadas com mais de 500 padrões o número máximo de padrões a serem levados em consideração, para que não haja perda na qualidade dos resultados, foi de 50 padrões.

O ajuste do parâmetro *spread* destas redes se faz necessário para que as RNAs sejam capazes de fornecer resultados com uma maior precisão.

O procedimento de redução de entradas da GRNN tem como objetivo a determinação de uma configuração de entrada que seja capaz de produzir resultados parecidos ou até melhores, utilizando-se menos variáveis de entrada. Para um determinado problema, pode ser necessário que algumas variáveis de entrada e um número mínimo de entradas sejam mantidos, para que a RNA não perca sua capacidade de generalização. A determinação destas variáveis e o número mínimo de entradas dependem muito do problema a ser resolvido, para isso, estudos podem ser feitos com o banco de dados de treinamento e testes podem ser realizados com o banco de dados de validação.

## 4 METODOLOGIA

### 4.1 Introdução

Para realizar a previsão de carga multinodal, são propostos seis sistemas previsores que se diferem pelo modo como as cargas locais são previstas e pelas RNAs utilizadas. O primeiro modo, sistema predictor do tipo PCL, realiza as previsões de cargas locais de forma individual, como ilustrado na Figura 4.1. O segundo modo, sistema predictor do tipo PCL-FPCG, realiza as previsões de cargas locais ( $CL$ ) por meio da previsão de carga global ( $CG$ ), dado por (4.1) e das previsões dos fatores de participação de carga global ( $FPCG$ ), dados por (4.2), como ilustrado na Figura 4.2.

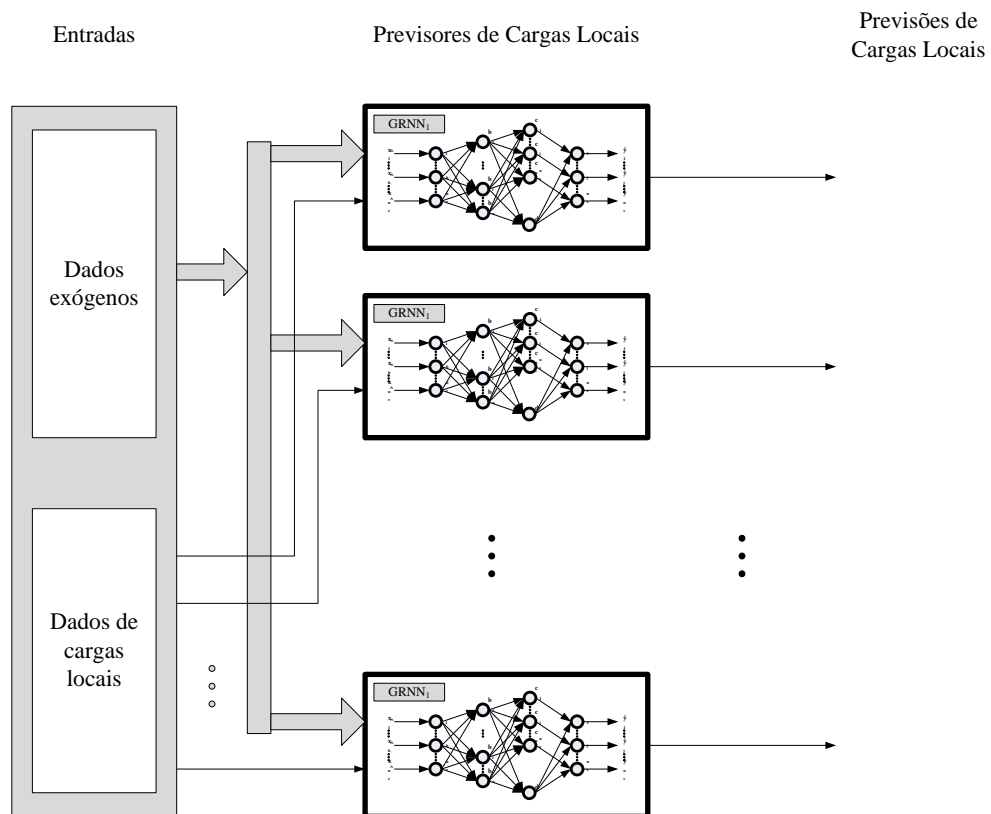


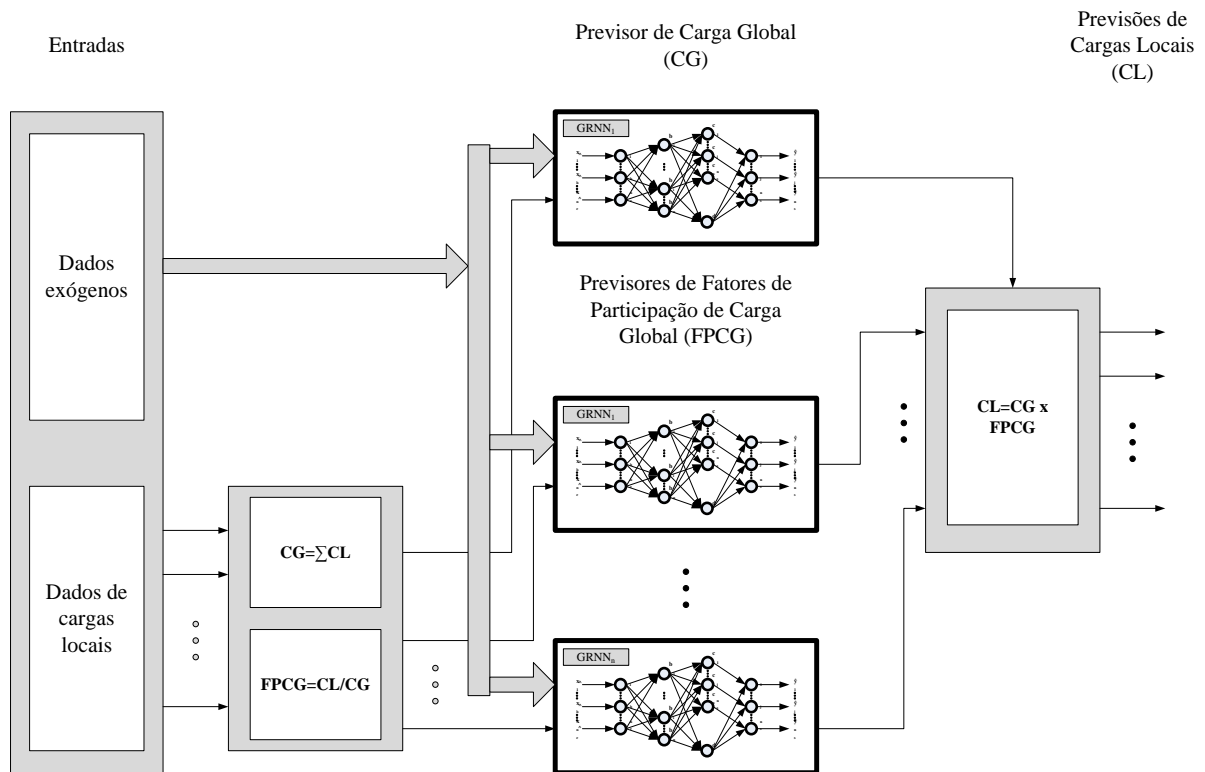
Figura 4.1 - Sistema predictor de carga multinodal do tipo PCL.

$$CG = \sum_{i=1}^n CL_i \quad (4.1)$$

$$FPCG_i = \frac{CL_i}{\sum_{i=1}^n CL_i} \quad (4.2)$$

Sendo:

$n$  – número de barramentos ou cargas locais do sistema.



**Figura 4.2** - Sistema preditor de carga multinodal do tipo PCL-FPCG.

As previsões se dão por RNAs. Como preditores foram utilizados as GRNNs convencionais (preditores do tipo GRNN), GRNNs modificadas (preditores do tipo GRNN-M) e GRNNs modificadas com número de entradas reduzido por meio do procedimento descrito em 3.5 (preditores do tipo GRNN-MR).

Portanto, cada sistema preditor varia conforme o modo, PCL ou PCL-FPCG e o tipo dos preditores utilizados, GRNN, GRNN-M ou GRNN-MR. Os sistemas foram nomeados de acordo com o modo e o preditor utilizado, conforme a Tabela 4.I.

Tais sistemas serão aplicados para realizar a previsão de carga multinodal de um subsistema de distribuição da Nova Zelândia composto por nove subestações de energia elétrica. Todos os dados foram cedidos pelo *Electricity Commission* da Nova Zelândia.

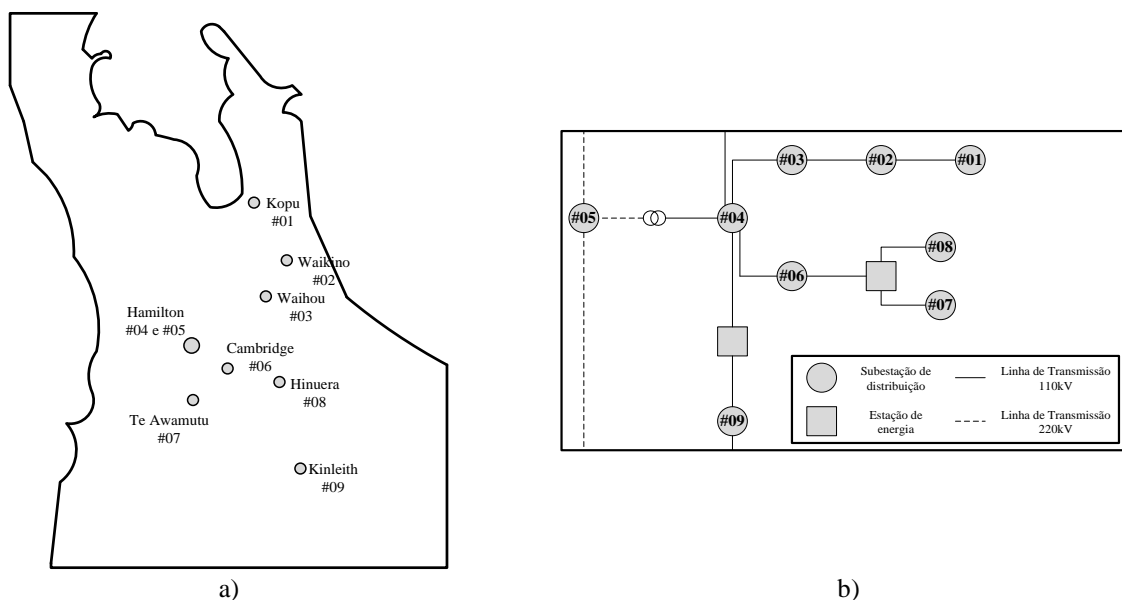
As especificações dos transformadores, que compõem cada uma das nove subestações, podem ser vistas pela Tabela 4.II. A localização geográfica e o diagrama elétrico podem ser conferidos pelas Figura 4.3 a) e b).

**Tabela 4.I** – Nomenclatura dos sistemas previsoers.

Modo	Previsores do tipo		
	GRNN	GRNN-M	GRNN-MR
PCL	PCL GRNN	PCL GRNN-M	PCL GRNN-MR
PCL-FPCG	PCL-FPCG GRNN	PCL-FPCG GRNN-M	PCL-FPCG GRNN-MR

**Tabela 4.II** - Especificações dos transformadores de cada subestação.

Subestação	Tensão (kV)	Potência (MVA)
#01 Kopu	2 x 110/66	2 x 45
#02 Waikino	2 x 110/33	2 x 30
#03 Waihou	3 x 110/33	3 x 20
#04 Hamilton 1	2 x 110/11	2 x 40
#05 Hamilton 2	2 x 220/33	2 x 100
#06 Cambridge	2 x 110/11	2 x 38
#07 Te Awamutu	2 x 110/11	2 x 40
#08 Hinuera	2 x 110/33	1 x 30 + 1 x 50
#09 Kinleith	1 x 110/33	1 x 30
Total	2 x 220/33 + 2 x 110/66 + 8 x 110/33 + 6 x 110/11	756



**Figura 4.3** - a) Localização geográfica das subestações, b) diagrama elétrico.

O banco de dados contém os valores de potência ativa, medidos de meia em meia hora de cada subestação, além de indicadores de dia do mês, mês, ano, dia da semana, feriado, horário de verão e valor da amostra da carga de janeiro de 2007 a março de 2009. O mesmo foi dividido em três partes: treinamento, validação e teste, conforme a Tabela 4.III. O banco de

dados de treinamento contém os padrões que serão utilizados para treinar as RNAs, o de validação contém os padrões que serão utilizados para determinar o parâmetro *spread* e no caso dos previsores do tipo GRNN-MR realizar a redução do número de entradas das RNAs, já o de teste será utilizado para avaliar os resultados obtidos por cada sistema predictor.

**Tabela 4.III - Divisão do banco de dados.**

Período (dd-mm-aaaa)	Banco de dados
01-01-2007 a 31-12-2008.	Treinamento
01-01-2009 a 07-01-2009.	Validação
08-01-2009 a 14-01-2009, 26-01-2009 e 06-02-2009	Teste

Para definir as entradas das RNAs, foram realizados seis estudos com a carga global, detalhados na seção 4.2.

Com o intuito de diminuir ruídos, recuperar dados faltantes e substituir anormalidades do banco de dados de treinamento foi realizado um pré-processamento das cargas locais, detalhado na seção 4.3, por meio de um filtro desenvolvido a partir de uma GRNN e de um filtro de média móvel.

## 4.2 Estudos para elaboração das entradas das RNAs

Com o intuito de elaborar um modelo de predictor de carga, de curto prazo, genérico, capaz de realizar previsões de carga global, cargas locais e fatores de participação de carga global, foram realizados seis estudos com o banco de dados de treinamento, levando em consideração somente a carga global. Estes estudos ajudaram a definir as entradas da rede, que são compostas de dados exógenos e valores de cargas passadas.

Deste modo, espera-se obter previsões de cargas locais sem a necessidade do estudo detalhado das mesmas, ganhando-se tempo e reduzindo a complexidade do problema da previsão de carga multinodal.

O banco de dados contém os valores de potência ativa, medidos de meia em meia hora de cada subestação, além de indicadores de dia do mês, mês, ano, dia da semana, feriado, horário de verão e valor da amostra da carga. Não se tem informações a respeito do tipo de carga, se é predominantemente residencial, comercial ou industrial. Os dados climáticos não foram disponibilizados.


Assim como no Brasil, a Nova Zelândia adotou o horário de verão, internacionalmente conhecido como *daylight saving time* (DST). Esta medida foi adotada por muitos países para economizar energia elétrica, principalmente nos horários de pico. Estima-se que no Brasil, ocorre uma redução em torno de 4 a 5 % da demanda no horário de pico, nos dias participantes deste horário. Devido ao horário de verão, cada ano apresenta um dia com 23 e outro com 25 horas. Antes de iniciar os estudos, será incluída uma hora nos dias com 23 horas e excluída uma hora dos dias com 25 horas, deixando assim todos os dias com 24 horas.

Por meio dos dados dos anos de 2007 e 2008, de carga global, foi possível realizar seis estudos.

- Estudo 1 – Comportamento da carga global durante os meses dos anos de 2007 e 2008.
- Estudo 2 – Comportamento da curva de carga média dos dias da semana dos anos de 2007 e 2008.
- Estudo 3 – Influência do horário de verão sobre as cargas.
- Estudo 4 – Influência de feriados e dias atípicos sobre as cargas.
- Estudo 5 – Periodicidade e frequência das cargas.
- Estudo 6 – Influência de cargas passadas sobre a carga.

O estudo 1 foi realizado com o objetivo de verificar o comportamento da carga global durante os meses dos anos de 2007 e 2008, neste sentido montou-se o gráfico da Figura 4.4 que contém as curvas de carga diária destes anos. Por meio deste estudo observou-se que o comportamento das cargas dos meses de 2007 com as cargas dos meses de 2008 foram muito parecidos. Portanto, para a previsão de um determinado período do ano de 2009, é muito importante inserir no treinamento o período correspondente dos anos de 2007 e 2008, pois as cargas deverão ser muito parecidas, ou pelo menos possuir as mesmas características, e.g. para prever o mês de janeiro de 2009 é importante que as RNAs sejam treinadas com, pelo menos, os dados de janeiro de 2007 e 2008. Também, pôde-se perceber que não houve crescimento de carga para o ano de 2008, sendo assim, espera-se para o ano de 2009, pouco ou nenhum crescimento de carga.

Por meio deste estudo, elaborou-se a primeira variável de entrada, dada por  $I_1$ , conforme (4.3), que indica os meses das cargas a serem previstas.




**Figura 4.4-** Comportamento da carga global dos anos de 2007 e 2008.

$$I_1 = \frac{m}{12}, m = \text{mês} = 1, \dots, 12. \quad (4.3)$$

Do estudo 2 conforme as curvas de carga média dos dias da semana dos anos de 2007 e 2008, ilustradas na Figura 4.5, foi possível observar que as curvas de carga dos dias da semana se diferem. Como o objetivo não é realizar a previsão de cada dia da semana utilizando uma RNA diferente, como em Chen, et al. (1996), e sim projetar uma única RNA que seja capaz de prever todos os dias, criou-se a segunda variável de entrada dada por  $I_2$ , indicando o dia da semana, conforme (4.4). Neste caso, foram diferenciadas as segundas-feiras das terças, quartas, quintas e sextas-feiras e também os sábados e domingos. As segundas-feiras foram diferenciadas dos demais dias úteis da semana pelo fato do comportamento das primeiras horas do dia, serem provenientes do final de semana, sendo assim caracterizado por um consumo de carga inferior a dos demais dias.



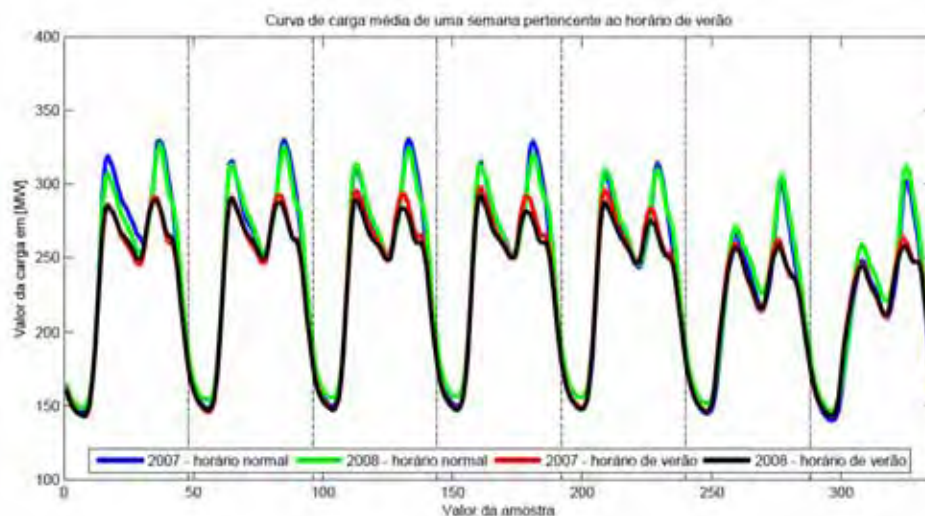


**Figura 4.5** - Curvas de carga média dos dias da semana de 2007 e 2008.

$$I_2 = \begin{cases} [1 \ 0 \ 0 \ 0]^T, & \text{segundas} - \text{feiras} \\ [0 \ 1 \ 0 \ 0]^T, & \text{terças a sextas} - \text{feiras} \\ [0 \ 0 \ 1 \ 0]^T, & \text{sábados} \\ [0 \ 0 \ 0 \ 1]^T, & \text{domingos} \end{cases} \quad (4.4)$$

Do estudo 3 por meio das curvas de carga média dos dias da semana de 2007 e 2008 pertencentes e não pertencentes ao horário de verão, ilustradas pela Figura 4.6, foi possível observar que o horário de verão influencia nas curvas de carga, reduzindo seus valores de pico durante os dias sob o horário de verão. Deste modo, é necessário diferenciar as cargas que estão sob o horário de verão das cargas que estão sob o convencional.

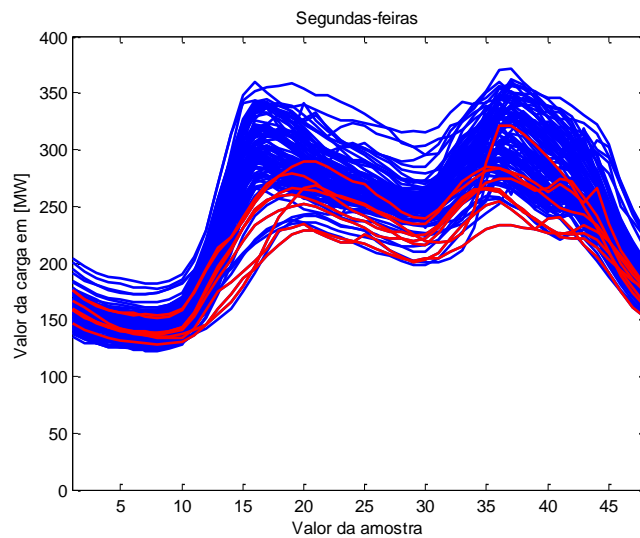
Para isso criou-se uma terceira variável de entrada dada por  $I_3$ , conforme (4.5), que indica se a carga do dia a ser previsto pertence ou não pertence ao horário de verão.




**Figura 4.6** - Curvas de carga média dos dias da semana de 2007 e 2008 pertencentes e não pertencentes ao horário de verão.

$$I_3 = \begin{cases} 1, & \text{pertence} \\ 0, & \text{n\~{a}o pertence} \end{cases} \quad (4.5)$$


Geralmente feriados e dias at\u00edpicos s\u00e3o caracterizados por um consumo diferenciado, que em grande maioria \u00e9 inferior ao consumo de um dia convencional. As curvas de carga dos dias da semana dos anos de 2007 e 2008, ilustradas na Figura 4.7, realizadas no estudo 4, comprova de fato este efeito. Portanto \u00e9 necess\u00e1rio diferenciar as cargas dos dias convencionais com as dos dias at\u00edpicos e feriados. Alguns autores preferem realizar a previs\u00e3o utilizando sistemas distintos, como em Song et al. (2005) onde os autores prop\u00f5em um sistema capaz de prever somente as cargas referentes aos feriados. Outros preferem utilizar o conhecimento pr\u00e9vio para reduzir os erros obtidos na previs\u00e3o de tais dias, como em Topalli et al. (2006). Outros extraem os feriados do banco de dados de treinamento e realizam a previs\u00e3o dos mesmos como sendo um s\u00e1bado ou domingo dependendo da informa\u00e7\u00e3o fornecida por um especialista, que analisou previamente o comportamento destas cargas, como em Aquino et al. (2006). Neste caso, deseja-se projetar uma RNA que seja capaz de prever os dias at\u00edpicos, feriados e os dias convencionais. Para isto criou-se a quarta vari\u00e1vel de entrada dada por  $I_4$ , conforme (4.6), que indica se a carga do dia a ser previsto corresponde a um dia convencional ou a um feriado ou dia at\u00edpico.



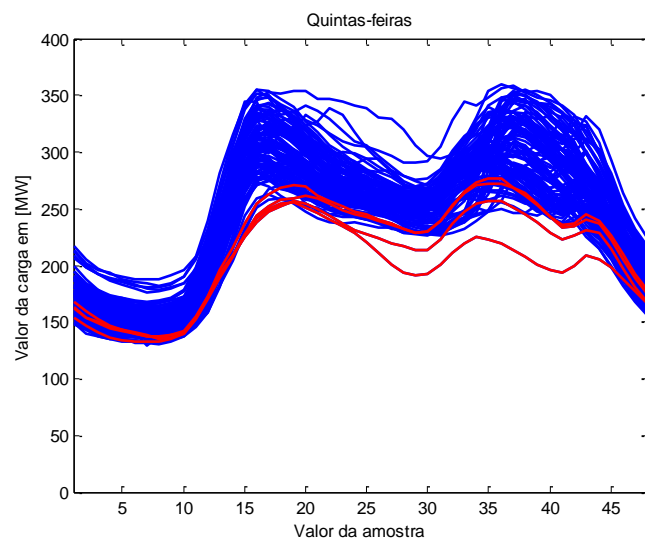
a)



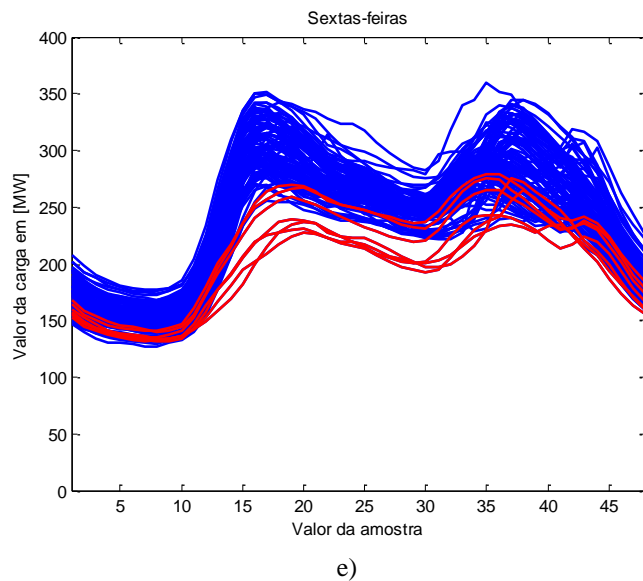
b)



c)




d)

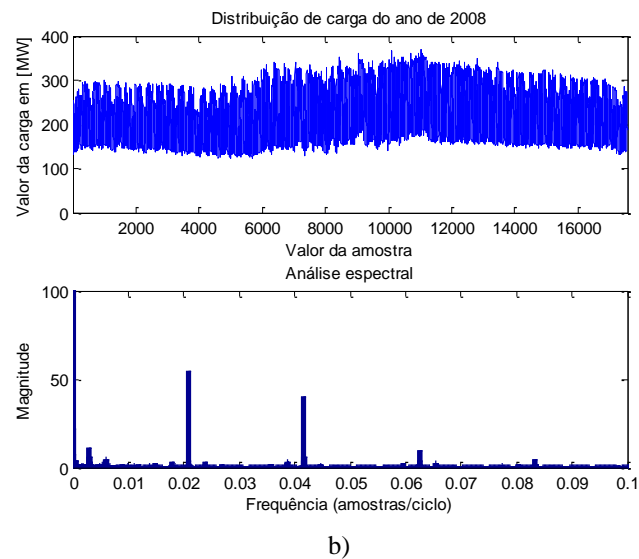


**Figura 4.7** - Curvas de carga dos dias úteis dos anos de 2007 e 2008, dias normais em azul e dias atípicos e feriados em vermelho, a) segundas-feiras, b) terças-feiras, c) quartas-feiras, d) quintas-feiras, e) sextas-feiras.

$$I_4 = \begin{cases} 1, & \text{feriado ou dia atípico} \\ 0, & \text{dia convencional} \end{cases} \quad (4.6)$$


Para verificar a periodicidade e frequência das cargas realizou-se a análise espectral das cargas dos anos de 2007 e 2008 conforme o estudo 5, ilustrado na Figura 4.8. Verificou-se que a carga possui uma periodicidade de 24 e 48 amostras, sendo que a fundamental pertence à frequência com período de 48 amostras, ou seja, a carga possui um comportamento que tende a ser repetido dia após dia. Deste modo optou-se por realizar a previsão de todas as cargas de um determinado dia  $d$ , ao invés de realizar a previsão de uma única carga. A saída do predictor será dada por um vetor contendo 48 elementos que corresponderão às cargas amostradas de meia em meia hora do dia  $d$  a ser previsto.





**Figura 4.8** - Análise espectral das curvas de carga global, a) do ano de 2007, b) do ano de 2008.

Por fim, o estudo 6, verificou a influência das cargas, média, máxima e mínima do dia  $d - 1$ , com as cargas, média, máxima e mínima do dia  $d$  a ser previsto, a correlação entre estas cargas é ilustrada pela Figura 4.9. Por meio deste verificou-se que existe uma forte correlação entre as cargas, média, máxima e mínima do dia  $d - 1$ , com as cargas, média, máxima e mínima do dia  $d$  a ser previsto, deste modo criou-se uma quinta variável de entrada dada por  $I_5$ , conforme (4.7), contendo os valores de cargas médio, máximo e mínimo do dia  $d - 1$ .



**Figura 4.9** - Correlação entre os valores de cargas globais, médios, máximo e mínimos dos dias  $d$  com os dias  $d - 1$ , dos anos de 2007 e 2008.

$$I_5 = \begin{bmatrix} \text{Valor de carga médio do dia } d - 1 \\ \text{Valor de carga máximo do dia } d - 1 \\ \text{Valor de carga mínimo do dia } d - 1 \end{bmatrix} \quad (4.7)$$

Desta forma, o padrão de entrada dos previsores de carga local, carga global e fator de participação de carga global, são definidos por cinco variáveis totalizando dez elementos de entrada e o padrão de saída é dado por 48 elementos de saída, conforme o sistema ilustrado pela Figura 4.10. Sete elementos de entrada correspondem a dados exógenos e três correspondem a cargas passadas. As sete entradas de dados exógenos indicam o mês, dia da semana, horário de verão e feriado, os dados de carga indicam os valores médio, máximo e mínimo da carga do dia anterior. As 48 saídas são referentes as 48 amostras de cargas previstas do dia seguinte. Os valores de cargas mudam de previsor para previsor. Os previsores de cargas locais utilizam como valores de cargas os valores de *CL*. O previsor de carga global utiliza o valor de *CG* e os previsores de fatores de participação de carga global utilizam os valores de *FPCG*.

As cargas locais foram normalizadas, dividindo-se os seus valores pelo da maior carga local do banco de dados de treinamento multiplicado por 1,1. A carga global foi normalizada, dividindo seu valor pelo da maior carga global do banco de dados de treinamento multiplicado por 1,1. Já os fatores de participação de carga global não precisaram ser normalizados, uma vez que seus valores estão entre 0 e 1.

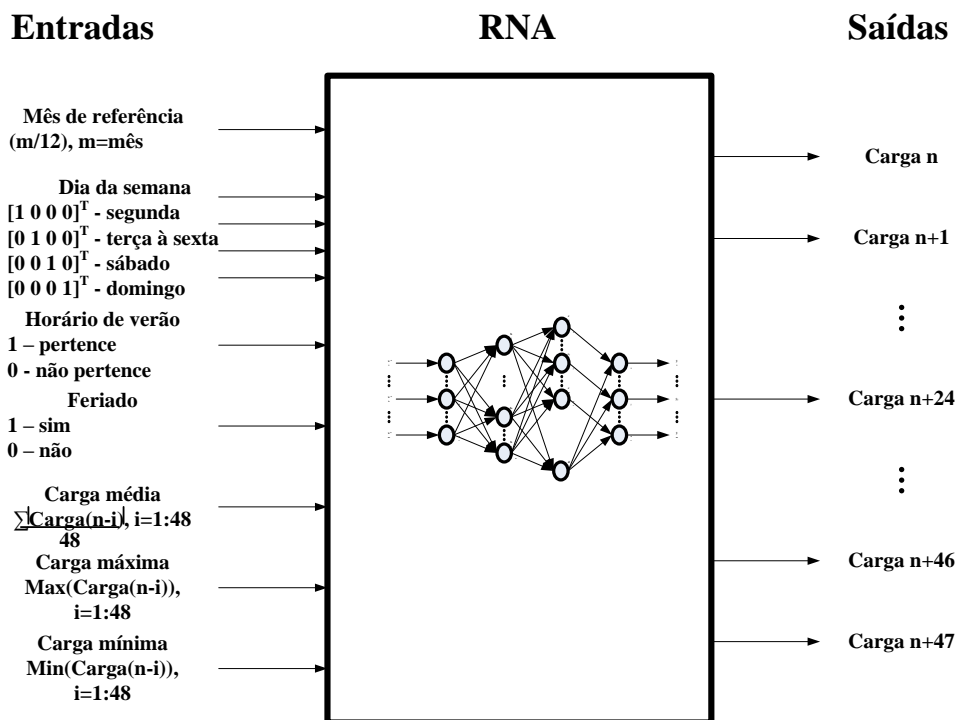


Figura 4.10 - Modelo de predictor de carga local/global/fator de participação de carga global.

### 4.3 Pré-processamento do banco de dados de treinamento

O pré-processamento se faz necessário para diminuir ruídos, recuperar dados faltantes e substituir anormalidades do banco de dados de treinamento, só assim as RNAs serão capazes de fornecer resultados precisos e confiáveis.

Os dados de carga de sistemas de energia elétrica são coletados por meio de sistemas SCADA (*Supervisory Control And Data Acquisition*), que atualmente são dotados de alta tecnologia, capazes de realizar a coleta com bastante precisão e rapidez. Mesmo assim, o manuseio é um processo bastante delicado, onde ruídos e o desaparecimento de dados podem ocorrer em qualquer ponto do sistema. Além disso, eventos especiais podem provocar anomalias no comportamento das cargas, como interrupções inesperadas, manutenções, entre outros. Estes três fatores prejudicam a capacidade de generalização das RNAs, pois o real comportamento das cargas é comprometido (FIDALGO; LOPES, 2005; KIARTZIS et al., 1996).

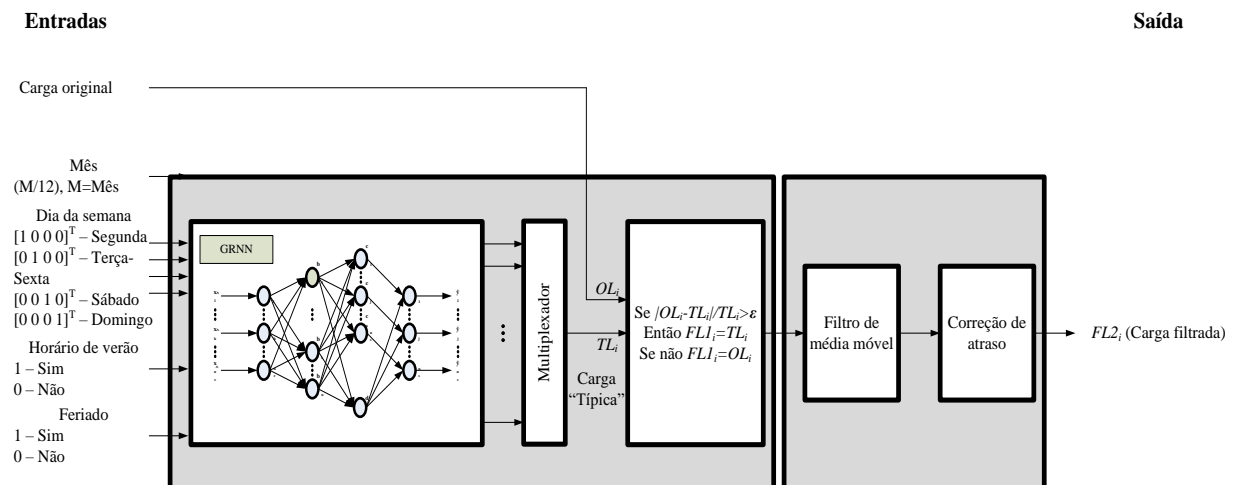
Para lidar com estes três tipos de problemas, foi desenvolvido um filtro, ilustrado pela Figura 4.11, composto de uma GRNN convencional e um filtro de média móvel, capaz de remover ruídos, recuperar dados faltantes e substituir anormalidades.

A GRNN é utilizada para produzir curvas de carga típica, no qual a entrada é composta somente pelos dados exógenos definidos na seção 4.2 e a saída é dada pela curva de carga típica, contendo as 48 amostras. O treinamento desta rede é realizado com o próprio banco de dados de treinamento. A carga típica é então comparada com a original e um erro é produzido. Se o valor absoluto deste erro for maior que um parâmetro pré-estabelecido  $\varepsilon$ , denominado tolerância, a carga original é substituída pelo valor de carga típica. No total, são produzidas pela GRNN 192 curvas de carga típica diferentes, pois os meses são divididos em 12, os dias da semana em quatro, feriados em dois e horário de verão em dois, multiplicando-se cada um destes obtêm-se 192 possibilidades.

O filtro de média móvel é um filtro passa baixa digital, que foi escolhido por ser de fácil programação e possuir apenas um único parâmetro a ser controlado, o valor da janela  $\alpha$ , que define o número de amostras que é utilizado para o cálculo da janela móvel. A média móvel é dada por (4.8), este valor é atrasado do valor original, portanto faz-se uma correção de atraso por meio de (4.9), desde que  $\alpha$  seja um número ímpar.

$$\overline{FL1}_i = \frac{1}{n} \sum_{j=i-\alpha+1}^i FL1_j \quad (4.8)$$

$$FL2_i = \overline{FL1}_{(i+0.5\alpha-0.5)} \quad (4.9)$$



**Figura 4.11** - Filtro proposto, composto de uma GRNN e um filtro de média móvel.

Os parâmetros do filtro proposto são dados pelo *spread* da GRNN, por  $\varepsilon$  e por  $\alpha$ . Os valores escolhidos para o filtro utilizado para o pré-processamento do banco de dados de treinamento podem ser conferidos pela Tabela 4.IV.



O parâmetro *spread* é responsável pela generalização das curvas de cargas típicas. Valores altos produzem cargas mais gerais enquanto que valores baixos produzem cargas mais específicas. É aconselhável o uso de valores médios, para uma boa generalização, neste caso foi utilizado o valor de 0,1.

A tolerância define o quanto se deseja que a carga filtrada se pareça com a carga típica, quanto menor for o seu valor, maiores são as chances de a carga filtrada se parecer com a carga típica, quanto maior for o seu valor, maiores são as chances de a carga filtrada se parecer com a carga original. Foi utilizada uma tolerância de 0,3 ou 30%.

O número de amostras da janela do filtro de média móvel controla a suavização da curva, para que não se percam as formas das curvas de carga, é aconselhável usar janelas pequenas, 3, 5 ou 7. Neste caso foi utilizado um filtro de média móvel com janela de 3 amostras.

**Tabela 4.IV - Parâmetros do filtro.**

Parâmetro	Valor
<i>Spread</i>	0,1
$\varepsilon$	30%
$\alpha$	3

Para melhor descrever o funcionamento deste filtro, será realizada a filtragem das cargas locais dos dias 208 e 209 de 2008, referentes à subestação #01.

Esta filtragem é descrita em 4 passos:

**Processo de filtragem:**

1. Primeiramente, treina-se a GRNN com os dados de carga da subestação #01 do ano de 2008, os parâmetros do filtro são: *spread*=0,1, tolerância=30% e janela de 3 amostras;
2. A GRNN produz as curvas de cargas típicas para os dias 208 e 209, ilustradas pela Figura 4.12;
3. Estas cargas são comparadas com a original, ilustrada pela Figura 4.12 e um erro absoluto é produzido, se este erro for maior que a tolerância, ilustrados pela Figura 4.13 então as cargas correspondentes assumem os valores das cargas típicas.
4. A saída do filtro GRNN serve de entrada para o filtro de média móvel, a saída do filtro de média móvel é atrasada e aplica-se um corretor de atraso para a correção, por fim obtêm-se a carga filtrada, ilustradas pela Figura 4.14.

Como pode ser observada através da curva de carga filtrada da Figura 4.14, esta é uma mistura das curvas de carga original e típica, suavizada pelo filtro de média móvel.




Figura 4.12. Curvas de carga, original e típica.

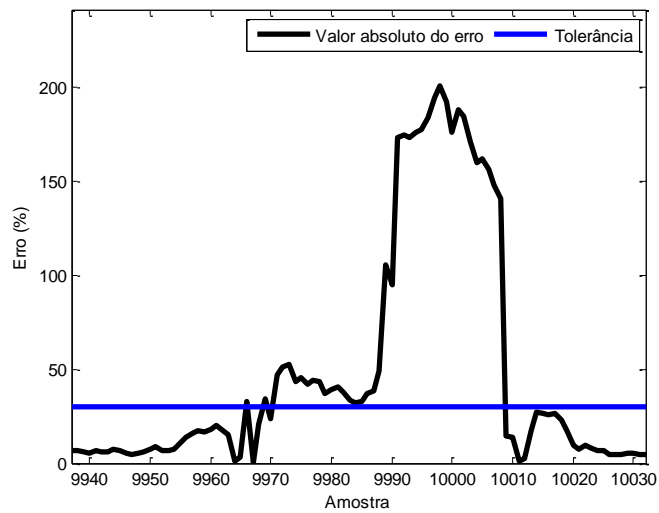


Figura 4.13 - Valor absoluto do erro entre a curva de carga original e típica e a tolerância.

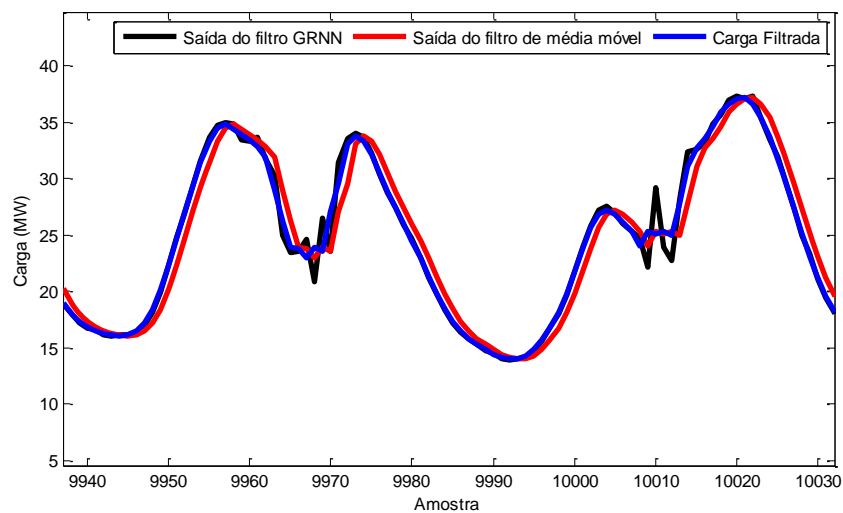


Figura 4.14 - Saídas do filtro GRNN, do filtro de média móvel (atrasada) e a carga filtrada (adiantada).

## 4.4 Conclusões

Por meio dos estudos realizados na seção 4.2 foi possível elaborar o modelo de previsor de carga, de curto prazo, genérico. As entradas de um a sete são referentes aos dados exógenos, que são dados globais, ou seja, iguais para todos os previsores. As entradas de oito a 10 são referentes aos dados de cargas, que são dados locais, ou seja, diferentes para cada previsor. Este modelo pôde ser elaborado a partir de estudos realizados somente com a carga global, sem a necessidade do estudo detalhado das locais, diminuindo-se assim a complexidade do problema a ser resolvido.

Os sistemas do tipo PCL são compostos por nove previsores e cada um realiza a previsão de uma carga local. Os sistemas do tipo PCL-FPCG são compostos por 10 previsores, um de carga global e nove de fator de participação, estes sistemas são uma alternativa para a resolução do problema de previsão de carga multinodal, podendo ou não fornecer resultados de melhor qualidade. Os previsores são dados por GRNNs convencionais, GRNNs modificadas e GRNNs modificadas com número de entradas reduzido.

Os previsores do tipo GRNN convencional, foram programados com o auxílio dos *toolboxes* de RNAs do aplicativo MATLAB, por meio da função *newgrnn*. Já os previsores do tipo GRNN-M e GRNN-MR foram programados em linguagem MATLAB, sem o auxílio dos *toolboxes* de RNAs. Para as GRNNs modificadas foi utilizado  $nmáx = 50$ . Para o procedimento de redução de entradas, foram levados em consideração, uma configuração com todas as entradas ativas e 63 aleatórias, dentre estas, foram testadas somente as que tivessem as entradas um e sete e no mínimo seis entradas ativas.

Para todos os sistemas foram obtidos resultados com o banco de dados de teste, tais resultados são ilustrados no capítulo 5, nas tabelas do apêndice A e nas figuras do apêndice B.

## 5 RESULTADOS

### 5.1 Introdução

Para avaliar os sistemas de previsão de carga multinodal, foram realizadas previsões de cargas locais e global correspondentes ao período dos dias 8 a 14 de janeiro, e dois feriados, correspondentes aos dias 26 de janeiro e 6 de fevereiro de 2009, totalizando nove dias. Para os sistemas do tipo PCL e PCL-FPCG foram obtidos os MAPEs diários, médio e máximo, da previsão das nove cargas locais dos nove dias, e o tempo médio gasto para o treinamento, a validação e a previsão de um dia por um previsor. Para os sistemas do tipo PCL-FPCG foram obtidos os MAPEs diários, médio e máximo, da previsão de carga global dos nove dias, e o tempo médio gasto para o treinamento, a validação e a previsão de um dia por um previsor. O MAPE pode ser obtido por (5.1).

$$MAPE = \frac{1}{Na} \sum_{n=1}^{Na} \frac{100 \cdot |C^{Real}(n) - C^{Previsto}(n)|}{C^{Real}(n)} \quad (5.1)$$

sendo:

$C^{Real}$  - valor de carga real.

$C^{Previsto}$  - valor de carga prevista.

$Na$ - Número de amostras previstas.

As tabelas contendo os MAPEs diários obtidos por cada sistema podem ser vistas no apêndice A. Além disso, neste mesmo apêndice, constam os valores do parâmetro *spread* utilizados em cada previsor, bem como a configuração de entrada dos previsores do tipo GRNN-MR que utilizam um número reduzido de entradas, conforme o procedimento descrito na seção 3.5.

As curvas de carga, locais e global, reais e previstas obtidas pelos sistemas previsores podem ser vistas pelas figuras contidas no apêndice B.

## 5.2 Previsão de cargas locais

### 5.2.1 Resultados

A Tabela 5.I, é referente aos MAPEs diários, médio (Médio) e máximo (Máximo), obtidos com a previsão das nove cargas locais, dos nove dias, para cada sistema predictor. A Tabela 5.II é referente ao tempo médio gasto para o treinamento, a validação e a previsão de um dia por um predictor de carga local/fator de participação.

**Tabela 5.I** - MAPEs diários, médios e máximos, obtidos nas previsões das nove cargas locais.

Dia	Sistema do tipo PCL			Sistema do tipo PCL-FPCG		
	GRNN	GRNN-M	GRNN-MR	GRNN	GRNN-M	GRNN-MR
Médio	4.95	4.99	5.03	5.26	5.06	5.02
Máximo	12.25	12.25	12.30	11.97	11.27	11.26

**Tabela 5.II** - Tempo médio gasto para o treinamento, a validação e a previsão de um dia por um predictor de carga local/fator de participação de carga global.

Tempo médio em (s) gasto para:	Sistema do tipo PCL			Sistema do tipo PCL-FPCG		
	GRNN	GRNN-M	GRNN-MR	GRNN	GRNN-M	GRNN-MR
Treinamento	0.0403	0.0008	0.0010	0.0455	0.0009	0.0016
Validação	0.8695	0.0819	1.3560	0.8841	0.0848	1.3725
Previsão	0.0083	0.0013	0.0013	0.0094	0.0014	0.0014

### 5.2.2 Discussão

Para comparação dos resultados, será utilizado como base, o sistema PCL GRNN.

Os MAPEs obtidos nas previsões das cargas locais do sistema base são compatíveis com os resultados encontrados na literatura especializada. Este sistema é capaz de realizar a previsão de cargas locais de dias convencionais e feriados com a mesma precisão.

Os resultados obtidos pelos sistemas do tipo PCL-FPCG apresentaram maior MAPE médio, porém, menor MAPE máximo, quando comparados com os resultados do sistema base, sendo assim, é possível realizar a previsão da carga local por meio da previsão do fator de participação e da previsão de carga global.

A GRNN-M foi capaz de obter, em menos tempo, resultados tão bons quanto os resultados obtidos com a GRNN. A GRNN-MR foi capaz de fornecer, em alguns casos,

resultados melhores, menor MAPE médio, que o do sistema base (previsores de carga local do sistema PCL GRNN-MR das subestações #02, #06 e #07; e previsores de carga local do sistema PCL-FPCG GRNN-MR das subestações #01, #04, #05, #06 e #09).

## 5.3 Previsão de carga global

### 5.3.1 Resultados

A Tabela 5.III, é referente aos MAPEs diários, médio (Médio) e máximo (Máximo), obtidos na previsão de carga global, dos nove dias. A Tabela 5.IV é referente ao tempo médio gasto para o treinamento, a validação e a previsão de um dia por um predictor.

**Tabela 5.III** - MAPEs diários, médios e máximos, obtidos nas previsões de carga global.

Dia	Previsor de carga global do sistema do tipo PCL-FPCG		
	GRNN	GRNN-M	GRNN-MR
Médio	3.30	2.95	3.00
Máximo	5.33	5.35	5.30

**Tabela 5.IV** - Tempo médio gasto para o treinamento, a validação e a previsão de um dia pelos previsores de cargas globais.

Tempo médio em (s) gasto para:	Previsor de carga global do sistema do tipo PCL-FPCG		
	GRNN	GRNN-M	GRNN-MR
Treinamento	0,0412	0,0047	0,0045
Validação	1,2530	0,0974	0,7855
Previsão	0,0085	0,0014	0,0014

### 5.3.2 Discussão

Para comparação dos resultados, será utilizado como base, o predictor de carga global do sistema PCL GRNN.

Os MAPEs obtidos na previsão de carga global do sistema base são compatíveis com os resultados encontrados na literatura especializada. Este sistema é capaz de realizar a previsão de cargas globais de dias convencionais e feriados com a mesma precisão.

A GRNN-M foi capaz de obter em menos tempo, resultados melhores, menor MAPE médio, que os obtidos com a GRNN.

A GRNN-MR foi capaz de fornecer menor MAPE diário máximo, quando comparado com a GRNN-M e menor MAPE médio, quando comparado com a GRNN. Neste caso foi possível realizar a previsão de carga global utilizando apenas sete variáveis de entrada sendo desnecessário o uso das variáveis de entrada referentes ao horário de verão, ao valor de carga máxima do dia anterior e ao valor de carga mínima do dia anterior, conforme a Tabela A.XVII.

A demanda global foi estimada com maior precisão do que as demandas locais, isto ocorre, pois seu comportamento é definido pela maioria e não pela individualidade de cada local. Deste modo, pôde-se perceber que ao melhorar os resultados obtidos com a previsão de carga global, também houve melhorias nas previsões de cargas locais dos sistemas do tipo PCL-FPCG, conforme os resultados ilustrados na Tabela 5.I e na Tabela 5.III.

## 6 CONCLUSÕES E PROPOSTAS PARA TRABALHOS FUTUROS

### 6.1 Conclusões Gerais

A GRNN é uma rede que vem sendo bastante utilizada na previsão de séries temporais, inclusive na de cargas elétricas. Neste trabalho, procurou-se evidenciar a sua capacidade de generalização para a previsão de carga multinodal de curto prazo. Além disso, foi realizada uma modificação em sua estrutura e proposto um procedimento para a redução do número de entradas da rede. Esta rede se adapta perfeitamente ao problema da previsão de carga multinodal, devido a sua grande capacidade de generalização e ao baixo tempo de treinamento e diagnóstico/previsão.

A GRNN modificada, proposta neste trabalho, possui as mesmas características da GRNN convencional como o treinamento em apenas uma apresentação dos padrões de treinamento e a baixa probabilidade de se cair em mínimos locais, com a vantagem de ser mais rápida.

O procedimento de redução de entradas pode ser aplicado em qualquer tipo de RNA, de preferência aquelas que possuam baixo tempo de treinamento. Este procedimento pode ser utilizado em problemas que envolvam um número elevado de variáveis de entrada, como a previsão de séries temporais e detecção de padrões (*data mining*). Para um determinado problema pode ser necessário que algumas entradas e um número mínimo sejam mantidos. A redução do número de entradas pode melhorar a capacidade de generalização das RNAs, por meio da remoção de entradas que possam estar influenciando negativamente na sua aprendizagem, além de acelerar o tempo de resposta da mesma.

Os estudos realizados no capítulo 4 possibilitaram a modelagem de um previsor de carga, de curto prazo, genérico que pode ser aplicado para a previsão de carga local, global e fator de participação. Deste modo, é possível realizar a previsão de carga local, sem a



necessidade de dados exógenos locais, reduzindo a complexidade do problema, uma vez que não foi necessário o estudo detalhado das cargas locais a serem previstas.

O filtro proposto no capítulo 4 se mostrou bastante eficiente na redução de ruídos e substituição de dados anômalos do banco de dados de treinamento e pode ser utilizado em vários outros tipos de problemas.

Por fim, os sistemas previsores desenvolvidos neste trabalho foram capazes de fornecer resultados compatíveis com os encontrados na literatura, apresentando na maioria das vezes MAPEs diários inferiores a 6% e se destacam pela rapidez com que realizam as previsões.

## **6.2 Propostas para trabalhos futuros**

Para trabalhos futuros, várias propostas podem ser feitas, como:

- Previsão de carga multinodal considerando os barramentos do sistema de energia elétrico brasileiro;
- Previsão de carga multinodal de potência ativa e reativa, por meio da previsão do fator de participação e do fator de potência de cada barramento;
- Previsão de carga multinodal agrupada, com fator de participação constante, entre os barramentos com mesmo perfil de carga;
- Inclusão de variáveis exógenas locais nas entradas dos previsores, e.g. dados climáticos;
- Uso de arquiteturas híbridas baseadas na GRNN e nas redes da família ART;

## REFERÊNCIAS

- ACKLEY, D.H.; HINTON, G.E.; SEJNOWSKY, T. J. A. Learning algorithm for Boltzmann machines. **Cognitive Sciences**, Malden, v. 9, p. 147-169, 1985.
- AL-HAMADI, H. M.; SOLIMAN, S. A. Long-term/mid-term electric load forecasting based on short-term correlation and annual growth. **Electric Power Systems Research**, Lausanne, v. 74, n. 3, p. 353-361, Jun. 2005.
- AL-SHAREEF, A. J.; MOHAMED, E. A.; AL-JUDAIBI, E. Next 24-hours load forecasting using artificial neural network (ANN) for the western area of Saudi Arabia. **Journal of King AbdulAziz University (JKAU): Engineering Science**, Jedahh, v. 19, n. 2, p. 25-40, 2008.
- AMJADY, N. Short-term bus load forecasting of power systems by a new hybrid method. **IEEE Transactions on Power Systems**, New York, v. 22, p. 333-341, n. 1, Feb. 2007.
- AMJADY, N.; KEYNIA, F. Mid-term load forecasting of power systems by a new prediction method. **Energy Conversion and Management**, Oxford, v. 49, n. 10, p. 2678-2687, Oct. 2008.
- AQUINO, R. R. B. et al. A hybrid intelligent system for short and mid-term forecasting for the CELPE distribution utility. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2006, Vancouver, Canada. **Proceedings...** Vancouver: [s.n.], 2006.
- BOX, G. E.; JENKINS, G. M. **Times series analysis: forecasting and control**. San Francisco: Holden-Day, 1976.
- CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network. **Neural Networks**, New York, v. 4, p. 565-588, 1991a.
- CARPENTER, G. A.; GROSSBERG, S.; ROSEN, D. B. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Networks**, New York, v. 4, p. 759-771, 1991b.
- CARPENTER, G. A. et al. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, New York, v. 3, p. 698-713, 1992.

CHEN, C. S.; TZENG, Y. M.; HWANG, J. C. The application of artificial neural networks to substation load forecasting. **Electric Power Systems Research**, Lausanne, v. 38, n. 2, p.153-160, 1996.

DA SILVA, A. P. A. et al. NeuroDem-a neural network based short term demand forecaster. In: **IEEE PowerTech Proceedings**, New York, v. 2, p. 6, 2001.

EKONOMOU, L. Greek long-term energy consumption prediction using artificial neural networks. **Energy**, Oxford, v. 35, p. 512-517, 2008.

FERREIRA, V. H.; DA SILVA, A. P. A. Regularization of short term load forecasting neural networks. **Learning and Nonlinear Models - Revista da Sociedade Brasileira de Redes Neurais (SBRN)**, Rio de Janeiro, v. 1, n. 5, p. 296–304, 2005.

FIDALGO, J. N.; LOPES, J. A. P. Load forecasting performance enhancement when facing anomalous events. **IEEE Transactions on Power Systems**, New York, v. 20, n. 1, p. 408-415, Feb. 2005.

GROSS, G.; GALIANA, F. D. Short-Term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, v. 3, p. 121-134, 1976a.

GROSSBERG, S. Adaptive pattern classification and universal recoding, II: feedback, expectation, olfaction, and illusions, **Biological Cybernetics**, New York, v. 23, n. 4, p. 187-202, 1976b.

GROSSBERG S. Competitive learning: from interactive activation to adaptive resonance. **Cognitive Science**, Malden, v. 11, p. 23-63, 1987.

HANDSCHIN E.; DÖRNEMANN, C. H. Bus load modeling and forecasting. **IEEE Transactions on Power Systems**, New York, v. 3, n. 2, p. 627-633, 1988.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. New Jersey: Prentice-Hall, 2008.

HUANG, M. Y.; CHEN, C. S.; LIN, C. H. Innovative service restoration of distribution systems by considering short-term load forecasting of service zones. **Electrical Power and Energy Systems**, New York, v. 27, p. 417-427, 2005.

JANG, J. S. R. ANFIS: Adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, New York, v. 23, n. 3, p. 665-685, may/Jun. 1993.

KERMANSHAHI, B.; IWAMIYA, H. Up to year 2020 load forecasting using neural nets. **International Journal of Electrical Power & Energy Systems**, Oxford, v. 24, n. 9, p. 789-797, 2002.

KIARTZIS, S. J. et al. Data pre-processing for short-term load forecasting in an autonomous power system using artificial neural networks. In: IEEE INTERNATIONAL CONFERENCE ON ELECTRONICS, CIRCUITS, AND SYSTEMS – ICECS, 3., 1996, New York. **Proceedings...** New York: IEEE, 1996. v. 2, p.1021-1024.

KOHONEN, T. Self-organized formation of topologically correct of feature maps. **Biological Cybernetics**, New York, v. 22, p. 159-168, 1982.

LIN, J. K. et al. Study of climatic effects on peak load and regional similarity of load profiles following disturbances based on data mining. **International Journal of Electrical Power & Energy Systems**, Oxford, v. 28, n. 3, p. 177-185, Mar. 2006.

LOPES, M. L. M.; LOTUFO, A. D. P.; MINUSSI, C. R. Application of the Fuzzy ART&ARTMAP neural network to the electrical load forecasting problem. In: ZHU, J. J.; FUNG, G. P. C. (Orgs.). **Forecasting models: methods and applications**. Hong Kong: iConcept Press, 2010. p. 179-190.

LOTUFO, A. D. P.; MINUSSI, C. R. Electric power systems load forecasting: a survey. In: INTERNATIONAL CONFERENCE ON ELECTRIC POWER ENGINEERING - POWERTECH, 1999, Budapest. **Proceedings...** New York: IEEE, 1999. p. 36-41.

LUCKS, M. B.; OKI, N. Winner-take-all circuit using CMOS technology. In: MIDWEST SYMPOSIUM IN CIRCUITS AND SYSTEMS, 1999, Las Cruces. **Proceedings...** New York: IEEE, 1999. v. 2, p. 1109-1112.

MAHDAVI, N. et al. A variable structure neural network model for mid-term load forecasting of Iran national power system. In: IEEE WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE - Neural Networks, 2008. **Proceedings...** New York: IEEE, 2008. p. 2572-2579.

MALKI, H. A.; KARAYIANNIS, N. B.; BALASUBRAMANIAN, M. Short-term electric power load forecasting using feedforward neural networks. **Expert Systems**, New York, v. 21, n. 3, p. 157-167, 2004.

MCCULLOCH, W.S .; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, New York, v. 5, p. 115-133, 1943.

MOODY, J.; DARKEN, C. J. Fast learning in networks of locally tuned processing units. **Neural Computation**, Cambridge, v. 1, p. 281-294, 1989.

NIU, D. X.; WANG, H. Q.; GU, Z. H. Short-term load forecasting using general regression neural network. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND CYBERNETICS, 2005, Guangzhou. **Proceedings...** New York: IEEE, 2005. v. 7, p. 4076-4082.

NOSE-FILHO, K. et al. Previsão de cargas elétricas utilizando diferentes arquiteturas de redes neurais artificiais com o auxílio das toolboxes do MATLAB. In: LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION - CLAGTEE, 8., 2009, Ubatuba. **Proceedings...** Guaratinguetá: FEG/Unesp, 2009.

OKI, N. Winner-take-all circuit using CMOS technology. In: MIDWEST SYMPOSIUM IN CIRCUITS AND SYSTEMS, 1998, Notre Dame. **Proceedings...** New York: IEEE, 1998. p. 568-570.

PANDIAN, S. C. et al. Fuzzy approach for short term load forecasting. **Electric Power System Research**, Oxford, v. 76, n. 6-7, p. 541-548, Apr. 2006.

PEDREGAL, D. J.; TRAPERRO, J. R. Mid-term hourly electricity forecasting based on a multi-rate approach. **Energy Conversion and Management**, Oxford, v. 51, p. 105-111, 2010.

PYNE, R. A. Short-term bus load forecasting and its intended use in scheduled outage analysis. **IEEE Conference on Decision and Control**, New York, v. 13, p. 593-597, Nov. 1974.

RANAWEERA, K. D.; KARADY, G. G.; FARNER, G. R. Economic impact analysis of load forecasting. **IEEE Transactions on Power Systems**, New York, v. 12, n. 3, p.1388-1392, 1997.

ROSEMBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, p. 386-408, 1958.

- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by Back-propagation errors. **Nature**, London, v. 323, p. 533-536, 1986.
- SAINI, L. M. Peak load forecasting using Bayesian regularization, resilient and adaptive backpropagation learning based artificial neural networks. **Electric Power Systems Research**, New York, v. 78, n. 7, July 2008.
- SAINI, L. M.; SONI, M. K. Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods. **IEEE Proceedings on Generation, Transmission and Distribution**, New York, v. 149, n. 5, p. 578- 584, 2002.
- SALGADO, R. M.; OHISHI, T.; BALLINI, R. A short-term bus load forecasting system. In: INTERNATIONAL CONFERENCE ON HYBRID INTELLIGENT SYSTEMS - HIS, 10., 2010, Atlanta. **Proceedings...** New York: IEEE, 2010. p. 55-60.
- SANO, T.; TEZUKA, I.; FUKUDA, Y. the load forecasting technology in the electric power distribution system. **Electrical Engineering in Japan**, New York, v. 153, n. 2, 2005.
- SENJYU, T. et al. Next day load curve forecasting using hybrid correction method. **IEEE Transactions on Power Systems**, New York, v. 20, n. 1, p. 102-109, 2005.
- SONG, K. et al. Short-term load forecasting for the holidays using fuzzy linear regression method. **IEEE Transactions on Power Systems**, New York, v. 20, n. 1, Feb. 2005.
- SPECHT, D. F. Probabilistic neural networks. **Neural Networks**, New York, v. 3, p. 110-118, 1990.
- SPECHT, D. F. A generalized regression neural network. **IEEE Transactions on Neural Networks**, New York, v. 2, p. 568-576, 1991.
- TELBANY, M. E.; KARMI, F. E. Short-term forecasting of Jordanian electricity demand using particle swarm optimization. **Electric Power Systems Research**, New York, v. 78, n. 3, p. 425-433, 2007.
- TOPALLI, A. K.; ERKMEN, I.; TOPALLI, I. Intelligent short-term load forecasting in Turkey. **Electrical Power and Energy Systems**, New York, v. 28, n. 7, p. 437-447, 2006.

TRIPATHI, M. M.; UPADHYAY, K. G.; SINGH, S. N. Short-term load forecasting using generalized regression and probabilistic neural networks in the electricity market. **The Electricity Journal**, Oxford, v. 21, n. 9, p. 24-34, 2008.

VILLALBA, S. A.; BEL, C. A. Hybrid demand model for load estimation and short-term load forecasting in distribution electric systems. **IEEE Transactions on Power Delivery**, New York, v. 15, n. 2, p. 764-769, Apr. 2000.

WASSERMAN, P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 1989.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. Dissertação (Mestrado) - Harvard University, Cambridge, 1974.

WIDROW, B.; HOFF JR, M. E. Adaptive switching circuits. **IRE WESCON Convention Record**, New York, p. 96-104, 1960.

WILLSHAW, D. J.; MALSBURG, C. von der. How patterned neural connections can be set up by self-organization. **Proceedings of the Royal Society of London Series B**, London, v. 194, p. 431-445, 1976.

XIA, C.; WNAG, J.; MCMENEMY, K. Short, medium and long term load forecasting model and virtual load forecaster based on radial basis function neural networks. **Electrical Power and Energy Systems**, New York, v. 32, p. 743-750, 2010.

YALCINOZ, T.; EMINOGLU, U. Short term and medium term power distribution load forecasting by neural networks. **Energy Conversion and Management**, Oxford, v. 46, p. 1393-1405, 2005.

YAP, K. S. et al. Short term load forecasting using a hybrid neural network. In: **IEEE INTERNATIONAL POWER AND ENERGY CONFERENCE - PECon**, 2006, Tehran. **Proceedings...** New York: IEEE, 2006. p.123-128.

YUN, Z. et al. RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment. **IEEE Transactions on Power Systems**, New York, v. 23, n. 3, p. 853-858, 2008.

ZHANG, Q.; LIU, T. Research on mid-long term load forecasting base on wavelet neural network. In: **INTERNATIONAL CONFERENCE ON COMPUTER ENGINEERING AND APPLICATIONS**, 2., 2010, Bali. **Proceedings...** New York: IEEE, 2010a. v. 2, p 217-220.

ZHANG, Q.; LIU, T. Research on mid-long term load forecasting based on fuzzy rules. In: INTERNATIONAL CONFERENCE ON COMPUTER ENGINEERING AND APPLICATIONS, 2., 2010, Bali Island. **Proceedings...** New York: IEEE, 2010b. p. 461-463.



## **Apêndice A - TABELAS**

As tabelas abaixo são referentes aos resultados individuais de cada sistema previsor de carga multinodal para as previsões de cargas locais e para a previsão de carga global. A seção A.1 é referente aos resultados da previsão de carga local e a seção A.2 é referente aos resultados da previsão de carga global. As cargas previstas são referentes aos dias 08/01/2009 a 14/01/2009 e aos dias 26/01/2009 e 06/02/2009. Também são ilustrados os valores do parâmetro *spread* utilizados para cada previsor e a configuração de entrada dos previsores do tipo GRNN-MR, que utilizam um número reduzido de entradas.

## A.1 Previsão de cargas locais

### A.1.1 Previsão de cargas locais pelo sistema predictor PCL GRNN.

A Tabela A.I é referente aos MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN, dos nove dias. A Tabela A.II é referente aos valores do parâmetro *spread* utilizados em cada predictor de carga local do sistema PCL GRNN.

**Tabela A.I** - MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN.

Dia	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
08/01/09	4,43	8,93	4,83	4,16	4,41	3,98	3,67	6,68	7,24
09/01/09	3,65	9,76	4,28	3,95	5,30	4,69	7,24	3,64	7,86
10/01/09	3,21	8,96	3,68	2,13	4,10	6,23	8,44	6,73	11,21
11/01/09	3,24	5,79	4,90	1,66	2,18	5,14	4,10	5,33	8,66
12/01/09	4,18	3,26	3,08	2,51	3,26	6,41	5,62	3,93	6,92
13/01/09	6,29	4,13	2,51	2,91	2,30	4,59	4,37	3,95	6,95
14/01/09	3,75	4,41	3,77	3,37	1,62	2,99	3,12	3,40	9,33
26/01/09	3,14	2,62	3,50	2,05	1,82	6,70	5,64	6,88	7,02
06/02/09	12,25	5,96	5,36	3,11	3,80	5,80	6,45	7,31	4,67
Médio	4,90	5,98	3,99	2,87	3,20	5,17	5,40	5,32	7,76
Máximo	12,25	9,76	5,36	4,16	5,30	6,70	8,44	7,31	11,21

**Tabela A.II** - Valores do parâmetro *spread* utilizados em cada predictor de carga local do sistema PCL GRNN.

Parâmetro <i>spread</i>	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
Parâmetro <i>spread</i>	0,0075	0,0150	0,0113	0,0075	0,0075	0,0375	0,0375	0,0075	0,3750

### A.1.2 Previsão de cargas locais pelo sistema predictor PCL GRNN-M.

A Tabela A.III é referente aos MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN-M, dos nove dias. A Tabela A.IV é referente aos valores do parâmetro *spread* utilizados em cada predictor de carga local do sistema PCL GRNN-M.

**Tabela A.III** - MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN-M.

Dia	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
08/01/09	4,43	8,93	4,83	4,16	4,41	3,41	4,04	6,68	9,70
09/01/09	3,65	9,76	4,28	3,95	5,30	2,37	7,89	3,64	10,04
10/01/09	3,21	8,96	3,68	2,13	4,10	6,16	8,93	6,73	11,29
11/01/09	3,24	5,79	4,90	1,66	2,18	5,12	4,55	5,33	8,71
12/01/09	4,18	3,26	3,08	2,51	3,26	6,46	5,61	3,93	6,97
13/01/09	6,29	4,13	2,51	2,91	2,30	5,48	4,92	3,95	6,71
14/01/09	3,75	4,41	3,78	3,37	1,62	2,56	3,52	3,40	6,76
26/01/09	3,14	2,62	3,50	2,05	1,82	6,71	5,73	6,88	7,02
06/02/09	12,25	5,96	5,36	3,11	3,80	5,97	6,82	7,31	4,51
Médio	4,90	5,98	3,99	2,87	3,20	4,92	5,78	5,32	7,97
Máximo	12,25	9,76	5,36	4,16	5,30	6,71	8,93	7,31	11,29

**Tabela A.IV** - Valores do parâmetro *spread* utilizados em cada predictor de carga local do sistema PCL GRNN-M.

Parâmetro <i>spread</i>	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
Parâmetro <i>spread</i>	0,0075	0,0150	0,0113	0,0075	0,0075	0,3750	0,0750	0,0075	0,3750

### A.1.3 Previsão de cargas locais pelo sistema predictor PCL GRNN-MR.

A Tabela A.V é referente aos MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN-MR, dos nove dias. A Tabela A.VI é referente aos valores do parâmetro *spread* utilizados em cada predictor de carga local do sistema PCL GRNN-MR. A configuração de entrada de cada predictor de carga local pode ser vista na Tabela A.VII.

**Tabela A.V** - MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL GRNN-MR.

Dia	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
08/01/09	4,98	8,15	4,83	3,12	4,44	3,36	3,56	6,68	9,06
09/01/09	4,96	8,88	4,28	2,44	5,18	2,37	7,05	3,64	9,39
10/01/09	3,39	8,51	3,68	7,56	4,10	6,23	8,46	6,73	11,29
11/01/09	4,38	4,06	4,90	7,26	2,27	5,12	3,81	5,33	8,71
12/01/09	4,24	3,18	3,08	4,16	3,67	6,46	5,38	3,93	6,97
13/01/09	5,52	4,62	2,51	2,79	2,60	5,47	4,31	3,95	6,72
14/01/09	3,42	4,07	3,78	2,49	1,84	2,53	3,01	3,40	7,38
26/01/09	2,90	2,62	3,50	2,08	1,82	6,77	5,53	6,88	7,03
06/02/09	12,30	5,96	5,36	3,30	3,80	6,00	6,39	7,31	4,51
Médio	5,12	5,56	3,99	3,91	3,30	4,92	5,28	5,32	7,89
Máximo	12,30	8,88	5,36	7,56	5,18	6,77	8,46	7,31	11,29

**Tabela A.VI** - Valores do parâmetro *spread* utilizados em cada predictor de carga local do sistema PCL GRNN-MR.

Parâmetro <i>spread</i>	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
Parâmetro <i>spread</i>	0,0075	0,0075	0,0113	0,0075	0,0075	0,3750	0,0150	0,0075	0,3750

**Tabela A.VII** - Configuração de entrada dos predictors de cargas locais do sistema PCL GRNN-MR.

Entrada/referência	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
1 Mês	1	1	1	1	1	1	1	1	1
2 Dia da semana	1	0	1	1	1	1	0	1	0
3 Dia da semana	0	1	1	0	1	1	1	1	1
4 Dia da semana	1	1	1	0	0	1	1	1	1
5 Dia da semana	0	1	1	0	1	0	1	1	1
6 Horário de verão	0	1	1	1	1	1	1	1	1
7 Feriado	1	1	1	1	1	1	1	1	1
8 Carga média	0	0	1	1	1	0	0	1	0
9 Carga máxima	1	0	1	1	1	1	0	1	0
10 Carga mínima	1	1	1	1	0	0	1	1	1

#### A.1.4 Previsão de cargas locais pelo sistema predictor PCL-FPCG GRNN.

A Tabela A.VIII é referente aos MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN, dos nove dias. A Tabela A.IX é referente aos valores do parâmetro *spread* utilizados em cada predictor de fator de participação de carga global do sistema PCL-FPCG GRNN.

**Tabela A.VIII** - MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN.

Dia	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
08/01/09	4,91	10,72	6,03	3,98	3,68	3,81	4,74	7,37	7,19
09/01/09	4,16	11,43	4,57	3,60	3,79	3,09	8,74	4,41	7,81
10/01/09	3,60	11,97	2,83	2,78	3,97	4,79	10,45	7,11	11,11
11/01/09	3,49	8,70	3,04	3,28	3,85	4,45	6,15	6,65	8,62
12/01/09	2,89	5,53	2,01	2,60	3,27	6,45	6,68	4,54	6,91
13/01/09	5,63	6,90	2,32	2,41	3,51	5,38	5,38	4,82	6,97
14/01/09	3,40	6,25	2,73	2,65	3,12	2,68	4,00	3,96	9,39
26/01/09	3,87	3,15	3,78	1,62	2,05	2,77	5,45	7,74	6,98
06/02/09	10,07	4,30	11,55	5,15	4,12	2,09	7,02	6,03	4,75
Médio	4,67	7,66	4,32	3,12	3,48	3,95	6,51	5,85	7,75
Máximo	10,07	11,97	11,55	5,15	4,12	6,45	10,45	7,74	11,11

**Tabela A.IX** - Valores do parâmetro *spread* utilizados em cada predictor de fator de participação de carga global do sistema PCL-FPCG GRNN.

Parâmetro <i>spread</i>	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
Parâmetro <i>spread</i>	0,0075	0,0075	0,3750	0,0075	0,0075	0,0375	0,0150	0,0075	0,3750

### A.1.5 Previsão de cargas locais pelo sistema predictor PCL-FPCG GRNN-M.

A Tabela A.X é referente aos MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN-M, dos nove dias. A Tabela A.XI é referente aos valores do parâmetro *spread* utilizados em cada predictor de fator de participação de carga global do sistema PCL-FPCG GRNN-M.

**Tabela A.X** - MAPEs, diários, médios e máximos obtidos nas previsões de cargas locais utilizando o sistema PCL-FPCG GRNN-M.

Dia	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
08/01/09	4,99	9,52	8,75	4,71	3,36	3,83	3,66	6,92	9,40
09/01/09	4,18	10,24	8,85	4,39	2,17	2,19	7,40	3,48	9,69
10/01/09	3,09	10,90	3,43	2,11	3,12	3,99	9,64	6,27	10,39
11/01/09	3,05	7,56	3,24	2,60	2,95	4,60	5,46	6,00	8,14
12/01/09	2,35	5,49	1,96	2,15	2,89	6,07	7,03	4,23	7,01
13/01/09	5,61	6,34	2,74	2,65	2,70	5,40	4,98	4,25	6,73
14/01/09	3,76	5,17	2,39	3,73	1,91	2,90	3,32	4,09	7,13
26/01/09	3,62	3,40	3,89	1,88	1,63	3,04	5,83	7,56	7,08
06/02/09	11,27	5,17	10,23	3,37	2,58	1,93	6,62	6,85	4,38
Médio	4,66	7,09	5,05	3,06	2,59	3,77	5,99	5,52	7,77
Máximo	11,27	10,9	10,23	4,71	3,36	6,07	9,64	7,56	10,39

**Tabela A.XI** - Valores do parâmetro *spread* utilizados em cada predictor de fator de participação de carga global do sistema PCL-FPCG GRNN-M.

Parâmetro <i>spread</i>	Subestação								
	#01	#02	#03	#04	#05	#06	#07	#08	#09
Parâmetro <i>spread</i>	0,0075	0,0113	0,3750	0,0075	0,0075	0,3750	0,0150	0,0075	0,3750



## A.2 Previsão de carga global

A Tabela A.XV é referente aos MAPEs, diários, médios e máximos obtidos nas previsões de carga global, dos nove dias, dos sistemas do tipo PCL-FPCG. A Tabela A.XVI é referente aos valores do parâmetro *spread* utilizados em cada predictor de carga global. A configuração de entrada do predictor de carga global do sistema PCL-FPCG GRNN-MR pode ser vista na Tabela A.XVII.

**Tabela A.XV** - MAPEs, diários, médios e máximos obtidos nas previsões de carga global.

Dia	GRNN	Previsor GRNN-M	GRNN-MR
08/01/09	3,14	2,66	2,58
09/01/09	3,85	2,87	2,69
10/01/09	5,34	5,35	5,30
11/01/09	3,98	3,99	3,90
12/01/09	2,30	2,31	2,37
13/01/09	2,96	2,07	2,01
14/01/09	2,64	1,82	1,69
26/01/09	3,18	3,19	3,60
06/02/09	2,38	2,33	2,82
Médio	3,30	2,95	3,00
Máximo	5,33	5,35	5,30

**Tabela A.XVI** - Valores do parâmetro *spread* utilizados pelos predictores de cargas globais.

	GRNN	Previsor GRNN-M	GRNN-MR
Parâmetro <i>spread</i>	0,3750	0,3750	0,1500

**Tabela A.XVII** - Configuração de entrada do predictor de carga global do sistema PCL-FPCG GRNN-MR.

Entrada/referência	Previsor GRNN-MR
1 Mês	1
2 Dia da semana	1
3 Dia da semana	1
4 Dia da semana	1
5 Dia da semana	1
6 Horário de verão	0
7 Feriado	1
8 Carga média	1
9 Carga máxima	0
10 Carga mínima	0




## **Apêndice B - FIGURAS**


As figuras da seção B.1 são referentes às curvas de carga, locais, reais e às curvas de carga, locais, previstas pelos diferentes sistemas previsores de carga multinodal. As figuras da seção B.2 são referentes às curvas de carga, globais, reais e curvas de carga, globais, previstas pelos diferentes previsores de carga global. As curvas de carga previstas foram às curvas de carga locais, de cada subestação e globais dos dias 08/01/2009 a 14/01/2009 e dos dias 26/01/2009 e 06/02/2009. As linhas verticais separam as curvas de carga de cada dia previsto, na sequência de previsão.

## B.1 Previsão de cargas locais

A Figura B.1 ilustra as curvas de carga locais da subestação #01, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.




a)




b)

**Figura B.1** - Curvas de carga locais da subestação #01, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).

A Figura B.2 ilustra as curvas de carga locais da subestação #02, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.



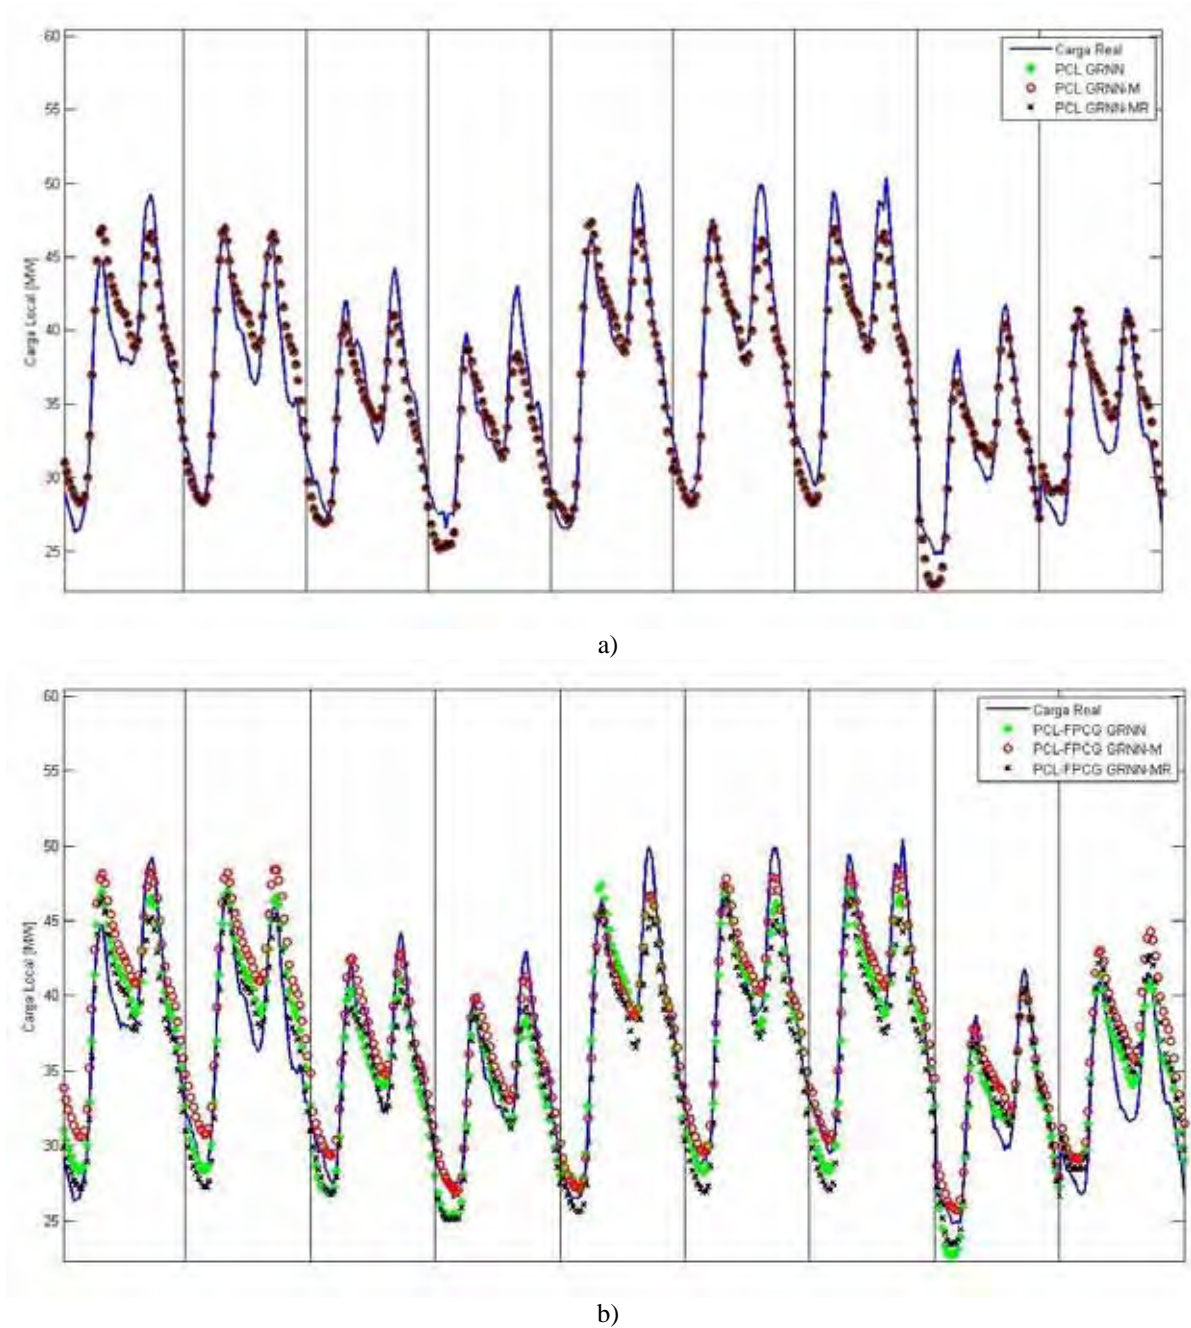
a)



b)

**Figura B.2** - Curvas de carga locais da subestação #02, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).


A Figura B.3 ilustra as curvas de carga locais da subestação #03, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.




**Figura B.3** - Curvas de carga locais da subestação #03, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).



A Figura B.4 ilustra as curvas de carga locais da subestação #04, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.




a)




b)

**Figura B.4** - Curvas de carga locais da subestação #04, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).

A Figura B.5 ilustra as curvas de carga locais da subestação #05, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.




a)




b)

**Figura B.5** - Curvas de carga locais da subestação #05, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).

A Figura B.6 ilustra as curvas de carga locais da subestação #06, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.



a)




b)


**Figura B.6** - Curvas de carga locais da subestação #06, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).



A Figura B.7 ilustra as curvas de carga locais da subestação #07, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.



a)




b)


**Figura B.7** - Curvas de carga locais da subestação #07, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).



A Figura B.8 ilustra as curvas de carga locais da subestação #08, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.




a)




b)

**Figura B.8** - Curvas de carga locais da subestação #08, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).

A Figura B.9 ilustra as curvas de carga locais da subestação #09, reais e previstas pelos sistemas tipo PCL e PCL-FPCG.



a)




b)

**Figura B.9** - Curvas de carga locais da subestação #09, reais e previstas pelos sistemas tipo PCL, a), e PCL-FPCG, b).

## B.2 Previsão de carga global

O gráfico da Figura B.10 ilustra as curvas de carga globais, reais e previstas.



**Figura B.10** - Curvas de carga globais, reais e previstas pelos previsores tipo GRNN, GRNN-M e GRNN-MR.

## Apêndice C - ARTIGOS SUBMETIDOS, ACEITOS E PUBLICADOS

### C.1 Artigos aceitos e publicados

NOSE-FILHO, K.; MAEDA, J. L. Y.; LOTUFO, A. D. P. Comparação de arquiteturas de redes neurais artificiais utilizadas para a previsão de cargas elétricas utilizando as toolboxes do matlab. In: **SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE**, 9., 20-23 Setembro, 2009, Brasília, DF, Brasil.

NOSE-FILHO, K.; ARAÚJO, K. A. M.; MAEDA, J. L. Y.; LOTUFO, A. D. P. Previsão de cargas elétricas utilizando diferentes arquiteturas de redes neurais artificiais com o auxílio das toolboxes do MATLAB. In: **LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION - CLAGTEE**, 8., 2009, Ubatuba, Brasil.

NOSE-FILHO, K.; LOTUFO, A. D. P.; MINUSSI, C. R. Previsão de potências ativa e reativa de curto prazo usando redes neurais artificiais de base radial. In: **SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS**, 3., 18-21 Maio, 2010, Belém, PA, Brasil.

NOSE-FILHO, K.; ALTRAN, A. B.; LOTUFO, A. D. P.; MINUSSI, C. R. Previsão de carga multinodal em sistemas de energia elétrica usando redes neurais artificiais. In: **CONGRESSO BRASILEIRO DE AUTOMÁTICA**, 18., 13-16 Setembro, 2010, Bonito, MS, Brasil.

NOSE-FILHO, K.; LOTUFO, A. D. P.; MINUSSI, C. R. Short-term multinodal load forecasting in distribution systems using general regression neural networks. In: **IEEE TRONDHEIM POWERTECH 2011**, 19-23 June, 2011, Trondheim, Norway. \*

NOSE-FILHO, K.; LOTUFO, A. D. P.; MINUSSI, C. R. Preprocessing data for short-term load fore-casting with a general regression neural net-work and a moving average filter. In: **IEEE TRONDHEIM POWERTECH 2011**, 19-23 June, 2011, Trondheim, Norway. \*\*

\* Artigo aceito

\*\* Artigo condicionalmente aceito