



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO
E SISTEMAS

UM MODELO DE REDE NEURAL ARTIFICIAL PARA PREVISÃO
AUTOMÁTICA DA CARGA ATIVA NODAL DE CURTO PRAZO EM
SISTEMAS DE TRANSMISSÃO E DISTRIBUIÇÃO DE ENERGIA
ELÉTRICA COM SUPERVISÃO E CONTROLE AUTOMATIZADOS

Cláudio Magalhães de Oliveira

Dissertação apresentada para a obtenção do grau de Mestre em Engenharia de Pro-
dução

Orientador: Raul Sidnei Wazlawick

Co-orientador: Luiz Jairo Branco Machado


Florianópolis

Março de 1999

Um Modelo de Rede Neural Artificial Para Previsão Automática da Carga Ativa Nodal de Curto Prazo em Sistemas de Transmissão e Distribuição de Energia Elétrica com Supervisão e Controle Automatizados

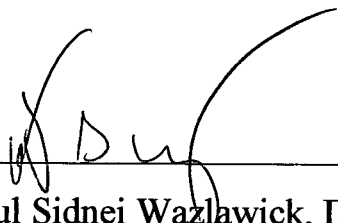
Cláudio Magalhães de Oliveira

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia, especialidade em Engenharia de Produção e aprovada em sua forma final pelo curso de Pós-Graduação em Engenharia de Produção e Sistemas da Universidade Federal de Santa Catarina.



Ricardo Miranda Barcia, Ph. D.

Banca Examinadora



Raul Sidnei Wazlawick, Dr.

Orientador

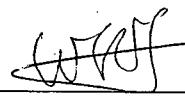


Luiz Jairo Branco Machado, D. Ing.

Co-orientador



Lia Caetano Bastos, Dra.



Walter Zelindro da Silva Filho, Eng.

À minha esposa e filhos.

Aos meus pais.

RESUMO

Este trabalho propõe, valida e verifica um modelo para previsão da carga ativa nodal horária, uma hora à frente, no Estado de Santa Catarina. O modelo proposto é fundamentado na técnica de Rede Neurais Artificiais (RNA's) e possui características que representam vantagens para utilização em sistemas de tempo real. O trabalho também compara o desempenho deste modelo, com o desempenho de um outro baseado na arquitetura Perceptron Múltiplas Camadas, treinada com o algoritmo de Retropropagação (MLP). Verifica, ainda, a validade da hipótese de que é possível, para este tipo de previsão (uma hora à frente), dispensar o uso da temperatura ambiente prevista para uma hora à frente na composição do vetor de entrada da rede neural, sem que isto implique em perda de qualidade das previsões (hipótese 1). Por fim, verifica a hipótese de que o uso, no vetor de saída da RNA, do percentual de variação da carga em substituição ao valor da carga, propicia uma maior precisão nas previsões bem como a possibilidade de redução no tamanho do conjunto de treinamento (hipótese 2).

O modelo proposto é baseado na arquitetura de RNA Função de Base Radial e demonstrou ter características atrativas: velocidade e facilidade de ajuste para utilização integrada a sistemas de tempo real; possui também muito maior velocidade e facilidade de ajuste que o modelo MLP. Além disto, é possível modificá-lo para que adicionalmente forneça índices de confiabilidade para as previsões. A arquitetura MLP é escolhida para a comparação, por ser uma das mais utilizadas em modelos de previsão de carga fundamentados na técnica de RNA's. O modelo MLP produz previsões mais precisas, porém as possibilidades de otimização do modelo proposto não são esgotadas. A hipótese 1 é validada, porém a hipótese 2 não se mostra válida.

ABSTRACT

The present work proposes, validates and verifies an hourly bus active load forecast model, one hour ahead, at Santa Catarina's State. The proposed model is based on the Artificial Neural Networks (ANNs) technique, and has features that represent advantages for application on real time systems. This work also compares the performance of this model with another one based on a Multilayer Perceptron architecture, trained with the Backpropagation algorithm (MLP). It also verifies the validity of the following hypothesis: it is possible for this type of forecast (one hour ahead) to release the use of the forecasted environment temperature for one hour ahead in the composition of the neural network input vector, without implying loss of quality of the forecasts (hypothesis 1). Finally, it verifies the hypothesis that the use, in the ANN output vector, of the load variation rate, in substitution to the load value, propitiates a larger precision of the forecasts and the possibility of reducing the training group size (hypothesis 2).

The proposed model is based on the Radial Base Function ANN architecture and demonstrates to possess attractive characteristics: speed and easiness of adjustment, for integrating it with real time systems, also showing to be easier to adjust and faster than the MLP model. Additionally, it is still possible to modify it so that it also provides reliability indexes for the forecasts. The MLP architecture is chosen for the comparison because it is the most utilized network in load forecast models based on ANNs. The MLP model produced more precise forecasts, nevertheless the possibility of improving the proposed model are not all exhausted. The hypothesis 1 is validated, but the hypothesis 2 is not.

AGRADECIMENTOS

Aos Professores Raul S. Wazlawick e Luiz Jairo B. Machado, pela orientação, incentivo e disponibilidade.

Ao amigo, Professor Paulo H. F. Vieira, pela iniciação no campo da Inteligência Artificial, sugestões, apoio e incentivo durante os momentos difíceis.

Ao companheiro de Pós-Graduação, Professor Sérgio L. Rivero, pelas boas discussões, grandes idéias e pronta ajuda.

Ao Engenheiro Flávio L. da Silva, chefe da Divisão de Desenvolvimento de Sistemas do Departamento de Informática da CELESC, pelo apoio e sensibilidade quanto a importância do conhecimento.

A CELESC, pela cessão de medições de potência e temperatura ambiente de seu sistema elétrico.

Aos Engenheiros da Diretoria de Engenharia e Operação da CELESC, em especial: Walter Zelindro da Silva Filho, Ivo José Turnes, Irineu Michel, Marina Bott Gonçalves, Paulo Neves de Lacerda, José Carlos Pereira Bianco e Luiz Artur Fritsch de Verney, pelas informações e apoio prestados.

Aos colegas do Laboratório de Sistemas de Conhecimento, pelo apoio e companheirismo.

A todos os demais que contribuíram para a realização deste trabalho.

ÍNDICE DE FIGURAS

<i>Figura 1 - Experimento D1, 12 agrupamentos</i>	55
<i>Figura 2 - Experimento D2, 13 agrupamentos</i>	56
<i>Figura 3 - Experimento D3, 12 agrupamentos</i>	57
<i>Figura 4 - Experimento D4, 10 agrupamentos</i>	58
<i>Figura 5 - Experimento D5, 12 agrupamentos</i>	59
<i>Figura 6 - Experimento E4, 21 agrupamentos</i>	60
<i>Figura 7 - Experimento F7, 38 agrupamentos</i>	61
<i>Figura 8 - Experimento I64, 15 agrupamentos</i>	67
<i>Figura 9 - Rede MLP de 3 camadas</i>	92
<i>Figura 10 - Rede RBF de 3 camadas (in ORR, 1996)</i>	96

ÍNDICE DE TABELAS

<i>Tabela 1 - Melhores Resultados dos Experimentos da Primeira Etapa</i>	<i>51</i>
<i>Tabela 2 - Melhores Resultados dos Experimentos</i>	<i>64</i>
<i>Tabela 3 - Massa de Dados Útilizada nos Experimentos</i>	<i>73</i>
<i>Tabela 4 - Experimento F7, 38 agrupamentos</i>	<i>81</i>
<i>Tabela 5 - Experimento I64</i>	<i>82</i>
<i>Tabela 6 - Resumo dos Resultados dos Experimentos do Grupo I</i>	<i>83</i>
<i>Tabela 7 - Resultados dos Experimentos do Grupo D</i>	<i>85</i>
<i>Tabela 8 - Resultados dos Experimentos do Grupo E</i>	<i>86</i>
<i>Tabela 9 - Resultados dos Experimentos do Grupo F</i>	<i>88</i>
<i>Tabela 10 - Resultados dos Experimentos do Grupo G</i>	<i>90</i>
<i>Tabela 11 - Resultados dos Experimentos do Grupo H</i>	<i>91</i>

SUMÁRIO

1. INTRODUÇÃO	9
1.1 DEFINIÇÃO E EVOLUÇÃO DO PROBLEMA	9
1.2 OBJETIVOS	15
1.3 JUSTIFICATIVA	16
1.4 PRINCIPAIS CONTRIBUIÇÕES DO TRABALHO	17
1.5 METODOLOGIA	17
1.6 ABRANGÊNCIA DO TRABALHO	18
1.7 ORGANIZAÇÃO DO TRABALHO	19
2. REDES NEURAIS ARTIFICIAIS E PREVISÃO	20
2.1 INTRODUÇÃO	20
2.2 ARQUITETURA PERCEPTRON MÚLTIPLAS CAMADAS	21
2.3 ARQUITETURA FUNÇÃO DE BASE RADIAL	23
2.4 TREINAMENTO DA REDE	25
2.5 AQUISIÇÃO E MODELAGEM DOS DADOS	27
2.6 AVALIAÇÃO DAS PREVISÕES	31
2.7 CONCLUSÕES	33
3. O MODELO PROPOSTO	35
3.1 ARQUITETURA BÁSICA	35
3.2 ENTRADA DA RNA	36
3.3 CAMADA INTERMEDIÁRIA DA RNA	38
3.4 SAÍDA DA RNA	39
4. EXPERIMENTAÇÃO	40
4.1 ORGANIZAÇÃO DOS EXPERIMENTOS	40
4.1.1 <i>Metodologia Adotada</i>	40
4.1.2 <i>Mensuração dos Resultados</i>	40
4.1.3 <i>Ambiente dos Experimentos</i>	41
4.2 MASSA DE DADOS	42
4.3 VALIDAÇÃO E VERIFICAÇÃO DO MODELO	43
4.3.1 <i>Metodologia Adotada</i>	43
4.3.2 <i>Melhores Resultados</i>	51
4.3.3 <i>Conclusões</i>	52
4.4 COMPARAÇÃO DO MODELO	62

4.4.1	<i>Metodologia Adotada</i>	62
4.4.2	<i>Melhores Resultados</i>	64
4.4.3	<i>Conclusões</i>	65
5.	CONSIDERAÇÕES FINAIS	68
5.1	CONCLUSÕES	68
5.2	RECOMENDAÇÕES	69
6.	ANEXOS	72
6.1	ANEXO 1: MASSA DE DADOS	73
6.2	ANEXO 2: DETALHAMENTO DOS MELHORES RESULTADOS	80
6.3	ANEXO 3: RESUMO DOS RESULTADOS DOS EXPERIMENTOS COM O MODELO MLP	83
6.4	ANEXO 4: RESULTADOS DOS EXPERIMENTOS COM O MODELO PROPOSTO	85
6.5	ANEXO 5: ARQUITETURA PERCEPTRON MÚLTIPLAS CAMADAS	92
6.6	ANEXO 6: ARQUITETURA FUNÇÃO DE BASE RADIAL	96
7.	REFERÊNCIAS BIBLIOGRÁFICAS	101

1. INTRODUÇÃO

Este capítulo relata o problema objeto deste trabalho (previsão de cargas), seu contexto, sua evolução no tempo e o conhecimento científico acumulado a seu respeito. Apresenta ainda as questões e hipóteses de trabalho, os objetivos estabelecidos e a justificativa para tal empreendimento, a metodologia adotada para atingir tais objetivos, os limites estabelecidos para o trabalho e sua organização.

1.1 Definição e Evolução do Problema

Uma concessionária de energia elétrica precisa conhecer a futura *demand de energia elétrica*¹, a ser suprida pelo seu *sistema de potência*². O conhecimento prévio da demanda futura é de grande ajuda em várias de suas atividades diárias, tais como a operação do sistema de transmissão e distribuição de energia elétrica, a compra e venda de energia e o planejamento da construção de usinas e subestações. Em consequência disto, uma das atividades desenvolvidas neste tipo de empresa é a elaboração de previsões sobre o comportamento futuro do consumo de energia elétrica (previsões de carga). O ponto futuro considerado compreende um horizonte que pode variar de minutos ou horas até anos à frente.

As previsões de carga são elaboradas tanto para as cargas nos *nós*³ (carga nodal) de maior relevância quanto para a *carga total*⁴ do sistema de potência. Elas podem ser classi-

¹ É o consumo de energia elétrica, tanto da energia ativa como da reativa, efetuada pelos clientes conectados a um sistema de distribuição de eletricidade.

² É o sistema de transmissão e distribuição de energia elétrica, constituído pelas linhas de transmissão e subestações.

³ Os nós considerados são os barramentos dos transformadores das subestações, as subestações e os pontos de interconexão com outros sistemas de potência.

⁴ É a soma das demandas individuais em todos os nós do sistema de potência.

ficadas, em função do ponto futuro considerado, como de muito curto, curto, médio ou longo prazo. As previsões de muito curto prazo são as previsões de carga de poucos minutos até uma hora à frente. Elas são usadas para auxiliar atividades de operação do sistema elétrico, tais como despacho econômico e avaliação da segurança. Já as previsões de curto prazo dizem respeito as previsões da carga horária em um período de até uma semana à frente. Elas são utilizadas na programação da manutenção e no auxílio à operação do sistema elétrico. As previsões de médio prazo, prevendo as cargas semanas ou meses à frente, são utilizadas nos planejamentos da produção e do intercâmbio de energia entre diferentes empresas de energia elétrica. Enfim as de longo prazo, procuram prever as cargas anos à frente e fornecem subsídios para o planejamento estratégico, tal como a previsão de construção das usinas, subestações e redes de transmissão e distribuição de energia elétrica.

A precisão da previsão é de grande importância na gerência da produção e distribuição da eletricidade. Previsões com alto grau de precisão possibilitam, otimização da produção, redução dos custos de produção, melhor coordenação hidrotérmica e melhor programação para as transferências de energia entre partes do sistema elétrico de uma concessionária ou entre sistemas elétricos de companhias distintas. Um sistema de previsão de cargas preciso é capaz de prover segurança, confiabilidade e economia para a operação de um sistema de potência (Bakirtzis, Petridis, et al., 1995, Bakirtzis, Theocharis, et al., 1995, Xiao & McLaren, 1995, Zebulum et al., 1996). Segundo Choueiki et al. (1997), para uma concessionária de eletricidade do Reino Unido, um incremento de 1% no erro da previsão de curto prazo causa um aumento nos custos operacionais anuais de 10 milhões de libras. Kiartzis et al. (1997) cita também o fato de que funções fundamentais existentes em modernos Sistemas de Gerenciamento de Energia ("*Energy Management Systems*" – EMS), fiam-se em previsões de carga de curto prazo precisas. Para este autor, a desregulamentação do setor elétrico e o conseqüente aumento na competição resultante, faz com que a capacidade de elaborar previsões de forma acurada, seja um importante fator para o futuro sucesso de uma companhia de energia elétrica.

Por outro lado, ao se observar o comportamento do mercado consumidor de energia elétrica, constata-se um crescimento do nível de exigência, quanto aos índices de qualidade e continuidade no fornecimento de energia. Níveis de oscilação na tensão e de interrupção

de fornecimento, a pouco tempo considerados normais, não são atualmente tolerados. A isto se soma a redução da disponibilidade de recursos energéticos renováveis e o acirramento da competição entre as concessionárias de energia elétrica gerado pela desregulamentação do setor. Estes fatos geram para uma concessionária de eletricidade, a necessidade de reduzir seus custos operacionais, diminuindo o desperdício na geração e distribuição de energia elétrica, e de exercer maior controle sobre seu sistema de potência, com sua operação sendo conduzida dentro de limites cada vez mais justos. Para a função de previsão de cargas, a consequência, além da busca por maior precisão nas previsões apontada em Kiartzis et al. (1997), é a necessidade de também conhecer a demanda futura em prazos cada vez menores e para um número maior de nós do sistema de potência controlado. Os trabalhos de AlFuhaid et al. (1997), Liu et al. (1995) e Martin (1996), relativos a previsões de muito curto prazo, para os próximos 30min. e 5min., e de Leite (1997), a respeito da previsão da carga nodal, demonstram esforços nesta direção. Cabe ressaltar que aumentar o número de nós e reduzir os horizontes das previsões, implica em dispor de um volume maior de informações renovado em intervalos de tempo cada vez menores, a respeito do estado do processo controlado.

A tendência geral de automação dos processos produtivos se estende aos *Centros de Operação de Sistema*⁵ – C.O.S das companhias de energia elétrica. Um exemplo disto é a crescente utilização de sistemas SCADA (“*Supervisory, Control and Data Acquisition*”) para supervisão e controle, em tempo real, dos sistemas de potência das concessionárias. O emprego do SCADA disponibiliza leituras de grandezas elétricas, em tempo real, para uma enorme quantidade de nós do sistema de potência controlado. A disponibilidade desta imensa gama de leituras em prazos tão curtos, torna viável a construção de sistemas automáticos de previsão de cargas nodais de curto prazo e muito curto prazo. Tal sistema, funcionando em tempo real e em fina sintonia com o SCADA, pode utilizar, de forma quase instantânea, as leituras disponibilizadas.

Com o propósito de obter previsões de carga precisas, diversas técnicas tem sido utilizadas para elaboração das previsões. Estas técnicas podem ser divididas em dois gru-

⁵ São as áreas responsáveis pela operação dos sistemas de produção, transmissão e distribuição de energia elétrica das concessionárias de energia elétrica.

pos: técnicas tradicionais e técnicas de inteligência artificial. Na categoria de técnicas tradicionais incluem-se as técnicas heurísticas e as técnicas estatísticas, tais como modelos de regressão e Box & Jenkins. No grupo de técnicas de inteligência artificial incluem-se os sistemas especialistas e as Redes Neurais⁶ Artificiais – RNA's (Bakirtzis, Petridis, et al., 1995, Bakirtzis, Theocharis, et al., 1995, Leite, 1997, Kiartzis et al., 1997, Zebulum et al., 1996).

As Redes Neurais Artificiais (RNA's) têm sido aplicadas com sucesso à previsão de cargas (Zebulum et al., 1996). Porém, da mesma forma que Leite (1997), observou-se que a maioria dos trabalhos na área estão voltados à previsão da carga total ativa do sistema. Kiartzis et al. (1997), relata que as RNA's têm sido utilizadas em um número significativo de Sistemas de Gerenciamento de Energia de abrangência mundial. Para este autor, a técnica de Redes Neurais Artificiais possui benefícios significativos quando comparada às técnicas tradicionais, tais como redução no esforço de modelagem e alta precisão. Há consenso sobre a existência de uma relação entre condições climáticas e variação da carga. Porém, não existe consenso de que o relacionamento da variação das condições do tempo com a variação da carga seja linear e as RNA's possuem a habilidade para construir um relacionamento não linear entre suas entradas e suas saídas, através do aprendizado por exemplos (dispensando a necessidade de um especialista). Além disto, elas não necessitam da identificação de um relacionamento funcional *explícito* entre cargas passadas, condições climáticas e a carga a ser prevista (Bakirtzis, Petridis, et al., 1995). Para Kiartzis et al. (1997), esta capacidade de aprender através de exemplos o relacionamento funcional entre as entradas do sistema (cargas passadas e condições climáticas) e suas saídas (as cargas futuras) torna as Redes Neurais Artificiais previsores ideais para este campo de aplicação.

Em muitos sistemas de potência a temperatura é a condição climática de maior relevância na variação da carga. A maioria das concessionárias de energia elétrica têm em seus sistemas de potência cargas sensíveis às condições climáticas, tais como sistemas de aquecimento e refrigeração (Xiao & McLaren, 1995). Assim, durante a modelagem do sistema, é usual incluir-se a temperatura ambiente (tanto as temperaturas passadas quanto a

⁶ Optou-se por utilizar o termo *Neural* em lugar de *Neuronal* ou *Neuronal*, seguindo-se o consenso quanto a terminologia, estabelecido via brass-nnet (lista de circulação de informações de brasileiros em redes neurais) e adotado pelo Conselho Nacional de Redes Neurais.

sua expectativa futura) no rol de suas variáveis de entrada. Porém, a inclusão de previsões das condições climáticas futuras na entrada do sistema implica a necessidade de se dispor de uma fonte confiável para o seu fornecimento.

A arquitetura de Rede Neural Artificial (RNA), usualmente aplicada à previsão de cargas, é a Perceptron Múltiplas Camadas (*Multilayer Perceptron*), treinada com o algoritmo de Retropropagação (*Backpropagation*), (Xiao & McLaren, 1995, Zebulum et al., 1996) e doravante denominada de MLP. A tendência do uso generalizado da arquitetura MLP não ocorre apenas no domínio do problema de previsão de cargas. Segundo Skapura (1996), esta arquitetura é o paradigma de rede de propósito mais geral e mais utilizado. Kiartzis et al. (1997) apresenta proposta de um modelo de sistema de previsão de cargas de curto prazo, baseado em uma rede MLP, para uso em um sistema de potência autônomo. A MLP é uma rede confiável e capaz de produzir previsões precisas. Porém, ela é uma RNA de treinamento lento, difícil ajuste e necessita de uma grande quantidade de exemplos de treinamento. Estas desvantagens dificultam a aplicação da arquitetura MLP em sistemas de tempo real.

Questões

A tendência de automação dos processos produtivos associada à necessidade de maior conhecimento e controle sobre o estado dos sistemas de transmissão e distribuição de energia elétrica gera a necessidade de sistemas de previsão de cargas mais precisos, abrangentes e rápidos. Para tanto, e de acordo com esta tendência, seu projeto deve buscar associar o funcionamento destes sistemas de previsão ao dos SCADA's bem como procurar minimizar a necessidade de intervenção humana à sua operação. A RNA de arquitetura MLP é confiável e capaz de produzir previsões precisas. Entretanto, seu treinamento é lento. Além disto, não há facilidade para obtenção de uma configuração ótima para sua arquitetura. Estes fatores a tornam pouco indicada para utilização em sistemas de previsão de cargas com elevado nível de autonomia e de operação em tempo real.

A inclusão das condições climáticas futuras no rol das variáveis de entrada Rede Neural Artificial, em especial da temperatura ambiente futura, propicia aumento na precisão das previsões de carga, principalmente em regiões sujeitas à variações bruscas de temperatura. Todavia, o sucesso esperado, advindo desta abordagem, pressupõe que as previ-

sões destas grandezas, além de disponíveis, possuam um alto nível de precisão. Para uma concessionária de energia elétrica nacional isto significa um requisito a mais, nem sempre disponível, para tornar operacional um sistema de previsão de cargas.

Hipóteses

Supõe-se possível a aplicação de uma arquitetura alternativa à arquitetura MLP na construção de uma RNA voltada à previsão de cargas. Esta arquitetura alternativa deve ser confiável e capaz de fornecer previsões de cargas precisas. Também deve ser capaz de minimizar as desvantagens da arquitetura MLP, decorrentes de sua baixa velocidade e dificuldade na obtenção da configuração ótima. Oliveira e Rivero (1998), relatam a equivalência na precisão das previsões do Produto Interno Bruto – PIB, obtidas por meio das arquiteturas de rede neural artificial MLP e Função de Base Radial (Radial Basis Function – RBF). Porém, segundo os autores, a RBF se mostrou mais rápida e simples para configuração.

Para a previsão da carga horária para uma hora à frente, supõe-se possível dispensar o uso de temperaturas ambientes previstas, sem que isto implique em redução na precisão das previsões, substituindo-as pelo gradiente da temperatura ambiente na última hora. Segundo Xiao e McLaren (1995), em muitos sistemas de potência, temperatura é a mais importante variável climática no que se refere aos seus efeitos sobre a carga. Em função disto, sugerem experimentar o uso de valores de máximo, mínimo, média e desvio da temperatura na composição do vetor de entrada da rede.

Supõe-se que o uso, no vetor de saída da RNA, do percentual de variação da carga em substituição ao valor da carga implique na redução do tamanho do conjunto de treinamento e numa maior precisão nas previsões. Observou-se que os trabalhos na área de previsão de cargas utilizam o valor da carga como saída da rede. A Rede Neural Artificial aprende agrupando padrões similares. Portanto, o emprego da alternativa proposta deverá reduzir o universo de padrões a classificar. Isto possibilitará a redução do tamanho do conjunto de treinamento sem perda da capacidade de generalização ou prejuízos no processo de aprendizado bem como um incremento na precisão das previsões.

1.2 Objetivos

O objetivo geral deste trabalho é propor, *validar*⁷ e *verificar*⁸ um modelo para previsão da carga ativa nodal horária, uma hora à frente, no Estado de Santa Catarina. Este modelo deverá ser fundamentado na técnica de Rede Neurais Artificiais e utilizar uma arquitetura de RNA distinta da arquitetura Perceptron Múltiplas Camadas treinada com o algoritmo de Retropropagação. Deverá também possuir características que representem vantagens para utilização em sistemas de tempo real. O modelo proposto poderá ser utilizado pela Centrais Elétricas de Santa Catarina - Celesc na construção de um sistema automático, capaz de operar em tempo real, para previsão da carga ativa nos nós de seu sistema de potência.

Os objetivos específicos são:

- a) *Comparar*⁹ o desempenho do modelo proposto, com o desempenho de um modelo baseado na arquitetura de RNA Perceptron Múltiplas Camadas, treinado com o algoritmo de Retropropagação.
- b) Validar a hipótese de que para este tipo de previsão (uma hora à frente) é possível dispensar o uso da temperatura ambiente prevista para uma hora à frente na composição do vetor de entrada da rede neural, sem que isto implique em perda de qualidade das previsões.
- c) Validar a hipótese de que o uso, no vetor de saída da RNA, do percentual de variação da carga em substituição ao valor da carga, propicia uma maior precisão nas previsões bem como a possibilidade de redução no tamanho do conjunto de

⁷ Define-se **validação** como o processo de assegurar-se de que o programa computacional, construído de forma a simular o modelo, funciona sem erros e da forma esperada pelos projetistas e implementadores.

⁸ Define-se **verificação** como o processo de mensurar e interpretar os resultados produzidos pelo modelo.

⁹ Defini-se **comparação** como o processo de comparar os resultados produzidos pelo modelo proposto com os resultados produzidos por outros modelos.

treinamento.

1.3 Justificativa

Com este trabalho se espera ter contribuído para o avanço do conhecimento no domínio da inteligência artificial aplicada à sistemas de tempo real. Pretende-se também obter um modelo para previsão de cargas nodais de curto prazo, que possa ser utilizado pela CELESC na construção de um sistema automático e de tempo real, para previsão de cargas nodais de curto prazo em seu sistema de potência.

As companhias de transmissão e distribuição de energia elétrica precisam estimar a futura demanda da carga de curto prazo, tanto da carga global quanto da carga nodal, a ocorrer em seu sistema de potência. Uma das técnicas atualmente utilizadas para a elaboração das previsões é a construção de sistemas de previsão fundamentados na técnica de RNA's. Estes sistemas de previsão são normalmente baseados na RNA Perceptron Múltiplas Camadas, treinada com o algoritmo de Retropropagação. A MLP é robusta, previsível e produz bons resultados. Porém ela é uma RNA de treinamento lento e de difícil ajuste, o que dificulta sua aplicação em sistemas de tempo real.

As concessionárias de energia elétrica precisam operar com eficiência seus sistemas de transmissão e distribuição de energia elétrica. Esta necessidade tem levado ao uso de sistemas SCADA para supervisão e controle em tempo real dos sistemas de potência. Em sintonia com esta tendência, a CELESC está atualmente implantando um SCADA para auxiliar a operação de seu sistema elétrico. O uso destes sistemas de supervisão e controle propicia uma maior disponibilidade de informações, em menores prazos, a respeito do sistema controlado. Este fato torna vantajosa a construção dos sistemas de previsão de cargas com funcionamento integrado ao dos sistemas SCADA.

Os fatos expostos levaram a busca de uma arquitetura de RNA mais adequada à previsão de cargas em sistemas de tempo real, bem como a pesquisa de um modelo de RNA para uso na previsão de cargas de curto prazo na CELESC.

1.4 Principais Contribuições do Trabalho

As principais contribuições deste trabalho são:

- a) Aprofundar o conhecimento no domínio de RNA's aplicadas a sistemas de previsão de cargas em tempo real.
- b) Trazer mais informações a respeito do relacionamento das variáveis: temperatura ambiente (passada, presente e futura) e carga (passada e presente), com a carga futura (uma hora à frente), no Estado de Santa Catarina.
- c) Aumentar o conhecimento sobre as formas de modelagem destas variáveis e seus efeitos na precisão das previsões de carga.
- d) Mostrar que a avaliação dos resultados obtidos, normalmente executada por meio da mensuração dos erros médio e máximo e desvio padrão, pode ser enriquecida por uma análise gráfica dos resultados, a qual possibilita identificar características adicionais que podem subsidiar a construção de redes especializadas em prever cargas para períodos específicos.

1.5 Metodologia

O trabalho foi dividido em 5 macro atividades, nomeadas: levantamento da situação atual, obtenção e análise de dados, revisão bibliográfica, proposição de um modelo inicial e experimentação. Na etapa de levantamento da situação atual, verificou-se como a CELESC elabora as previsões de carga para seu sistema de potência e qual o conhecimento existente nesta empresa a respeito do domínio do problema. Em seguida, realizou-se a atividade de obtenção e análise de dados. Nesta segunda etapa, foi obtida da CELESC uma massa de dados relativa a leituras de carga e temperatura ambiente em seu sistema elétrico e efetuada uma análise da mesma, buscando conhecer o comportamento da demanda de

carga. Em paralelo com esta atividade foi realizada a atividade de revisão bibliográfica. Nesta etapa pesquisou-se quais modelos fundamentados na técnica de redes neurais já foram experimentados em previsão de cargas, arquiteturas de RNA alternativas, possíveis de serem experimentadas no domínio do problema e quais são as variáveis relacionadas e relevantes para a previsão de cargas. A atividade realizada na quarta etapa foi a de proposição de um modelo inicial. Nesta etapa, a partir dos resultados obtidos nas etapas anteriores, foi proposto um modelo alternativo aos identificados na revisão bibliográfica. A última atividade realizada foi a atividade de experimentação. Nesta última etapa o modelo inicialmente proposto foi construído e em seguida validado, ajustado verificado e finalmente comparado com um modelo baseado na arquitetura MLP. Os trabalhos desta última etapa foram realizados por meio de simulação computacional.

1.6 Abrangência do Trabalho

Em virtude dos prazos estabelecidos para conclusão deste trabalho, foi proposto e experimentado apenas uma arquitetura de RNA como alternativa à arquitetura MLP, bem como apenas a previsão da demanda ativa horária para a próxima hora. Desta forma, foram deixadas de lado a previsão da demanda de potência reativa e a previsão da demanda de potência ativa de muito curto prazo e de curto prazo em outros pontos futuros - tais como para a próxima meia hora ou para as próximas 24 horas. Tampouco não se experimentou prever as demandas de potência ativa de médio e longo prazos.

O modelo proposto foi experimentado com uma massa de dados referente a leituras de temperatura ambiente e carga de um transformador de uma das subestações da CELESC, relativas ao período de aproximadamente 1 mês. Esta limitação da quantidade de pontos e do período deve-se ao fato que por ocasião do início dos experimentos, o SCADA desta concessionária encontrava-se em fase de implantação e estes eram os únicos dados de leituras automáticas disponíveis. Os histórico de leituras coletadas manualmente pelos operadores das subestações não foram utilizados devido a baixa confiabilidade na sua precisão.

Embora recomendado pela bibliografia, não foi experimentado o uso no vetor de

entrada da RNA, das variáveis: luminosidade, velocidade do vento, umidade e cobertura solar (sol, parcialmente nublado, nublado, nublado com chuva fina ocasional e chuva). A limitação na experimentação com a composição do vetor de entrada foi devida a inexistência na CELESC de um histórico referente a estas variáveis.

1.7 Organização do Trabalho

Este trabalho está organizado em 5 capítulos: Introdução, Redes Neurais Artificiais e Previsão, O Modelo Proposto, Experimentação e finalmente Conclusões e Recomendações. A introdução, apresenta o problema objeto deste trabalho, seu contexto, sua evolução no tempo e o conhecimento científico acumulado a seu respeito. Apresenta ainda as questões e hipóteses de trabalho, os objetivos estabelecidos, a justificativa para tal empreendimento, a metodologia adotada para atingir tais objetivos, a abrangência estabelecida para o trabalho e sua organização. Já o Capítulo II, Redes Neurais Artificiais e Previsão, apresenta a base teórica utilizada para o desenvolvimento do trabalho. O Capítulo III, intitulado O Modelo Proposto, apresenta o modelo inicialmente escolhido para tratar o problema alvo. O Capítulo IV, Experimentação, descreve o processo de construção, validação e verificação do modelo proposto bem como sua comparação com um segundo modelo, baseado na arquitetura de RNA Perceptron Múltiplas Camadas, treinada com o algoritmo de Retro Propagação. Finalmente o Capítulo V, Conclusões e Recomendações, relata as conclusões a cerca do trabalho empreendido e apresenta recomendações para futuros trabalhos relacionados à previsão de cargas.

2. REDES NEURAIIS ARTIFICIAIS E PREVISÃO

Este capítulo apresenta a base teórica utilizada para o desenvolvimento deste trabalho. É conceituada de forma resumida a Inteligência Artificial e sua técnica de Redes Neurais Artificiais e é abordado o problema de previsão de cargas sob a ótica desta técnica. São comentadas as arquiteturas de Redes Neurais Artificiais MLP e RBF, a aquisição e modelagem dos dados, o treinamento das RNA's e os critérios para a avaliação das previsões.

2.1 Introdução

Inteligência Artificial – IA é uma área de conhecimento cujo propósito é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas que aparentemente necessitam *cognição* quando realizadas por humanos (Haykin, 1994). Tafner et. al. (1995) definem IA como um conjunto de técnicas de programação que têm como característica comum desempenhar funções que são normalmente associadas à inteligência humana, tais como: raciocínio, aprendizagem e auto-aperfeiçoamento. Inclui-se neste conjunto a técnica de Redes Neurais Artificiais – RNA's.

Inspiradas nas redes neurais biológicas, as Redes Neurais Artificiais tem sido aplicadas com sucesso na solução problemas em vários e distintos domínios, tais como: processamento de sinais, controle, reconhecimento de padrões, medicina, reconhecimento e produção de voz, e negócios (Fausett, 1994). Uma de suas propriedades, de importância fundamental, é a capacidade de aprender a partir de seu ambiente e de aperfeiçoar sua performance através do aprendizado (Haykin, 1994).

A previsão de cargas pode ser formulada como um problema onde o que se deseja é proceder um mapeamento não linear entre as entradas e as saídas de um sistema, represen-

tadas através de uma “*tupla*” vetorial composta por um vetor com as entradas (grandezas com valores conhecidos a “*priori*”) e outro com as saídas (grandezas cujos valores futuros se deseja conhecer) do sistema. De acordo com Dandolini (1997), as Redes Neurais Artificiais propiciam uma forma relativamente fácil para modelar e prever sistemas não lineares. Elas possuem a capacidade de construir um relacionamento não linear entre as entradas e saídas de um sistema, representadas pelas entradas e saídas da rede, através do aprendizado por exemplos (dispensando a necessidade de um especialista). As RNA’s são muito eficientes na aprendizagem de padrões em dados com ruído, incompletos e que podem conter dados contraditórios. Também são eficientes em questões onde especialistas são ineficazes ou onde regras claras a respeito do comportamento do problema em questão não podem ser facilmente formuláveis. Segundo Kiartzis et al. (1997), a capacidade de aprender através de exemplos faz da Rede Neural Artificial um previsor ideal para aplicações de previsão de cargas.

Para a construção bem sucedida de uma aplicação baseada em RNA’s, há três pontos importantes que necessitam de atenção especial: o processo de aquisição e modelagem dos dados, a seleção da arquitetura de rede mais apropriada para o problema em questão e o treinamento da rede (Skapura, 1996). Fogelman-Soulié (1995), citado em Dandolini (1997), classifica as RNA’s, segundo suas principais áreas de atuação, em quatro categorias principais: *classificação e diagnóstico; aproximação de função; compressão, extração de características e quantização; otimização*. Sob esta ótica, o problema da previsão de cargas classifica-se como tratável pelas RNA’s da categoria *aproximação de função*. As arquiteturas de Redes Neurais Artificiais Perceptron Múltiplas Camadas (*Multilayer Perceptron*) treinada com o algoritmo de Retropropagação (*Backpropagation*) e Função de Base Radial (Radial Basis Function – RBF) comportam-se como *aproximadores universais* (Haykin, 1994).

2.2 Arquitetura Perceptron Múltiplas Camadas

A arquitetura Perceptron Múltiplas Camadas (*Multilayer Perceptron*), treinada com o algoritmo de Retropropagação (*Backpropagation*), é o paradigma de Rede Neural Artificial de propósito mais geral e mais utilizado (Skapura, 1996). No domínio da previsão de

cargas através de Redes Neurais Artificiais, esta é a arquitetura de RNA usualmente utilizada (Xiao & McLaren, 1995, Zebulum et al., 1996). No campo de aplicações financeiras, também a MLP é a RNA normalmente utilizada (Skapura, 1996). Para este autor, o uso maciço desta arquitetura de RNA na indústria financeira provavelmente não está associado a uma característica especial da MLP que a faz mais apropriada para aplicações financeiras, e sim ao fato de que por ser a Rede Neural Artificial mais utilizada isto a faz também a mais acessível através dos pacotes de software para simulação disponíveis comercialmente.

A Perceptron Múltiplas Camadas (*Multilayer Perceptron*), treinada com o algoritmo de Retropropagação (*Backpropagation*), é uma RNA não linear, de múltiplas camadas e de percorrimento à frente (*feedforward*). Esta RNA comporta-se como um aproximador universal. A MLP mostra-se um veículo prático para realização de um mapeamento não linear, de natureza geral, entre entrada e saída. Este tipo de treinamento é um método de gradiente descendente, usado para minimizar o erro quadrático total da saída computada pela rede (Fausett, 1994, Haykin, 1994, Skapura, 1996). O Anexo 5: Arquitetura Perceptron Múltiplas Camadas descreve de forma detalhada esta arquitetura de RNA.

A rede MLP pode ser vista como uma aplicação do método de otimização conhecido como *aproximação estocástica*. Ela realiza aproximações globais para o mapeamento entre a entrada e a saída da rede. A vantagem do uso do método global é um menor requerimento de capacidade de armazenamento e melhor performance de generalização. Sua desvantagem é a lentidão do processo de aprendizagem Haykin (1994). Também não há uma forma fácil de se obter os parâmetros ótimos para esta arquitetura. Estes fatores dificultam a aplicação da arquitetura MLP em sistemas de tempo real.

Buscando melhorar a performance ou especializar a MLP para o trato de problemas específicos, alguns pesquisadores criaram variações desta RNA. Estas arquiteturas alternativas apresentam um modelo de processamento para o armazenamento de informação levemente diferente da arquitetura original (Skapura 1996). A partir das informações apresentadas por este autor, conclui-se que duas destas arquiteturas apresentam potencial para utilização em previsão de cargas: a rede de Jordan e a rede de Ligação Funcional (*Functional-Link*).

A rede de Jordan é uma RNA recorrente. Sua arquitetura é uma variação da rede de

Elman (também uma RNA recorrente). O principal aspecto desta rede é o uso de *unidades de estado*, conectadas com os neurônios de saída e interconectadas entre si, como parte do vetor de entrada da rede. As unidades de estado são neurônios cuja função é fornecer “*feedback*” a respeito da saída prévia produzida pela rede. As vantagens apresentadas pela rede de Jordan são suas maiores facilidades em distinguir entre padrões de entrada similares e em aprender padrões que estão relacionados entre si dentro de uma seqüência temporal específica. Choueiki et. al. (1997), em seus experimentos buscando otimizar a construção de uma MLP voltada à previsão de cargas, relatam uma ligeira melhora nos resultados obtidos com o uso da rede de Elman e recomendam o seu uso em aplicações de previsão de carga.

A rede de Ligação Funcional distingue-se basicamente da MLP pelas forma de funcionamento da camada de entrada da rede. Para a MLP, a camada de entrada tem apenas a finalidade de transferir os valores de entrada, de forma inalterada, para sua camada oculta. Na rede de Ligação Funcional os valores da entrada são tratados por uma ligação funcional, o que permite que a camada de entrada modifique os padrões de entrada antes de distribuí-los para a segunda camada da rede. Uma vantagem no uso da ligação funcional é a possibilidade de redução do número de neurônios necessários a arquitetura da rede (simplificação da arquitetura).

2.3 Arquitetura Função de Base Radial

A arquitetura Função de Base Radial (*Radial Basis Function*), doravante denominada de RBF, é uma RNA múltiplas camadas e de percorrimento à frente (*feedforward*). Da mesma forma que a MLP, esta rede também comporta-se como um aproximador universal. De acordo com Haykin (1994), sempre existe uma rede RBF capaz de reproduzir com precisão o comportamento de uma rede MLP, e vice versa. Segundo este autor, duas das características da arquitetura RBF são suas capacidade de aprendizado rápido e sensibilidade reduzida a ordem de apresentação dos dados de treinamento.

O método função de base radial tem suas origens nas técnicas de interpolação exata de um conjunto de dados dentro de um espaço multidimensional (Powell, 1987, cf. in

Bishop, 1995). O aumento dimensional que ocorre na segunda camada (camada oculta) da rede está baseado no princípio, enunciado por Cover (1965, cf. in Haykin, 1994) de que um complexo problema de classificação de padrões lançado de forma não linear em um espaço de grande dimensão é mais fácil de ser linearmente separável do que em um espaço de pequena dimensão. Segundo Haykin (1994), a funcionalidade da RBF pode ser vista como o *ajuste de uma curva (aproximação)* em um espaço de grande dimensão. Visto sob esta perspectiva, o processo de aprendizado da RBF equivale a encontrar uma superfície em um espaço multidimensional que dá o melhor ajuste para os dados de treinamento. Generalização, nesta arquitetura equivale ao uso desta superfície multidimensional para interpolar os dados de teste. O Anexo 6: Arquitetura Função de Base Radial descreve de forma detalhada esta arquitetura de RNA.

A rede RBF realiza aproximações locais para o mapeamento entre a entrada e a saída da rede. A vantagem do uso do método local é sua capacidade de aprendizado rápido e conseqüente possibilidade de operar em tempo real. O aprendizado pelo método local também requer uma quantidade pequena - quando comparado com o método global - de exemplos de treinamento para aprender uma tarefa simples. A desvantagem dos métodos locais é sua necessidade de grandes quantidades de memória (Haykin, 1996).

Dandolini (1997) relata os resultados de seus experimentos com as arquiteturas MLP e RBF, buscando classificar empresas quanto as suas saúdes financeiras. Embora este enfoque (classificação) seja diferente do enfoque deste trabalho (previsão), em ambos os casos deseja-se que a RNA realize a aproximação de uma função não linear, bem como possua capacidade de generalização. No decorrer de seu trabalho, a autora reporta como melhor resultado alcançado a obtenção do percentual de acerto no teste, de 81,25% para ambas as arquiteturas MLP e RBF. Neste experimento, a rede RBF se mostrou 29 vezes mais rápida que a MLP. Na conclusão de seu trabalho, Dandolini, ao recomendar o uso da RBF para problemas de classificação, cita também a facilidade para a determinação dos parâmetros ótimos para a rede.

Os resultados obtidos por Dandolini (1997) ratificam as afirmações de Haykin (1994) a respeito da rapidez da RBF, quando comparada a MLP, e da equivalência destas duas arquiteturas quanto a capacidade de generalização. Confirmam ainda os resultados obtidos por Oliveira et al. (1998), referentes à previsões em séries temporais econômicas

por meio das arquiteturas MLP e RBF. Estes autores também comprovam em seus experimentos a rapidez e maior facilidade na determinação dos parâmetros ótimos de funcionamento da RBF, bem como a equivalência destas duas arquiteturas quanto a capacidade de generalizar.

2.4 Treinamento da Rede

Fausett (1994) define aprendizado como o processo de formação de associações entre padrões relacionados. Aristóteles observou que a memória humana conecta itens (idéias, sensações, etc.) que são similares, que são contrários, que ocorrem próximos entre si ou que ocorrem de forma fortemente sucessiva (Kohonen, 1987, citado em Fausett, 1994). A Rede Neural Artificial MLP utiliza o processo de aprendizado por treinamento supervisionado. Já a RBF utiliza um processo de aprendizado híbrido, realizado em duas etapas. Na primeira etapa, ela utiliza o aprendizado por treinamento não supervisionado e na segunda etapa, os conceitos do processo de aprendizado por treinamento supervisionado.

Segundo Haykin (1994), o processo de treinamento supervisionado pode ser visto como um problema de ajuste de curva. A rede, por si só, pode ser considerada simplesmente como um mapeamento não linear entre a entrada e a saída. Desta forma, o que se deseja da rede é que ela seja capaz de produzir uma boa interpolação não linear dos dados de entrada. Esta propriedade é conhecida como *generalização*. Uma rede neural com boa capacidade de generalização produzirá um correto mapeamento entre a entrada e a saída sempre que a entrada seja levemente diferente dos exemplos usados no seu treinamento. Por outro lado, se durante o treinamento de uma rede MLP, por muitas vezes lhe for apresentado os mesmos pares de treino, ela perderá a capacidade de generalizar e passará a memorizar estes padrões.

A generalização é influenciada por três fatores: o tamanho e eficiência do conjunto de treinamento, a arquitetura da rede e a complexidade física do problema em questão. A arquitetura da rede está diretamente relacionada ao problema em questão e sobre o problema não é possível controle. Assim, controlar o tamanho e eficiência do conjunto de

treino é a forma mais simples de se alcançar uma boa generalização (Hush & Horne, 1993, citado em Haykin, 1994).

Para a RNA Perceptron Múltiplas Camadas de uma camada oculta, treinada com o algoritmo de Retropropagação, Haykin (1994) e Fausett (1994) recomendam um número de pares de treinamento de acordo com a (1).

$$N > (W / \epsilon) \quad 1$$

Onde:

N = número de pares de treinamento

W = número de conexões sinápticas (pesos)

ϵ = fração de erro permitido no teste

Desta forma, em uma MLP, para um percentual de erro nos testes de 10%, o número de pares de treinamento deve ser aproximadamente 10 vezes o número de pesos existentes na rede. Porém, Bakirtzis, Petridis, et al. (1995) relatam a obtenção de um percentual **médio** de erro nos testes de 2,34%, utilizando uma MLP com 36.288 conexões e um conjunto de treinamento composto de aproximadamente 365 exemplos. Consequentemente, embora também não tenha sido relatado o percentual **máximo** de erro obtido nos testes, é cabível supor que, para a previsão de cargas, também há outras variáveis que devem ser consideradas para a obtenção de uma estimativa acurada do tamanho mínimo necessário ao conjunto de treino.

Não se encontrou na literatura referências a uma metodologia que permita o cálculo do tamanho do conjunto de treino necessário ao treinamento das RNA's utilizadas na previsão de cargas. Observou-se porém que seu tamanho esta associado a uma janela de tempo cujo tamanho varia em função do nível de especialização da RNA e dos resultados obtidos por cada autor. Para a previsão da carga horária, a literatura consultada cita o uso de janelas de tempo com valores desde 2 meses (Lu et. al., 1993) e 3 meses (Xiao & McLaren, 1995, Wakita & Yokoyama, 1995) até 1 a 5 anos (Bakirtzis, Petridis, et al., 1995, Kirtzis, 1997, Choueiki et. al., 1997).

Uma das características da carga é sua não-estacionaridade. Em decorrência disto, é recomendável que a RNA seja treinada periodicamente, de forma a aprender o comportamento mais recente da carga. A frequência de treinamento sugerida na bibliografia varia de anual à diária. Bakirtzis, Petridis, et al. (1995), ao comparar o treinamento anual com o mensal e o diário, relatam ganhos de 8% e 11% com o uso dos treinamentos mensal e diário, respectivamente. Considerando-se o percentual de erro médio, com treinamento anual, (obtido por estes autores) de 2,34%, estes ganhos de 8% e 11%, traduzem-se em percentuais de erro médios de 2,15% e 2,08%, respectivamente.

2.5 Aquisição e Modelagem dos Dados

As atividades de aquisição e modelagem dos dados tem como objetivos identificar as variáveis que tem influência na carga futura que se deseja prever e modela-las adequadamente, de forma a compor o vetor de entrada da Rede Neural Artificial. Segundo Xiao e McLaren (1995), durante a construção da RNA, as atividades de maior relevância são a escolha da arquitetura da rede e a seleção dos conjuntos de treinamento. A seleção das variáveis de entrada da rede é parte da escolha da arquitetura. Para esta atividade não há uma regra geral a ser seguida. Utiliza-se heurística, experimentação, análise estatística dos dados e relatos de trabalhos anteriores para determinar quais variáveis tem influência significativa na carga do sistema. De acordo com Lu et. al. (1993), a arquitetura da RNA é dependente das características individuais dos sistemas elétricos. Sistemas com diferentes características de carga requerem RNA's com diferentes arquiteturas. Entretanto, uma vez que a arquitetura é identificada para um dado sistema, ela não precisa ser modificada frequentemente.

Cargas de curto prazo são dependentes principalmente de combinações não lineares de variáveis que podem ser classificadas, de acordo com suas dependências, em fatores climáticos, sociais, sazonais e aleatórios. As condições climáticas são responsáveis por variações significativas na carga (Leite, 1997, Xiao & McLaren, 1995). A maioria das concessionárias de energia elétrica tem, em seu sistema de potência, cargas sensíveis às condições climáticas, tais como sistemas de aquecimento e refrigeração. Nos modelos que utilizam condições climáticas a temperatura é a variável que é sempre levada em conside-

ração. Em muitos sistemas de potência, temperatura é a mais importante variável climática no que se refere aos seus efeitos sobre a carga (Xiao & McLaren, 1995). Para Abu-El-Magdad (1981) e Ohlsson (1994), citados em Leite (1997), a intensidade luminosa e/ou nebulosidade é uma variável climática tão importante quanto a temperatura. Sua variação afeta o uso da energia elétrica para iluminação de forma quase instantânea, enquanto a variação da temperatura reflete-se de forma mais lenta no comportamento da carga. Outras variáveis climáticas que influenciam na carga são a umidade, que se reflete especialmente nas cargas relativas a equipamentos de ar condicionado (AlFuhaid et. al., 1997), e a velocidade do vento (Leite, 1997, Xiao & McLaren, 1995). As variáveis sociais que afetam a carga são as atividades humanas relacionadas ao trabalho, escola e lazer, refletidas nos ciclos semanais e diários e nos feriados. Já os fatores sazonais são o crescimento da carga e as variações climáticas decorrentes das mudanças de estações. Por fim, os fatores aleatórios são os efeitos acidentais causados por eventos fortuitos distintos dos já descritos. Nesta categoria incluem-se perturbações no sistema elétrico, variações de carga ocasionadas por mudança no regime de operação de grandes indústrias ou eventos ocasionais relacionados com o clima e a vida social, desportiva e cultural (temporais, inundações, jogos de futebol, carnaval, festas religiosas, conflitos, greves etc).

Relacionou-se a seguir alguns exemplos de variáveis e suas respectivas modelagens, utilizadas ou sugeridas na bibliografia para compor o vetor de entrada da rede.

- Temperatura: previstas e passadas, horária, máxima, mínima, média e desvio padrão.
- Umidade: previstas e passadas, horária, máxima e mínima.
- Indicador de intensidade luminosa.
- Indicador de nebulosidade (cobertura solar).
- Velocidade do vento.
- Hora do dia, para um determinado dia da semana. Geralmente é representada em números binários.
- Dia da semana: Geralmente representado por números binários. Podem também

ser representados por valores decimais.

- Dia do ano: Geralmente representado por um número binário. Uma alternativa proposta por Kiartzis et. al. (1997) é representá-lo através de uma função trigonométrica, da seguinte forma: *seno* ($2\pi d/365$) e *coseno* ($2\pi d/365$), onde $d=1, 2, \dots, 365$ é o dia do ano .
- Indicador de evento especial ou feriado.
- Carga passadas: nas últimas horas (no máximo os 48 últimos valores horários), 24 horas atrás e 1 semana atrás.
- Cargas previstas: máxima e mínima.
- Energia diária prevista.

A composição do vetor de entrada da rede também está diretamente relacionada ao nível de especialização adotado para a Rede Neural Artificial, que também reflete na composição do conjunto de treinamento da rede. Um exemplo é o uso ou não de um indicador de evento especial ou feriado como parte do vetor de entrada da rede. Alguns autores tem preferido utilizar redes especializadas nestes dias especiais ou rotinas específicas para correção dos desvios na previsão ocorridas em função destes eventos, em substituição a este indicador. Na primeira forma, previsão por meio de redes especializadas, utiliza-se uma RNA específica para a previsão de cargas do feriado. Esta rede é treinada com dados obtidos a partir de um histórico do comportamento da carga em feriados semelhantes (Mohammed et. al., 1994, citado em Bakirtzis, Petridis, et al., 1995). A segunda forma emprega a mesma RNA utilizada para previsão dos dias normais porém tendo sua previsão corrigida por um índice baseado no conhecimento acumulado sobre o comportamento da carga em feriados (Papalexopoulos et. al., 1994, citado em Bakirtzis, Petridis, et al., 1995).

Uma outra maneira utilizada para especializar as RNA's é construí-las para previsão de cargas em determinados conjuntos de dias da semana. A análise das curvas de carga diárias mostra similaridades de comportamento no consumo de energia elétrica em determinados dias da semana. Em função deste fato, buscando aumentar a precisão das previ-

sões, Zebulum et al. (1996) e AlFuhaid et. al. (1997), dentre outros, agrupam os dias com maior similaridade no perfil de consumo e especializam as RNA's para previsão de cargas para cada grupo identificado. Todavia, Bakirtzis, Petridis, et al. (1995), em seus experimentos comparando a precisão das previsões da carga horária obtidas por uma RNA para uso em previsões para todos os dias da semana – *rede tipo A* (o dia da semana é codificado como parte da entrada da rede, em binário – 7 bits) versus a precisão das previsões obtidas com redes especializadas para cada dia da semana – *rede tipo B*, obtiveram resultados ligeiramente superiores com o uso da arquitetura *A* (genérica), desde que utilizando-se um número similar de exemplos de treinamento para as duas RNA's. Os conjuntos de treinamento foram construídos a partir do histórico dos dados relativos a um período de 1 ano (para a rede tipo A) e de 5 anos (para as redes do tipo B). Os percentuais de erro médios obtidos com estes conjuntos de treinamento foram de 2,34% e 2,40% para as redes do tipo A e B, respectivamente.

Durante a fase de elaboração do conjunto de treinamento da RNA, é relevante se levar em conta as irregularidades existentes nos dados. Em um sistema de transmissão e distribuição de energia elétrica, monitorado por um sistema de supervisão e controle em tempo real, o histórico de dados disponível é constituído pelas informações periódicas, oriundas de sensores de campo, relativas a grandezas elétricas (tensão, cargas ativa e reativa, ...), estados de equipamentos e condições climáticas. Os valores destas informações estão sujeitos a erros devidos a precisão, desajustes e falhas dos equipamentos envolvidos com a medição e transmissão das leituras. Além destes erros, constam no histórico valores irregulares de dados relativos a grandezas elétricas e estados de equipamentos, decorrentes das interrupções no fornecimento de energia.

RNA's aprendem a partir dos exemplos de situações passadas que lhe são apresentados. Lu et. al. (1993) alertam que RNA's (os autores utilizaram em seus experimentos a arquitetura MLP) são sensíveis a dados com erros. De acordo com Kirtzis et. al. (1997), devido as irregularidades nos dados de carga, dois tipos de problemas são observados em sistemas de previsão de cargas baseados em RNA's. O primeiro problema é que durante a fase de treinamento da RNA, dados de carga irregulares resultam em elevados erros de treinamento. O segundo problema ocorre durante a fase de utilização da rede. Nesta fase, os dados irregulares são introduzidos como parte da entrada da RNA e ocasionam elevados

erros de previsão.

Com o propósito de superar os problemas decorrentes do uso de dados com erros, Lu et. al. (1993) recomendam o uso de técnicas inteligentes para filtragem dos dados a serem apresentados à RNA. Kiartzis et. al. (1997) recomendam que os *dados brutos*¹⁰ sejam *pré-processados*¹¹ antes de serem apresentados à RNA. Em seus experimentos, estes autores experimentaram pré-processar os dados de cargas, corrigindo-os a partir de sua comparação com curvas *típicas* de carga. Os percentuais de erro médio nas previsões, obtidos com o uso de dados brutos versus o uso de dados pré-processados, foram de 2,21% e 1, 86%. Cabe ressaltar que ambas as RNA's foram treinadas com dados pré-processados. Uma segunda alternativa seria utilizar dados pré-processados por um *estimador de estados*¹².

2.6 Avaliação das Previsões

Não foi encontrada uma metodologia padrão para avaliação da qualidade das previsões de carga. O método mais utilizado, identificado na bibliografia consultada é o MAPE - Mean Absolute Percentage Error (2). Outros métodos também identificados são: RMSE - Root Mean Squared Error (4), EPMax - Erro Máximo Percentual (5), EA - Erro Absoluto

¹⁰ Dados na forma bruta significam dados da forma que foram originalmente obtidos dos sensores, portanto sujeitos a erros em seus valores, devidos a falhas ou desajustes nos equipamentos envolvidos nas medições, bem como aos erros inerentes associados aos próprios sensores.

¹¹ O pré-processamento implica em procurar corrigir os erros existentes nos dados brutos, bem como repor as leituras inexistentes decorrentes de falha nos sensores ou interrupções no fornecimento de energia elétrica.

¹² Um estimador de estados (do tipo estático) pode ser definido como sendo uma função que, a partir de um conjunto de medidas $z \in Z$, contendo erros (ruídos) $v \in V$ (introduzidos pelo sistema de medição), permite determinar um vetor \hat{X} cujas componentes são as melhores estimativas possíveis para as componentes do vetor de estado X da rede elétrica. O vetor de estado X da rede elétrica é constituído pelos valores dos ângulos elétricos e pelos módulos das tensões nas barras do sistema, enquanto que o vetor de medidas Z tem por componentes as medidas dos fluxos de potência ativa e reativa nas linhas de transmissão, as medidas das injeções de potência ativa e reativa e as medidas dos valores das tensões nas barras deste sistema elétrico.

(7), CV – Coeficiente de Variação (9) e Desvio Padrão. O Coeficiente de Variação, da mesma forma que o Desvio Padrão, é uma medida de dispersão. Ele indica o espalhamento do erro. Leite (1997) utiliza uma variação dos índices MAPE, EPMax e EA, cujos novos índices são respectivamente representados pelos índices MAPE* (3), EPMax* (6) e EA* (8). A diferença entre eles é que os índices originais são apresentados como um percentual da carga real (valores absolutos) e os novos, apresentados como um percentual da *carga base* (valores relativos). Neste trabalho é utilizada como carga base o maior valor inteiro da carga máxima verificada em todo conjunto de medidas disponíveis.

$$\text{MAPE} = \frac{100}{n} \sum_{k=1}^n \frac{|\hat{C}_k - C_k|}{C_k} \quad 2$$

$$\text{MAPE}^* = \frac{100}{C_{base}} \frac{1}{n} \sum_{k=1}^n |\hat{C}_k - C_k| \quad 3$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{C}_k - C_k)^2} \quad 4$$

$$\text{EPMax} = 100 \text{Max} \left(\sum_{k=1}^n \frac{|\hat{C}_k - C_k|}{C_k} \right) \quad 5$$

$$\text{EPMax}^* = \frac{100}{C_{base}} \text{Max} \left(\sum_{k=1}^n |\hat{C}_k - C_k| \right) \quad 6$$

$$EA = 100 \frac{|\hat{C}_k - C_k|}{C_k} \quad 7$$

$$EA^* = 100 \frac{|\hat{C}_k - C_k|}{C_{base}} \quad 8$$

$$CV = \frac{1}{\bar{C}} \sqrt{\frac{1}{n} \sum_{k=1}^n (\hat{C}_k - C_k)^2} \quad 9$$

Onde:

C_k = valor real da carga para o k-ésimo elemento da série

\hat{C}_k = valor previsto da carga para o k-ésimo elemento da série

\bar{C} = valor médio da carga da série

C_{base} = maior valor inteiro da carga máxima verificada nas séries disponíveis

n = número de elementos da série

2.7 Conclusões

É inegável que o uso de condições ambientais futuras como variáveis do vetor de entrada da rede resulta na obtenção de previsões mais precisas. Porém, este uso conduz a duas importantes questões que precisam ser levadas em consideração. A primeira é que nos experimentos usualmente relatados, os testes são realizados utilizando parte da massa de dados (histórico) disponível. Isto significa que o estado das condições ambientais futuras, incluídas como parte do vetor de entrada e utilizadas nos testes, não são valores previstos (obtidos a partir de algum sistema de previsão) e sim valores reais. Assim, os resultados obtidos nos testes da rede, embora teoricamente corretos, estão superestimados pois pressupõem a inexistência de erros nas previsões destas condições climáticas. A segunda questão é que o uso das previsões das condições climáticas no vetor de entrada, implica na

necessidade de se dispor de uma fonte altamente confiável para o fornecimento de previsões para estas grandezas. Esta segunda questão, embora não impeça, dificulta tornar operacional tal sistema de previsão de cargas em uma concessionária de energia elétrica nacional.

3. O MODELO PROPOSTO

Este capítulo apresenta a proposta de um modelo alternativo ao modelo MLP, para uso na previsão de cargas. Se justifica a escolha da arquitetura RBF como arquitetura básica do modelo e descreve-se a entrada, a camada intermediária e a saída do modelo proposto.

3.1 Arquitetura Básica

A arquitetura Função de Base Radial foi a arquitetura de RNA escolhida para compor o modelo proposto. Oliveira et al. (1998), Dandolini (1997) e Haykin (1994) reportam a rapidez da arquitetura Função de Base Radial, quando comparada a arquitetura Perceptron Múltiplas Camadas, bem como a equivalência destas duas arquiteturas quanto a capacidade de *generalizar*. Leite (1997), em seu trabalho relativo a previsão da carga nodal de curto prazo, sugere como tema para trabalho futuro a *“Implementação de um modelo de previsão cujo algoritmo seja rápido e eficiente, utilizando-se: métodos de segunda ordem, evitando, assim, que o usuário tenha que definir η e α , uma rede RBF (Radial Basis Function), ou outra metodologia que permita atingir esse objetivo.”* (η e α referem-se a taxa de aprendizado e ao momento, respectivamente). Outro tema sugerido por este autor é o *“desenvolvimento de um algoritmo que gere índices de confiabilidade para os valores previstos.”* As considerações destes autores influenciaram fortemente a escolha da RBF como arquitetura básica de RNA do modelo proposto. Além das características de rapidez e capacidade de *generalização* desta arquitetura, é teoricamente possível projetar uma RNA Função de Base Radial de forma a produzir índices de confiabilidade como parte de sua saída.

3.2 Entrada da RNA

A melhor entrada para a RNA é aquela que possibilite que o aprendizado sobre o comportamento da demanda da potência ativa (carga) ocorra o mais rapidamente e com o menor erro possível. Com o propósito de definir a melhor entrada para a RNA, foi selecionado inicialmente um conjunto de variáveis candidatas a compor o vetor de entrada da rede. Durante a etapa de Experimentação, utilizou-se este conjunto de variáveis candidatas como a base para a composição dos vários vetores de entradas testados. A escolha das variáveis candidatas foi baseada na revisão bibliográfica realizada, na massa de dados disponível e no conhecimento extraído dos técnicos da CELESC sobre o comportamento do sistema elétrico catarinense. A descrição e forma de codificação das variáveis são descritas a seguir.

Hora do dia (H_{bin} , H_{sen} e H_{cos}). A variável **hora do dia** foi codificada de duas formas distintas. Na primeira, a hora do dia foi codificada de forma binária (H_{bin}) e representada em 5 neurônios. Esta é a forma de representação normalmente encontrada na literatura. Desta forma a variável **hora do dia** é codificada em 24 representações distintas, o que é coerente, pois o comportamento da demanda de potência é distinto para cada hora em questão. Isto porém, elimina a possibilidade de representar o deslocamento temporal da hora dentro do dia. Na segunda forma, buscando representar também este deslocamento temporal, utilizou-se a idéia apresentada em Kiartzis et al. (1997), para a representação do dia do ano e codificou-se a **hora do dia** através de uma função trigonométrica. Assim, associou-se o transcorrer das horas dentro de um dia, com o deslocamento de um ponto sobre uma circunferência cujo perímetro representa as 24 horas do dia. A **hora do dia** foi então codificada (em 2 neurônios) como o seno (H_{sen}) e o cosseno (H_{cos}) do ângulo formado pelo deslocamento do ponto. Esta forma de representação também possibilita uma redução de 3 neurônios no tamanho do vetor de entrada.

Dia da semana (D_s). O dia da semana (de domingo à sábado) foi codificado de forma binária e representado em 3 neurônios.

Carga na hora h (C_h). Foi representado em 1 neurônio, a potência nodal ativa (em megawatts) na hora h .

Carga na hora $h-23$ (C_{h-23}). Foi representado em 1 neurônio, a potência nodal ativa (em megawatts) na hora $h-23$.

Carga na hora $h-24$ (C_{h-24}). Foi representado em 1 neurônio, a potência nodal ativa (em megawatts) na hora $h-24$.

Carga na hora $h-167$ (C_{h-167}). Foi representado em 1 neurônio, a potência nodal ativa (em megawatts) na hora $h-167$.

Carga na hora $h-168$ (C_{h-168}). Foi representado em 1 neurônio, a potência nodal ativa (em megawatts) na hora $h-168$ (1 semana atrás).

Temperatura ambiente na hora h (T_h). A temperatura ambiente na hora h , em graus Celsius, foi representada em 1 neurônio.

Temperatura ambiente na hora $h-167$ (T_{h-167}). A temperatura ambiente na hora $h-167$, em graus Celsius, foi representada em 1 neurônio.

Temperatura ambiente na hora $h-168$ (T_{h-168}). A temperatura ambiente na hora $h-168$, em graus Celsius, foi representada em 1 neurônio.

Temperatura ambiente uma hora à frente (T_{h+1}). Foi também representada em 1 neurônio, a temperatura ambiente, em graus Celsius, na hora $h+1$.

Diferença da Carga entre a hora h e a hora $h-1$ (DMw). Foi codificado em 1 neurônio a diferença entre a potência ativa na hora h e a potência ativa na hora $h-1$ ($MW_h - MW_{h-1}$).

Diferença da Carga entre a hora $h-168$ e a hora $h-169$ ($DMw_{h168-h169}$). Foi codificado em 1 neurônio a diferença entre a potência ativa na hora $h-168$ e a potência ativa na hora $h-169$ ($MW_{h168} - MW_{h-169}$).

Coefficiente de variação da carga entre a hora h e a hora $h-1$ (CMw). Foi codificado em 1 neurônio o coeficiente de variação da potência ativa entre a hora h e a hora $h-$

$$1 ((C_h - C_{h-1}) / C_{h-1}).$$

Percentual de variação da carga entre a hora h e a hora h-1 (PMw). Foi codificado em 1 neurônio o percentual de variação da potência ativa entre a hora h e a hora h-1 ($100(C_h - C_{h-1}) / C_{h-1}$).

Diferença da temperatura ambiente entre a hora h e a hora h-1 (DT). Foi codificado também em 1 neurônio a diferença, em graus Celsius, entre a temperatura ambiente na hora h e a temperatura ambiente na hora h-1 ($T_h - T_{h-1}$).

Diferença da temperatura ambiente entre a hora h-168 e a hora h-169 (DT_{h168-h169}). Foi codificado também em 1 neurônio a diferença, em graus Celsius, entre a temperatura ambiente na hora h-168 e a temperatura ambiente na hora h-169 ($T_{h-168} - T_{h-169}$).

Coefficiente de variação da temperatura ambiente entre a hora h e a hora h-1 (CT). Foi codificado em 1 neurônio o coeficiente de variação da temperatura ambiente entre a h e a hora h-1 ($(T_h - T_{h-1}) / T_{h-1}$).

Percentual de variação da temperatura ambiente entre a hora h e a hora h-1 (PT). Foi codificado em 1 neurônio o percentual de variação da temperatura ambiente entre a h e a hora h-1 ($100(T_h - T_{h-1}) / T_{h-1}$).

3.3 Camada Intermediária da RNA

Durante o treinamento da RNA, na camada intermediária da RBF, os padrões oriundos da camada de entrada são classificados e agrupados em grupos (*clusters*) segundo sua similaridade com o padrão que identifica cada agrupamento (*cluster*). No modelo proposto, o padrão que identifica cada agrupamento (centro do agrupamento) foi obtido por meio do algoritmo de formação de agrupamentos (*clusterização*) **K-Médias** (*K-Means*, Moody & Darken, 1989, citado em Bishop, 1995). A mensuração da similaridade entre o padrão de entrada e o centro do agrupamento foi efetuada através da distância Euclidiana entre os padrões (Haykin, 1994, Pandya & Macy, 1995). Ao final do treinamento da rede, o tamanho de cada agrupamento (raio do agrupamento) foi fixado como a distância Euclidiana máxima do agrupamento.

O valor do sinal de saída de cada agrupamento é o valor de saída da função de base radial adotada para o agrupamento. Neste trabalho utilizou-se a função Gaussiana como função de ativação para todos os agrupamentos da camada intermediária.

3.4 Saída da RNA

A saída da RNA é a previsão do valor da carga uma hora à frente ($h+1$). Além da carga em valores absolutos, experimentou-se também prever sua variação entre a hora h e a hora $h+1$. O valor de saída da rede foi codificado em 1 neurônio. Neste trabalho utilizou-se a função identidade como função de ativação para o neurônio da camada de saída.

4. EXPERIMENTAÇÃO

Este capítulo relata as experiências realizadas com o modelo de rede neural inicialmente escolhido. Se descreve o processo de construção, validação e verificação do modelo proposto, bem como sua comparação com um segundo modelo, baseado na arquitetura de RNA Perceptron Múltiplas Camadas, treinada com o algoritmo de Retropropagação.

4.1 Organização dos Experimentos

4.1.1 Metodologia Adotada

O modelo proposto foi construído, *validado, verificado e comparado* por meio de simulação computacional. Os experimentos foram organizados em duas etapas. Na primeira etapa construiu-se e ajustou-se o modelo de RNA proposto no Capítulo 3, de forma a maximizar seu desempenho computacional e minimizar os erros das previsões. Na segunda etapa, foi construído e ajustado um segundo modelo, baseado na arquitetura de RNA Perceptron Múltiplas Camadas (utilizou-se 3 camadas), treinada com o algoritmo de Retropropagação. Concluídos os ajustes do Modelo MLP, comparou-se os resultados obtidos na primeira etapa com os resultados obtidos nesta etapa.

4.1.2 Mensuração dos Resultados

A qualidade das previsões produzidas pelas RNA's foi mensurada por meio de 3 indicadores distintos. A escolha dos indicadores foi fundamentada no propósito de medir os erros relativos máximo e médio, bem como o espalhamento do erro. Os indicadores utilizados foram os índices MAPE* (Erro Médio Percentual), EPMax* (Erro Máximo Percentual) e CV (Coeficiente de Variação), descritos no capítulo 2.6. Para o cálculo dos índices relativos, utilizou-se como carga base o primeiro valor inteiro acima da carga máxima

verificada na massa de dados disponível (22,8 MW). O valor de carga base utilizado foi 23 MW. Com o propósito de enriquecer a fase de verificação, além do uso dos indicadores citados, se efetuou uma análise dos gráficos construídos com os valores previstos durante a fase de testes versus os valores reais da série.

4.1.3 Ambiente dos Experimentos

Os experimentos foram realizados sob as seguintes condições:

- As RNA's foram construídas em software, a partir dos códigos elaborados e utilizados por Oliveira et. al. (1998). O código da rede RBF foi construído a partir dos conhecimentos teóricos descritos em Haykin (1994), Orr (1996) e Pandya e Macy (1995). Já a rede MLP foi codificada a partir do algoritmo proposto em Fausett (1994). Para a MLP, utilizou-se a função de ativação sigmoide bipolar.
- Os experimentos foram realizados sob o ambiente de computação científica **MatLab**.
- A massa de dados utilizada foi obtida junto às Centrais Elétricas de Santa Catarina S.A. – CELESC e refere-se a medições de Carga e Temperatura Ambiente, efetuadas no sistema elétrico catarinense no decorrer do verão de 1998.
- Os tempos de processamento, para os melhores experimentos, foram tomados em um microcomputador PC, sob sistema operacional Windows98 e ambiente MatLab, com a seguinte configuração: microprocessador Pentium II de 400Mz, 64Mb de memória RAM e disco rígido IDE de 4GB. Os tempos de processamento foram cronometrados apenas para a fase de treinamento das RNA's.

Foram realizados um total de 637 experimentos. Destes, 289 ocorreram na primeira etapa e o restante (348) na etapa posterior. Os experimentos da primeira etapa foram utilizados para ajustar 22 variações do modelo proposto. Já os da segunda etapa foram utilizados para ajustar um único modelo MLP.

4.2 Massa de Dados

A massa de dados utilizada na experimentação, foi obtida junto à CELESC e é referente as medidas horárias da potência ativa (carga) do transformador TT2 da subestação Rio do Sul (RDS) e da temperatura ambiente nesta subestação, coletados no período de 13/01/98 a 28/02/98. Estas medições foram efetuadas de forma automática pelo sistema de supervisão e controle (SCADA) da CELESC. O SCADA, atualmente em implantação, monitora as grandezas elétricas em pontos pré-determinados do sistema elétrico catarinense, controlado por esta concessionária de energia elétrica.

Como o SCADA encontra-se em fase de implantação, são frequentes as interrupções nas leituras automáticas. Em função disto, foi utilizado o período de 18/01/98 a 14/02/98 (4 semanas completas) como base para os experimentos, por ser este o período onde ocorreram menos interrupções nas leituras. Desta massa de dados, foram desconsiderados os valores de leituras com zero, pois são relativos às falhas no SCADA, bem como outras leituras onde se constatou erros grosseiros nas medições. A Tabela 3 do Anexo 1: Massa de Dados contém esta massa de dados. Os valores destacados em negrito referem-se aos valores desconsiderados.

Após a exclusão das leituras onde ocorreram falhas nos sensores ou com os erros grosseiros de medição, a massa de dados resultante, ainda em sua forma bruta, foi separada em 2 lotes e utilizada para o treinamento e teste das RNA's. Foram incluídos no primeiro lote os dados referentes às 3 primeiras semanas (período de 18/01/98 a 07/02/98). Este lote foi utilizado posteriormente para a construção dos conjuntos de treinamento das RNA's. No segundo lote colocou-se o restante dos dados, relativos a quarta e última semana (período de 08/02/98 a 14/02/98). O segundo lote foi utilizado para a construção dos conjuntos de teste das RNA's.

4.3 Validação e Verificação do Modelo

4.3.1 Metodologia Adotada

Os trabalhos realizados nesta etapa tiveram como objetivos principais validar e verificar o modelo proposto no Capítulo 3. A partir destes objetivos, o modelo proposto foi construído e ajustado de forma a maximizar seu desempenho computacional e minimizar os erros das previsões.

Os experimentos realizados nesta etapa foram divididos em 7 grandes grupos, nomeados de A a H. A partir do conjunto de variáveis candidatas descrito no item 3.2 e das informações obtidas durante a revisão bibliográfica realizada, elaborou-se inicialmente um conjunto composto por 6 vetores de entrada distintos. Para este conjunto de vetores de entrada foram realizados um grupo de experimentos buscando identificar a melhor alternativa para o vetor de entrada e o número ideal de agrupamentos para compor a camada intermediária da RNA. O melhor vetor de entrada deste grupo de experimentos foi então ligeiramente modificado gerando novo conjunto de vetores de entrada que foram novamente experimentados em um novo grupo de experimentos. Esta metodologia foi sucessivamente empregada, por 7 vezes, resultando nos 7 grupos de experimentos citados.

Os conjuntos de treinamento e teste, utilizados para o treinamento e teste das RNA's nos diversos grupos, foram construídos a partir da massa de dados descrita no capítulo 4.2. Os experimentos dos 3 primeiros grupos (de A a C) serviram a um propósito de calibragem e não serão relatados. Durante a etapa de experimentação foram realizados um total de 289 experimentos, utilizados para ajustar 22 variações do modelo proposto. O melhor resultado foi alcançado no experimento F7, utilizando-se 38 agrupamentos na camada intermediária.

Experimentos do Grupo D

Neste grupo de experimentos foram testadas 6 configurações distintas para o vetor de entrada. Estas configurações foram elaboradas a partir do conjunto de variáveis candi-

datas ao vetor de entrada, detalhadas no item 3.2, do conhecimento obtido durante a revisão bibliográfica e junto aos técnicos da CELESC, sobre o comportamento da carga no sistema elétrico catarinense. As composições dos vetores de entrada testados estão descritas a seguir.

Experiência D1. O vetor de entrada **D1** (12 neurônios) foi construído a partir das variáveis: dia da semana (D_s - 3 neurônios), hora do dia em binário (H_{bin} - 5 neurônios), carga na hora h (C_h - 1 neurônio), temperatura ambiente na hora h (T_h - 1 neurônio), variação da carga entre a hora h e a hora $h-1$ (DMw - 1 neurônio) e variação da temperatura ambiente entre a hora h e a hora $h-1$ (DT - 1 neurônio), nesta ordem.

Experiência D2. O vetor de entrada **D2** (13 neurônios) foi construído incluindo a variável temperatura ambiente na hora $h+1$ (T_{h+1}), codificada em 1 neurônio, no final do vetor de entrada **D1**.

Experiência D3. O vetor de entrada **D3** (12 neurônios) foi construído substituindo, no vetor de entrada **D1**, a variável variação da temperatura ambiente (DT), codificada em 1 neurônio, pela variável temperatura ambiente na hora $h+1$ (T_{h+1}), também codificada em 1 neurônio.

Experiência D4. O vetor de entrada **D4** (11 neurônios) foi construído excluindo-se a variável variação da temperatura ambiente (DT) do vetor de entrada **D1**.

Experiência D5. O vetor de entrada **D5** (14 neurônios) foi construído incluindo-se a variável hora do dia como função trigonométrica (H_{sen} e H_{cos}), codificada em 2 neurônios, no vetor de entrada **D1**. A nova variável foi incluída após a variável hora do dia em binário.

Experiência D6. O vetor de entrada **D6** (9 neurônios) foi construído substituindo, no vetor de entrada **D1**, a variável hora do dia em binário (H_{bin}), codificada em 5 neurônios, pela variável hora do dia como função trigonométrica (H_{sen} e H_{cos}), codificada em 2 neurônios.

Experimentos do Grupo E

Neste grupo de experimentos, procurou-se experimentar variações sobre o vetor de entrada **D1**, de forma a melhorar a qualidade das previsões obtidas. As variações experimentadas foram estabelecidas a partir de variações na escala das variáveis potência ativa e temperatura ambiente. O vetor de entrada **D1**, foi escolhido por ter produzido os melhores resultados do grupo **D**.

Experiência E1. O vetor de entrada **E1** (12 neurônios) foi elaborado substituindo-se, no vetor de entrada **D1**, a variável variação da carga entre a hora **h** e a hora **h-1** (**DMw**) pela variável coeficiente de variação da potência ativa entre a hora **h** e a hora **h-1** (**CMw**). Assim, o vetor de entrada **E1** foi composto com as seguintes variáveis: dia da semana (**D_s** - 3 neurônios), hora do dia (**H_{bin}** - 5 neurônios), carga (**C_h** - 1 neurônio), temperatura ambiente (**T_h** - 1 neurônio), coeficiente de variação da potência ativa (**CMw** - 1 neurônio) e variação da temperatura ambiente (**DT** - 1 neurônio), nesta ordem.

Experiência E2. O vetor de entrada **E2** (12 neurônios) foi elaborado substituindo-se, no vetor de entrada **D1**, a variável variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**DT**) pela variável coeficiente de variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**CT**). Assim, o vetor de entrada **E2** foi composto com as seguintes variáveis: dia da semana (**D_s** - 3 neurônios), hora do dia (**H_{bin}** - 5 neurônios), carga (**C_h** - 1 neurônio), temperatura ambiente (**T_h** - 1 neurônio), variação da potência ativa (**DMw** - 1 neurônio) e coeficiente de variação da temperatura ambiente (**CT** - 1 neurônio), nesta ordem.

Experiência E3. O vetor de entrada **E3** (12 neurônios) foi elaborado substituindo-se, no vetor de entrada **D1**, a variável variação da potência ativa entre a hora **h** e a hora **h-1** (**DMw**) pela variável coeficiente de variação da potência ativa entre a hora **h** e a hora **h-1** (**CMw**) e a variável variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**DT**) pela variável coeficiente de variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**CT**). Assim, o vetor de entrada **E3** foi composto com as seguintes variáveis: dia da semana (**D_s** - 3 neurônios), hora do dia (**H_{bin}** - 5 neurônios), carga (**C_h** - 1 neurônio), temperatura ambiente (**T_h** - 1 neurônio), coeficiente de variação da potência ativa (**CMw** - 1 neurônio) e coeficiente de variação da temperatura ambiente (**CT** - 1 neurônio), nesta ordem.

Experiência E4. O vetor de entrada **E4** (12 neurônios) foi elaborado substituindo-se, no vetor de entrada **E3**, a variável coeficiente de variação da potência ativa entre a hora **h** e a hora **h-1** (**CMw**), pela variável percentual de variação da potência ativa entre a hora **h** e a hora **h-1** (**PMw**). Assim, o vetor de entrada **E4** foi composto com as seguintes variáveis: dia da semana (**D_s** - 3 neurônios), hora do dia (**H_{bin}** - 5 neurônios), carga (**C_b** - 1 neurônio), temperatura ambiente (**T_h** - 1 neurônio), percentual de variação da potência ativa (**PMw** - 1 neurônio) e coeficiente de variação da temperatura ambiente (**CT** - 1 neurônio), nesta ordem.

Experiência E5. O vetor de entrada **E5** (12 neurônios) foi elaborado substituindo-se, no vetor de entrada **E3**, a variável coeficiente de variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**CT**), pela variável percentual de variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**PT**). Assim, o vetor de entrada **E4** foi composto com as seguintes variáveis: dia da semana (**D_s** - 3 neurônios), hora do dia (**H_{bin}** - 5 neurônios), carga (**C_b** - 1 neurônio), temperatura ambiente (**T_h** - 1 neurônio), coeficiente de variação da potência ativa (**CMw** - 1 neurônio) e percentual de variação da temperatura ambiente (**PT** - 1 neurônio), nesta ordem.

Experiência E6. O vetor de entrada **E6** (12 neurônios) foi elaborado substituindo-se, no vetor de entrada **E3**, a variável coeficiente de variação da potência ativa entre a hora **h** e a hora **h-1** (**CMw**), pela variável percentual de variação da potência ativa entre a hora **h** e a hora **h-1** (**PMw**), e a variável coeficiente de variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**CT**), pela variável percentual de variação da temperatura ambiente entre a hora **h** e a hora **h-1** (**PT**). Assim, o vetor de entrada **E6** foi composto com as seguintes variáveis: dia da semana (**D_s** - 3 neurônios), hora do dia (**H_{bin}** - 5 neurônios), carga (**C_b** - 1 neurônio), temperatura ambiente (**T_h** - 1 neurônio), percentual de variação da potência ativa (**PMw** - 1 neurônio) e percentual de variação da temperatura ambiente (**PT** - 1 neurônio), nesta ordem.

Experimentos do Grupo F

Neste grupo de experimentos, buscando melhorar a qualidade das previsões obtidas, foi experimentado novas variações sobre o vetor de entrada **D1**. O objetivo perseguido durante a elaboração dos novos vetores de entrada foi o de fornecer informações adicionais

à RNA a respeito dos valores de cargas e temperaturas passadas. O vetor de entrada **D1** foi escolhido por ter produzido, na média, os melhores resultados até o momento.

Experiência F1. O vetor de entrada **F1** (14 neurônios) foi construído incluindo-se, no final do vetor de entrada **D1**, os valores absolutos das variáveis carga na hora **h-23** (C_{h-23}) e carga na hora **h-24** (C_{h-24}). Portanto, o vetor de entrada **F1** foi composto pelas variáveis: dia da semana (D_s - 3 neurônios), hora do dia (H_{bin} - 5 neurônios), carga (C_h - 1 neurônio), temperatura ambiente (T_h - 1 neurônio), variação da potência ativa (DMw - 1 neurônio), variação da temperatura ambiente (DT - 1 neurônio), carga na hora **h-23** (C_{h-23} - 1 neurônio) e carga na hora **h-23** (C_{h-23} - 1 neurônio), nesta ordem.

Experiência F2. O vetor de entrada **F2** (14 neurônios) foi construído incluindo-se, no final do vetor de entrada **D1**, os valores absolutos das variáveis carga na hora **h-167** (C_{h-167}) e carga na hora **h-168** (C_{h-168}). Portanto, o vetor de entrada **F2** foi composto pelas variáveis: dia da semana (D_s - 3 neurônios), hora do dia (H_{bin} - 5 neurônios), carga (C_h - 1 neurônio), temperatura ambiente (T_h - 1 neurônio), variação da potência ativa (DMw - 1 neurônio), variação da temperatura ambiente (DT - 1 neurônio), carga na hora **h-167** (C_{h-167} - 1 neurônio) e carga na hora **h-168** (C_{h-168} - 1 neurônio), nesta ordem.

Experiência F3. Os resultados obtidos nos experimentos do subgrupo **F2** foram superiores aos melhores resultados anteriormente obtidos (Experiência **D1**). Porém, devido aos erros de leitura existentes na massa de dados original, o que acarretou a exclusão de algumas informações desta massa de dados, os conjuntos de treinamento e teste construídos para o treinamento da RNA utilizada na Experiência **F2**, ficaram um pouco menores que os utilizados na Experiência **D1**. Buscando uma correta comparação entre estas duas Experiências (**D1** e **F2**), os experimentos deste subgrupo **F3** tiveram como propósito refazer a experiência **D1** com massas de treinamento e teste equivalentes às da Experiência **F2**. Para tanto, os conjuntos de treinamento e teste utilizados neste subgrupo, foram construídos excluindo-se dos conjuntos de treinamento e teste utilizados na Experiência **D1**, os vetores de entrada relativos a horários inexistentes nos conjuntos de treinamento e teste da Experiência **F2**.

Experiência F4. O vetor de entrada **F4** (15 neurônios) foi construído incluindo-se, no final do vetor de entrada **F2**, o valor absoluto da variável temperatura ambiente na hora

h-167 (T_{h-167}). Portanto, o vetor de entrada **F4** foi composto pelas variáveis: dia da semana (D_s - 3 neurônios), hora do dia (H_{bin} - 5 neurônios), carga (C_h - 1 neurônio), temperatura ambiente (T_h - 1 neurônio), variação da potência ativa (DMw - 1 neurônio), variação da temperatura ambiente (DT - 1 neurônio), carga na hora **h-167** (C_{h-167} - 1 neurônio), carga na hora **h-168** (C_{h-168} - 1 neurônio) e temperatura ambiente na hora **h-167** (T_{h-167} - 1 neurônio), nesta ordem.

Experiência F5. O vetor de entrada **F5** (15 neurônios) foi construído substituindo-se, no do vetor de entrada **F4**, a variável valor absoluto da temperatura ambiente na hora **h-167** (T_{h-167}) pela variável valor absoluto da temperatura ambiente na hora **h-168** (T_{h-168}). Portanto, o vetor de entrada **F5** foi composto pelas variáveis: dia da semana (D_s - 3 neurônios), hora do dia (H_{bin} - 5 neurônios), carga (C_h - 1 neurônio), temperatura ambiente (T_h - 1 neurônio), variação da potência ativa (DMw - 1 neurônio), variação da temperatura ambiente (DT - 1 neurônio), carga na hora **h-167** (C_{h-167} - 1 neurônio), carga na hora **h-168** (C_{h-168} - 1 neurônio) e temperatura ambiente na hora **h-168** (T_{h-168} - 1 neurônio), nesta ordem.

Experiência F6. O vetor de entrada **F6** (17 neurônios) foi construído incluindo-se, no final do vetor de entrada **F5**, as variáveis variação da carga entre as horas **h-168** e **h-169** ($DMw_{h168-h169}$) e variação da temperatura ambiente entre as horas **h-168** e **h-169** ($DT_{h168-h169}$). Portanto, o vetor de entrada **F6** foi composto pelas variáveis: dia da semana (D_s - 3 neurônios), hora do dia (H_{bin} - 5 neurônios), carga (C_h - 1 neurônio), temperatura ambiente (T_h - 1 neurônio), variação da potência ativa (DMw - 1 neurônio), variação da temperatura ambiente (DT - 1 neurônio), carga na hora **h-167** (C_{h-167} - 1 neurônio), carga na hora **h-168** (C_{h-168} - 1 neurônio), temperatura ambiente na hora **h-168** (T_{h-168} - 1 neurônio), variação da carga entre as horas **h-168** e **h-169** ($DMw_{h168-h169}$ - 1 neurônio) e variação da temperatura ambiente entre as horas **h-168** e **h-169** ($DT_{h168-h169}$ - 1 neurônio), nesta ordem. Como os erros de leitura, existentes na massa de dados original, acarretaram a exclusão de algumas informações desta massa de dados, a inclusão das novas variáveis no vetor de entrada da rede implicaram na redução do tamanho dos conjuntos de treinamento e teste. O conjunto de treinamento desta Experiência foi construído com 1 exemplo a menos que o conjunto de treinamento utilizado na Experiência **F5**. Já o conjunto de teste foi construído com menos três exemplos de teste.

Experiência F7. O vetor de entrada **F7** (15 neurônios) foi construído excluindo-se, do vetor de entrada **F6**, as variáveis valor absoluto da temperatura ambiente na hora **h-168** e variação da temperatura ambiente entre as horas **h-168** e **h-169**. Portanto, o vetor de entrada **F7** foi composto pelas variáveis: dia da semana (D_s - 3 neurônios), hora do dia (H_{bin} - 5 neurônios), carga (C_h - 1 neurônio), temperatura ambiente (T_h - 1 neurônio), variação da carga (DMw - 1 neurônio), variação da temperatura ambiente (DT - 1 neurônio), carga na hora **h-167** (C_{h-167} - 1 neurônio), carga na hora **h-168** (C_{h-168} - 1 neurônio) e variação da carga entre as horas **h-168** e **h-169** ($DMw_{h168-h169}$ - 1 neurônio), nesta ordem

Experimentos do Grupo G

Nos Experimentos anteriores experimentou-se alternativas para o vetor de entrada da RNA enquanto o alvo (saída da RNA) foi mantido fixo como o valor absoluto da carga. Neste grupo de experimentos, buscando melhorar ainda mais a qualidade das previsões obtidas, o vetor de entrada da RNA foi mantido fixo e experimentou-se alternativas para representação do alvo. Os vetores de entrada das Experiências **F2** e **F7** foram utilizados como vetores de entrada deste grupo de experimentos, por terem se mostrado as melhores alternativas já experimentadas.

Experiência G1. O alvo como o valor absoluto da carga na hora **h+1**, foi substituído pela diferença em valores absolutos entre a carga nos instantes **h+1** e **h** ($DMw_{h+1} = C_{h+1} - C_h$). Nesta Experiência utilizou-se o vetor de entrada **F7**.

Experiência G2. O alvo como o valor absoluto da carga na hora **h+1**, foi substituído pelo percentual da variação da carga entre os instantes **h+1** e **h** ($PMw_{h+1} = 100(C_{h+1} - C_h) / C_h$). Nesta Experiência também utilizou-se o vetor de entrada **F7**.

Experiência G3. O alvo como o valor absoluto da carga na hora **h+1**, foi substituído pela diferença em valores absolutos entre a carga nos instantes **h+1** e **h** ($DMw_{h+1} = C_{h+1} - C_h$). Nesta Experiência utilizou-se o vetor de entrada **F2**.

Experimentos do Grupo H

Neste grupo de experimentos, experimentou-se variações na escala das variáveis Carga, Temperatura Ambiente e demais variáveis derivadas destas grandezas, que compõem os vetores de entrada e saída da RNA. As variações experimentadas foram elaboradas a partir do vetor de entrada F7. Este vetor de entrada foi escolhido por ter produzido o melhor resultado até o momento.

Experiência H1. As variáveis Carga, Temperatura e as demais variáveis derivadas destas grandezas, tiveram seus valores escalados no intervalo de 0 a 1, de acordo com a (10). Os valores máximo e mínimo utilizados na fórmula foram o primeiro valor inteiro menor que o menor valor, existente na série, da variável considerada e o primeiro valor inteiro maior que o maior valor, também existente na série, da variável considerada. Os maiores e menores valores encontrados na série foram de 6,6 e 22,8MW para a Carga e 17,1 e 38,3°C para a Temperatura Ambiente.

$$V_{norm} = \frac{V - V_{min}}{V_{max} - V_{min}} \quad 10$$

Carga (6, 23)
Temperatura (17, 39)

Onde:

V_{norm} = Valor escalado

V = Valor original

V_{min} = Valor mínimo

V_{max} = Valor máximo

Experiência H2. As variáveis Carga, Temperatura e as demais variáveis derivadas destas grandezas, tiveram seus valores escalados de 0 a 100, de acordo com a (11). Os valores máximo e mínimo utilizados na fórmula, foram os mesmos utilizados na experiência H1.

$$V_{norm} = 100 \frac{V - V_{min}}{V_{max} - V_{min}}$$

11

Onde:

V_{norm} = Valor escalado

V = Valor original

V_{min} = Valor mínimo

V_{max} = Valor máximo

4.3.2 Melhores Resultados

A Tabela 1 apresenta os melhores resultados obtidos na primeira etapa. No Experimento F7 com 38 agrupamentos, o tempo de processamento decorrido durante a fase de treinamento da RNA, foi de 10,60 segundos. O detalhamento dos experimentos realizados em cada grupo desta etapa pode ser obtido no Anexo 4: Resultados dos Experimentos com o Modelo Proposto.

Tabela 1 - Melhores Resultados dos Experimentos da Primeira Etapa

Vetor de entrada	Agrupamentos	MAPE* ¹³ treinamento	EPMax* ¹⁴ treinamento	CV ¹⁵ treinamento	MAPE* teste	EPMax* teste	CV teste
D1	12	4,2530	28,0480	0,0958	4,5045	19,0981	0,1062
E4	21	4,2099	22,9197	0,0972	4,6633	23,5201	0,1064
F7	38	2,4766	28,4283	0,0592	3,4069	19,8876	0,0802
G1	8	4,5520	32,6732	0,1029	5,3477	25,6045	0,1256
H1	20	5,4955	29,4429	0,1160	11,1717	44,0979	0,2556

¹³ É o Erro Médio Percentual, dado por (3), onde C_{base} é igual a 23MW.

¹⁴ É o Erro Máximo Percentual, dado por (6), onde C_{base} é igual a 23MW.

¹⁵ É o Coeficiente de Variação, dado por (9).

4.3.3 Conclusões

Experimentos do Grupo D

Neste grupo de experimentos, o melhor resultado foi obtido com o uso do vetor de entrada **D1** e 12 agrupamentos na camada intermediária.

O uso da hora do dia codificada na forma binária produz melhores resultados do que o uso da hora do dia codificada como função trigonométrica. A exceção são os períodos de carga mínima do Domingo, Segunda-feira e Quarta-feira, quando os melhores resultados foram obtidos utilizando-se, simultaneamente, a hora do dia em binário e a hora do dia como função trigonométrica. (Figura 1 - Experimento D1, 12 agrupamentos X Figura 5 - Experimento D5, 12 agrupamentos).

O uso da variação da temperatura ambiente na última hora ($T_h - T_{h-1}$) em lugar da temperatura ambiente na hora $h+1$ (utilizou-se a real em lugar da prevista), melhora a qualidade das previsões de carga para 1 hora à frente ($h+1$). As exceções mais significativas foram os períodos de carga mínima no Domingo e Segunda-feira e as pontas de Domingo e Sexta-feira (Figura 1 - Experimento D1, 12 agrupamentos X Figura 3 - Experimento D3, 12 agrupamentos).

O uso da variação da temperatura ambiente na última hora ($T_h - T_{h-1}$) melhora sensivelmente a qualidade das previsões para a carga 1 hora à frente. Porém, o uso simultâneo da variação da temperatura ambiente na última hora e da temperatura ambiente para a hora $h+1$ (utilizou-se a real em lugar da prevista), confunde a RNA e piora a previsão (Figura 1 - Experimento D1, 12 agrupamentos X Figura 2 - Experimento D2, 13 agrupamentos).

O uso da informação da temperatura ambiente na hora $h+1$ produz resultados ligeiramente melhores quando comparado ao não uso de nenhuma informação relativa a temperatura ambiente (Figura 3 - Experimento D3, 12 agrupamentos X Figura 4 - Experimento D4, 10 agrupamentos).

Experimentos do Grupo E

Para este grupo de experimentos, os menores índices de erro foram obtidos com uso do vetor E4 e 21 agrupamentos na camada intermediária. Estes resultados são levemente inferiores aos resultados obtidos com o uso do vetor D1. Porém, a análise gráfica dos resultados (Figura 1 - Experimento D1, 12 agrupamentos X Figura 6 - Experimento E4, 21 agrupamentos) mostra que os resultados obtidos com o uso do vetor de entrada E4, quando comparados aos obtidos por meio do vetor de entrada D1, produz melhores resultados para as pontas noturnas de Terça-feira, Quarta-feira, e Quinta-feira e para as manhãs de Quarta-feira, Quinta-feira e Sexta-feira. Portanto, embora os indicadores escolhidos sejam eficientes para medir a qualidade das previsões produzidas pelas RNA's, a análise gráfica dos resultados possibilita identificar características adicionais que podem subsidiar a construção de redes especializadas em prever cargas para períodos específicos.

Experimentos do Grupo F

Para este grupo de experimentos, o melhor resultado foi obtido com uso do vetor F7 e 38 agrupamentos na camada intermediária (Figura 7 - Experimento F7, 38 agrupamentos). Este resultado é também o melhor resultado obtido nos experimentos da primeira etapa.

São equivalentes os resultados obtidos utilizando-se ou não, no vetor de entrada da rede neural, os valores das cargas nos instantes **h-23** e **h-24** (Experiências **F1** e **D1**).

A inclusão, no vetor de entrada da RNA, dos valores das Cargas nos instantes **h-167** e **h-168**, melhora a qualidade da previsão da Carga para o instante **h+1** (Experiência **F2**).

Os menores índices de erro foram obtidos em experimentos nos subgrupos **F2** e **F7** e o melhor resultado de cada subgrupo se equivale. Contudo, o uso do vetor de entrada da Experiência **F7** propicia uma maior estabilidade na qualidade das previsões quanto a variações no número de agrupamentos da camada intermediária. Em virtude desta alta estabilidade na qualidade das previsões, o vetor de entrada da Experiência **F7** foi eleito como o

melhor vetor de entrada até este momento.

Experimentos do Grupo G

O melhor resultado deste grupo de Experimentos (Experiência G1, 8 agrupamentos) é sensivelmente pior que o obtido utilizando o alvo como valor absoluto da carga (Experiência F7, 38 agrupamentos). Contudo, para uma conclusão inequívoca sobre a superioridade da abordagem de uso do alvo como valor absoluto da carga, faz-se necessário repetir os Experimentos utilizando-se um maior volume de dados.

Experimentos do Grupo H

Os resultados obtidos utilizando os valores da Carga e Temperatura Ambiente escalados de acordo com as fórmulas explicitadas e utilizadas nos experimentos **H1** e **H2**, foram inferiores aos obtidos no experimento **F7**. Todavia, o fato de se ter obtido diferentes resultados a partir da variação da escala, mostra que há espaço para trabalhos na direção de identificar e definir escalas específicas para as diferentes variáveis que compõem o vetor de entrada da RNA.

Figura 1 - Experimento D1, 12 agrupamentos




Figura 2 - Experimento D2, 13 agrupamentos




Figura 3 - Experimento D3, 12 agrupamentos




Figura 4 - Experimento D4, 10 agrupamentos

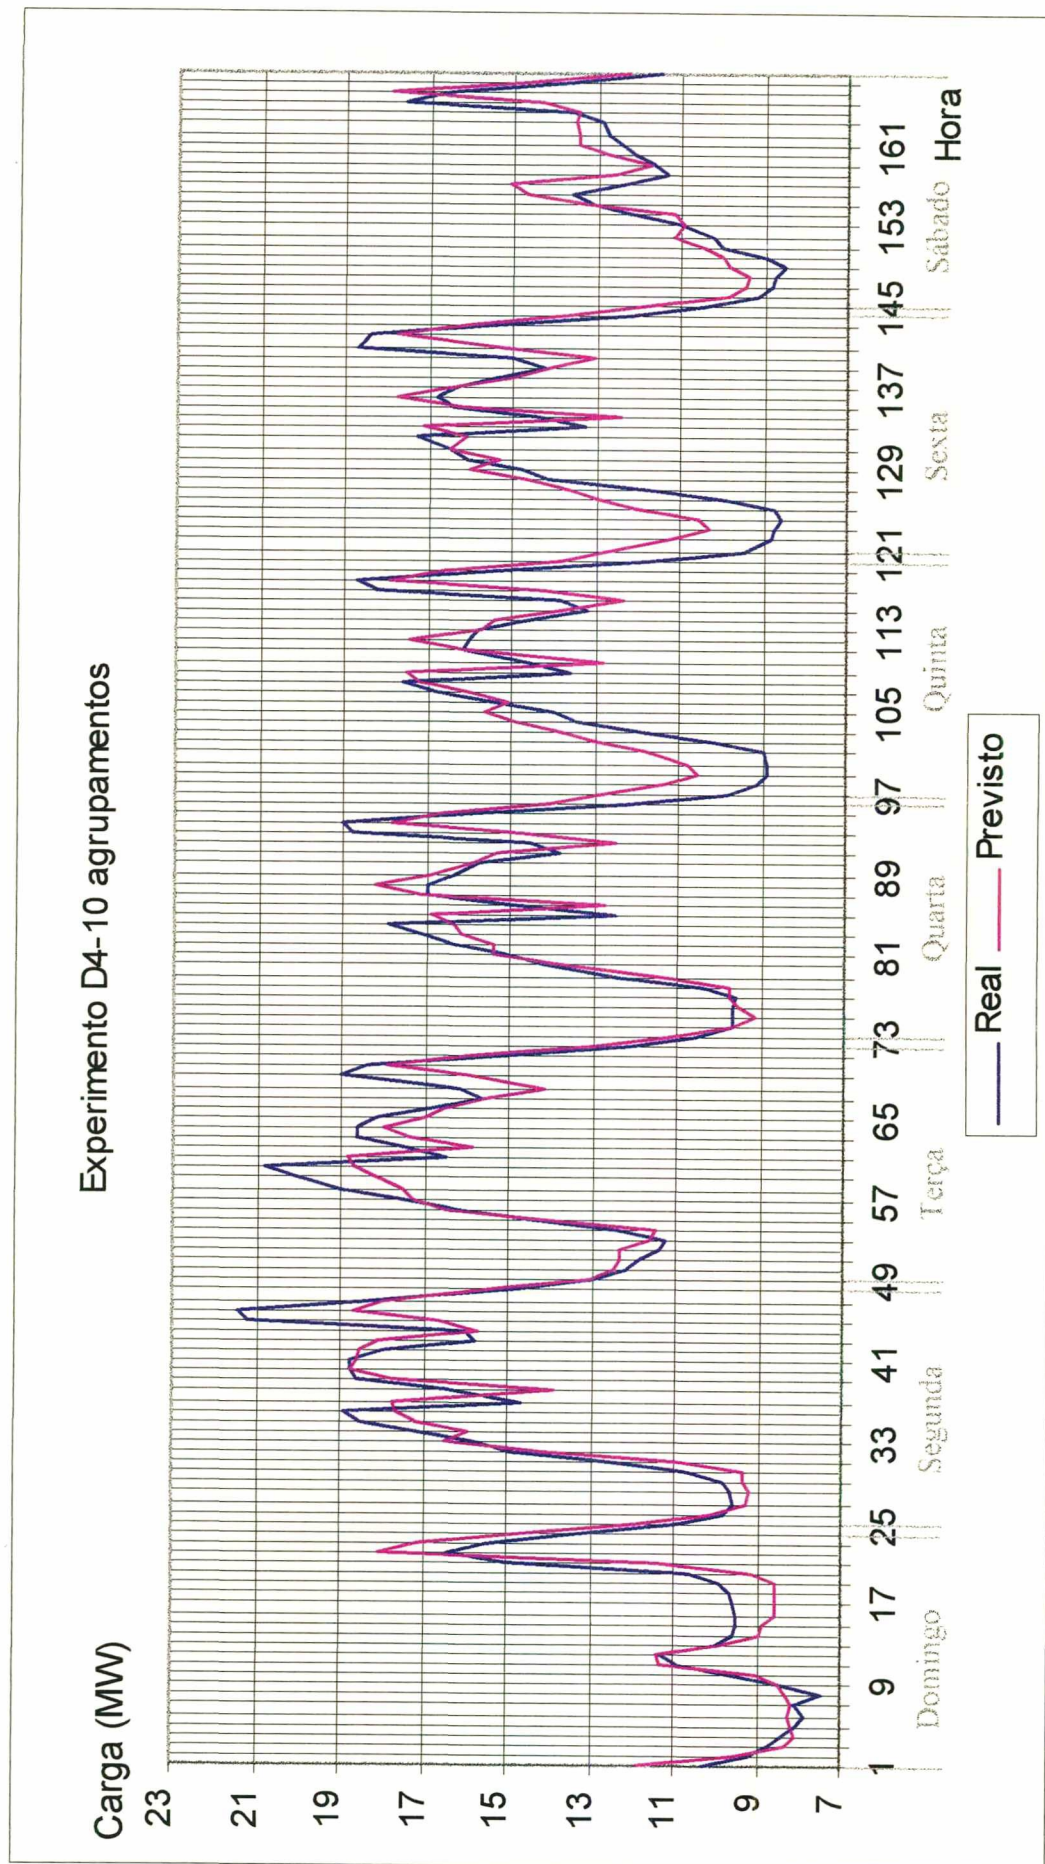


Figura 5 - Experimento D5, 12 agrupamentos




Figura 6 - Experimento E4, 21 agrupamentos





Figura 7 - Experimento F7, 38 agrupamentos



4.4 Comparação do Modelo

4.4.1 Metodologia Adotada

Os trabalhos realizados nesta etapa tiveram como objetivo principal comparar o desempenho e a qualidade dos resultados produzidos pelo modelo proposto com os produzidos por um modelo baseado na arquitetura de RNA Perceptron Múltiplas Camadas e treinado com o algoritmo de Retropropagação.

A partir do objetivo proposto, construiu-se um modelo fundamentado na arquitetura MLP - Modelo MLP (utilizou-se 3 camadas), que foi, em seguida, ajustado de forma a minimizar os erros de previsão. Procedido o ajuste, comparou-se os resultados obtidos com este modelo com os resultados obtidos na etapa anterior.

Os Experimentos desta etapa foram agrupados em um único grupo, nomeado Grupo I e divididos em 2 fases. Na primeira fase, o propósito dos Experimentos foi o de se obter uma idéia aproximada da magnitude dos valores dos *parâmetros livres*¹⁶ da RNA que melhor ajustam o modelo MLP, bem como da magnitude dos erros das previsões produzidas por este modelo. Para isto fixou-se o valor do Erro Relativo Médio (MAPE*) admissível no treinamento em 1,00% (um valor possivelmente não atingível) e variou-se os demais parâmetros livres. Uma vez obtida uma visão geral dos ajustes e do desempenho da rede, iniciou-se os Experimentos da segunda fase. Nos experimentos desta fase, a partir do resultados da fase anterior, procedeu-se um ajuste fino no modelo MLP e comparou-se os melhores resultados obtidos nesta etapa com os melhores resultados da etapa anterior. Para se obter o ajuste fino do modelo MLP, baseado nos resultados obtidos na fase anterior, o número de neurônios na camada oculta foi pré-fixado em 10, os valores para a taxa de aprendizado foram limitados ao intervalo de 0,01 a 0,07 e os valores para o Erro Relativo Médio (MAPE*) admissível no treinamento foram limitados ao intervalo de 0,1 a 3,25.

¹⁶ Os parâmetros livres considerados foram o número de neurônios da camada oculta, a taxa de aprendizado e os critérios para parada do treinamento: número máximo de épocas e erro relativo médio percentual (MAPE*).

Em seguida efetuou-se Experimentos utilizando combinações dos parâmetros. O resultados obtidos nesta etapa foram mensurados com os mesmos indicadores utilizados na etapa anterior.

Os vetores de entrada e de saída utilizados nos Experimentos desta etapa foram compostos da mesma forma que a adotada no Experimento F7 da etapa anterior. Os valores das variáveis Carga e Temperatura Ambiente foram escalados no intervalo de -1 a 1 , de acordo com a (12). Os valores máximo e mínimo utilizados na fórmula de normalização foram o primeiro valor inteiro menor que o menor valor, existente na série, da variável considerada e o primeiro valor inteiro maior que o maior valor, existente na série, da variável considerada. Os maiores e menores valores encontrados na série são, para a Carga, 6,6 e 22,8MW, e para a temperatura ambiente, 17,1 e 38,3°C. O Experimento F7 foi utilizado para a comparação por ter produzido os melhores resultados obtidos na primeira etapa.

$$V_{norm} = 2 \frac{V - V_{min}}{V_{max} - V_{min}} - 1 \quad 12$$

Carga (6, 23)
Temperatura (17, 39)

Onde:

V_{norm} = Valor escalado

V = Valor original

V_{min} = Valor mínimo

V_{max} = Valor máximo

Os conjuntos de treinamento e teste, utilizados durante os Experimentos desta etapa para o treinamento e teste das RNA's, foram construídos de forma idêntica aos utilizados no Experimento F7. Utilizou-se a função de ativação sigmoideal bipolar para os neurônios das camadas oculta e de saída da rede. Os pesos da RNA foram iniciados aleatoriamente

entre 0 e 0,1.

Durante esta etapa foram realizados um total de 348 Experimentos, utilizados para ajustar um único modelo MLP.

4.4.2 Melhores Resultados

A Tabela 2 apresenta um quadro comparativo com os melhores resultados obtidos nos Experimentos das etapas 1 e 2. Como os pesos do Modelo MLP são inicializados de forma aleatória, este modelo dificilmente produz os mesmos resultados. Por isto, o melhor resultado (I_m) apresentado na Tabela 2 foi o resultado da média aritmética simples dos resultados de 9 experimentos semelhantes. A Figura 8 - Experimento I64, 15 agrupamentos, e a Tabela 5 do Anexo 2: Detalhamento dos Melhores Resultados apresentam o resultado obtido no experimento I64. Este experimento produziu o resultado mais próximo do resultado médio (I_m). Um maior detalhamento dos experimentos realizados na etapa 2 pode ser obtido na Tabela 6 do Anexo 3: Resumo dos Resultados dos Experimentos com o Modelo MLP.

Tabela 2 - Melhores Resultados dos Experimentos

Vetor de Entrada	Camada oculta	Taxa de aprendizado	Número. máximo de épocas	MAPE* máximo admissível treinamento	Número de épocas	MAPE* treinamento	EPMax* treinamento	CV treinamento	MAPE* teste	EPMax* teste	CV teste	Tempo de treinamento (seg.)
F7	38	-	-	-	-	2,4766	28,4283	0,0592	3,4069	19,8876	0,0802	11
I54	10	0,05	5000	3,25*	108	3,2496	31,2469	0,0748	3,4704	19,7665	0,0788	274
I51	10	0,05	5000	3,20*	119	3,1989	31,3593	0,0740	3,3981	19,7046	0,0778	299
I48	10	0,05	10000	0,10	10000	1,9625	24,6948	0,0484	2,3515	11,8081	0,0528	27215
I_m	10	0,05	10000	0,10	10000	1,9261	23,6519	0,0465	2,5352	12,8745	0,0572	26470

4.4.3 Conclusões


O melhor resultado na fase de testes foi alcançado no Experimento **I48**, utilizando o modelo MLP (MAPE* = 2,35%). No melhor resultado médio obtido com este Modelo (**I_m**), o valor do MAPE* obtido na fase de teste foi de 2,53%. Este valor (2,53%) está próximo ao percentual de erro médio obtido por Bakirtzis, Petridis, et. al. (1995), na fase de testes, com treinamento com dados relativos a demanda horária do período de 1 ano (2,34%). Também está próximo ao percentual de erro médio obtido por Lu et. al. (1993), na fase de testes, utilizando dados brutos (2,21%). Nos Experimentos **I_m**, o modelo MLP foi ajustado com 10 neurônios na camada oculta, taxa de aprendizado de 0,05 e 10.000 épocas de treinamento. Utilizando estes valores para os neurônios da camada oculta e taxa de aprendizado e elevando-se o número de épocas de treinamento a RNA passou a apresentar *memorização*.

No melhor resultado médio obtido com o modelo MLP (Experimento **I_m**), o MAPE* obtido no teste foi aproximadamente 26% superior ao obtido no melhor Experimento com o modelo RBF (Experimento F7). Considerando-se o EPMax*, o resultado alcançado com o modelo MLP foi 35% superior. Contudo, estes resultados foram obtidos após um tempo de treinamento médio, para o modelo MLP, de 7h21m17s, enquanto para o modelo RBF, foram suficientes 11s de treinamento. Para produzir um resultado similar ao produzido pelo melhor Experimento utilizando o modelo RBF, o modelo MLP necessitou de um tempo de treinamento de 4m59s, que é aproximadamente 2600% a mais que o tempo gasto para o treinamento do modelo RBF (11s).

Além da maior velocidade de treinamento do modelo RBF, foi confirmada sua maior facilidade de ajuste. Não foi identificada uma metodologia científica para o ajuste dos parâmetros das RNA's. Os valores ótimos para os parâmetros foram obtidos através de heurística e experimentação. A rede MLP possui um conjunto maior de parâmetros para ajuste que a rede RBF. Isto trouxe como consequência maior complexidade e demora no seu ajuste. No modelo MLP utilizado, foi preciso ajustar o número de neurônios na camada oculta, o valor da taxa de aprendizado e os valores para os critérios de parada do treinamento: erro máximo admissível e número máximo de épocas. Já no modelo RBF, apenas

foi necessário ajustar o número de agrupamentos.

Figura 8 - Experimento I64, 15 agrupamentos



5. CONSIDERAÇÕES FINAIS

Este capítulo relata as conclusões a cerca do trabalho empreendido e apresenta recomendações para futuros trabalhos relacionados à previsão de cargas.

5.1 Conclusões

Foi proposto, validado e verificado um modelo para previsão da carga nodal ativa horária, uma hora à frente, no estado de Santa Catarina. O modelo proposto foi baseado na arquitetura de RNA Função de Base Radial e demonstrou possuir características atrativas: velocidade de treinamento e facilidade de ajuste, para utilização integrada a sistemas de tempo real. Durante a fase de verificação do modelo proposto, os melhor resultado obtido nos testes foi: $MAPE^* = 3,4069$, $EPM_{max}^* = 19,8876$ e $CV = 0,0802$. Para produzir estes resultados, o Modelo RBF necessitou de 11s para treinamento.

Ao se comparar o modelo proposto com um modelo baseado na arquitetura de RNA MLP, verificou-se que o Modelo MLP apresentou um resultado mais preciso. O melhor resultado médio obtido nos testes com o Modelo MLP foi: $MAPE^* = 2,5352$, $EPM_{max}^* = 12,8745$ e $CV = 0,0572$. Este resultado está próximo aos resultados obtidos por Bakirtzis, Petridis, et. al. (1995) e por Lu et. al. (1993), também utilizando a arquitetura MLP. Todavia, para produzir este resultado foi necessário, em média, 7h21m17s de treinamento. Para o Modelo MLP produzir resultados com precisão equivalente a dos melhores resultados obtidos com o Modelo RBF, foram necessários 4m59s de treinamento. Este tempo é 2600% maior que o tempo gasto pelo Modelo RBF. Além da muito maior velocidade de treinamento do modelo RBF, confirmou-se a sua maior facilidade de ajuste.

Embora o modelo MLP tenha apresentado resultados mais precisos, são impressionantes a maior facilidade de ajuste e a velocidade de treinamento do Modelo RBF. Um sistema de previsão automático e em tempo real, baseado na técnica de RNA's, precisa ser retreinado periodicamente. Como ajustar tal sistema, de forma satisfatória e rápida, a cada

retreinamento, utilizando pouca ou nenhuma intervenção humana? Estas observações justificam um esforço adicional em busca de otimização do Modelo RBF.

Além das vantagens inerentes à facilidade de ajuste e velocidade de treinamento do Modelo RBF, também é teoricamente possível modificar o modelo para que adicionalmente forneça índices de confiabilidade para as previsões. A informação sobre o nível de confiabilidade das previsões seguramente trará grandes benefícios aos processos que a utilizam.

Foi validada a hipótese de que para a previsão de carga ativa uma hora à frente, é possível dispensar o uso da temperatura ambiente prevista para uma hora à frente na composição do vetor de entrada da rede neural, sem que isto implique em perda de qualidade das previsões. A temperatura prevista para a hora $h+1$ foi substituída pela variação da temperatura entre as horas $h-1$ e h .

Não se mostrou válida a hipótese de que o uso, no vetor de saída da RNA, do percentual de variação da carga em substituição ao valor da carga, propicia uma maior precisão nas previsões bem como a possibilidade de redução no tamanho do conjunto de treinamento. Porém, antes de se descartar definitivamente esta hipótese, é prudente que os experimentos sejam refeitos com um maior volume de dados.

5.2 Recomendações

Há vários trabalhos, relacionados ao tema deste trabalho, que ainda podem ser empreendidos: otimização do modelo, inclusão de novas características no modelo, especialização do modelo, verificação da robustez do modelo e construção de novos modelos são alguns exemplos.

No grupo de otimização do modelo proposto recomenda-se trabalhos relativos à entrada da rede e à camada intermediária da rede. Com relação a entrada da rede, é preciso procurar melhorar a forma de escalar as variáveis do vetor de entrada, pois se observou que o modelo é muito sensível a isto. O Modelo proposto também deve ser testado incluindo-se, no vetor de entrada da rede, informações sobre: luminosidade, velocidade do

vento, umidade do ar e cobertura solar. Com relação à camada intermediária da rede, incluem-se, entre outros: experimentações com outros tipos de funções de base radial; uso de funções de base radial específicas para cada agrupamento; uso de um comprimento (raio) variável para cada agrupamento (função da distância entre agrupamentos vizinhos); experimentar usar os mapas auto-organizáveis de Kohonen (Haykin, 1994, Fausett, 1995) para efetuar o agrupamento dos padrões de entrada.

No grupo de inclusão de novas características no modelo recomenda-se modificar o modelo proposto de forma a incluir a propriedade de plasticidade, possibilitando assim que a rede possa autoajustar seu número de agrupamentos. Recomenda-se também, modificar o modelo para que adicionalmente forneça índices de confiabilidade para as previsões. Os índices podem ser calculados a partir das distâncias entre os centros dos agrupamentos e o padrão de entrada. Também é importante estudar o emprego da tecnologia de agentes na construção de uma estrutura de controle para o modelo. Dentro deste enfoque, o modelo proposto serviria como o núcleo e ponto de partida para construção de um *agente previsor*.

Como trabalhos relacionados ao grupo especialização do modelo, recomenda-se experimentar especializar o modelo não por tipo de dia de semana (curvas de carga similares), que é a abordagem tradicional, e sim por períodos (horários) onde o comportamento da variação da carga sejam similares. Para isto deve-se pré-agrupar os padrões em agrupamentos onde os períodos/horários com percentual e o sinal (positivo ou negativo) de variação das cargas sejam semelhantes. Pode-se utilizar os mapas auto-organizáveis de Kohonen (Haykin, 1994, Fausett, 1995) para efetuar o agrupamento. Também é possível experimentar especializar a rede em função da faixa de demanda (ponta, média, leve, mínima). Uma outra forma é experimentar especializar a rede para os horários onde ocorrerem erros de previsão acima de um valor pré-estabelecido. Uma maneira de se fazer isto é incluir na estrutura de controle (sugerida como trabalho no grupo de inclusão de novas características no modelo) a capacidade de identificar dinamicamente os erros muito altos e subdividir (especializar) a RNA de acordo com a necessidade/comportamento do ponto elétrico (nó) em questão (a curva de carga é específica para o alimentador).

Como trabalho do grupo construção de novos modelos, recomenda-se experimentar um novo modelo, híbrido, estruturado como descrito a seguir. O novo modelo deverá ser dividido em 2 grandes blocos. O primeiro bloco deverá ser baseado em uma arquitetura de

RNA capaz de efetuar classificação através de treinamento não supervisionado. Já o segundo bloco deverá ser fundamentado no conceito de treinamento supervisionado. Para o primeiro bloco poderia ser utilizado os mapas auto-organizáveis de Kohonen ou uma rede ART (*“Adaptive Resonance Theory”*). A rede ART possui a capacidade adicional de poder realizar treinamento incremental, o que propicia a possibilidade de uma nova abordagem para o retreinamento de sistemas de previsão de cargas. Para o segundo bloco poderia ser novamente utilizado uma função identidade ou experimentado uma rede MLP. Também recomenda-se examinar a possibilidade de emprego do sistema FAN (Free Associative Neurons) no problema alvo. O sistema FAN é um sistema híbrido, baseado em redes conexionistas, modelagem difusa e representação de padrões. Ele é baseado fracamente na noção do aprendizado por adaptação neural, utiliza técnicas de conjuntos difusos para promover a granularidade de informações e permite incluir diferentes métodos de associação de padrões para melhorar a sua capacidade de aprendizado (Raitz et. al.,1997, citado em Dandolini, 1997).

Como trabalhos de verificação da robustez do modelo, sugere-se experimentar treinar o modelo com uma massa de dados relativa a períodos mais longos, por exemplo 6 a 12 meses. Neste caso, experimentar colocar no vetor de entrada a informação do dia do ano codificada como função trigonométrica. Também é interessante se verificar a degradação na precisão da previsão em função da defasagem de treinamento. Por fim, Lu et. al. (1993) mostram que a RNA MLP é muito sensível a dados com erros. Recomenda-se que também se verifique a sensibilidade do modelo proposto a dados com erros. Para tanto, o modelo proposto deve ser testado com dados brutos e com dados pré-processados (não mais em sua forma bruta). Como dados pré-processados podem ser utilizados os dados produzidos por um estimador de estados.

6. ANEXOS

6.1 Anexo 1: Massa de Dados

Os valores em **negrito** referem-se a valores de leituras com erros grosseiros, que não foram utilizados para elaboração dos conjuntos de treinamento e teste das RNA's.

Tabela 3 - Massa de Dados Utilizada nos Experimentos

Mês	Dia do mês	Dia da semana	Hora do dia	Transformador TT2 (MW)	Temperatura ambiente (°C)						
								10	16,9	23,6	
								11	18,1	24,7	
								12	17,9	26,8	
								13	13,9	27,1	
								14	15,6	26,7	
								15	17,8	27,4	
								16	17,4	27,8	
								17	17,3	28,3	
Janeiro	17	Sábado	24	11,8	25,3			18	16,0	27,9	
	18	Domingo	1	9,7	24,9			19	14,1	27,1	
			2	8,8	24,5			20	14,0	25,5	
			3	8,0	24,1			21	17,6	24,1	
			4	7,8	23,8			22	20,6	23,9	
			5	7,5	22,9			23	16,6	23,5	
			6	7,3	22,3			24	13,1	23,5	
			7	7,1	21,9		20	Terça	1	11,2	23,4
			8	6,8	22,3			2	9,9	23,4	
			9	7,9	25,9			3	9,7	23,5	
			10	9,1	28,1			4	9,7	23,3	
			11	10,3	31,0			5	9,6	23,7	
			12	10,7	32,5			6	10,8	23,4	
			13	9,7	34,0			7	12,4	23,2	
			14	9,1	35,3			8	14,9	23,8	
			15	9,0	35,6			9	15,4	24,5	
			16	9,1	36,0			10	17,0	24,6	
			17	9,0	36,0			11	18,5	26,6	
			18	9,1	35,0			12	18,7	29,7	
			19	9,4	32,7			13	15,0	31,0	
			20	9,8	28,3			14	17,4	31,7	
			21	12,7	26,1			15	19,0	32,7	
			22	15,6	25,1			16	19,1	33,0	
			23	14,2	24,4			17	18,7	33,0	
			24	11,7	23,6			18	17,6	32,5	
	19	Segunda	1	9,8	23,2			19	15,8	31,4	
			2	8,9	22,7			20	15,5	29,6	
			3	9,0	22,2			21	18,6	27,7	
			4	8,8	22,1			22	21,5	26,2	
			5	8,8	21,8			23	19,0	25,3	
			6	10,4	22,0			24	14,7	24,7	
			7	11,8	22,0		21	Quarta	1	12,5	24,2
			8	14,0	22,2			2	11,1	23,9	
			9	15,2	22,2			3	10,9	23,9	
								4	10,7	23,7	

		5	10,5	24,1			15	19,1	32,2	
		6	11,4	24,6			16	18,9	31,3	
		7	12,5	24,3			17	18,1	29,1	
		8	14,7	24,1			18	15,4	25,2	
		9	15,4	25,8			19	13,8	26,0	
		10	17,5	27,5			20	14,0	25,0	
		11	18,5	28,7			21	18,1	24,2	
		12	19,1	30,9			22	18,5	23,5	
		13	15,0	32,3			23	16,6	24,0	
		14	17,0	34,2			24	13,7	23,6	
		15	19,4	34,9		24	Sábado	1	11,8	23,2
		16	19,2	35,3				2	10,5	23,4
		17	18,9	34,4				3	10,1	23,8
		18	17,5	33,8				4	10,0	23,4
		19	14,9	32,8				5	9,9	23,9
		20	15,0	31,3				6	9,9	23,4
		21	18,6	29,5				7	10,9	23,6
		22	21,9	27,5				8	10,7	24,0
		23	19,3	26,3				9	11,5	26,0
		24	15,3	26,1				10	12,6	26,7
22	Quinta	1	13,2	25,8				11	13,3	28,4
		2	11,9	25,6				12	13,9	30,5
		3	11,5	25,7				13	13,4	32,5
		4	11,4	25,6				14	12,5	32,1
		5	11,3	26,3				15	12,0	29,1
		6	12,5	25,4				16	9,4	23,2
		7	13,6	25,5				17	11,1	23,1
		8	15,5	26,1				18	12,3	23,1
		9	17,6	27,0				19	12,6	23,5
		10	19,1	28,4				20	13,3	23,2
		11	20,1	29,8				21	15,2	22,8
		12	20,3	32,4				22	15,0	22,3
		13	16,7	34,1				23	13,0	22,0
		14	18,7	35,6				24	11,0	22,0
		15	21,1	35,8		25	Domingo	1	9,4	21,8
		16	20,9	34,9				2	8,5	21,4
		17	20,0	33,2				3	7,9	21,8
		18	17,6	31,5				4	7,6	21,7
		19	14,9	28,1				5	7,3	21,3
		20	14,5	27,9				6	7,2	21,6
		21	17,6	26,8				7	7,3	21,3
		22	18,2	25,0				8	6,6	21,2
		23	15,7	24,7				9	7,9	22,1
		24	13,1	24,0				10	9,0	22,8
23	Sexta	1	11,1	23,7				11	10,0	24,0
		2	10,1	23,2				12	10,6	27,6
		3	10,0	22,9				13	9,3	29,9
		4	9,8	23,8				14	8,8	31,6
		5	9,8	23,4				15	8,6	31,8
		6	11,3	23,9				16	8,6	32,9
		7	12,6	23,7				17	8,8	33,0
		8	14,8	23,5				18	9,1	31,5
		9	16,1	24,1				19	9,7	29,6
		10	17,9	25,0				20	10,9	28,3
		11	19,0	27,4				21	13,3	27,3
		12	19,2	29,2				22	13,6	26,4
		13	15,2	31,1				23	12,4	25,8
		14	17,0	32,2				24	10,7	24,6

26	Segunda	1	9,3	24,1	11	19,9	32,5		
		2	8,8	23,7	12	20,2	34,6		
		3	8,7	23,4	13	16,2	35,9		
		4	8,7	22,8	14	17,5	37,3		
		5	8,9	22,8	15	20,3	37,9		
		6	10,2	22,7	16	19,9	37,5		
		7	11,5	22,7	17	19,4	38,3		
		8	13,2	23,2	18	16,5	34,8		
		9	14,8	23,6	19	13,2	26,9		
		10	16,6	24,4	20	15,8	26,3		
		11	17,6	26,2	21	19,7	25,8		
		12	18,0	29,4	22	19,4	25,5		
		13	14,5	29,4	23	17,2	25,4		
		14	16,2	30,0	24	13,8	25,1		
		15	18,4	32,5	29	Quinta	1	11,7	24,3
		16	18,4	32,5			2	10,7	24,0
		17	18,0	31,2			3	10,1	24,3
		18	14,7	29,7			4	10,0	24,5
		19	21,3	25,9			5	10,1	24,7
		20	19,3	23,8			6	11,4	24,5
		21	17,5	23,2			7	12,8	24,4
		22	17,3	23,5			8	15,2	24,7
		23	14,2	23,1			9	16,1	25,0
		24	11,3	23,1			10	18,1	26,8
27	Terça	1	9,9	22,8			11	19,3	28,7
		2	9,2	21,6			12	19,2	29,3
		3	9,3	21,9			13	15,5	29,6
		4	9,1	21,5			14	16,9	30,0
		5	8,9	21,1			15	18,9	30,3
		6	10,3	21,5			16	19,2	30,9
		7	11,9	21,5			17	18,7	30,5
		8	13,8	21,8			18	16,8	30,1
		9	14,9	23,2			19	14,8	28,8
		10	16,3	24,1			20	15,0	27,6
		11	18,0	27,0			21	19,2	26,6
		12	18,5	28,8			22	20,5	25,9
		13	14,8	30,9			23	18,1	25,8
		14	16,8	32,7			24	14,4	25,3
		15	19,2	33,7	30	Sexta	1	12,4	25,0
		16	19,3	35,0			2	11,2	24,7
		17	19,2	35,1			3	10,9	24,5
		18	17,9	35,0			4	10,9	24,8
		19	16,0	33,8			5	10,4	24,3
		20	15,8	31,6			6	11,8	25,2
		21	20,0	29,8			7	13,4	25,0
		22	21,7	28,8			8	15,3	25,1
		23	19,1	28,1			9	16,7	25,7
		24	15,2	27,3			10	18,2	26,7
28	Quarta	1	12,7	26,3			11	19,0	27,0
		2	11,9	25,5			12	19,0	27,5
		3	11,5	25,7			13	15,0	28,6
		4	11,2	25,1			14	16,4	29,7
		5	11,0	25,0			15	18,2	30,6
		6	12,2	25,0			16	18,1	31,5
		7	13,4	24,3			17	18,1	31,0
		8	15,4	24,8			18	16,4	31,1
		9	16,5	25,8			19	15,0	30,4
		10	18,6	29,1			20	15,3	25,8

		21	16,9	24,6			7	11,2	20,9		
		22	16,7	24,7			8	13,8	20,9		
		23	14,7	23,9			9	14,6	22,6		
		24	12,2	23,4			10	16,4	25,0		
31	Sábado	1	11,0	22,8			11	18,1	26,8		
		2	10,0	23,5			12	14,4	29,6		
		3	9,7	23,5			13	16,1	32,0		
		4	9,6	23,4			14	18,2	31,4		
		5	9,3	23,5			15	18,0	30,1		
		6	9,5	23,3			16	18,2	29,9		
		7	10,3	23,1			17	17,5	29,3		
		8	10,5	23,2			18	15,1	27,7		
		9	11,3	24,6			19	15,0	26,8		
		10	12,3	26,0			20	18,8	26,8		
		11	13,4	28,0			21	19,7	25,8		
		12	14,1	29,5			22	16,3	25,1		
		13	12,7	30,3			23	13,2	24,5		
		14	12,0	31,5			24	14,4	23,9		
		15	12,2	32,0		3	Terça	1	11,3	23,5	
		16	12,4	27,7			2	9,9	23,3		
		17	12,4	29,0			3	9,8	23,2		
		18	12,8	27,0			4	9,9	23,6		
		19	13,1	25,3			5	10,0	23,6		
		20	13,0	25,2			6	10,6	23,1		
		21	15,6	24,6			7	12,5	23,4		
		22	15,2	24,4			8	15,7	23,7		
		23	13,2	24,1			9	16,1	23,7		
		24	10,3	23,9			10	18,0	23,8		
Fevereiro	1	Domingo	1	8,8	24,1		11	18,8	25,3		
			2	8,5	23,7		12	18,8	27,1		
			3	7,6	23,7		13	15,4	29,6		
			4	7,5	23,2		14	16,8	31,4		
			5	7,4	23,0		15	18,6	32,7		
			6	7,3	23,1		16	18,8	32,1		
			7	7,5	23,0		17	18,5	31,7		
			8	7,1	23,1		18	17,3	28,9		
			9	8,5	23,4		19	15,2	27,5		
			10	9,5	24,4		20	16,0	26,7		
			11	10,8	25,1		21	19,1	25,3		
			12	11,0	25,0		22	19,1	25,1		
			13	9,2	27,2		23	16,6	24,6		
			14	8,5	28,0		24	13,6	24,8		
			15	8,5	27,4		4	Quarta	1	11,9	25,1
			16	8,4	29,6		2	10,6	24,8		
			17	8,4	30,9		3	10,2	24,7		
			18	8,6	29,8		4	10,1	24,6		
			19	9,0	29,0		5	10,2	24,2		
			20	10,2	27,7		6	11,1	24,2		
			21	13,9	25,9		7	12,8	23,8		
			22	14,3	24,2		8	15,6	24,1		
			23	12,9	23,8		9	16,3	25,0		
			24	11,0	23,4		10	17,8	27,6		
	2	Segunda	1	9,5	22,6		11	18,9	29,0		
			2	8,5	21,9		12	19,2	30,9		
			3	8,3	21,5		13	15,4	31,9		
			4	8,4	21,2		14	17,0	33,8		
			5	8,6	21,6		15	19,2	33,2		
			6	10,0	21,2		16	19,1	33,2		

		17	14,0	24,7			3	10,5	24,0	
		18	18,8	32,4			4	10,2	23,8	
		19	0	0			5	10,2	24,0	
		20	0	0			6	10,8	24,3	
		21	0	0			7	11,4	24,2	
		22	0	0			8	11,9	24,1	
		23	0	0			9	12,3	23,8	
		24	0	0			10	11,7	22,9	
5	Quinta	1	0	0			11	13,9	23,6	
		2	0	0			12	14,1	23,9	
		3	0	0			13	12,3	24,6	
		4	0	0			14	11,5	26,4	
		5	0	0			15	11,6	29,2	
		6	0	0			16	11,9	29,9	
		7	0	0			17	11,9	29,8	
		8	0	0			18	11,8	30,0	
		9	13,4	21,7			19	12,1	29,9	
		10	17,7	26,4			20	12,4	28,2	
		11	18,7	28,9			21	16,3	25,7	
		12	18,9	28,4			22	16,8	24,8	
		13	19,2	26,2			23	15,0	23,9	
		14	16,3	25,7			24	13,0	23,6	
		15	18,0	26,6		8	Domingo	1	10,3	23,3
		16	18,1	27,2			2	9,2	22,9	
		17	17,7	28,8			3	8,7	22,0	
		18	13,1	24,0			4	8,4	21,8	
		19	15,1	28,1			5	8,1	21,4	
		20	15,3	26,9			6	7,9	21,8	
		21	19,3	25,9			7	8,1	21,5	
		22	20,1	25,3			8	7,5	21,6	
		23	17,1	24,9			9	8,5	23,1	
		24	14,1	24,8			10	9,7	25,8	
6	Sexta	1	11,7	24,6			11	10,9	29,2	
		2	10,5	24,2			12	11,3	31,3	
		3	10,4	23,6			13	10,0	31,7	
		4	10,4	23,4			14	9,6	31,1	
		5	10,5	23,4			15	9,5	31,7	
		6	11,0	23,6			16	9,5	32,7	
		7	12,5	23,4			17	9,6	32,7	
		8	15,4	23,6			18	9,7	32,3	
		9	16,4	23,9			19	9,9	30,9	
		10	18,3	25,9			20	10,6	28,5	
		11	18,8	27,1			21	15,0	26,4	
		12	15,0	21,6			22	16,4	25,4	
		13	15,4	29,5			23	15,5	25,0	
		14	17,1	31,9			24	13,3	24,0	
		15	19,0	32,9		9	Segunda	1	11,0	23,9
		16	18,9	32,9			2	9,8	24,0	
		17	18,7	33,0			3	9,6	23,7	
		18	17,1	32,3			4	9,7	23,5	
		19	15,3	31,4			5	9,8	23,3	
		20	15,1	29,5			6	10,7	22,9	
		21	19,4	27,4			7	12,6	22,8	
		22	20,8	26,4			8	14,9	22,6	
		23	18,4	25,7			9	15,8	22,8	
		24	15,3	25,3			10	17,2	24,0	
7	Sábado	1	12,6	25,1			11	18,5	25,1	
		2	11,2	24,6			12	18,9	26,7	

		13	14,7	27,6			23	15,8	19,9	
		14	16,4	28,2			24	12,1	19,6	
		15	18,6	29,2		12	Quinta	1	9,8	19,2
		16	18,8	31,4				2	9,1	19,3
		17	18,8	31,5				3	8,9	19,1
		18	18,0	31,1				4	8,9	18,3
		19	15,8	29,3				5	9,0	17,4
		20	16,0	28,0				6	10,1	17,1
		21	21,2	27,3				7	11,9	17,1
		22	21,4	26,7				8	13,4	17,1
		23	18,4	26,2				9	14,0	18,2
		24	14,8	25,9				10	15,4	21,9
10	Terça	1	13,0	25,8				11	16,8	24,6
		2	12,2	25,5				12	17,6	26,6
		3	11,9	25,4				13	13,6	26,6
		4	11,4	25,3				14	14,6	25,9
		5	11,2	25,1				15	16,2	25,7
		6	12,4	25,1				16	16,0	25,5
		7	14,4	24,5				17	15,8	24,9
		8	16,2	24,6				18	14,6	24,9
		9	17,5	25,3				19	13,2	23,8
		10	19,0	26,6				20	13,8	22,4
		11	20,1	29,0				21	18,2	21,3
		12	20,8	30,9				22	18,7	20,6
		13	16,5	29,2				23	15,3	20,0
		14	17,5	25,4				24	11,8	19,4
		15	18,6	26,7		13	Sexta	1	9,4	19,4
		16	18,6	25,8				2	8,8	19,5
		17	18,1	25,9				3	8,7	19,3
		18	16,8	26,5				4	8,6	18,1
		19	15,6	24,3				5	8,7	17,4
		20	16,2	23,4				6	9,9	17,3
		21	19,0	23,0				7	11,8	17,5
		22	18,4	21,5				8	14,1	17,7
		23	15,1	21,2				9	14,8	19,0
		24	12,1	21,6				10	16,1	22,8
11	Quarta	1	10,5	21,6				11	16,5	23,7
		2	9,7	21,4				12	17,3	25,2
		3	9,7	21,0				13	13,3	25,9
		4	9,7	20,6				14	14,4	27,6
		5	9,6	20,4				15	16,4	25,6
		6	10,4	19,8				16	16,8	25,0
		7	12,4	20,0				17	16,3	23,5
		8	14,2	19,7				18	15,4	22,8
		9	15,1	20,1				19	14,2	22,1
		10	16,3	20,5				20	15,0	21,3
		11	17,1	21,7				21	18,7	20,8
		12	17,9	23,7				22	18,4	20,6
		13	12,5	26,1				23	15,5	20,3
		14	14,9	28,1				24	12,2	20,9
		15	17,0	28,1		14	Sábado	1	10,4	21,1
		16	17,0	27,3				2	9,1	20,5
		17	16,3	26,8				3	8,8	20,4
		18	15,7	25,7				4	8,7	19,9
		19	13,8	24,0				5	8,5	19,7
		20	14,5	21,8				6	9,0	19,5
		21	18,8	20,7				7	10,0	19,6
		22	19,0	20,3				8	10,2	19,7

9	11,0	21,5
10	12,2	22,9
11	13,1	24,7
12	13,6	25,9
13	12,3	26,8
14	11,3	25,8
15	11,6	25,2
16	12,1	25,8

17	12,4	25,1
18	12,7	24,3
19	12,9	23,9
20	13,6	23,0
21	17,6	21,7
22	16,5	21,4
23	13,7	21,3
24	11,5	21,0

6.2 Anexo 2: Detalhamento dos Melhores Resultados

Anexou-se apenas o detalhamento do experimento que produziu o melhor resultado em cada etapa. O Experimento I64 foi apresentado como melhor resultado do grupo I por ter sido o experimento deste grupo que apresentou o resultado mais próximo ao melhor resultado médio do grupo.

Tabela 4 - Experimento F7, 38 agrupamentos

Valor Real	Valor Pre- visto	MAPE* % teste						
10,3000	10,9811	2,96	21,4000	20,4439	4,16	18,7000	17,9276	3,36
9,2000	9,5204	1,39	18,4000	15,9526	10,64	15,3000	15,0933	0,90
8,7000	7,9093	3,44	14,8000	15,2838	2,10	11,8000	12,5987	3,47
8,4000	7,6193	3,39	13,0000	12,7619	1,04	9,4000	10,2649	3,76
8,1000	7,5465	2,41	12,2000	11,5272	2,93	8,8000	9,2534	1,97
7,9000	7,6767	0,97	11,9000	11,3813	2,26	8,7000	9,1664	2,03
8,1000	7,4505	2,82	11,4000	11,5987	0,86	8,6000	9,6221	4,44
7,5000	7,8698	1,61	11,2000	11,2317	0,14	8,7000	10,3516	7,18
8,5000	7,4881	4,40	12,4000	11,4156	4,28	9,9000	11,0356	4,94
9,7000	10,0054	1,33	14,4000	13,4413	4,17	11,8000	11,8743	0,32
10,9000	11,2408	1,48	16,2000	15,8625	1,47	14,1000	13,7304	1,61
11,3000	11,9190	2,69	17,5000	16,3579	4,97	14,8000	15,0583	1,12
10,0000	10,3542	1,54	19,0000	18,4155	2,54	16,1000	14,9208	5,13
9,6000	9,4334	0,72	20,1000	18,8890	5,27	16,5000	16,4093	0,39
9,5000	9,1196	1,65	20,8000	18,7716	8,82	16,4000	17,9864	6,90
9,5000	9,3290	0,74	16,5000	16,2212	1,21	16,8000	18,4752	7,28
9,6000	10,0439	1,93	17,5000	16,3337	5,07	16,3000	17,2592	4,17
9,7000	10,0858	1,68	18,6000	18,5984	0,01	15,4000	15,5783	0,78
9,9000	9,7741	0,55	18,6000	18,4158	0,80	14,2000	14,1215	0,34
10,6000	9,7892	3,53	18,1000	17,5057	2,58	15,0000	13,4439	6,77
15,0000	13,4869	6,58	16,8000	16,7088	0,40	18,7000	16,0923	11,34
16,4000	15,5305	3,78	15,6000	15,2591	1,48	18,4000	17,4240	4,24
15,5000	14,7721	3,16	16,2000	15,5271	2,93	15,5000	14,9309	2,47
13,3000	13,5436	1,06	19,0000	17,1457	8,06	12,2000	13,1522	4,14
11,0000	11,2265	0,98	18,4000	18,0573	1,49	10,4000	10,8197	1,82
9,8000	10,2015	1,75	15,1000	14,7367	1,58	9,1000	9,4107	1,35
9,6000	9,1289	2,05	12,1000	12,3360	1,03	8,8000	8,8300	0,13
9,7000	9,2557	1,93	10,5000	10,1768	1,41	8,7000	9,1104	1,78
9,8000	9,6293	0,74	9,7000	9,4280	1,18	8,5000	9,3299	3,61
10,7000	10,4699	1,00	9,7000	9,0707	2,74	9,0000	9,7271	3,16
12,6000	11,7934	3,51	9,7000	9,4927	0,90	10,0000	10,4111	1,79
14,9000	14,7599	0,61	9,6000	9,6536	0,23	10,2000	11,1471	4,12
15,8000	15,6147	0,81	10,4000	10,0747	1,41	11,0000	10,7902	0,91
17,2000	16,2456	4,15	12,4000	11,4744	4,02	12,2000	11,5929	2,64
18,5000	17,4835	4,42	14,2000	14,5251	1,41	13,1000	13,6878	2,56
18,9000	16,5542	10,20	15,1000	15,2087	0,47	13,6000	14,6067	4,38
14,7000	17,2990	11,30	16,3000	15,2176	4,71	12,3000	13,4088	4,82
16,4000	16,3866	0,06	17,1000	15,6402	6,35	11,3000	11,6579	1,56
18,6000	18,0791	2,26	17,9000	15,9318	8,56	11,6000	10,9028	3,03
18,8000	19,1139	1,36	12,5000	15,6082	13,51	12,1000	11,9351	0,72
18,8000	17,3920	6,12	14,9000	14,4085	2,14	12,4000	12,1626	1,03
18,0000	15,5051	10,85	17,0000	18,7464	7,59	12,7000	12,3040	1,72
15,8000	16,2345	1,89	17,0000	19,1544	9,37	12,9000	12,5280	1,62
16,0000	18,6081	11,34	17,6000	17,5672	0,14	13,6000	12,9481	2,83
21,2000	18,5339	11,59	13,6000	18,1742	19,89	17,6000	15,5661	8,84
			14,6000	14,8450	1,07	16,5000	17,9885	6,47
			16,2000	17,7772	6,86	13,7000	13,8610	0,70
			16,0000	17,8020	7,83	11,5000	11,5447	0,19
			15,8000	16,7536	4,15			

Tabela 5 - Experimento I64

Valor Real	Valor Pre- visto	MAPE* teste						
10,3000	10,7758	2,07	16,0001	16,8890	3,86	15,8000	16,0660	1,16
9,2001	9,3080	0,47	21,2000	18,6569	11,06	18,7000	19,5958	3,89
8,6999	8,9181	0,95	21,4000	20,0262	5,97	15,3000	16,4031	4,80
8,4001	8,4340	0,15	18,4000	16,5983	7,83	11,8001	13,0127	5,27
8,1000	7,9399	0,70	14,8000	14,5345	1,15	9,4000	10,2510	3,70
7,8999	7,7615	0,60	12,9999	13,9274	4,03	8,8001	8,0699	3,17
8,1000	7,9797	0,52	12,2001	12,3089	0,47	8,6999	8,4823	0,95
7,5001	8,2305	3,18	11,9000	11,9985	0,43	8,6000	9,0299	1,87
8,5000	8,6782	0,77	11,4000	11,8606	2,00	8,6999	8,4932	0,90
9,7001	10,0939	1,71	11,2000	11,6293	1,87	9,9000	9,2767	2,71
10,9001	11,3359	1,89	12,4000	12,4616	0,27	11,8001	10,7650	4,50
11,2999	11,9347	2,76	14,4000	14,6143	0,93	14,1000	13,8647	1,02
9,9999	11,0143	4,41	16,2000	16,9976	3,47	14,8000	15,1521	1,53
9,5999	10,1170	2,25	17,5000	17,3871	0,49	16,1000	16,4383	1,47
9,5000	9,9821	2,10	19,0001	18,6838	1,38	16,5001	17,7054	5,24
9,5000	9,7526	1,10	20,1000	19,6514	1,95	16,3999	17,2127	3,53
9,5999	9,5898	0,04	20,8000	19,4948	5,67	16,7999	17,4069	2,64
9,7001	9,3732	1,42	16,5001	16,2934	0,90	16,3000	16,9638	2,89
9,9000	9,9466	0,20	17,5000	17,3982	0,44	15,4000	15,2865	0,49
10,6000	11,6453	4,54	18,6001	18,1607	1,91	14,2000	15,6056	6,11
15,0000	13,8221	5,12	18,6001	18,8623	1,14	15,0000	15,7059	3,07
16,3999	16,5169	0,51	18,0999	18,2143	0,50	18,7000	17,5110	5,17
15,4999	14,4905	4,39	16,7999	16,6749	0,54	18,4000	19,0876	2,99
13,3000	12,7557	2,37	15,6001	16,2217	2,70	15,4999	15,6185	0,52
11,0000	11,0750	0,33	16,2000	16,2270	0,12	12,2001	13,1144	3,98
9,8000	10,0147	0,93	19,0001	18,3035	3,03	10,3999	10,9697	2,48
9,5999	9,5986	0,01	18,4000	18,8494	1,95	9,1000	9,1467	0,20
9,7001	9,3591	1,48	15,0999	15,6724	2,49	8,8001	8,9854	0,81
9,8000	9,4706	1,43	12,0999	13,3040	5,24	8,6999	9,3713	2,92
10,7000	11,6561	4,16	10,5001	10,1099	1,70	8,5000	9,1612	2,87
12,6001	12,4656	0,58	9,7001	9,2273	2,06	9,0000	8,9307	0,30
14,9000	14,9285	0,12	9,7001	9,1814	2,25	9,9999	9,8913	0,47
15,8000	15,7642	0,16	9,7001	9,3945	1,33	10,2000	10,8274	2,73
17,1999	17,0618	0,60	9,5999	9,1356	2,02	11,0000	10,9807	0,08
18,4999	18,1415	1,56	10,3999	10,1393	1,13	12,2001	11,0521	4,99
18,8999	16,9163	8,62	12,4000	11,6051	3,46	13,1000	13,2427	0,62
14,6999	15,7721	4,66	14,2000	14,4740	1,19	13,6000	14,0534	1,97
16,3999	17,2960	3,90	15,0999	15,6695	2,48	12,3000	12,2574	0,19
18,6001	17,6376	4,18	16,3000	16,6834	1,67	11,2999	11,2703	0,13
18,8000	18,5555	1,06	17,1000	17,7247	2,72	11,6000	10,7249	3,80
18,8000	18,2876	2,23	17,9000	17,3638	2,33	12,0999	10,7605	5,82
18,0000	16,6956	5,67	12,5000	14,7139	9,63	12,4000	12,7437	1,49
15,8000	16,6593	3,74	14,9000	14,7790	0,53	12,7000	11,8463	3,71
			17,0000	17,6478	2,82	12,9000	12,4934	1,77
			17,0000	18,2110	5,27	13,6000	13,6575	0,25
			17,6000	17,7503	0,65	17,6000	16,0797	6,61
			13,6000	16,7493	13,69	16,5001	18,0344	6,67
			14,6000	14,8365	1,03	13,7000	14,5682	3,77
			16,2000	16,4774	1,21	11,5000	11,8409	1,48
			16,0001	17,1655	5,07			

6.3 Anexo 3: Resumo dos Resultados dos Experimentos com o Modelo MLP

O “*” significa que foi este o critério de parada utilizado durante o treinamento. Os experimentos em negrito são os apresentados na Tabela 2 - Melhores Resultados dos Experimentos

Tabela 6 - Resumo dos Resultados dos Experimentos do Grupo I

Vetor de Entrada	Camada oculta	Taxa de aprendizado	Número. máximo de épocas	MAPE* máximo admissível no treinamento	Número de épocas	MAPE* treinamento	EPMax* treinamento	CV treinamento	MAPE* teste	EPMax* teste	CV teste	Tempo de treinamento (seg.)
I1	2	0,99	500	3,00*	46	2,9964	34,2806	0,0731	6,8101	25,4893	0,1248	34
I2	5	0,99	500	3,00*	71	2,9980	32,4642	0,0723	6,6210	25,1542	0,1242	100
I3	8	0,99	500	3,00*	87	2,9984	32,1652	0,0720	6,4912	25,1169	0,1227	181
I4	10	0,99	500	3,00*	91	2,9993	31,5710	0,0727	6,5762	24,7132	0,1240	230
I5	14	0,99	500	3,00*	94	2,9999	31,4782	0,0727	6,5760	24,7326	0,1240	336
I6	15	0,99	500	3,00*	94	2,9981	31,4846	0,0727	6,5672	24,7249	0,1239	361
I7	18	0,99	500	3,00*	96	2,9991	31,4728	0,0726	6,6334	24,8689	0,1248	436
I8	20	0,99	500	3,00*	97	2,9987	31,4783	0,0727	6,6035	24,8362	0,1244	462
I9	25	0,99	500	3,00*	97	2,9982	31,4911	0,0727	6,6015	24,8509	0,1244	574
I10	30	0,99	500	3,00*	96	2,9998	31,4823	0,0727	6,6344	24,9066	0,1249	674
I11	35	0,99	500	3,00*	96	2,9995	31,4698	0,0726	6,6504	24,9421	0,1251	780
I12	2	0,05	4000	3,00*	174	2,9983	31,9335	0,0711	3,1924	19,4501	0,0749	129
I13	5	0,05	4000	3,00*	189	2,9977	31,9502	0,0711	3,2072	19,5013	0,0750	265
I14	8	0,05	4000	3,00*	191	2,9989	31,9457	0,0711	3,2135	19,5477	0,0751	397
I46	2	0,05	4000	2,80*	264	2,7999	32,5482	0,0691	3,0977	19,8387	0,0742	-
I47	5	0,05	4000	2,80*	380	2,7997	32,5073	0,0693	3,0393	19,4903	0,0741	-
I48	8	0,05	4000	2,80*	417	2,7998	32,5096	0,0693	3,0262	19,4336	0,0693	-
I15	10	0,05	4000	2,80*	388	2,8000	32,4961	0,0693	3,0381	19,4605	0,0740	1110
I54	10	0,05	5000	3,25*	108	3,2496	31,2469	0,0748	3,4704	19,7665	0,0788	274
I51	10	0,05	5000	3,20*	119	3,1989	31,3593	0,0740	3,3981	19,7046	0,0778	299
I52	10	0,05	5000	3,00*	187	2,9995	31,9865	0,0711	3,2207	19,9865	0,0752	481
I16	14	0,05	4000	2,80*	386	2,7999	32,5190	0,0692	3,0357	19,4700	0,0740	1359
I17	15	0,05	4000	2,80*	375	2,7999	32,5226	0,0692	3,0448	19,4858	0,0740	1437
I18	18	0,05	4000	2,80*	372	2,8000	32,4979	0,0692	3,0455	19,4816	0,0740	1693
I19	20	0,05	4000	2,80*	378	2,7997	32,5240	0,0692	3,0456	19,4874	0,0740	1893
I20	25	0,05	4000	2,80*	374	2,7997	32,5068	0,0691	3,0450	19,4807	0,0740	2382

I21	30	0,05	4000	2,80*	361	2,8000	32,5100	0,0691	3,0497	19,4947	0,0740	2531
I22	35	0,05	4000	2,80*	372	2,7997	32,5342	0,0691	3,0506	19,5131	0,0740	3034
I23	40	0,05	4000	2,80*	375	2,7996	32,5243	0,0691	3,0524	19,5131	0,0740	3553
I24	45	0,05	4000	2,80*	370	2,8000	32,5459	0,0691	3,0604	19,5322	0,0741	3858
I25	50	0,05	4000	2,80*	378	2,7999	32,5390	0,0691	3,0593	19,5374	0,0741	4415
I26	10	0,01	4000	2,80*	1451	2,7999	31,6830	0,0688	2,8759	18,9302	0,0722	3728
I43	10	0,01	8000	2,75*	2315	2,7500	31,7852	0,0686	2,8392	18,8641	0,0723	6163
I44	10	0,01	8000	2,70*	6704	2,7000	31,6884	0,0680	2,8043	18,9024	0,0716	1802
I45	10	0,01	8000	2,65	8000	2,6644	31,5923	0,0674	2,8159	19,3204	0,0723	2045
I27	10	0,03	4000	2,80*	529	2,7998	32,1181	0,0690	2,9507	19,2227	0,0729	1337
I28	10	0,07	4000	2,80*	436	2,7999	32,6473	0,0694	3,1051	19,5998	0,0750	1102
I29	10	0,10	4000	2,80*	386	2,7999	32,7523	0,0695	3,2516	19,8906	0,0763	979
I30	10	0,15	4000	2,80*	407	2,8000	32,8982	0,0694	3,4058	20,3201	0,0779	1026
I31	10	0,20	4000	2,80*	350	2,7996	33,0961	0,0690	3,4679	20,9455	0,0792	886
I32	10	0,25	4000	2,80*	368	2,7997	33,3484	0,0690	3,4964	21,0072	0,0794	928
I33	10	0,30	4000	2,80*	298	2,7993	33,4581	0,0692	3,7526	21,3802	0,0823	825
I34	10	0,35	4000	2,80*	285	2,7998	32,7835	0,0687	3,7726	21,8907	0,0827	720
I35	10	0,40	4000	2,80*	332	2,7995	32,7055	0,0680	3,6705	21,4089	0,0809	842
I36	10	0,05	5000	2,75*	897	2,7500	32,4922	0,0688	2,9613	19,4456	0,0735	2261
I37	10	0,05	5000	2,70*	1495	2,6999	32,4708	0,0681	2,9300	19,8128	0,0733	3853
I38	10	0,05	5000	2,65*	1606	2,6500	32,4425	0,0673	2,8584	19,7962	0,0716	4095
I39	10	0,05	5000	2,60*	2468	2,5999	30,6381	0,0650	2,8514	18,7172	0,0704	6582
I40	10	0,05	8000	2,55*	2573	2,5498	30,7923	0,0638	2,8574	16,8349	0,0685	6887
I41	10	0,05	8000	2,50*	3038	2,4999	30,3320	0,0629	2,8418	15,6561	0,0671	7717
I42	10	0,05	8000	2,45*	3300	2,4498	30,1953	0,0619	2,8234	15,1645	0,0667	8727
I46	10	0,05	5000	0,10	5000	2,1938	29,5651	0,0546	2,5983	11,9522	0,0589	1341
I59	10	0,05	5000	0,10	5000	2,2197	27,7964	0,0549	2,6104	13,9544	0,0603	1339
I47	10	0,05	7500	0,10	7500	1,9367	25,2918	0,0476	2,5578	14,8220	0,0600	2009
I60	10	0,05	7500	0,10	7500	2,0489	26,4945	0,0502	2,7014	11,4805	0,0592	2027
I48	10	0,05	1000	0,10	1000	1,9625	24,6948	0,0484	2,3515	11,8081	0,0528	2721
I56	10	0,05	1000	0,10	1000	1,9115	22,1264	0,0450	2,7127	12,5834	0,0616	2704
I61	10	0,05	1000	0,10	1000	1,8950	23,9839	0,0465	2,4209	12,7812	0,0533	2702
I64	10	0,05	1000	0,10	1000	1,8946	22,9137	0,0458	2,5168	13,6927	0,0571	2665
I65	10	0,05	1000	0,10	1000	1,8660	24,0168	0,0453	2,6541	14,5544	0,0609	2653
I66	10	0,05	1000	0,10	1000	1,9625	24,6948	0,0484	2,3515	11,8081	0,0528	2661
I67	10	0,05	1000	0,10	1000	1,9146	22,8594	0,0456	2,5974	12,9210	0,0581	2659
I68	10	0,05	1000	0,10	1000	2,0699	23,4551	0,0485	2,6094	12,1749	0,0584	2523
I69	10	0,05	1000	0,10	1000	1,8580	24,1224	0,0454	2,6030	13,5469	0,0600	2530
I57	10	0,05	1250	0,10	1250	1,7995	22,4918	0,0441	2,6874	15,8851	0,0625	3208
I53	10	0,05	1250	0,10	1250	1,8917	23,0858	0,0460	2,6139	11,5379	0,0564	-
I54	10	0,05	1250	0,10	1250	1,8118	22,8578	0,0435	2,7606	13,3551	0,0636	3360
I49	10	0,05	1500	0,10	1500	1,7725	21,5730	0,0420	2,7916	11,7605	0,0622	3835
I58	10	0,05	1500	0,10	1500	1,7655	19,1997	0,0411	3,0153	11,9121	0,0655	3850
I50	10	0,05	2000	0,10	2000	1,7470	18,0268	0,0402	2,8790	12,5789	0,0640	5129
I62	10	0,05	2000	0,10	2000	1,7307	19,0905	0,0409	2,7921	10,7157	0,0616	5374
I63	10	0,05	2000	0,10	2000	1,7146	22,1003	0,0415	2,6097	11,4289	0,0585	5335

6.4 Anexo 4: Resultados dos Experimentos com o Modelo Proposto

O “*” indica o melhor resultado obtido no grupo. Os experimentos em negrito são os apresentados na Tabela 1 - Melhores Resultados dos Experimentos da Primeira Etapa

Tabela 7 - Resultados dos Experimentos do Grupo D

Vetor de entrada	Agrupamentos	MAPE treinamento	EPMax* treinamento	CV treinamento	MAPE* teste	EPMax* teste	CV teste
D1	8	4,5210	32,2231	0,1008	5,0090	22,6270	0,1225
D1	9	4,3636	30,9381	0,0981	4,6360	21,0725	0,1119
D1	10	4,4009	29,5090	0,0973	4,8455	19,1862	0,1125
D1	11	4,3538	29,4672	0,0978	5,0011	20,6435	0,1146
D1*	12	4,2530	28,0480	0,0958	4,5045	19,0981	0,1062
D1	13	4,2809	28,8777	0,0975	4,9865	20,9753	0,1161
D1	14	4,2004	28,3292	0,0958	5,0482	19,9146	0,1167
D1	16	4,2240	29,4557	0,0948	4,8866	20,7665	0,1098
D2	10	4,3028	31,8941	0,0989	6,0962	26,0863	0,1392
D2	11	4,5334	31,7396	0,0997	5,9207	26,6442	0,1411
D2	12	4,4700	31,5816	0,0983	6,1169	26,1440	0,1419
D2*	13	4,2959	31,2040	0,0974	5,2448	24,6315	0,1260
D2	14	4,2787	31,8022	0,0952	5,6104	25,1997	0,1317
D3	10	4,6436	34,3534	0,1049	5,4553	21,6259	0,1258
D3	11	4,5074	31,6248	0,0999	5,2568	23,5495	0,1300
D3*	12	4,4286	31,7565	0,1009	4,9073	22,1843	0,1161
D3	13	4,4134	31,8132	0,1009	5,7554	22,8296	0,1308
D3	14	4,1919	29,7674	0,0938	6,5880	25,1312	0,1474
D4	8	4,6834	29,0387	0,1007	5,9633	19,7752	0,1276
D4	9	4,5992	28,6678	0,1007	5,3562	20,1667	0,1175
D4*	10	4,6138	28,2649	0,1005	5,1667	19,7710	0,1142
D4	11	4,7050	29,2268	0,1028	5,7298	19,6059	0,1252
D4	12	4,4937	29,1754	0,0995	6,6816	25,2412	0,1468
D4	13	4,4910	28,7157	0,0993	6,6389	24,6526	0,1466
D5	5	5,2538	31,2998	0,1158	5,6884	24,0584	0,1354
D5	8	4,6756	32,2128	0,1054	4,9526	20,1873	0,1160
D5	9	4,5898	32,7671	0,1048	4,8464	20,7413	0,1160
D5	10	4,6680	32,7107	0,1057	4,9060	20,0963	0,1188
D5	11	4,4800	30,2482	0,1011	4,5712	19,1307	0,1101
D5*	12	4,2523	30,4183	0,0965	4,8005	20,1806	0,1086
D5	13	4,4329	29,5344	0,0974	4,9013	20,5209	0,1127
D5	14	4,2738	28,6287	0,0951	5,5134	22,6963	0,1237
D5	16	4,2425	28,2601	0,0957	5,3511	21,1556	0,1221
D6	5	5,2866	31,2054	0,1162	5,7289	24,0303	0,1360

D6	7	4,7285	33,7461	0,1070	5,2444	20,4604	0,1202
D6	8	4,5396	33,6124	0,1036	4,7471	21,4306	0,1153
D6	9	4,3656	30,9716	0,0986	5,4892	22,1142	0,1229
D6	10	4,3012	29,6179	0,0973	4,6242	22,1976	0,1130
D6	11	4,3839	29,1703	0,0991	5,1473	19,3870	0,1144
D6*	12	4,1121	28,0633	0,0936	4,6810	21,2108	0,1090
D6	13	4,3653	28,6585	0,0961	4,9567	22,1244	0,1151
D6	14	4,1829	28,9163	0,0928	4,8417	20,1600	0,1122
D6	16	4,1389	28,2493	0,0933	4,7361	20,0022	0,1126

Tabela 8 - Resultados dos Experimentos do Grupo E

Vetor de entrada	Agrupamentos	MAPE* treinamento	EPMax* treinamento	CV treinamento	MAPE* teste	EPMax* teste	CV teste
E1	8	5,4951	25,2616	0,1153	7,0373	20,7338	0,1469
E1	9	5,7969	25,9973	0,1194	6,1697	19,5152	0,1307
E1*	10	5,5455	25,7261	0,1163	6,0507	20,5327	0,1289
E1	11	5,4881	24,8497	0,1147	6,2434	20,9257	0,1314
E1	12	5,5364	24,7491	0,1153	6,6394	21,3116	0,1384
E1	13	5,5496	24,7752	0,1155	6,6466	21,1042	0,1382
E1	14	5,6005	24,6196	0,1164	7,8160	26,7428	0,1656
E1	16	5,6818	23,1075	0,1164	8,2970	30,4194	0,1748
E2	8	4,7114	32,1980	0,1020	5,2942	19,7520	0,1157
E2	9	4,5982	28,6642	0,1006	5,3541	20,1680	0,1175
E2*	10	4,6128	28,2616	0,1004	5,1651	19,7729	0,1142
E2	11	4,7054	29,2316	0,1028	5,7297	19,6072	0,1252
E2	12	4,4939	29,1783	0,0995	6,6805	25,2360	0,1468
E2	13	4,4912	28,7182	0,0993	6,6375	24,6397	0,1465
E2	14	4,2770	28,4810	0,0943	6,2184	21,2731	0,1355
E2	16	4,1531	26,4777	0,0909	7,5522	31,2002	0,1699
E3	8	5,8962	24,7468	0,1207	7,0934	23,1192	0,1494
E3*	9	5,8750	23,3589	0,1193	7,0342	23,5349	0,1475
E3	10	5,7029	23,1671	0,1173	7,8031	27,5353	0,1633
E3	11	5,7923	23,2251	0,1185	8,0787	28,1316	0,1686
E3	12	5,7604	23,8409	0,1181	8,0470	27,1536	0,1684
E3	13	5,6990	23,7295	0,1168	7,9486	26,4793	0,1663
E4	10	5,5962	29,6562	0,1274	6,3588	42,6128	0,1490
E4	11	5,4839	28,2537	0,1264	6,0885	43,5143	0,1457
E4	12	4,6693	22,1492	0,1060	5,2549	26,3481	0,1241
E4	13	4,6212	22,8506	0,1550	5,1824	22,0412	0,1263
E4	14	4,7046	22,8605	0,1078	5,0712	21,8895	0,1214
E4	15	4,6973	22,2759	0,1072	5,5138	24,5661	0,1309
E4	16	4,2907	22,5784	0,0975	5,1797	20,6391	0,1193
E4	17	4,5636	22,7072	0,1027	5,1299	18,6713	0,1144
E4	18	4,4057	22,1004	0,1016	4,7702	22,9774	0,1108
E4	19	4,3555	23,0654	0,1004	5,0121	23,2503	0,1169
E4	20	4,2854	25,0447	0,0974	4,8211	25,7130	0,1114
E4*	21	4,2099	22,9197	0,0972	4,6633	23,5201	0,1064
E4	22	4,0186	23,1575	0,0925	4,6925	22,7130	0,1068
E4	23	4,1651	23,4353	0,0952	4,7941	20,9111	0,1081

E4	24	4.3262	22.0688	0.0996	5.4648	22.4678	0.1208
E4	25	4.3274	22.3732	0.1000	5.4699	22.4838	0.1205
E4	27	4.1987	22.3174	0.0990	5.3962	22.5252	0.1192
E4	30	3.9742	23.0204	0.0909	5.1435	19.5073	0.1148
E4	32	3.9630	22.9303	0.0907	5.0071	20.5274	0.1121
E4	33	3.9369	23.5116	0.0905	4.9981	20.9433	0.1168
E5	8	5.1275	32.4279	0.1156	5.7774	22.9557	0.1307
E5	10	5.4936	30.7146	0.1201	5.9925	21.6462	0.1313
E5	12	4.8420	34.9494	0.1103	5.2963	20.7086	0.1195
E5	14	4.7060	32.1908	0.1059	5.2547	23.2095	0.1206
E5	15	4.8161	30.0226	0.1070	5.6742	20.9787	0.1232
E5*	16	4.2657	30.2331	0.0995	5.1073	21.6819	0.1124
E5	17	4.6050	31.3778	0.1044	5.1999	22.8462	0.1164
E5	18	4.7431	32.1820	0.1060	4.9938	22.1117	0.1149
E6	8	7,7086	34,4525	0,1640	7,3285	20,8073	0,1558
E6	9	6,3950	49,0908	0,1432	6,7959	31,9961	0,1640
E6	10	5,6321	43,0427	0,1256	5,8313	31,0601	0,1305
E6	11	5,5357	36,8497	0,1218	5,6122	23,8604	0,1256
E6	12	5,3304	35,5101	0,1171	5,3709	24,0775	0,1211
E6	13	7,7086	34,4525	0,1640	7,3285	20,8073	0,1558
E6	14	5,4869	30,9328	0,1170	5,9515	21,5885	0,1323
E6	16	4,3650	29,6905	0,0983	5,5675	23,8545	0,1328
E6	18	5.1012	26.3352	0.1113	5.3930	22.8781	0.1246
E6*	25	4.6578	29.3740	0.1051	4.9504	26.7404	0.1203
E6*	27	4.6358	29.7376	0.1044	4.9391	24.7481	0.1198
E6	30	4.4743	32.1850	0.1014	5.0207	21.1685	0.1201
E6	35	4.4861	32.8829	0.1017	5.1996	22.8665	0.1214

Tabela 9 - Resultados dos Experimentos do Grupo F

Vetor de entrada	Agrupamentos	MAPE* treinamento	EPMax* treinamento	CV treinamento	MAPE* teste	EPMax* teste	CV teste
F1	6	6.3116	28.1599	0.1286	6.1422	22.0807	0.1291
F1	8	4.5980	28.9946	0.1031	4.7906	21.7460	0.1090
F1*	9	4.4245	28.7556	0.0993	4.5060	22.6955	0.1048
F1	10	4.7586	32.1032	0.1056	5.4991	23.5976	0.1240
F1	12	4.4665	28.6034	0.0996	5.2165	22.3745	0.1187
F1	14	4.3068	27.2915	0.0975	5.5779	23.8818	0.1213
F1	16	4.5354	24.8622	0.0988	6.1732	21.5149	0.1318
F1	18	4.6046	22.3932	0.0998	6.1054	22.7116	0.1350
F1	20	4.6876	23.1974	0.1015	5.9857	22.6113	0.1284
F2	8	4.4919	29.9188	0.0961	5.2794	23.3610	0.1095
F2	10	4.0781	29.4589	0.0874	5.4673	23.0069	0.1162
F2	12	3.7523	31.0163	0.0798	4.8808	18.2962	0.1005
F2	14	3.5852	31.3240	0.0779	5.0077	19.4808	0.1026
F2	16	3.4810	29.9616	0.0756	4.9970	19.9410	0.1024
F2	18	3.4712	29.7655	0.0751	5.2157	20.7976	0.1036
F2	20	3.2810	29.2643	0.0726	4.6911	20.1979	0.0954
F2	22	3.2627	28.8725	0.0722	4.7279	19.9138	0.0951
F2	24	3.1384	28.8822	0.0703	4.6681	19.1288	0.0960
F2	26	2.8351	29.2506	0.0664	3.9836	19.2818	0.0856
F2	27	2.9768	29.5945	0.0682	4.5044	19.2747	0.0941
F2*	28	2.7384	29.2832	0.0653	3.4400	19.1992	0.0797
F2	29	3.0175	28.8906	0.0687	4.5418	19.1591	0.0942
F2	30	2.8904	28.6249	0.0667	4.3945	18.9002	0.0923
F2	32	2.7846	27.2162	0.0645	4.5716	20.7030	0.0966
F2	35	2.7861	26.8105	0.0644	4.5471	21.4568	0.0973
F2	40	2.7855	26.2026	0.0643	4.5002	21.7559	0.0973
F2	45	2.5639	24.9909	0.0590	4.9284	20.5438	0.1069
F2	50	2.5431	24.9356	0.0599	4.4061	20.7488	0.0960
F3	10	4.4595	30.2647	0.0990	4.7829	19.6003	0.1128
F3	11	4.4316	30.6904	0.0989	4.7844	19.1856	0.1116
F3*	12	4.3342	29.4866	0.0980	4.3380	20.4902	0.1021
F3	13	4.4493	29.8333	0.0974	4.8696	17.7665	0.1130
F3	14	4.0845	26.7928	0.0900	4.4955	19.9460	0.1090
F3	16	3.9833	29.6863	0.0892	4.9425	20.9731	0.1168
F3	18	3.9245	25.8467	0.0876	4.9674	20.4188	0.1166
F4	10	3.7284	30.6506	0.0812	4.5470	22.6918	0.0942
F4	12	3.6879	30.5160	0.0814	4.8688	22.2132	0.1003
F4	15	3.5779	28.8071	0.0782	4.5406	19.9245	0.0936
F4	20	3.1119	30.1865	0.0703	4.9984	22.9921	0.1030
F4	25	3.1603	28.0341	0.0719	4.6957	22.5167	0.0954
F4	30	3.1017	28.6970	0.0709	4.5775	22.6960	0.0965
F4	35	2.7214	27.3513	0.0630	5.0235	21.7058	0.1079
F4	40	2.6588	27.9677	0.0623	4.8341	21.3296	0.1031
F4	45	2.5323	28.1361	0.0601	4.2866	22.1713	0.0940
F4	47	2.5815	27.9033	0.0609	4.3443	23.8081	0.0948
F4*	50	2.6103	28.5549	0.0618	4.2335	23.7684	0.0929
F5	12	4.0136	32.1979	0.0864	5.4507	22.5296	0.1117
F5	15	3.6888	30.8058	0.0819	5.7445	22.2512	0.1136

F5	20	3,3154	27,2507	0,0733	4,6872	20,3817	0,0959
F5	25	3,1132	23,1821	0,0684	4,4017	19,4446	0,0933
F5	27	3,1329	24,2953	0,0688	4,7115	19,3722	0,0985
F5	29	2,9459	24,3823	0,0667	4,6058	19,2825	0,0976
F5*	30	2,9898	24,2000	0,0671	4,2247	19,5238	0,0921
F5	31	2,8976	24,9798	0,0661	4,3491	19,4866	0,0940
F5	32	3,0727	24,4779	0,0677	4,8697	20,0096	0,1014
F5	33	2,9493	24,4826	0,0669	5,2729	22,2370	0,1137
F5	35	2,7327	26,9477	0,0644	4,8846	19,4558	0,1039
F5	40	2,8653	26,0937	0,0649	4,9706	20,8947	0,1040
F5	45	2,7323	27,2736	0,0630	5,1638	21,6759	0,1089
F6	10	4,0491	27,7945	0,0877	4,7268	20,8213	0,0982
F6	15	3,5290	28,8780	0,0775	5,0053	20,6397	0,1025
F6	17	3,1102	28,1411	0,0701	4,6483	21,6993	0,0962
F6	19	3,0165	30,5120	0,0688	3,9968	21,8426	0,0869
F6*	20	2,8483	32,1550	0,0654	3,8598	21,8738	0,0834
F6	21	2,8556	31,9457	0,0655	3,8717	21,0607	0,0833
F6	22	3,1348	29,0001	0,0698	4,2333	21,8086	0,0894
F6	25	3,0598	27,3120	0,0702	4,2120	19,7142	0,0902
F6	30	2,9691	27,8082	0,0688	4,0838	20,2064	0,0886
F6	35	2,8175	29,7329	0,0665	4,3274	20,5966	0,0943
F6	40	2,8068	29,4294	0,0656	4,5927	20,3862	0,0999
F7	10	4,1302	28,2959	0,0879	5,5482	20,8400	0,1161
F7	15	3,5926	28,4517	0,0794	5,0589	19,4687	0,1023
F7	20	3,4041	28,4256	0,0763	5,2298	21,1926	0,1077
F7	25	3,0063	31,9861	0,0688	4,6301	20,4610	0,1023
F7	30	2,7031	31,2627	0,0653	3,4793	21,1428	0,0813
F7	32	2,6059	31,2997	0,0638	3,6171	20,1409	0,0830
F7	35	2,4765	30,3095	0,0604	3,4945	19,6554	0,0806
F7	36	2,4658	30,3642	0,0602	3,4933	19,6112	0,0807
F7	37	2,4640	30,9534	0,0604	3,5137	19,4464	0,0808
F7*	38	2,4766	28,4283	0,0592	3,4069	19,8876	0,0802
F7	39	2,4911	29,1638	0,0598	3,4156	19,7409	0,0798
F7	40	2,4947	30,3658	0,0602	3,4291	19,8397	0,0798
F7	41	2,5108	27,6461	0,0594	3,4831	19,6776	0,0800
F7	42	2,4940	26,1900	0,0590	3,4305	20,4724	0,0798
F7	45	2,4614	26,1731	0,0589	3,6050	18,9548	0,0816
F7	47	2,4425	26,3419	0,0586	3,5765	18,9759	0,0812
F7	50	2,4226	26,6034	0,0586	3,6511	19,0099	0,0820
F7	60	2,4475	27,4162	0,0588	3,7330	17,8240	0,0827
F7	100	2,1691	25,1254	0,0533	4,0176	18,4640	0,0910
F7	150	2,1808	24,5021	0,0523	5,6859	18,0612	0,1181
F7	200	2,0811	21,5827	0,0508	7,7512	24,4218	0,1623

Tabela 10 - Resultados dos Experimentos do Grupo G

Vetor de entrada	Agrupamentos	MAPE treina- mento	EPMax* treina- mento	CV treinamento	MAPE* teste	EPMax* teste	CV teste
G1	5	5.4688	30.9124	0.1177	5.7165	26.2837	0.1274
G1*	8	4.5520	32.6732	0.1029	5.3477	25.6045	0.1256
G1	12	3,5349	28,2305	0,0794	6,5671	33,4574	0,1532
G1	15	2.6412	30.5139	0.0669	7.2110	34.8039	0.1683
G1	20	2,5651	31,4505	0,0659	7,0641	31,8771	0,1642
G1	25	2.4773	30.0271	0.0635	7.3366	34.9784	0.1673
G1	30	2,4659	29,7055	0,0631	7,3109	34,8269	0,1668
G1	35	2.3237	27.7092	0.0586	7.1852	33.2936	0.1676
G1	38	2,2517	27,7145	0,0571	7,3322	34,5109	0,1725
G1	40	2.2699	28.9703	0.0578	7.2999	34.6307	0.1722
G1	45	2.3580	26.8717	0.0592	7.3384	33.5305	0.1721
G1	50	2.3520	27.3093	0.0590	7.2922	32.9811	0.1712
G2*	20	2.6371	31.2407	0.0673	6.8504	32.3474	0.1605
G2	25	2.5699	29.5816	0.0647	7.0849	33.2530	0.1628
G2	28	2.5956	29.5057	0.0652	7.0010	33.0756	0.1622
G2	30	2.5485	29.1883	0.0642	7.0027	32.8966	0.1616
G2	35	2.4264	27.1348	0.0603	6.9213	31.5022	0.1627
G2	40	2.3785	28.4499	0.0594	7.0340	32.9897	0.1674
G2	45	2.4043	26.5311	0.0598	7.0622	31.6733	0.1671
G3*	12	3.5619	30.9420	0.0826	5.7712	29.4592	0.1402
G3	15	2.6554	31.3182	0.0688	6.2213	36.7418	0.1522
G3	20	2.5389	30.3496	0.0654	6.4308	33.2548	0.1543
G3	28	2.4823	29.1569	0.0628	6.4941	32.0792	0.1531
G3	30	2.4420	29.0168	0.0626	6.5101	32.2834	0.1534
G3	40	2.4838	30.3146	0.0625	6.4705	30.6797	0.1520

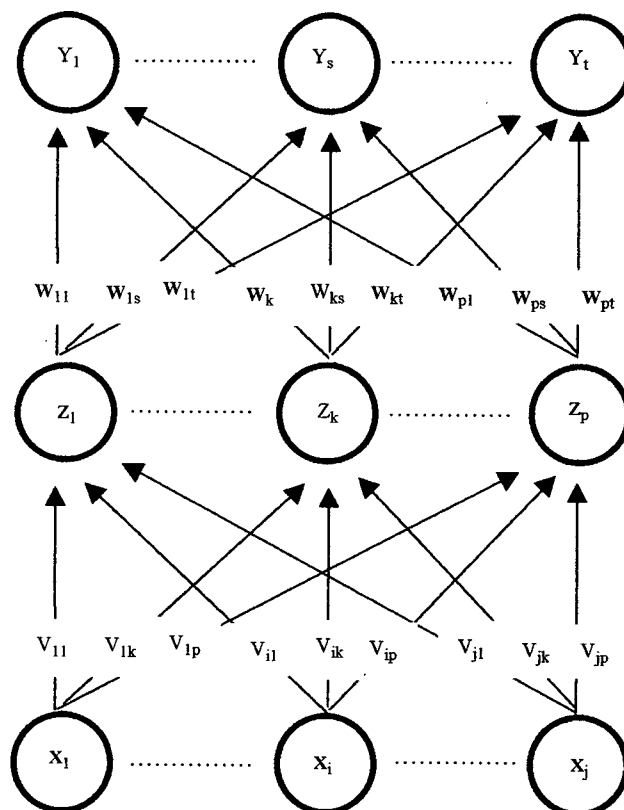
Tabela 11 - Resultados dos Experimentos do Grupo H

Vetor de entrada	Agrupamentos	MAPE treinamento	EPMax* treinamento	CV treinamento	MAPE* teste	EPMax* teste	CV teste
H1*	20	5.4955	29.4429	0.1160	11.1717	44.0979	0.2556
H1	25	5.2074	35.4598	0.1101	11.2601	42.3639	0.2470
H1	38	5.1623	34.5005	0.1110	11.2222	40.2399	0.2406
H1	50	5.2308	34.4389	0.1139	11.4789	44.6805	0.2479
H1	70	4.7611	27.7447	0.1006	11.9552	42.3299	0.2584
H1	100	5.0609	27.9410	0.1084	11.6309	42.6611	0.2514
H1	120	3.6731	22.7377	0.0818	12.4545	42.4845	0.2618
H1	150	2.7080	21.5247	0.0613	13.3641	43.0619	0.2750
H2	20	3.2359	30.6016	0.0704	12.5999	43.3709	0.2722
H2	25	3.0540	30.4747	0.0699	12.3757	42.8439	0.2663
H2*	30	2.9682	29.9507	0.0683	12.3129	42.7970	0.2658
H2	38	2.7138	29.6851	0.0632	12.4856	42.9162	0.2667
H2	50	2.3265	27.0069	0.0572	12.5620	43.5781	0.2660
H2	75	2.2879	23.9301	0.0552	12.7012	43.6211	0.2669
H2	150	1.9344	22.5990	0.0493	13.4844	44.5902	0.2753

6.5 Anexo 5: Arquitetura Perceptron Múltiplas Camadas

A arquitetura Perceptron Múltiplas Camadas (*Multilayer Perceptron*) é o paradigma de Rede Neural Artificial de propósito mais geral e mais utilizado. Esta arquitetura de RNA é inspirada nas redes neurais biológicas e composta por neurônios do tipo Perceptron, proposto por Rosenblatt em 1962. A MLP é uma RNA não linear, de múltiplas camadas e de percorrimento à frente (*feedforward*). Esta rede comporta-se como um aproximador universal e mostra-se um veículo prático para realização de um mapeamento não linear, de natureza geral, entre entrada e saída.

Figura 9 - Rede MLP de 3 camadas



A rede MLP (Figura 9) é formada por 3 ou 4 camadas de neurônios. A primeira camada contém os sinais de entrada da rede, a(s) camada(s) intermediária(s) ou oculta(s) representa(m) a distribuição do conhecimento dentro da rede e a última camada os valores da saída da rede. As ligações entre as camadas de neurônios são ponderadas por pesos,

cujo valor traduz a intensidade entre estas ligações.

Na maioria das implementações atuais a saída de cada neurônio é dada por uma função de ativação não linear. As duas funções de ativação normalmente utilizadas são a função sigmoideal binária (13) e a função sigmoideal bipolar (14). A função sigmoideal binária produz valores de saída entre 0 e 1 e a bipolar entre -1 e 1.

Função sigmoideal binária:

$$f(x) = \frac{1}{1 + \exp(-x)} \quad 13$$

Função sigmoideal bipolar:

$$f(x) = \frac{2}{(1 + \exp(-x)) - 1} \quad 14$$

Onde x representa o nível de ativação do neurônio.

A rede MLP pode ser vista como uma aplicação do método de otimização conhecido como *aproximação estocástica* (Haykin, 1994). Ela realiza aproximações globais para o mapeamento entre a entrada e a saída da rede. O treinamento da rede é normalmente efetuado por meio do algoritmo de Retropropagação (*Backpropagation*). Este algoritmo executa um treinamento supervisionado da rede, utilizando a retropropagação do erro entre a saída produzida pela rede e o alvo. O treinamento é feito em três fases: propagação à frente (*feedforward*) do padrão de entrada (padrão de treinamento), cálculo e retropropagação do erro apurado e ajuste dos pesos associados às conexões dos neurônios na direção do menor erro entre a saída produzida pela rede e o alvo. Após o treinamento, o uso da rede envolve apenas a fase de propagação à frente (*feedforward*).

A base matemática para o algoritmo de Retropropagação é a técnica de otimização do gradiente descendente. A idéia básica é calcular derivadas parciais de uma função de aproximação $F(\mathbf{w};\mathbf{x})$, realizada pela rede para todos os elementos do vetor de pesos ajustáveis \mathbf{w} para um dado valor do vetor de entrada \mathbf{x} (Haykin, 1994). O gradiente da função dá a direção na qual a função aumenta mais rapidamente e o negativo do gradiente dá a direção na qual a função diminui mais rapidamente. Aplicada à minimização de erro da rede, a função representa o erro e suas variáveis são os pesos da rede.

Os parâmetros livres, que necessitam serem ajustados para o treinamento da rede são: o número de neurônios na camada oculta, a inicialização dos pesos da rede, o valor da taxa de aprendizado, o erro máximo admissível no treinamento e número máximo de épocas de treinamento. Caso não haja conhecimento prévio a respeito de quais sejam os bons valores de inicialização de pesos para o problema em questão, uma boa alternativa é a sua inicialização aleatória. A taxa de aprendizado se traduz no tamanho dos passos dados, ao percorrer a superfície de erro, em busca do ponto de erro mínimo global. Passos mais largos propiciam um treinamento mais rápido porém aumentam o risco de que se passe o ponto de mínimo e a rede não consiga estabilizar. O número de épocas de treinamento e o erro máximo admissível no treinamento são critérios para a parada do treinamento. Redes treinadas com um número de épocas excessivo memorizam os vetores de entrada e perdem a capacidade de generalizar. Por fim, um valor muito baixo para o erro máximo admissível pode se mostrar impossível de ser alcançado durante o treinamento.

Um outro parâmetro que pode ser utilizado no algoritmo de Retropropagação é o momento (*momentum*). A introdução deste parâmetro modifica a direção para a alteração de pesos. A direção que era função do gradiente descendente corrente, passa a ser função da combinação entre os gradientes descendentes corrente e anterior. Esta técnica procura aumentar as chances da rede estabilizar no ponto de erro mínimo global, diminuindo portanto a possibilidade da rede estabilizar em um ponto de mínimo local.

A rede MLP treinada com o algoritmo de Retropropagação possui equilíbrio entre uma boa memorização do conjunto de treinamento e uma boa capacidade de resposta às entradas similares ao padrão de treinamento (generalização). Isto habilita a rede a reconhecer padrões que são similares aos do conjunto de treinamento ou padrões com ruído. Suas desvantagens são o elevado tempo para treinamento e o grande número de parâmetros a


ajustar. A quantidade de parâmetros soma-se a falta de uma metodologia para o ajuste ideal de seus valores. Os valores são geralmente obtidos através de técnicas heurísticas e experimentação.

Uma descrição detalhada da arquitetura Perceptron Múltiplas Camadas pode ser obtida em Dandolini (1997), Fausett (1994), Haykin (1994) e Skapura (1996).

6.6 Anexo 6: Arquitetura Função de Base Radial

A arquitetura Função de Base Radial é uma rede de múltiplas camadas e propagação direta (*feedforward*). Esta rede pertence a classe de RNA's onde a ativação dos neurônios da camada oculta é determinada pela distância entre o vetor de entrada e um vetor padrão. Segundo Haykin (1994), o funcionamento da RBF se baseia na procura do ajuste de uma curva (aproximação) em um espaço de grande dimensão. Sob esta ótica, seu processo de aprendizado busca encontrar uma superfície num espaço multidimensional que dá o melhor ajuste para os dados de treinamento. A generalização, é o uso desta superfície multidimensional para interpolar os dados de teste.

Figura 10 - Rede RBF de 3 camadas (in ORR, 1996)



A RBF (Figura 10) é normalmente composta de uma estrutura de três camadas. A primeira camada é composta por neurônios (x) que representam os sinais de entrada da

rede. A segunda camada é composta por neurônios ($h(x)$) normalmente denominados de agrupamentos. Cada um destes agrupamentos circunscreve uma região espacial por meio de um centro e um raio próprios. Nesta camada, o espaço de entrada é transformado, de maneira não linear, em um espaço de maior dimensão. A terceira camada é formada por neurônios que representam a dimensão do vetor de saída desejado. Nesta última camada, os padrões resultantes da camada intermediária são então transformados no padrão de saída.

O método função de base radial tem suas origens nas técnicas de interpolação exata de um conjunto de dados dentro de um espaço multidimensional (Powell, 1987, cf. in Bishop, 1995). O problema da interpolação exata requer que todo vetor de entrada seja mapeado exatamente para um vetor alvo. Assim, o objetivo é encontrar uma função $f(x)$ capaz de proceder este mapeamento, como mostra a (15)

$$f(x_n) = t_n \quad 15$$

Onde:

x é o vetor de entrada da rede;

t é o alvo;

n é o número de vetores de entrada.

A interpolação exata implica no uso de uma função de interpolação que passe exatamente por todos os pontos do mapeamento. Uma de suas desvantagens é que quando há ruído nos dados, a função de interpolação que dá a melhor generalização é uma função mais suave e que faz uma média sobre o ruído. Uma outra desvantagem é que o número de funções da camada oculta é igual ao número de padrões do conjunto de dados (Bishop, 1995). Buscando eliminar estas desvantagens, Broomhead e Lowe (1988) e Moody e Darken (1989), citados em Bishop (1995), introduziram modificações no procedimento de interpolação exata de forma a suavizar a função de interpolação e fazer com que o número de funções da camada oculta seja determinado pela complexidade do mapeamento a ser

representado.

O aumento dimensional que ocorre na segunda camada (camada oculta) da rede está baseado no princípio, enunciado por Cover (1965, cf. in Haykin, 1994) de que um complexo problema de classificação de padrões lançado de forma não linear em um espaço de grande dimensão é mais fácil de ser linearmente separável do que em um espaço de pequena dimensão. Procedido o aumento dimensional, a função $f(\mathbf{x})$ é mapeada para um vetor formado de um conjunto de funções $\{f_i(\mathbf{x}) \mid i=1,2,\dots,M\}$ como mostrado na (16).

$$f(x) = [f_1(x), f_2(x), \dots, f_M(x)]^T \quad 16$$

Onde:

x é o padrão de entrada;

M é a quantidade de agrupamentos da camada oculta.

A transformação das dimensões que ocorre na camada oculta da rede é efetivada pelo mapeamento não linear do espaço de entrada. Para a consecução deste mapeamento são utilizadas funções de base radial. A saída de uma rede RBF (Haykin, 1994, p. 243) tem a forma da (17).

$$F(x) = \sum_{i=1}^M w_i h(\|x - x_i\|) \quad 17$$

Onde:

$\{h(\|x - x_i\|) \mid i=1,2,\dots,M\}$ é o conjunto das M funções (agrupamentos) da camada oculta conhecidas como funções de base radial;

x é o padrão de entrada;

$\|\mathbf{x} - \mathbf{x}_i\|$ é a norma da distância (usualmente a distância euclidiana);

$\mathbf{x}_i \in \mathcal{R}^p, i = 1, 2, \dots, M$ são os centros das funções de base radial (agrupamentos);

w são os coeficientes desconhecidos (pesos) que minimizam a diferença da função $F(\mathbf{x})$ em relação ao alvo.

Normalmente utiliza-se a função gaussiana como a função $h(\mathbf{x})$. A função $h(\mathbf{x})$ assume então a forma da (18).

$$h(\mathbf{x}) = \exp\left[-\frac{1}{2\sigma_i^2}\|\mathbf{x} - \mathbf{x}_i\|^2\right] \quad i = 1, 2, \dots, M \quad 18$$

Onde:

\mathbf{x}_i são os centros dos agrupamentos;

σ_i são as larguras dos agrupamentos.

O treinamento da RBF acontece em dois estágios. No primeiro estágio os parâmetros das funções de base radial são determinados utilizando métodos de treinamento não supervisionado. Os métodos de treinamento empregados são rápidos e usam apenas os dados de entrada da rede (não utilizam os dados relativos ao alvo). No segundo estágio o treinamento é supervisionado e implica na determinação dos pesos da última camada da rede. Os pesos podem ser otimizados através da minimização de uma função de erro tal com a função de erro da soma dos quadrados.

Bishop (1995) mostra que o emprego da álgebra linear na metodologia de cálculo da rede torna os cálculos mais fáceis e mais rápidos. Para que isto se torne possível, é necessário que as funções de base radial sejam mantidas fixas. Além disto, o uso da função de erro como uma função quadrática dos pesos torna possível que seu mínimo seja encontrado a partir da solução de um conjunto de equações lineares. Por fim, embora possível, não é interessante o emprego de uma função não linear para a ativação dos neurônios da

última camada. O emprego de uma função não linear no cálculo da saída da rede, bem como de outra função de erro, faz com que o problema de otimização dos pesos deixe de ser um problema tratável pela álgebra linear. Como demonstra Bishop (1995), utilizando-se os conceitos expostos, a partir da (15) e da (17) pode-se escrever, em notação matricial, a (19), a qual provê a solução para o problema da otimização dos pesos da rede.

$$\mathbf{W}^T = \mathbf{H}^\Psi \mathbf{T} \quad 19$$

Onde:

\mathbf{W}^T é a transposta da matriz de pesos;

\mathbf{H}^Ψ é a pseudo-inversa da matriz de funções de base radial;

\mathbf{T} é a matriz de alvos.

O uso da álgebra linear na metodologia de cálculo da rede torna a RBF extremamente rápida. Segundo Haykin (1994), duas das características da arquitetura Função de Base Radial são sua capacidade de aprendizado rápido e sensibilidade reduzida a ordem de apresentação dos dados de treinamento. Maiores detalhes a respeito desta arquitetura de RNA podem ser obtidos em Bishop (1995), Haykin (1994), Orr (1996) e Pandya e Macy (1995).

7. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] AlFuhaid A. S., El-Sayed M. A., Mahmoud M. S. (1997). Cascaded Artificial Neural Networks For Short-Term Load Forecasting. *IEEE Transactions on Power Systems*, 12 (4), 1524-1529.
- [2] Bakirtzis, A. G., Petridis, V., Kiartzis S. J., Alexiadis M. C., Maissis A. H. (1995). A NEURAL NETWORK SHORT TERM LOAD FORECASTING MODEL FOR THE GREEK POWER SYSTEM. *IEEE Transactions on Power Systems*, 11 (2), 858-863.
- [3] Bakirtzis, A. G., Theocharis, J. B., Kiartzis S. J., Satsios, K. J. (1995). SHORT TERM LOAD FORECASTING USING FUZZY NEURAL NETWORKS. *IEEE Transactions on Power Systems*, 10 (3), 1518-1524.
- [4] Bishop, C. M. (1995). *Neural Networks for Pattern Recognition*. New York: Oxford University Press.
- [5] Choueiki, M. H., Mount-Campbel, C. A., Ahalt, S. C. (1997). BUILDING A 'QUASI OPTIMAL' NEURAL NETWORK TO SOLVE THE SHORT-TERM LOAD FORECASTING PROBLEM. *IEEE Transactions on Power Systems*, 12 (4), 1432-1439.
- [6] Dandolini, G. V. (1997). *UM PROCEDIMENTO PARA AVALIAÇÃO DA SAÚDE FINANCEIRA DE PEQUENAS EMPRESAS: ESTUDO DE UM CASO USANDO REDES NEURONAIAS ARTIFICIAIS*, Dissertação, Florianópolis: UFSC/PPEG.
- [7] Fausett, L. V. (1994). *Fundamentals of Neural Networks*. Englewood Cliffs, New Jersey: Prentice- Hall.
- [8] Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. Englewood Cliffs, New Jersey: Macmillan College.

- [9] Kiartzis S. J., Zoumas C. E., Theocharis J. B., Bakirtzis, A. G., Petrdis, V. (1997). NEURAL NETWORK BASED SHORT TERM LOAD FORECASTING. *IEEE Transactions on Power Systems*, 8(1), 336-342.
- [10] Leite, F. E. A. (1997). *Aplicação de Redes Neurais Artificiais na Previsão de Curto Prazo da Carga Nodal de Sistemas de Energia Elétrica*. Campinas: Unicamp (Dissertação).
- [11] Lu C. N., Wu H. T., Vemuri S. (1993). SHORT TERM LOAD FORECASTING IN AN AUTONOMOUS POWER SYSTEM USING ARTIFICIAL NEURAL NETWORKS. *IEEE Transactions on Power Systems*, 12(4), 1591-1596.
- [12] Martin, M (1996). INTEGRATED MODEL FOR VERY SHORT-TERM LOAD FORECASTING. *12th Power Systems Computation Conference*, Dresden, 245-251.
- [13] Oliveira, C. M. de, Rivero, S. L. M., Wazlawick, R. S., Pezzi, S., Bastos, L. C. (1998). A previsão do PIB brasileiro através das redes neurais Perceptron Multicamadas e Função de Base Radial. Florianópolis, UFSC, <http://www.inf.ufsc.br/lsc/producao.html>, em 10/08/98.
- [14] Orr, M. J. L. (1996) *Introduction to Radial Basis Function Networks*. Edinburg, <http://www.cns.ed.ac.uk/people/mark/papers/rbf.html>, em 07/10/98
- [15] Pandya, A. S., Macy, R. B. (1995) *Pattern Recognition with Neural Networks in C++*. USA: IEEE Press.
- [16] Skapura, D. M. (1996). *Building Neural Networks*. New York: ACM Press.
- [17] Tafner, M. A., Xerez, M., Filho, I. W. R. (1995). *Redes Neurais Artificiais: introdução e princípios de neurocomputação*. Blumenau: EKO: Ed. da FURB.
- [18] Wakita R., Yokoyama A. (1995). NEXT DAY PEAK LOAD FORECASTING USING SEAZONAL ARTIFICIAL NEURAL NETWORK MODEL. *International Power Engineering ConferenceEEE Transactions on Power Systems*. Singapore, 660-665.
- [19] Xiao, B., McLaren, P. G. (1995). An Artificial Neural Network for Short Term Lo-

ad Forecasting. *IEEE/WESCANEX'95 Proceedings*, 129-132.

- [20] Zebulum, R. S., Pacheco, M. A., Vellasco M. (1996). Um Sistema Inteligente de Previsão de Carga Aplicado ao Setor Elétrico Brasileiro. *V Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica*, Recife, 791-797.