

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**“Sistema Inteligente Para Previsão de Carga
Multinodal em Sistemas Elétricos de Potência”**

ALESSANDRA BONATO ALTRAN

Orientador: Prof. Dr. Carlos Roberto Minussi

Co-orientador: Prof. Dr. Francisco Villarreal Alvarado

Tese apresentada à Faculdade de
Engenharia - UNESP – Campus de Ilha
Solteira, para obtenção do título de
Doutor em Engenharia Elétrica.

Área de Conhecimento: Automação.

Ilha Solteira – SP
Novembro/2010

FICHA CATALOGRÁFICA

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

A469s Altran, Alessandra Bonato.
Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência / Alessandra Bonato Altran. -- Ilha Solteira : [s.n.], 2010.
86 f. : il.

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

Orientador: Carlos Roberto Minussi
Co-orientador: Francisco Villarreal Alvarado
Inclui bibliografia

1. Previsão de carga multinodal. 2. Redes neurais (Computação). 3. Funções de base radial.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência

AUTORA: ALESSANDRA BONATO ALTRAN

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

CO-ORIENTADOR: Prof. Dr. FRANCISCO VILLARREAL ALVARADO

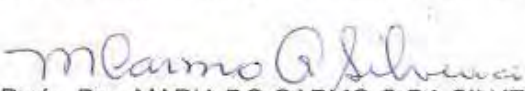
Aprovada como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. CARLOS ROBERTO MINUSSI


Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

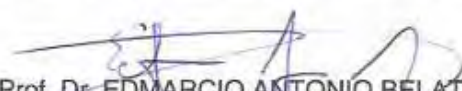
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARIA DO CARMO G DA SILVEIRA

Polo Computacional / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. GELSON DA CRUZ JUNIOR

Escola de Engenharia Elétrica e de Computação / Universidade Federal de Goiás


Prof. Dr. EDMARCIO ANTONIO BELATI

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC

Data da realização: 27 de novembro de 2010.

Ao Pai do Céu.

Aos meus pais, Alziro e Luiza.

A gradecimentos

Venho com estas singelas palavras registrar meu eterno agradecimento às pessoas que fizeram parte, de uma forma ou de outra, de minha caminhada.

Primeiramente aos meus pais, Alziro e Luiza, pelo apoio permanente e pelo grande exemplo de força, de luta, de fé, de esperança... De vida! Sem eles eu não teria alcançado mais esta vitória.

Aos meus “amigos do coração”, pela paciência, pelas palavras de conforto, pelo incentivo constante, pelo apoio e, acima de tudo, pelo carinho que me ofereceram nos momentos mais difíceis, provando o real valor de uma verdadeira amizade.

Agradeço ao meu orientador Prof. Dr. Carlos Roberto Minussi, pela paciência e compreensão. Ao meu co-orientador Prof. Dr. Francisco Villarreal pelo incentivo.

Aos membros da banca examinadora Prof^ª. Dr^ª. Anna Diva Plasencia Lotufo, Prof. Dr. Edmarcio Antonio Belati, Prof. Dr. Gelson da Cruz Junior e Prof^ª. Dr^ª. Maria do Carmo Gomes da Silveira, pela grande colaboração.

Agradeço, ainda, aos funcionários do departamento de engenharia elétrica, Deoclécio e Cristina, e aos funcionários da biblioteca, em especial à Neide e ao João.

À CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pelo apoio financeiro, que viabilizou a realização do trabalho.

“Só sei que nada sei.”

Sócrates

Resumo

A previsão de carga, em sistemas de energia elétrica, constitui-se numa atividade de grande importância, tendo em vista que a maioria dos estudos realizados (fluxo de potência, despacho econômico, planejamento da expansão, compra e venda de energia, etc.) somente poderá ser efetivada se houver a disponibilidade de uma boa estimativa da carga a ser atendida. Deste modo, visando contribuir para que o planejamento e operação dos sistemas de energia elétrica ocorram de forma segura, confiável e econômica, foi desenvolvida uma metodologia para previsão de carga, a previsão multinodal, que pode ser entendida como um sistema inteligente que considera vários pontos da rede elétrica durante a realização da previsão. O sistema desenvolvido conta com o uso de uma rede neural artificial composta por vários módulos, sendo esta do tipo *perceptron* multicamadas, cujo treinamento é baseado no algoritmo retropropagação. Porém, foi realizada uma modificação na função de ativação da rede, em substituição à função usual, a função sigmoide, foram utilizadas as funções de base radial. Tal metodologia foi aplicada ao problema de previsão de cargas elétricas a curto-prazo (24 horas à frente).

Palavras-chave: Previsão de Carga Multinodal, Redes Neurais Artificiais, Funções de Base Radial

A bstract

Load forecasting in electric power systems is a very important activity due to several studies, e.g. power flow, economic dispatch, expansion planning, purchase and sale of energy that are extremely dependent on a good estimate of the load. Thus, contributing to a safe, reliable, economic and secure operation and planning this work is developed, which is an intelligent system for multinodal electric load forecasting considering several points of the network. The multinodal system is based on an artificial neural network composed of several modules. The neural network is a multilayer perceptron trained by backpropagation where the traditional sigmoide is substituted by radial basis functions. The methodology is applied to forecast loads 24 hours in advance.

Keywords: Load Forecasting Multinodal, Artificial Neural Networks, Radial Basis Function.

Lista de Figuras

Figura 3.1 – Modelo da previsão de carga por redes neurais.	24
Figura 3.2 – Estratégia de previsão de carga via deslocamento da janela	26
Figura 3.3 – Sistema para a previsão de carga multinodal.	27
Figura 4.1 – Modelo de um neurônio biológico.	33
Figura 4.2 – Componentes de um neurônio artificial.	35
Figura 4.3 – Modelo não-linear de um neurônio.	35
Figura 4.4 – Tipos de funções de ativação.	36
Figura 4.5 – Disposição de uma rede neural artificial.	37
Figura 4.6 – Aprendizado supervisionado.	38
Figura 4.7 – Aprendizado não-supervisionado.	39
Figura 5.1 – Funções de base radial encontradas na literatura.	43
Figura 5.2 – Funções de base radial propostas.	44
Figura 6.1 – <i>Perceptron</i> multicamadas.	47
Figura 6.2 – Esquema de adaptação de pesos do algoritmo Retropropagação.	51

Lista de Figuras

- Figura 7.1 – Resultado para previsão de carga para o sistema previsor global utilizando as seis funções de ativação 62
- Figura 7.2 – Resultado para previsão de carga para o primeiro módulo do sistema previsor local utilizando as seis funções de ativação. 63
- Figura 7.3 – Resultado para previsão de carga para o segundo módulo do sistema previsor local utilizando as seis funções de ativação. 64
- Figura 7.4 – Resultado para previsão de carga para o terceiro módulo do sistema previsor local utilizando as seis funções de ativação. 65

Lista de Tabelas

Tabela 5.1 – Funções de base radial e respectivas derivadas.	44
Tabela 6.1 – Funções de ativação e suas respectivas derivadas.	52
Tabela 7.1 – Especificação dos parâmetros da rede neural do sistema previsor global.	58
Tabela 7.2 – Especificação dos parâmetros da rede neural do sistema previsor local Módulo 1.	59
Tabela 7.3 – Especificação dos parâmetros da rede neural do sistema previsor local Módulo 2.	59
Tabela 7.4 – Especificação dos parâmetros da rede neural do sistema previsor local Módulo 3.	59
Tabela 7.5 – Resultados obtidos, para cada função, no sistema previsor global.	60
Tabela 7.6 – Resultados obtidos, para cada função, no sistema previsor local - Módulo 1.	61
Tabela 7.7 – Resultados obtidos, para cada função, no sistema previsor local - Módulo 2.	61
Tabela 7.8 – Resultados obtidos, para cada função, no sistema previsor local - Módulo 3.	61

Sumário

CAPÍTULO 1 – INTRODUÇÃO	14
1.1 – Introdução Geral	14
1.2 – Organização do Trabalho	16
CAPÍTULO 2 – PREVISÃO DE CARGAS ELÉTRICAS	18
2.1 – Introdução	18
2.2 – Cargas Elétricas	18
2.3 – Horizontes de Previsão	20
2.4 – Técnicas e Procedimentos de Previsão	21
2.5 – Conclusão	22
CAPÍTULO 3 – ESQUEMA DESENVOLVIDO PARA PREVISÃO DE CARGA	23
3.1 – Introdução	23
3.2 – Esquema Desenvolvido	23
3.3 – Conclusão	29
CAPÍTULO 4 – REDES NEURAIIS ARTIFICIAIS	31
4.1 – Introdução	31

4.2 – Notação Histórica	32
4.3 – Modelo Biológico	33
4.4 – Modelo Neural Artificial	34
4.5 – Arquitetura de Redes Neurais Artificiais	36
4.6 – Aprendizado em Redes Neurais Artificiais	38
4.7 – Tipos de Redes Neurais Artificiais	39
4.8 – Conclusão	40
CAPÍTULO 5 – FUNÇÕES DE BASE RADIAL	41
5.1 – Introdução	41
5.2 – Função de Base Radial	41
5.3 – Principais Funções	43
5.2 – Conclusão	45
CAPÍTULO 6 – APLICAÇÃO DO ESQUEMA DESENVOLVIDO	46
6.1 – Introdução	46
6.2 – Perceptron Multicamadas	47
6.3 – Algoritmo Retropropagação	48
6.4 – Funções de Ativação	51
6.5 – Algoritmo Retropropagação na Previsão de Carga	52
6.6 – Critérios para Avaliação da Rede Neural	54
6.7 – Conclusão	55
CAPÍTULO 7 – RESULTADOS OBTIDOS	57
7.1 – Introdução	57
7.2 – Parâmetros Utilizados	58
7.3 – Resultados	60
7.4 – Conclusão	66

CAPÍTULO 8 – CONCLUSÃO	67
8.1 – Conclusão Geral	67
8.2 – Sugestões para Trabalhos Futuros	68
CAPÍTULO 9 - REFERÊNCIAS BIBLIOGRÁFICAS	70
APÊNDICE A – DADOS HISTÓRICOS DE CARGA	79
A1 – Sistema Previsor Global	80
A2 – Sistema Previsor Local – Módulo 1	81
A3 – Sistema Previsor Local – Módulo 2	82
A4 – Sistema Previsor Local – Módulo 3	83
APÊNDICE B – TRABALHOS PUBLICADOS	84

I ntrodução

1.1 - Introdução Geral

Diversos estudos e planejamentos em sistemas de energia elétrica, para que sejam efetuados, necessitam da previsão de cargas elétricas. Dentre os estudos mais comuns está o despacho econômico, fluxo de potência e estabilidade transitória; entre os planejamentos estão, geração, transmissão, expansão e compra e venda de energia. Assim, para que o sistema opere de modo seguro, confiável e econômico, uma boa previsão de carga é necessária (RANAWERA, KARADY ; FARNER, 1997; KERMANSHAHI ; IWAMIYA, 2002), tanto na geração quanto na transmissão e na distribuição. Deste modo, tem-se a necessidade de prever não uma, mas várias cargas em vários pontos do sistema de energia elétrica de maneira rápida e precisa.

É possível encontrar na literatura uma grande quantidade de trabalhos envolvendo previsão de cargas elétricas, porém, muitos deles utilizam métodos que necessitam da modelagem matemática da carga como: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado, filtro de Kalman, métodos ARIMA de Box e Jenkins (BOX; JENKINS, 1976; O'DONOVAN, 1983).

Vários fatores podem influenciar na modelagem da carga, tais como: condições meteorológicas (velocidade do vento, nebulosidade, variações bruscas de temperatura) e fatores diversos como efeito dos dias atípicos (feriados, greves, etc.). O conhecimento de tais fatores permite representar, da melhor maneira, o comportamento da carga para então servir como entrada para o algoritmo de previsão escolhido. Bons resultados são obtidos apesar de,

às vezes, serem requeridos grandes esforços computacionais, além de técnicas de modelagem complexas. Outro tipo de aplicação que tem mostrado grande eficiência é o emprego de técnicas inteligentes (BENDER, 1996), que não necessitam de uma modelagem matemática da carga, em especial, as redes neurais artificiais (FINE, 1999; HAYKIN, 1994; KARTALOPOULOS, 1996; SIMPSON, 1989; WASSERMAN, 1989).

A solução do problema de previsão de cargas elétricas via redes neurais artificiais, trata-se de uma solução baseada no treinamento, considerando dados históricos de carga, informações sobre o clima, tempo, entre outros.

Uma rede neural artificial é um sistema computacional baseado no funcionamento do cérebro humano; é, na verdade, um modelo matemático inspirado em uma simplificação do sistema neural biológico, com capacidade de aprendizado, generalização, associação e abstração. Com o interesse dos pesquisadores em uma forma de computação que se inspirasse no cérebro humano, em 1943, surge a neurocomputação, quando McCulloch e Pitts propuseram o neurônio artificial (McCULLOCH ; PITTS, 1943). A partir deste modelo, foram desenvolvidas várias concepções de redes neurais artificiais, porém, os resultados se mostravam pouco significativos.

Somente após os anos 70 é que houve considerável avanço, principalmente com o advento do algoritmo retropropagação (WERBOS, 1974) e da rede de Hopfield (WASSERMAN, 1989) e, sobretudo, pelo avanço da microeletrônica. A partir dos anos 80, foi que permitiram a idealização de estruturas em *hardware* de modo eficiente.

O algoritmo retropropagação tem por finalidade o aprendizado supervisionado (regra baseada no binômio entrada – saída) das redes neurais artificiais, compostas por várias fileiras de neurônios dispostos em paralelos e funções de ativação contínuas. Com esta estrutura é possível executar tarefas como o reconhecimento de padrões, diagnósticos complexos, previsão, entre outros.

A opção pelo uso de técnicas inteligentes na previsão de cargas se tornou cada vez mais comum e, é possível encontrar várias abordagens na literatura especializada. Nos trabalhos de Saini (SAINI ; SONI, 2002) e (MALKI; KARAYIANNIS ; BALASUBRAMANIAN, 2004) os autores utilizam redes neurais artificiais para realizar a previsão de cargas de curto prazo, no primeiro foram utilizados os métodos de Levenberg-Marquardt e Quasi-Newton para o treinamento das redes, no segundo foi utilizado o convencional método do erro retropropagado para o treinamento da rede. No artigo de (PANDIAN, et al., 2006), os autores utilizam lógica *fuzzy* para realizar a previsão de cargas de curto prazo.

Nos trabalhos de (TELBANY ; KARMI; 2008) e (YUN, et al., 2008) os autores fazem uso de sistemas híbridos para realizar a previsão de cargas de curto prazo, o primeiro utiliza *particle swarm optimization* (PSO) para realizar o treinamento de uma rede neural artificial, o segundo utiliza redes de funções de base radial (RBF), do inglês, Radial Basis Function, e o ANFIS (que é um sistema híbrido que combina lógica *fuzzy* com redes neurais artificiais).

Já o artigo de (YALCINOZ ; EMINOGLU, 2005), os autores realizam uma previsão em sistemas de distribuição considerando alguns pontos da rede, porém, a previsão é feita ponto a ponto, separadamente, o que demanda muito tempo devido a manipulação de uma grande quantidade de dados.

Deste modo, o objetivo desta pesquisa é apresentar a metodologia desenvolvida para resolução do problema de previsão de cargas elétricas, porém, uma previsão considerando vários pontos da rede elétrica (subestações, transformador, etc.), a previsão multinodal, cujo tempo de processamento é da mesma magnitude (pouco superior) de uma previsão global.

O esquema de previsão desenvolvido utiliza, basicamente, uma rede neural do tipo *perceptron* multicamadas, que faz uso do algoritmo retropropagação, como algoritmo de treinamento. Porém, foi realizada uma modificação na arquitetura convencional, a função de ativação usual, função sigmoide, foi substituída por funções de base radial.

Sendo assim, apesar da utilização das funções de base radial como função de ativação da rede neural ter caráter inédito, bem como a proposta de duas dessas funções, a principal contribuição deste trabalho foi o desenvolvimento da metodologia para a previsão de carga multinodal fazendo uso de sistemas inteligentes.

1.2 - Organização do Trabalho

Este texto está dividido em nove capítulos os quais buscam, de forma significativa, o bom entendimento do trabalho realizado, através da apresentação da teoria envolvida.

No capítulo 2, é realizado um estudo sobre previsão de cargas elétricas, ressaltando sua importância para a operação do sistema elétrico. Apresentam-se os objetivos e horizontes de previsão, enfatizando a utilização de técnicas inteligentes. Trata, ainda, dos procedimentos para previsão, fazendo uma breve apresentação dos modelos clássicos, utilizados na

literatura e, dos modelos baseados em técnicas inteligentes, como o caso das redes neurais artificiais.

O capítulo 3 trata da apresentação do esquema desenvolvido para a previsão de carga multinodal. Para tanto, optou-se por fazer uma abordagem de toda a teoria envolvida, sendo esta, apresentada nos capítulos subsequentes.

No capítulo 4 é realizado um estudo sobre redes neurais artificiais, desde seu advento, fazendo comparação através do modelo biológico e o modelo artificial de um neurônio; apresentando a seguir sua formulação estrutural, através das funções de ativação, arquitetura, aprendizado, finalizando com a apresentação dos tipos de redes neurais artificiais.

O capítulo 5 tem a finalidade de apresentar, de forma sucinta, as funções de base radial, enfatizando suas principais propriedades, além da apresentação gráfica e uma breve análise de suas principais características. Optou-se por fazer essa abordagem, pois, tais funções foram utilizadas como função de ativação da rede neural desenvolvida, cuja aplicação será apresentada no capítulo 6.

No capítulo 6 apresenta-se a aplicação da metodologia desenvolvida para a aplicação de redes neurais artificiais na previsão de cargas elétricas a curto prazo. Para tanto, é realizada a apresentação detalhada do método utilizado para resolução do problema proposto, explicitando a utilização dos sistemas previsores (sistema predictor global e sistema predictor local), ressaltando a importância da adaptação dos dados, tanto de carga (normalização), quanto de tempo (binarização); e as particularidades dos parâmetros envolvidos. Apresentam-se, ainda, as funções e respectivas derivadas, utilizadas para o treinamento e diagnóstico da rede neural, e critérios para a avaliação de desempenho.

No capítulo 7 são apresentados os resultados obtidos através da metodologia desenvolvida para previsão de cargas multinodal. A obtenção destes resultados se deu através de simulação computacional, utilizando-se a linguagem de programação FORTRAN. Os resultados estão representados gráfica e numericamente.

No capítulo 8 é apresentada a conclusão geral deste trabalho e algumas sugestões para trabalhos futuros. No capítulo 9 relacionam-se as referências bibliográficas.

O trabalho contém, ainda, dois apêndices: o apêndice A, em que são apresentados os arquivos de dados históricos de cargas elétricas, utilizados como entrada da rede neural artificial, e o apêndice B, em que são apresentados os artigos publicados durante todo o processo de desenvolvimento desta pesquisa.

Previsão de Cargas Elétricas

2.1 - Introdução

O sistema elétrico brasileiro, por ser predominantemente com geração hidrelétrica, armazena energia através do estoque de água em grandes reservatórios a montante das usinas. O controle desses estoques é feito de maneira ótima e o despacho dessas usinas determina o melhor aproveitamento dessas reservas de energia. Observa-se, assim, que a antecipação das decisões de o quanto se deve gerar é primordial. Essas decisões são produto da previsão de carga a ser atendida. Assim sendo, a minimização do desvio (erro) da previsão de carga é sempre de suma relevância.

Por outro lado, em consequência do fato do mercado de energia se tornar cada vez mais competitivo, a compra e venda de eletricidade é intensificada e, nesse processo, o risco de perda tem de ser mínimo, a previsão de carga exerce um papel importante para os sistemas de potência, pois, afeta de forma significativa os preços das tarifas elétricas (HIPPERT; PEDREIRA; SOUZA, 2001; VEHVILÄINEN; KEPPO, 2003; SFETSOS, 2003). A seguir, serão apresentadas, de forma sucinta, as principais características.

2.2 - Cargas Elétricas

As cargas elétricas são compostas por uma infinidade de aparelhos e dispositivos elétricos que, em conjunto, apresentam tendências que podem ser previstas de forma estatísti-

ca. Porém, essas tendências são influenciadas por fatores que interferem na forma de modelar a carga, tais como: condições meteorológicas, fatores sazonais, entre outros.

Para realizar a previsão é necessário que se faça uma análise prévia desses fatores, de forma a verificar a influência que eles têm no comportamento da carga. Assim, existem inúmeros métodos para previsão que se baseiam nas informações sobre o passado e, ainda, assumem que o comportamento ocorrido no passado irá refletir no futuro de alguma forma.

Os métodos empregados para previsão de carga podem ser classificados em (O'DONOVAN, 1983):

1. **Métodos intuitivos** - não usam um modelo matemático formal para descrever o comportamento da carga.
2. **Métodos autônomos** - usam modelos baseados somente na extrapolação de observações passadas da carga, ou seja, é uma técnica dependente do tempo.
3. **Métodos causais** - assumem que a carga exhibe uma relação de causa e efeito com uma ou mais variáveis independentes, que irão descrever seu comportamento.

A previsão de carga está associada à evolução da carga no tempo (série temporal), e através dele, que é dividida em duas classes (O'DONOVAN, 1983):

- **Estacionária** - os dados da carga mantêm uma média constante no tempo.
- **Não-Estacionária** - os dados da carga variam com o tempo. Assim, trata-se de um comportamento em que não se observa uma tendência estatística.

Ainda em relação às cargas, vale lembrar que o sistema elétrico de potência atende diferentes tipos de consumidores, tais como: residencial, comercial e industrial, que apresentam alguns fatores que dificultam o trabalho de previsão:

- **Fatores climáticos** - temperatura, velocidade do vento, neblina, umidade relativa do ar, temporal com relâmpago e trovão, chuva, neve, entre outros. Dentre todos os fatores mencionados, a temperatura influencia diretamente no consumo de energia elétrica delimitando o uso de condicionador de ar, aquecedor, refrigerador, etc. (SWARUP; SATISH, 2002; HIPPERT; PEREIRA ; SOUZA, 2001; MURTO, 1998);
- **Fatores de tempo** - acontecimentos relacionados a determinados períodos do ano, tais como: férias, feriados, início do ano escolar, natal, ano novo, semana típica em que corresponde ao ciclo de trabalho e descanso, etc. (MURTO, 1998);
- **Fatores econômicos e demográficos** - área demográfica (rural, residencial, industrial), crescimento industrial, aparecimento de novas indústrias, variação na agricultura, ten-

dências econômicas, variação nos preços de eletricidade, administração da carga (demanda), entre outros. (MURTO, 1998);

- **Fatores esporádicos** - eventos esportivos, programas de televisão, paralisação das indústrias (MURTO, 1998).

2.3 - Horizontes de Previsão

A previsão de carga pode ser realizada em diferentes intervalos de tempo, tendo finalidades diferentes para cada horizonte. Os horizontes, usados na previsão de carga são divididos em (AL-KANDARI et al., 2004; METAXIOTIS et al., 2003; MURTO, 1998; SWARUP ; SATISH, 2002; YALCINOZ ; EMINOGLU, 2005):

- **Previsão a longo prazo** – usam-se intervalos anuais; é importante para o processo decisório do aumento da capacidade de atendimento ao mercado consumidor. Baseado no fato de o setor elétrico brasileiro ser predominantemente hidrelétrico e envolver montantes expressivos de intercâmbio de energia entre as empresas, o planejamento da expansão pode exigir intervalos longos de tempo (10, 15 até 20 anos) entre a tomada de decisão e o aumento efetivo da capacidade de atendimento ao sistema.
- **Previsão a médio prazo** – usam-se intervalos mensais; sua principal aplicação é na otimização da alocação das máquinas geradoras, com o objetivo de se ter uma operação econômica. Existe também o emprego da previsão de médio prazo para se executar estudos elétricos de situações de instabilidade da rede elétrica, objetivando manter uma segurança do sistema.
- **Previsão a curto prazo** – usam-se intervalos semanais; tem por finalidade uma alocação econômica dos geradores, observando restrições operativas, de maneira que o custo da produção de energia elétrica seja menor. Com uma boa previsão de carga de curto prazo também se pode otimizar o uso de geradores térmicos, objetivando o despacho econômico.
- **Previsão a curtíssimo prazo** – usam-se intervalos inferiores a uma hora; tenta exprimir com maior exatidão o perfil instantâneo da carga, pois, estes valores serão forte subsídio para o processo decisório de maior disponibilidade de potência, bem como um efetivo gerenciamento da carga de demanda, assumindo assim, fundamental importância no processo de realocação de manutenções de unidades geradoras hidráulicas/térmicas; partida de unidades térmicas para atendimento à demanda; realocação das folgas de po-

tência entre empresas visando otimizar o uso de potência em função da diversidade da carga e gerenciamento da carga de demanda no período de ponta.

2.4 - Técnicas e Procedimentos de Previsão

As técnicas para realizar a previsão de carga são classificadas de duas formas (GROSS; GALIANA, 1987; BUNN; FARMER, 1985) ;

- **Modelos não-dinâmicos** - a carga é expressa como uma série temporal discreta consistindo de valores previstos para cada hora durante um período;
- **Modelos dinâmicos** - carga é identificada não apenas como uma função de tempo do dia, mas também de seus comportamentos mais recentes. Por essa razão, para que se faça a previsão em determinada hora, é necessário que tenham sido realizadas previsões em horas anteriores.

Os procedimentos de previsão usados na prática, procedimentos estatísticos, variam muito, podendo ser simples e intuitivos, com pouca ou nenhuma análise dos dados, ou mais quantitativos e complexos com uma análise de dados considerável. Para se montar o modelo de previsão, é necessário analisar a curva obtida pelo gráfico dos dados passados, ou seja, é necessário realizar uma modelagem prévia da carga, já que as previsões são baseadas no fato de um valor futuro ser função dos valores passados.

Dentre os procedimentos estatísticos de previsão, podem-se destacar alguns modelos, tais como:

- **Automáticos ou da Caixa-Preta** - surgiram na década de 60 e incluem os modelos de regressão, média-móveis, ajustamento sazonal e alisamento exponencial (WHEELWRIGHT ; MAKRIDAKIS, 1985);
- **Box-Jenkins** - propostos no início da década de 70, consistindo de uma classe geral de modelos lineares conhecidos como ARIMA (BOX; JENKINS, 1976; O'DONOVAN, 1983; MOGHRAM; RAHMAN, 1989; MURTO, 1998);
- **Bayesianos** - também introduzidos na década de 70 caracterizam-se pela possibilidade de incorporação de informações subjetivas no processo de modelagem da série (SOUZA, 1989).

Ao observar que essas técnicas estatísticas não apresentavam bons resultados para muitas aplicações, pelo fato de apresentarem alguma não-linearidade no conjunto de dados,

ou possuírem um tamanho de amostras restrito, iniciou-se uma busca por formas alternativas de previsão, assim, surgiram os sistemas especialistas que são modelos heurísticos baseados na inteligência artificial e que tentam imitar o raciocínio humano.

Os métodos baseados na inteligência artificial demonstram grande eficiência quando aplicados ao problema de previsão de cargas elétricas. Existem inúmeras técnicas que apresentam resultados promissores, tais como: as baseadas no hibridismo entre a lógica nebulosa, redes neurais artificiais, métodos estatísticos e estocásticos que, quando unidas, tendem a obter melhores resultados (WANG; HATZIARGYRIOU; TSOUKALAS, 2002; LIAO; TSAO, 2004; VILLALBA; BEL, 2000; KERMANSHAH; IWAMIYA, 2002; CHANDRASHEKARA; ANANTHAPADMANABHA; KULKARNI, 1999; CHUI et al., 1997; SKARMAN, GEORGIPOULOS; GONZALEZ, 1998).

Em suma, um sistema especialista é um programa que possui uma base de conhecimento em um domínio restrito e usa um raciocínio conclusivo e complexo na execução de tarefas (MOGHRAM ; RAHMAN, 1989; METAXIOTIS et al., 2003; MURTO, 1998).

2.5 - Conclusão

Neste capítulo apresentou-se um estudo sobre a previsão de cargas elétricas, fazendo-se um adendo às cargas elétricas. Trataram-se dos horizontes e principais procedimentos de previsão, enfatizando o uso de técnicas baseadas em inteligência artificial que se destacam pela sua habilidade de aprendizado e sua capacidade de generalização, associação e busca paralela, que as tornam capazes de identificar e assimilar as características mais marcantes das séries sem necessitar da trabalhosa formulação teórica, imprescindível para os procedimentos estatísticos. No capítulo a seguir será apresentada a metodologia proposta para previsão de cargas elétricas.

Esquema Desenvolvido para Previsão de Carga

3.1 - Introdução

A seguir, apresenta-se o esquema básico, proposto nesta pesquisa, visando a previsão de carga multinodal. Trata-se de um sistema inteligente em que a previsão é realizada considerando-se vários pontos (nós) da rede elétrica. Este é o caso da previsão aplicada no ambiente, por exemplo, dos sistemas de distribuição de energia elétrica, em que se faz necessário conhecer o comportamento da demanda em diversos barramentos do sistema, bem como contemplar a distinção entre os vários tipos de consumidores (CHANDRASHEKARA; ANANTHAPADMANABHA; KULKARNI, 1999; VILLALBA; BEL, 2000; YALCINOZ; EMINOGLU, 2004): residencial, comercial e industrial.

O sistema previsional proposto é baseado no uso de uma rede neural composta por módulos. Cada módulo é composto por redes do tipo *perceptron* multicamadas, cujo treinamento é realizado usando-se o algoritmo retropropagação, o qual é bastante conhecido na literatura especializada. Porém, foram feitas alterações no *perceptron* convencional: a função de ativação usual (função sigmoide) foi substituída por funções de base radial.

3.2 - Esquema Desenvolvido

A previsão de carga, em sistemas de energia elétrica, constitui-se numa atividade de grande importância, tendo em vista que a maioria dos estudos realizados (fluxo de potên-

cia, despacho econômico, planejamento da expansão, estabilidade transitória, compra e venda de energia, etc.) somente poderá ser efetivada se houver a disponibilidade de uma boa estimativa da carga a ser atendida. Estes estudos visam proporcionar, aos engenheiros, um conjunto de informações vitais para que os sistemas elétricos possam ser planejados e operados de forma segura, confiável e econômica.

A previsão de carga pode ser realizada usando-se os métodos clássicos, citados no capítulo anterior, tais como: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado, filtro de Kalman, métodos ARIMA de Box e Jenkins. Além destas técnicas, nos últimos 10 anos tem sido intensificado o uso de procedimentos baseados na inteligência artificial (BENDER, 1996). Neste contexto, destacam-se as redes neurais artificiais (FINE, 1999; HAYKIN, 1994; KARTALOPOULOS, 1996; SIMPSON, 1989; WASSERMAN, 1989] e a lógica *fuzzy* (KARTALOPOULOS, 1996; MCNEIL; THRO, 1994; TERANO, ASAI; SUGENO, 1991; ZADEH, 1965). Grande parte das propostas de metodologias para previsão de carga, por redes neurais, emprega, como técnica de treinamento, o algoritmo retropropagação (*backpropagation*) (WERBOS, 1974). O algoritmo retropropagação é um procedimento de adaptação de pesos da rede neural baseado no método do gradiente descendente (WIDROW; LEHR, 1990), tal metodologia será detalhada no capítulo seguinte.

Na figura 3.1, apresenta-se um diagrama esquemático para previsão de carga por redes neurais.

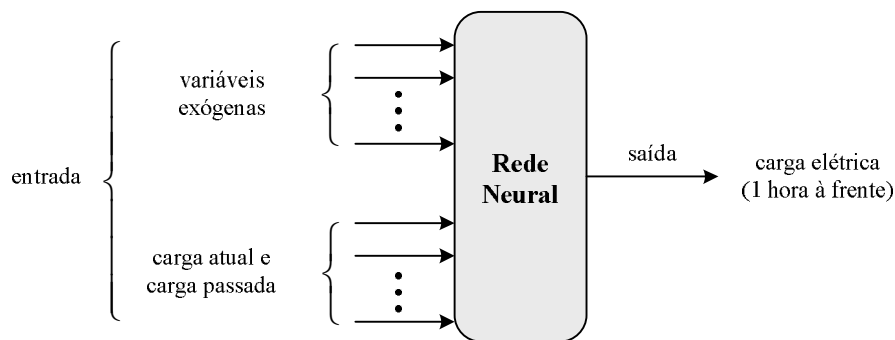


Figura 3.1 - Modelo da previsão de carga por redes neurais.

Há dois subconjuntos de dados de entrada: dados referentes à série histórica da carga elétrica e dados exógenos. Os dados históricos das cargas podem ser usados tomando-se o procedimento mais usual na área de previsão de carga que é o método do movimento de uma janela (PARK; SHARKAWI; MARK II, 1991), cujo deslocamento é arbitrado, por exemplo, em 1 hora (previsão 1 hora à frente). Os dados exógenos compreendem as demais

informações importantes para o processo de previsão, excluindo-se os dados históricos das cargas, ou seja, os dados climáticos, estações, meses do ano, dias da semana, etc.

O problema da previsão de carga, considerando-se o i -ésimo módulo, pode ser formulado da seguinte forma:

$$\begin{aligned} \mathbf{X}(h) &= [\mathbf{t}^T \ L(h-3) \ L(h-2) \ L(h-1) \ L(h)]^T, \quad \mathbf{X} \in R^m \\ \mathbf{Y}(h) &= [L(h+1)], \quad \mathbf{Y} \in R^1 \end{aligned} \tag{3.1}$$

sendo:

- m : dimensão do vetor \mathbf{X} ;
- $L(h-p)$: valor da carga p horas anterior à hora corrente h ;
- $L(h+1)$: valor da carga elétrica correspondente à hora subsequente a hora corrente h ;
- \mathbf{t} : vetor de tempo referente aos dados históricos (dia da semana, hora, etc.) representados em codificação binária [0, 1].
- $\mathbf{X}(h)$: vetor aplicado na entrada da rede neural correspondente a hora h ;
- $\mathbf{Y}(h)$: estímulo aplicado na saída da rede neural correspondente a hora $h+1$.

Na formulação (3.1), deliberadamente, visando à simplicidade de notação, foi dispensado o índice i que identifica o i -ésimo módulo neural. Supondo-se $p = 3$, isto é, cada janela contém os dados da carga elétrica relativas as 3 horas passadas e a carga atual (tempo discreto igual à hora h). Esta é a estratégia que será usada nesta pesquisa, ainda que muitas outras possam ser perfeitamente adotadas.

Outras estratégias podem ser experimentadas, aumentando-se o tamanho da janela, bem como, usando-se dados da carga associados a outros instantes. Por exemplo, se a previsão refere-se a uma quarta-feira, pode-se usar o valor da carga observada na quarta-feira da semana anterior, ou até mesmo de quartas-feiras de meses anteriores. Esta estratégia, se bem projetada, igualmente, pode contribuir para a redução do erro da previsão, o qual pode ser estimado, usando-se o conceito *MAPE* (*Medium Absolute Percentual Error*) (SRINIVASAN, 1998) e o erro máximo, dados pelas equações 3.2 e 3.3:

$$MAPE = \frac{1}{NT} \left\{ \sum_{h=1}^{NT} \left(\frac{|L(h) - \underline{L}(h)|}{L(h)} \right) \right\} \times 100 \tag{3.2}$$

$$Erro \ Máximo \ (\%) = \max \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100 \tag{3.3}$$

sendo:

$L(h)$: valor da carga real referente à hora h ;

$\underline{L}(h)$: valor da carga estimada pela rede neural referente à hora h ;

NT : número total de horas da curva de carga.

As cargas elétricas $L(h-3), \dots, L(h-1)$ representam o laço de realimentação da saída, constituindo uma rede neural recorrente.

Este processo consiste no movimento de uma “janela” [Djukanovic et al., 1995] de tamanho m (m componentes), conforme pode-se visualizar na figura 3.2.

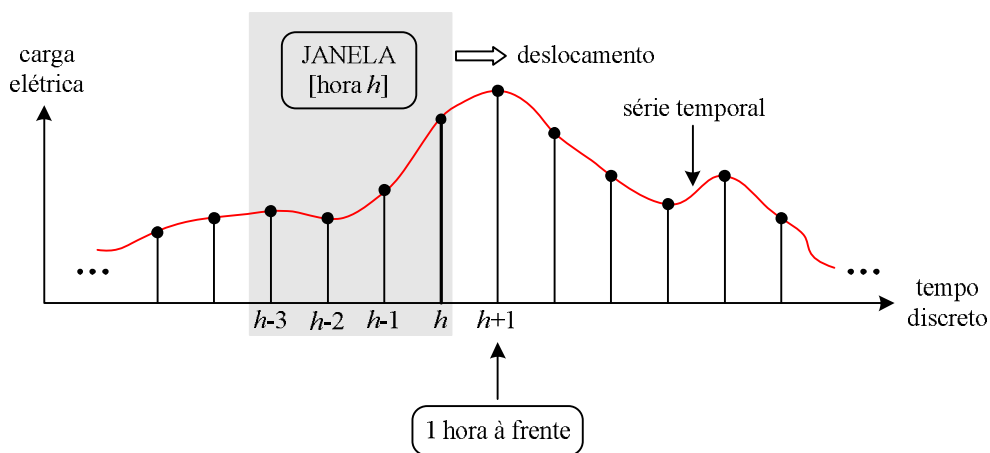


Figura 3.2 - Estratégia de previsão de carga via deslocamento da janela.

Este procedimento é dividido em duas fases distintas: treinamento e previsão.

- **Fase de Treinamento** - O vetor de saída $Y(h)$ binário corresponde ao valor da carga 1 hora à diante, ou seja, é aplicado na saída, durante o processo de treinamento, ou quando executado o treinamento continuado.
- **Fase de Previsão** - Durante esta fase, a saída representa a carga prevista 1 hora à frente na codificação binária, a qual, posteriormente, é convertida numa grandeza real (*watts* previstos).

O esquema de previsão multinodal desenvolvido (ALTRAN et al., 2009; ALTRAN; MINUSSI, 2009) é composto por várias redes neurais, sendo cada uma delas estruturada da forma descrita anteriormente. Na figura 3.3 é apresentado o sistema predictor proposto.

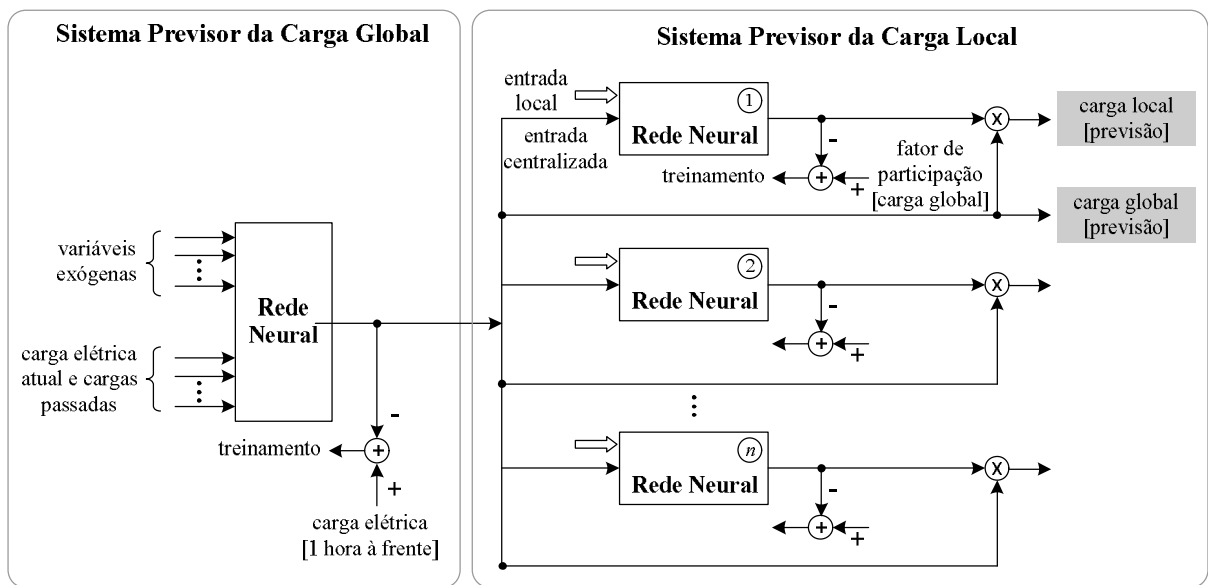


Figura 3.3 - Sistema para a previsão de carga multinodal.

O esquema de previsão multinodal é estruturado, basicamente, através de dois sistemas previsores, o Sistema Previsor Global (*SPG*), composto por uma rede neural responsável pela previsão de carga global, e o Sistema Previsor Local (*SPL*), que é formado por vários módulos (sendo cada módulo representado por uma rede neural). Cada um deles é responsável pela previsão local, ou seja, em pontos de interesse da rede elétrica (subestação, transformador, etc.).

Cada módulo do *SPL* é treinado de forma independente, usando as informações disponíveis (séries históricas da potência da carga, dados climáticos, tipo de consumidor, etc.), em que são estabelecidas as estimativas das cargas por barramento (carga local). Neste caso, determinam-se o Fator de Participação da Carga Global (*FPCG*) (ALTRAN et. al., 2009) para cada nó de interesse, ou seja, $FPCG_j, j = 1, 2, \dots, n$ (n : número de nós). Estes fatores são representados por séries temporais que são usadas para estimar a carga em cada nó, bem como servir para outros estudos de interesse, em geral, dinâmica e classificação das cargas.

Em outras palavras, no *SPL* a entrada de cada módulo, para a fase de treinamento, é composta pelos valores das cargas (dados históricos) e dados referentes ao tempo (dia da semana e hora). Para a fase do diagnóstico, a entrada é composta pelo vetor de saída do sistema previsor global ($Y(h)$) que, por sua vez, gera como saída a carga local prevista estimada a partir do *FPCG*.

Conforme mencionado anteriormente, em cada módulo local, a estimativa do *FPCG* é determinada, também, usando-se redes neurais. Desta forma, o conjunto de cargas locais (*CL*) é definido como carga global (*CG*), dado pela equação (3.4). Cada carga possui um fator de participação da carga global (*FPCG*), dado pela equação (3.5).

$$CG = \sum_{j=1}^N CL_j \quad (3.4)$$

$$FPCG_j = \frac{CL_j}{CG} \quad (3.5)$$

O treinamento destas redes locais é bastante simples, visto que a entrada é composta por dados locais, que são particularidades de cada nó, e pela série temporal da carga elétrica global, determinada pelo *SPG*, constituindo entradas de dimensão reduzida. Os dados locais podem conter, também, informação que possam contribuir para a melhoria do modelo da carga nodal, ou seja, pode usar vários tipos de estratégias, inclusive, outros dispositivos inteligentes, em geral, outra rede neural, lógica *fuzzy*, multiagentes (DUNIN-KEPLICZ; VERBRUGGE, 2010), etc.

Deve-se observar que este esquema para a previsão de carga multinodal possui um paralelismo natural, ou seja, uma vez concluído o treinamento do *SPG*, os módulos do *SPL* podem ser treinados e operados de forma independente. Com esta concepção, evidentemente, há necessidade de dispor de módulos neurais que apresentem qualidades fundamentais: confiabilidade e rapidez na obtenção da solução. A previsão de carga de cada nó considerado de interesse pode ser estimada multiplicando o *FPCG* pelo valor da carga global prevista pelo módulo *SPG* em cada instante da série temporal.

Observa-se que outros estudos podem ser realizados usando-se a metodologia proposta. Por exemplo, se a série temporal do *FPCG* for muito próxima de um valor constante, ou seguindo outra forma comportamental, pode-se melhor inferir sobre a composição da carga elétrica (residencial, comercial, industrial).

A fase da previsão é realizada da seguinte forma:

1. Execução da previsão da carga global: $CG^{(\text{previsão})}(h)$;
2. Tomando-se os valores da carga global e as entradas locais, é realizada a previsão dos *FPCG's* referentes a cada nó, ou seja, $FPCG_j^{(\text{previsão})}(h)$, $j = 1, 2, \dots, n$. Após a conclusão da fase de treinamento, a carga local horária pode ser estimada por:

$$CL_j^{(previsão)}(h) = FPCG_j^{(previsão)}(h) \times CG^{(previsão)}(h) \quad (3.6)$$

A expressão (3.6) corresponde à previsão das cargas locais para cada hora considerada. Este procedimento torna-se vantajoso, pois, o comportamento dos *FPCG's* é, via de regra, mais “suave”, se comparado ao comportamento das cargas locais. Deste modo, o treinamento da rede neural torna-se mais rápido e trabalha com um menor número de informações, isto é, os estímulos de entrada são compostos por um número menor de componentes, conforme será discutido no capítulo de aplicações (capítulo 6).

A previsão de carga multinodal proposta possui um tempo de execução um pouco superior à previsão global convencional (em função, evidentemente, do maior ou menor número de nós de interesse para a previsão), isto porque o tempo destinado à realização do conjunto das redes neurais modulares (previsão local) é bastante reduzido. Ressalta-se que o tempo para conclusão da previsão multinodal se aproximará ao tempo de execução da previsão global, à medida que forem exploradas outras arquiteturas neurais que, eventualmente, possam produzir resultados de forma mais rápida, em geral, empregando-se redes neurais da família ART (*Adaptive Resonance Theory*) (CARPENTER; GROSSBERG; REYNOLDS, 1991). Por exemplo, em (LOPES; MINUSSI; LOTUFO, 2005) e (LOPES; LOTUFO; MINUSSI, 2010), foram apresentadas experiências neste sentido (proposição de arquitetura ART&ARTMAP *Fuzzy*), considerando a previsão global com tempo de processamento muitíssimo inferior (< 5%), se comparado ao tempo de execução da rede neural retropropagação comumente usada na literatura. Nesta pesquisa, está-se usando uma rede neural retropropagação com funções de base radial, que é uma versão mais eficiente entre as redes neurais baseadas em operações de derivadas (gradiente) (YUN et al., 2008), como forma de testar a viabilidade da previsão multinodal. A previsão de carga multinodal, baseada nas redes neurais da família ART, é um tema de pesquisa que deve ser abordado posteriormente, tendo em vista a maior complexidade modelar. O principal enfoque desta pesquisa de doutorado é, por conseguinte, a investigação sobre a viabilidade da implantação da previsão multinodal por redes neurais.

3.3 - Conclusão

Neste capítulo foi apresentada a estruturação do sistema para previsão de carga multinodal usando-se redes neurais artificiais do tipo *perceptron* multicamadas, com o algo-

ritmo retropropagação (algoritmo de treinamento) e as funções de base radial como funções de ativação, que serão apresentados nos capítulos subsequentes.

Foram detalhados os sistemas previsores, Sistema Previsor Global e Sistema Previsor Local, que compõem o esquema de previsão proposto, bem como seu funcionamento, estruturação das redes utilizadas, desde sua formulação até as estratégias para composição da entrada das redes e, ainda, salientou-se a participação da carga global em cada sistema previsor local, através da determinação do *FPCG*.

Nos capítulos subsequentes (capítulos 4, 5 e 6) serão apresentados, detalhadamente, os conceitos fundamentais que servem de base para o funcionamento esquema desenvolvido, e sua aplicação, propriamente dita, no problema de previsão de cargas elétricas.

Redes Neurais Artificiais

4.1 - Introdução

Com os avanços da neurofisiologia, tornou-se possível desvendar vários mecanismos, sobre o fluxo e o processamento de informações, que ocorrem no cérebro humano. Alguns desses mecanismos foram modelados matematicamente permitindo a elaboração de algoritmos computacionais, que simulam a mais básica das estruturas cerebrais, o neurônio.

A interconexão entre neurônios permite que ocorra troca de informação, entre os mesmos, dando origem à inteligência biológica. Logo, a capacidade de implementar computacionalmente versões simplificadas de neurônios biológicos deu origem a uma subespecialidade da inteligência artificial, conhecida como redes neurais artificiais (HAYKIN, 1994). Em outras palavras, as redes neurais artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência.

Assim, no que segue será realizada apresentação das principais características das redes neurais artificiais, iniciando com uma breve notação histórica, abordando a comparação entre o neurônio biológico e o artificial, a arquitetura e o aprendizado, terminando com a apresentação de alguns tipos de redes neurais artificiais. Na sequência, apresentam-se os principais conceitos e definições sobre redes neurais artificiais, como forma de subsidiar a formulação do problema da previsão de carga multinodal que será abordada em capítulo subsequente.

4.2 – Notação Histórica

Os estudos realizados na tentativa de desvendar o funcionamento do cérebro humano vêm ocorrendo a mais de 100 anos, porém, os primeiros conceitos formais das Redes Neurais Artificiais (RNA) surgiram em 1943, quando (MCCULLOCH; PITTS, 1943) propuseram o primeiro modelo de neurônio artificial, cujo trabalho fazia uma analogia entre células vivas e o processo eletrônico, simulando o comportamento do neurônio natural.

Em (HEBB, 1949), publicou o livro “*The Organization of Behavior*”, introduzindo o conceito básico da aprendizagem Hebbiana que é baseada na premissa de que a capacidade da aprendizagem em redes neurais vem da alteração da eficiência sináptica, isto é, a conexão somente é reforçada, se tanto as células pré-sinápticas quanto as pós-sinápticas estiverem excitadas.

Já em 1951, Minsky propôs as redes baseadas em reforço, com formas simples de aprendizado. Em 1958 (VON NEUMANN, 1958) descreveu a modelagem do desempenho do cérebro através de *hardware* em seu livro, intitulado “*The Computer and the Brain*”.

Em 1962 foi publicado o livro “*Principles of Neurodynamics*” por Rosenblatt (ROSEMBLATT, 1962), em que se introduziu a rede denominada *perceptron* (estrutura neural mais empregada na literatura especializada), porém, (MINSKY; PAPERT, 1969), descobriram que as redes *perceptron* eram incapazes de resolver alguns problemas elementares como ou-exclusivo, o que acabou desestimulando a pesquisa nessa área.

A retomada do trabalho com redes neurais se deu no final da década de 70 e início da década de 80, por Grossberg, Kohonen, Anderson, Hopfield, entre outros. A maior contribuição nessa fase foi o desenvolvimento do algoritmo *Backpropagation* (Retropropagação), proposto, em 1974 (WERBOS, 1974), e redescoberto por Rumelhart, Hilton e Willians (1986).

A partir deste novo impulso, o interesse pelo estudo das redes neurais artificiais voltou a ser crescente, persistindo até os dias de hoje, é possível encontrar seu uso para solução dos mais diversificados problemas, tais como: reconhecimento de padrão, aproximação de funções, previsão, otimização combinatorial, modelagem de sistemas, representação de conhecimento, processamento de voz e imagem, entre outros.

4.3 - Modelo Biológico

Para que se fizesse possível a modelagem matemática e computacional dos mecanismos sobre o fluxo e o processamento de informações, muito estudo foi realizado na tentativa de compreender o funcionamento do cérebro humano.

O sistema nervoso humano é formado por cerca de 100 bilhões de neurônios, em que, cada um se comunica, em média, com mais 10 mil, podendo modificar sua resposta, de acordo com o comportamento dos outros. Vários neurônios se interconectam para formar uma rede neuronal (termo geralmente usado como referência ao neurônio natural). Cada módulo é responsável pelas tarefas que são realizadas no sistema nervoso, tais como, controle da ação muscular, aquisição e processamento de padrões luminosos, sonoros, térmicos, etc.

Os processos cognitivos podem ser vistos como uma combinação de várias sub-redes, as quais atuam de forma cooperativa para sua realização. O elemento básico constituinte do cérebro humano é o neurônio biológico (figura 4.1), uma célula que recebe e envia informação para várias partes do organismo, e são essenciais na determinação do funcionamento e comportamento do corpo humano e do raciocínio Haykin, (1994).

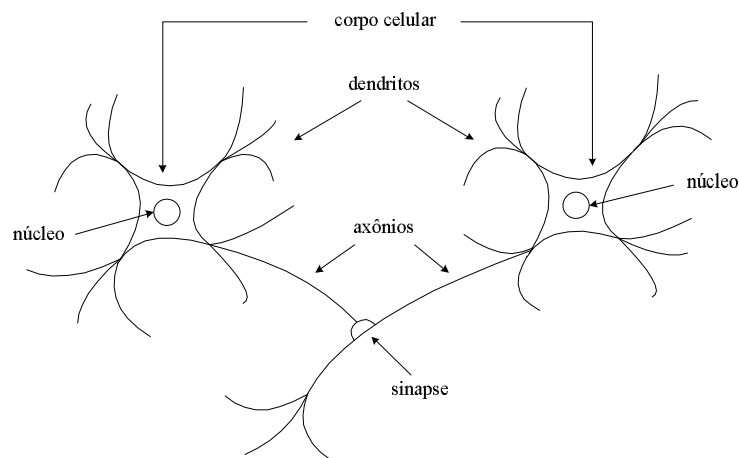


Figura 4.1 – Modelo de um neurônio biológico.

O neurônio é uma célula composta por um núcleo, um corpo celular (do idioma grego, sôma), responsável pela recepção e geração de impulsos nervosos representando o processamento de informação; por vários prolongamentos do corpo celular, denominados dendritos, que têm a função de receber as informações, ou impulsos nervosos de outros neurônios e conduzi-las ao corpo celular; e por uma única fibra nervosa denominada axônio, também ligados ao corpo celular, que se conecta a vários outros neurônios.

As conexões que ocorrem entre os neurônios (junções axônio/dendritos) são chamadas de sinapses, que, mais especificamente, podem ser tratadas como ponto de contato en-

tre a terminação axônica de um neurônio e o dendrito do outro. As sinapses são como válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios. Esta capacidade é definida como sendo eficiência sináptica Haykin (1994).

4.4 - Modelo Neural Artificial

Com o desenvolvimento da inteligência artificial, surgiram idéias de como representar, através da modelagem matemática (e computacional), o funcionamento do processo de aprendizagem do cérebro humano. Foi a partir dos estudos com as redes neuronais biológicas que surgiram as redes neurais artificiais.

Assim, as redes neurais artificiais nada mais são do que a representação da tentativa de reprodução da capacidade de processamento do cérebro. Semelhante ao cérebro humano, a rede neural artificial possui um neurônio (artificial) cuja função é imitar as características do neurônio biológico. Dentre essas características destacam-se, principalmente:

1. **Processamento paralelo maciço:** Capacidade de armazenar o conhecimento através do treinamento.
2. **Interligações entre neurônios feitas por conexões sinápticas:** Transmissão de informação de forma a permitir que as mesmas sejam armazenadas.
3. **Capacidade de generalização:** Permite que a rede neural artificial forneça, em tempo real, “saída” para entradas que não participam da fase de treinamento.

O neurônio artificial é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural artificial, assim como o neurônio biológico é para a rede neuronal.

Na figura 4.2 é mostrado o primeiro modelo de um neurônio artificial, formulado por McCulloch e Pitts (1943). Este modelo tenta simular as realidades biológicas que ocorrem dentro de uma célula do sistema nervoso, fazendo uma analogia à figura 4.1.

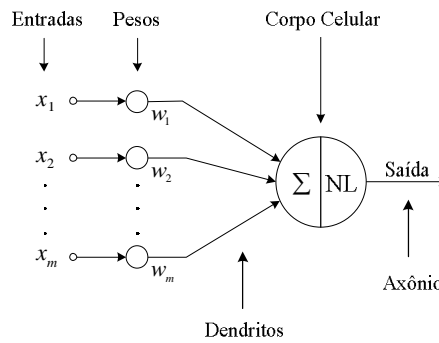


Figura 4.2 – Componentes de um neurônio artificial.

A forma de representação de um neurônio artificial com m entradas é dada através da figura 4.3, em que ϕ é uma função não-linear denominada função de ativação, sua definição será dada no que segue.

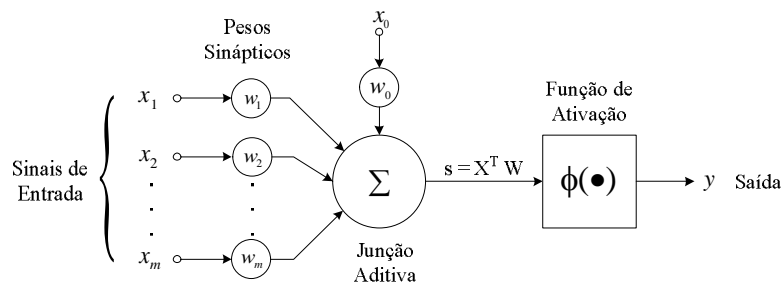


Figura 4.3 – Modelo não-linear de um neurônio.

Deste modo, através da figura 4.3, é possível identificar três elementos básicos de um modelo neural:

- Um conjunto de sinapses (ou elos de conexão), em que cada elo é caracterizado por um peso ou força própria. As entradas x_i correspondem aos sinais dentro da sinapse biológica. Essas entradas são multiplicadas aos respectivos pesos sinápticos w_i , que está relacionado com a “resistência” de uma única ligação sináptica biológica. Ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui tanto valores negativos como positivos.
- Um somador, que corresponde ao corpo celular biológico, que tem a função de adicionar os sinais de entrada ponderados pelas respectivas sinapses do neurônio; as operações descritas aqui constituem um combinador linear.
- Uma função de ativação para restringir a amplitude da saída do neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo

permissível de amplitude do sinal de saída a um valor finito. O intervalo normalizado da amplitude de saída de um neurônio é escrito como o intervalo unitário fechado $[0,1]$ ou, alternativamente, $[-1,+1]$.

No modelo neural da figura 4.3, cada entrada X é ponderada por um peso sináptico com W . Se a soma ponderada das entradas for maior que o valor de w_0 , denominado *bias*, o neurônio é “ativado” provocando um pulso na saída (equação 4.1), caso contrário, ele não é “ativado”. O peso *bias* pondera uma entrada $x_0 = +1$, que atua como controle do nível de saída do neurônio. A saída intermediária do neurônio é, então, dada por (WIDROW; LEHR, 1990):

$$s = \sum_{i=0}^m w_i x_i \quad (4.1)$$

A ativação do neurônio é feita por uma função denominada *função de ativação*, mencionada anteriormente, que podem ser do tipo:




Figura 4.4 – Tipos de funções de ativação.

As funções do tipo relé são apropriadas para sistemas binários, enquanto que as funções sigmoidais (*threshold*) podem ser empregadas tanto para sistemas contínuos quanto binários. A função de ativação mais empregada na literatura é a função sigmoide; devido o fato de ser a única a ter similaridade com o neurônio biológico, além de ser contínua e apresentar derivada simples.

4.5 - Arquitetura de Redes Neurais Artificiais

Uma rede neural artificial consiste de elementos de processamento (neurônios) e suas conexões (sinapses). Na maioria dos casos, possui sempre uma camada de entrada e uma camada de saída. Entre a camada de entrada e a camada de saída, existe um número variável de camadas intermediárias (ou camadas escondidas). Cada saída pode ser usada como entrada

a vários neurônios (através de ramificações) e cada neurônio pode receber várias entradas procedentes de outros neurônios. Cada conexão entre neurônios possui um peso que determina sua contribuição na decisão do disparo controlando, dessa forma, os estímulos. A esta disposição das camadas e o número de neurônios por camada, dá-se o nome de arquitetura da rede neural (HAYKIN, 1994), exemplificada pela figura 4.5.




Figura 4.5 – Disposição de uma rede neural artificial.

Além da disposição das camadas, as redes neurais artificiais podem ser classificadas em dois tipos quanto sua estrutura (método de propagação da informação recebida): (SIMPSON, 1989; WASSERMAN, 1989; HAYKIN, 1994; KARTALOPOULOS, 1996; MENDES FILHO; CARVALHO, 1997):

- **Redes recorrentes** (ou *feedback*) - contém laço de realimentação, ou seja, se contém conexões das saídas de uma determinada camada para a entrada da mesma camada ou de camadas anteriores.
- **Redes não-recorrentes** (ou *feedforward*) - não contém laço de realimentação, cada neurônio recebe sinais somente das camadas anteriores. São redes que não possuem memória, sendo que sua saída é determinada em função da entrada e dos valores dos pesos (HAYKIN, 1994).

4.6 – Aprendizado em Redes Neurais Artificiais

A propriedade mais importante que apresentam as redes neurais artificiais é a habilidade que elas têm de aprender e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O objetivo do treinamento, ou aprendizagem, é fazer com que a aplicação de um conjunto de entradas (vetores), produza um conjunto de saídas desejado (HAYKIN, 1994).

Um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizado denomina-se algoritmo de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, estes algoritmos diferem entre si, principalmente, pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Quanto ao tipo de aprendizado, pode-se classificá-lo em dois grupos distintos, como segue abaixo.

- **Aprendizado supervisionado**

No aprendizado supervisionado, ou treinamento associativo, a rede é treinada através da combinação dos padrões de entrada e saída. Este processo usa um agente externo (*teacher*) que indica à rede um comportamento bom ou ruim de acordo com o padrão de entrada.

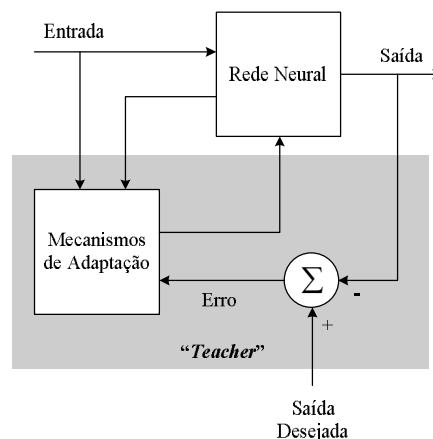


Figura 4.6 – Aprendizado supervisionado.

São fornecidos à rede pares de treinamento, representando os vetores de entrada e as saídas desejadas. Um vetor de entrada é aplicado à rede e a saída correspondente é calculada e comparada com o correspondente vetor de saída desejada. O erro é propagado através da

rede e os pesos são alterados por um algoritmo na tentativa de minimizá-lo. As técnicas de aprendizagem supervisionadas incluem: decidir quando desativar a aprendizagem, decidir como e por quanto tempo apresentar os pares de treinamento, além de suprir informações de erro e desempenho (HAYKIN, 1994).

- **Aprendizado não-supervisionado**

No aprendizado não-supervisionado, ou auto-organização, a rede é treinada usando apenas o vetor de entrada. Este processo não emprega um agente externo (*teacher*) indicando a resposta desejada para os padrões de entrada, ou seja, é uma rede autônoma; usam-se, entretanto, exemplos de coisas semelhantes para que a rede responda de maneira semelhante. O método não-supervisionado auto-organiza os dados apresentados e descobre suas propriedades coletivas, ou seja, extrai propriedades estatísticas do conjunto de treinamento e agrupa vetores similares em classes (HAYKIN, 1994).

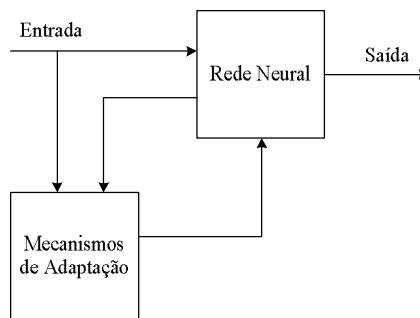


Figura 4.7 – Aprendizado não-supervisionado.

Existem diversos algoritmos para efetuar a aprendizagem de redes neurais artificiais. Dentre eles destacam-se (HAYKIN, 1994), Regra de *Hebb*, Regra delta de *Widrow e Hoff*, Regra delta generalizada e algoritmo de aprendizagem Retropropagação.

4.7 – Tipos de Redes Neurais Artificiais

Existem diversos modelos de redes neurais artificiais sendo usadas nas mais variadas aplicações; dentre os modelos de redes neurais mais conhecidos, destacam-se:

- Rede Neural de McCulloch-Pitts (MCP) (McCULLOCH; PITTS, 1943).
- Perceptron de Camada Simples (SLP – *Simple Layer Perceptron*) (ROSENBLATT, 1958, 1962).

- Perceptron Multicamadas (MLP - *Multi Layer Perceptron*) (HEBB, 1949).
- Rede Neural ADALINE (WIDROW; HOFF, 1960).
- Rede Neural *Feedforward* (MLFF - *Multi Layer Feedforward*) (MINSKY; PAPERT, 1969).
- SOM (*Self Organizing Map*) de Kohonen (KOHONEN, 1972).
- Rede Neural Retropropagação (BPN - *Backpropagation Network*) (RUMELHART, HILTON; WILLIAMS, 1986).
- Rede de Hopfield (HOPFIELD, 1982).
- Rede ART (*Adaptive Resonance Theory*) (GROSSBERG, 1976).
- Rede CNM (*Combinatorial Neural Model*) (MACHADO; ROCHA, 1989).
- Rede CPN (*Counterpropagation Network*) (HECHT-NIELSEN, 1987).
- Rede BAM (*Bidirectional Associative Memory*) (KOSKO, 1988).
- Rede Neocognitron (FUKUSHIMA, MIYAKE; ITO, 1980).
- Rede RBFN (*Radial Basis Function Network*) (POWELL, 1985).

4.8 – Conclusão

As redes neurais artificiais são técnicas computacionais que têm se mostrado extremamente eficientes na solução de problemas, onde os métodos tradicionais da computação convencional não têm apresentado soluções satisfatórias, podendo ser vistas como um conjunto de neurônios, que são ligados uns aos outros, através de conexões, análogas às sinapses. Estas conexões armazenam o conhecimento da rede, que é adquirido através do treinamento e adaptação dos pesos.

Dessa forma, neste capítulo, foram abordados conceitos de redes neurais artificiais iniciando com a apresentação dos modelos de neurônio biológico e artificial, identificando, em cada um deles, os principais componentes e, ainda, no caso do neurônio artificial, sua representação matemática. Foi mostrado desde a arquitetura de uma rede neural até os tipos de redes.

Funções de Base Radial

5.1 - Introdução

Como visto anteriormente, as redes neurais artificiais têm como um de seus elementos básicos, uma função de ativação que é responsável por restringir a amplitude da saída do neurônio. Na literatura, a função de ativação mais utilizada é a função sigmoide, por ter maior similaridade com neurônio biológico.

Neste capítulo será apresentado um breve estudo sobre funções de base radial, a fim de analisar a possibilidade de utilizá-las como função de ativação das redes neurais. De início será realizada a apresentação das principais características dessa classe de funções, a seguir, apresentar-se-ão as funções encontradas na literatura, seguidas das funções propostas, tanto na forma gráfica quanto analítica.

5.2 – Função de Base Radial

As funções de base radial formam uma classe especial de funções. Em geral, são funções não-lineares cujos valores diminuem (ou aumentam) monotonicamente em relação à distância de um ponto central (MARK, 1996). Esse ponto costuma-se chamar centro da função de base radial (GIROSI; POGGIO, 1991).

Uma função base radial $\phi(\|x - x_i\|)$ apresenta simetria radial, ou seja, depende apenas da distância entre o centro da função e um ponto genérico x . Neste caso, os pontos x_i são

chamados de centros das funções de base radial (POWELL, 2001; HEIMES; HEUVELN, 1998).

O uso das funções de base radial, no contexto de aproximações de funções, tem sua origem na teoria da interpolação de dados. A solução do problema de interpolação é obtida através de uma combinação linear de translações de uma função de base radial convenientemente escolhida. A seguir apresenta-se a forma mais geral da solução do problema de interpolação.

Utiliza-se uma função $f \in C(\Omega)$, em que $C(\Omega)$ é o espaço das funções contínuas em Ω , cujos valores em um conjunto de pontos $X = \{x_1, x_2, \dots, x_m\} \subset \Omega \subset R^n$ são conhecidos. Esse conjunto de pontos é, normalmente, chamado de centro. Sendo assim, a solução procurada é da forma (BUHMANN, 2000; POGGIO; GIROSI, 1990; WENDLAND, 1999):

$$f(x) = \sum_{i=1}^m \mu_i \Phi(x, x_i) + p(x) \quad (5.1)$$

sendo:

- f : função de interpolação;
- μ_i : pesos da função de interpolação;
- p : polinômio de grau muito pequeno, geralmente linear ou quadrático;
- Φ : função radial em sua forma mais geral.

A função $\Phi : \Omega \times \Omega \rightarrow R$, é radial com respeito a distância euclidiana, expressa por (BECKERT ; WENDLAND, 2001):

$$\|x\| = \sqrt{x_1^2 + \dots + x_n^2} \quad (5.2)$$

em que: $x = (x_1, \dots, x_n) \in R^n$.

Em outras palavras, pode-se dizer que a função f consiste de uma soma ponderada de funções de base radial Φ radialmente simétricas ao centro x_i .

De forma a possibilitar o melhor entendimento da noção de função de base radial, as funções Φ são simplificadas em duas situações especiais (WENDLAND; SCHABACK, 2001):

1. $\Phi(x, x_i) = \phi(x - x_i)$ com $\phi : R^n \rightarrow R$ (translação constante);
2. $\Phi(x, x_i) = \phi(\|x - x_i\|)$ com $\phi : [0, \infty) \rightarrow R$ (radialidade);

sendo, $\|x - x_i\|$ a distância entre x e x_i (CHEN; CHEN, 1995; MULGREW, 1996), como visto anteriormente.

Em Micchelli (1986) indicou a existência de um conjunto de funções (tanto limitadas quanto ilimitadas) que são adequadas, por resultarem em um conjunto de equações lineares para incógnitas μ_i , para os quais existe uma única solução. A seguir serão apresentadas algumas destas funções.

5.3 - Principais Funções

Na literatura, encontram-se diversas funções de base radial, tais como gaussiana, multiquadrática, multiquadrática recíproca, secante hiperbólica e *spline* de placas finas, (ASTORINO; RIMONDO, 2004; MAI-DUY; TRAN-CONG, 2003), ilustradas pela figura 5.1.

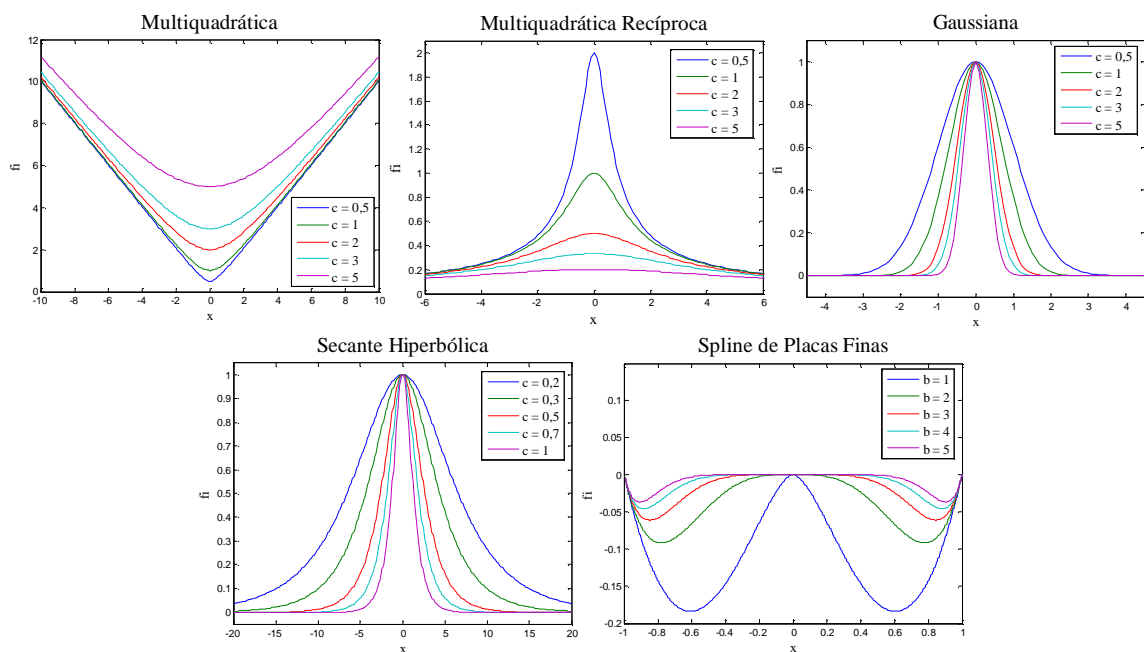


Figura 5.1 – Funções de base radial encontradas na literatura.

Porém, em se tratando da utilização dessas funções como função de ativação das redes neurais artificiais, são apontadas duas funções que apresentam características que inviabilizam a utilização das mesmas, sendo elas, a função multiquadrática, por ser uma função ilimitada, e a função *spline* de placas finas, por ser uma função não diferenciável.

Baseado no estudo de algumas dessas funções, duas novas funções de base radial foram propostas, a multiquadrática recíproca inversa (obtida através de uma modificação da função multiquadrática recíproca) e a secante hiperbólica recíproca (obtida através de uma modificação da função secante hiperbólica) (ALTRAN, 2005; ALTRAN; MINUSSI; VILLARREAL, 2008), como mostra a figura 5.2.

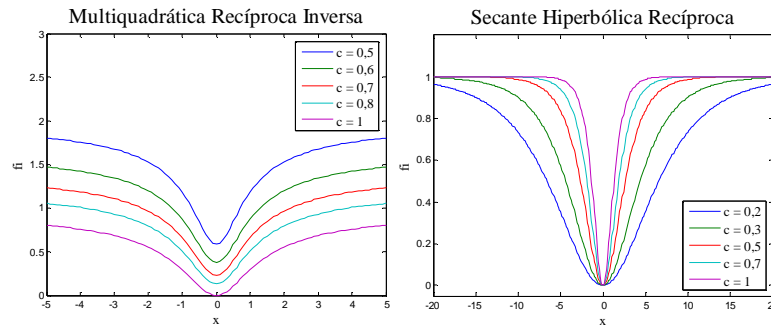


Figura 5.2 – Funções de base radial propostas.

A tabela 5.1, mostra a forma analítica das funções de base radial, e respectivas derivadas, que podem ser utilizadas como função de ativação de uma rede neural artificial, em que c representa o centro das funções de base radial.

Tabela 5.1 – Funções de base radial e respectivas derivadas.

<i>Funções</i>		<i>Derivadas</i>
Multiquadrática Recíproca	$y_i = \frac{1}{\sqrt{(x^2 + c^2)}}$	$y'_i = -\frac{x}{(x^2 + c^2)} y_i$
Gaussiana	$y_i = e^{-cx^2}$	$y'_i = -2cx y_i$
Secante Hiperbólica	$y_i = \frac{2}{e^{cx} + e^{-cx}}$	$y'_i = -\frac{2}{(e^{cx} + e^{-cx})^2 (ce^{cx} - ce^{-cx})}$
Multiquadrática Recíproca Inversa	$y_i = \frac{1}{c} - \frac{1}{\sqrt{x^2 + c^2}}$	$y'_i = \frac{x}{(x^2 + c)^{3/2}}$
Secante Hiperbólica Recíproca	$y_i = 1 - \frac{2}{e^{cx} + e^{-cx}}$	$y'_i = \frac{2}{(e^{cx} + e^{-cx})^2 (ce^{cx} - ce^{-cx})}$

5.4 - Conclusão

Neste capítulo foi realizada a apresentação das funções de base radial, iniciando com uma definição formal da mesma. Em seguida, foi realizada a apresentação gráfica das funções de base radial encontradas na literatura e também de duas outras propostas pela autora, anteriormente, finalizando com a apresentação analítica das funções de interesse (aquelas que podem ser usadas como função de ativação de uma rede neural artificial).

Através do estudo de tais funções, observou-se que nem todas as funções de base radial podem ser utilizadas como função de ativação de uma rede neural artificial, sendo estas as funções multiquadrática e *spline* de placas finas, por serem ilimitadas ou não-diferenciáveis, características necessárias e fundamentais para o funcionamento da rede.

Vale enfatizar que a função de ativação não pode ser ilimitada, pois, a mesma tem o objetivo de restringir o intervalo de amplitude do sinal de saída a um valor finito, geralmente $[0, 1]$; e também não podem ser não-diferenciáveis, pois, o algoritmo de treinamento utiliza a derivada da função de ativação.

A aplicação do Esquema Desenvolvido

6.1 - Introdução

Conforme discutido no capítulo 3, objetivo desta pesquisa é o desenvolvimento de sistema para a previsão de carga multinodal. A rede neural utilizada foi uma rede *perceptron* multicamadas, porém, utilizando funções de base radial como funções de ativação. Deste modo foi possível explorar ao máximo o potencial desta arquitetura. Assim sendo, na sequência são apresentadas a rede neural *perceptron* multicamadas e suas estratégias de treinamento; em virtude deste fato, realiza-se um tratamento detalhado do algoritmo retropropagação, e sua aplicação no problema de previsão de carga multinodal.

O algoritmo retropropagação é considerado, na literatura, um referencial em termos de precisão; logo, é considerado uma das principais ferramentas usada para resolver problemas reais, neste caso, a previsão de cargas elétricas. O principal objetivo é investigar como funciona a arquitetura do algoritmo retropropagação quando se aplica a ele diferentes funções de ativação, ou seja, dependendo da função de não-linearidade usada no algoritmo, como a saída da rede neural é processada, tanto na forma global quanto modular e, principalmente, qual o tempo de processamento demandado por elas, já que umas das desvantagens do algoritmo é apresentar convergência lenta.

6.2 - *Perceptron* Multicamadas

O *perceptron* multicamadas tem sido aplicado com grande sucesso na resolução de problemas complexos; isto se dá devido seu treinamento ocorrer de forma supervisionada usando um algoritmo muito popular, conhecido como algoritmo retropropagação (*Backpropagation*) (WERBOS, 1974). O desenvolvimento deste representa um marco nas redes neurais artificiais, pois, fornece um método computacional eficiente para o treinamento das redes *perceptron* multicamadas (HAYKIN, 1994).

Uma rede *perceptron* multicamadas consiste, tipicamente, de um conjunto de unidades que constituem uma camada de entrada, uma ou mais camadas intermediárias, e uma camada de saída; como mostra a figura 6.1.




Figura 6.1 – *Perceptron* multicamadas.

Nessas redes, cada camada tem uma função específica. A camada de saída recebe estímulos da camada de entrada e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características. Seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema. Se existirem conexões certas entre as unidades de entrada e um conjunto suficientemente grande de unidades intermediárias, pode-se sempre encontrar a representação que irá produzir o mapeamento correto da entrada para a saída através das unidades intermediárias.

Como provou Cybenko, são necessárias, no máximo, duas camadas intermediárias com um número suficiente de unidades por camada, para se produzir quaisquer mapeamentos. Também foi provado que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua (CYBENKO, 1989).

O treinamento de uma rede *perceptron* multicamadas, usando o algoritmo de treinamento retropropagação, consiste em dois passos:

- Primeiramente, o padrão é apresentado às unidades da camada de entrada e, a partir desta camada, as unidades intermediárias calculam sua resposta que é produzida na camada de saída e o erro é calculado;
- A seguir, o erro é propagado, a partir da camada de saída, até a camada de entrada e os pesos das conexões das unidades das camadas intermediárias são modificados.

Depois que a rede estiver treinada e o erro estiver em um nível satisfatório, ela poderá ser usada como uma ferramenta para classificação de novos dados. Para isso, a rede deverá ser usada apenas de modo progressivo (*feedforward*). Ou seja, novas entradas serão apresentadas à camada de entrada. São processadas nas camadas intermediárias e os resultados são apresentados na camada de saída, como no treinamento, mas sem retropropagação do erro. A saída apresentada é o modelo dos dados na interpretação da rede.

6.3 - Algoritmo Retropropagação

A primeira concepção do algoritmo retropropagação foi apresentada em 1974 por Werbos (1974). A partir desta concepção, foi possível realizar uma forma de ajustar os pesos de uma rede neural das unidades de entrada para a unidade de saída. Os erros observados nas unidades da camada intermediária são determinados pelo erro propagado na direção inversa das unidades da camada de saída. Por esta razão, o método é chamado algoritmo de aprendizagem retropropagação, podendo este ser esquematizado pelos seguintes procedimentos:

1. Apresentação de um padrão X a rede, o qual fornece uma saída Y ;
2. Cálculo do erro (diferença entre o valor desejado e a saída) para cada saída;
3. Determinação do erro retropropagado pela rede associado à derivada parcial do erro quadrático de cada elemento relacionado aos pesos;
4. Ajuste dos pesos de cada elemento;
5. Apresenta-se um novo padrão a rede e repete-se o processo até que haja a convergência da rede, ou seja, ($|\text{erro}| \leq \text{tolerância arbitrada}$).

O algoritmo retropropagação é um procedimento sistemático de adaptação de pesos das redes neurais, baseado no método do gradiente descendente (KROSE; SMAGT,

1996; WASSERMAN, 1989). A adaptação de pesos é realizada de tal forma que o erro quadrático da rede seja minimizado. Inicialmente os valores dos pesos são adotados como números aleatórios considerando o intervalo $\{0,1\}$ (WIDROW; LEHR, 1990). A soma dos erros quadráticos instantâneos de cada neurônio da última camada (saída da rede) é dada por (WIDROW; LEHR, 1990):

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (6.1)$$

sendo:

$$\varepsilon_i : d_i - y_i$$

d_i : saída desejada do i -ésimo elemento da última camada da rede;

y_i : saída do i -ésimo elemento da última camada da rede;

ns : número de neurônios da última camada da rede.

Considerando o i -ésimo neurônio da rede, e usando o método do gradiente descendente, o ajuste de pesos pode ser formulado da seguinte forma (WIDROW; LEHR, 1990):

$$V_i(h+1) = V_i(h) - \theta_i(h) \quad (6.2)$$

sendo:

$$\theta_i(h) : \gamma(\nabla_i(h));$$

γ : parâmetro de controle da estabilidade ou taxa de treinamento;

h : índice de iteração;

$\nabla_i(h)$: gradiente do erro quadrático relacionado aos pesos do neurônio i ;

$$V_i = [w_{0i} \ w_{1i} \ w_{2i} \ \cdots \ w_{ni}]^T.$$

A direção adotada em (6.2), para a minimização da função objetivo do erro quadrático, corresponde à direção oposta do gradiente. O parâmetro γ determina o comprimento do vetor $\theta_i(h)$ e serve como controle de estabilidade do processo iterativo (LOPES, MINUSSI; LOTUFO, 2003).

Desta maneira, obtém-se o seguinte esquema para adaptação dos pesos (WIDROW; LEHR, 1990):

$$V_i(h+1) = V_i(h) + 2\gamma \beta_i X_i. \quad (6.3)$$

Se o i -ésimo elemento estiver na última camada, então:

$$\beta_i = \sigma_i \varepsilon_i. \quad (6.4)$$

Por outro lado, se o i -ésimo elemento estiver nas outras camadas, tem-se:

$$\beta_i = \sigma_i \sum_{j \in Q(i)} w_{ij} \beta_j \quad (6.5)$$

em que:

σ_i \triangleq derivada da função de ativação, relativa a s_i ;

$Q(i)$: conjunto dos índices que estão na próxima camada, a camada do i -ésimo elemento, e estão interligados ao i -ésimo elemento.

O algoritmo retropropagação é abordado na literatura sob várias formas com o propósito de torná-lo mais rápido computacionalmente. Uma formulação bastante interessante é o algoritmo retropropagação com momento (WIDROW; LEHR, 1990).

Então, efetuando-se o cálculo do gradiente, como indicado na equação (6.5), considerando-se as funções de ativação e o termo momento, obtém-se o seguinte esquema de adaptação de pesos (WIDROW; LEHR, 1990):

$$v_{ij}(h+1) = v_{ij}(h) + \Delta v_{ij}(h) \quad (6.6)$$

sendo:

$$\Delta v_{ij}(h) = 2\gamma(1-\eta)\beta x_i + \eta \Delta v_{ij}(h-1)$$

v_{ij} : peso correspondente à interligação entre o i -ésimo e j -ésimo neurônio;

η : constante momento ($0 \leq \eta < 1$).

O parâmetro β_j é calculado de forma semelhante ao esquema de adaptação realizado pelo algoritmo retropropagação convencional sem momento. A figura 6.2 ilustra o esquema de adaptação de pesos, usado pelo algoritmo retropropagação com momento, na rede *perceptron* multicamadas.

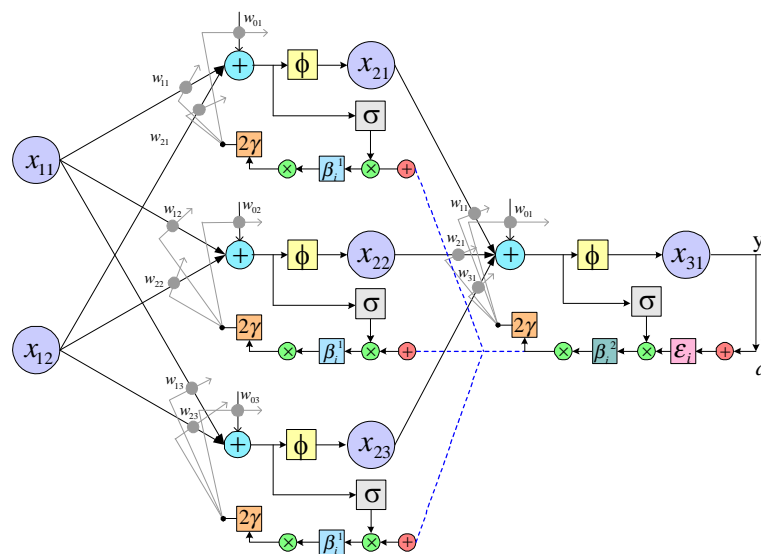


Figura 6.2 – Esquema de adaptação de pesos do algoritmo Retropropagação.

6.4 - Funções de Ativação

Como visto anteriormente, as redes neurais artificiais têm como um de seus elementos básicos, uma função de ativação que é responsável por restringir a amplitude da saída do neurônio.

As funções de ativação de um neurônio artificial são funções diferenciáveis e não-lineares. Esta não-linearidade se torna importante pelo fato desta função de ativação fornecer à rede neural uma saída similar à saída de um neurônio que, normalmente, não é linearmente dependente de suas entradas.

Deste modo, uma classe de funções que despertou interesse foram as funções de base radial (MULGREW, 1996; MAI-DUY; TRAN-CONG, 2003), porém, nem todas as funções encontradas na literatura puderam ser empregadas pelo fato de não serem limitadas ou diferenciáveis.

Assim, na aplicação do esquema desenvolvido, foram usadas as funções, gaussiana (G), multiquadrática recíproca (MR) e secante hiperbólica (SH). Além destas, duas novas funções foram propostas, a função multiquadrática recíproca inversa (MRI) e a função secante hiperbólica recíproca (SHR), obtidas através da modificação de funções já existentes.

A tabela a seguir (tabela 6.1) apresenta as funções de ativação e suas respectivas derivadas, que foram usadas na metodologia desenvolvida, a função sigmoide (S) foi utilizada apenas a critério de comparação.

Tabela 6.1 - Funções de ativação e suas respectivas derivadas

		Representação	
		Funções	Derivadas
Função de Ativação	G	$\phi(s) = e^{-c \cdot s^2}$	$\sigma(s) = -2 \ c \ s \ e^{-cs^2}$
	MR	$\phi(s) = \frac{1}{\sqrt{(s^2 + c^2)}}$	$\sigma(s) = -\frac{s}{(s^2 + c^2)^{3/2}}$
	MRI	$\phi(s) = \frac{1}{c} - \frac{1}{\sqrt{s^2 + c^2}}$	$\sigma(s) = \frac{s}{(s^2 + c)^{3/2}}$
	SH	$\phi(s) = \frac{2}{e^{cs} + e^{-cs}}$	$\sigma(s) = -\frac{2 (ce^{cs} - ce^{-cs})}{(e^{cs} + e^{-cs})^2}$
	SHR	$\phi(s) = 1 - \frac{2}{e^{cs} + e^{-cs}}$	$\sigma(s) = \frac{2}{(e^{cs} + e^{-cs})^2 (ce^{cs} - ce^{-cs})}$
	S	$\phi(s) = \frac{1}{1 + e^{-\lambda s}}$	$\sigma(s) = \frac{\lambda}{1 + e^{-\lambda s}} \left[1 - \frac{1}{1 + e^{-\lambda s}} \right]$

6.5 - Algoritmo Retropropagação na Previsão de Carga

A previsão de carga a curto-prazo (previsão diária) é realizada da seguinte forma; a implementação de recorrência na saída em um determinado instante será utilizada como entrada no instante subsequente. São considerados os dados históricos horários dentro de um intervalo preestabelecido, em geral, mensal.

O esquema de previsão multinodal desenvolvido é composto, basicamente, por dois sistemas previsores interligados, um sistema previsor global e um sistema previsor local, conforme descrito no capítulo 3.

No sistema previsor global, a entrada da rede, para uma determinada hora h , é definida como sendo os valores da carga, extraídos dos dados históricos; por exemplo, quatro instantes (o valor corrente, uma, duas e três horas anteriores), e dados referentes ao tempo (mês, dia da semana, feriado e hora). A saída da rede corresponde ao valor da carga referente à hora ($h + 1$), ou seja, hora posterior a hora corrente. O conjunto que compõe a entrada/saída é definido considerando esta estratégia até completar todo o intervalo de tempo da série temporal. Este esquema pode ser modificado visando obter melhores resultados, através

da introdução de outras variáveis (dias nublados, entre outros). Assim, o vetor de entrada e a saída, respectivamente, são definidos da seguinte forma (equação 3.1):

$$\mathbf{X}(h) = [t^T L(h-3) L(h-2) L(h-1) L(h)]^T, \quad \mathbf{X} \in R^m$$

$$\mathbf{Y}(h) = [L(h+1)], \quad \mathbf{Y} \in R^1$$

sendo:

- $L(h-p)$: valor da carga P horas anteriores à hora corrente h ;
- $L(h+1)$: valor da carga correspondente à hora subsequente a hora corrente h ;
- t : vetor de tempo referente aos dados históricos (dia da semana, hora, etc.) representados de modo similar ao código binário $(-1,+1)$;
- m : dimensão do vetor \mathbf{X} .

A escolha desta representação binária (para t) é preferível em relação à representação $(0,+1)$, tendo em vista que, o componente “0” de entrada à rede não proporciona modificação nos pesos. Deste modo, a representação $(-1,+1)$ produz uma convergência mais rápida, conseqüentemente, mais eficiente. As cargas elétricas $L(h-3), \dots, L(h-1)$ representam o laço de realimentação, com atraso, da saída. Deste modo, esta rede é do tipo recorrente.

Os dados que compõem o treinamento, ou seja, os arquivos de entrada e saída das redes neurais; para cada vetor, são dados de tempo (dia do mês, dia da semana (se é feriado ou não) e a hora do dia), cargas horárias correntes e valores de cargas considerando-se três horas anteriores. A carga futura (uma hora à frente) constitui a saída da rede para o sistema predictor global. Não foram considerados os dados de temperatura em conseqüência da não disponibilidade dos mesmos. Considerando-se a representação binária, em geral, o vetor t terá dimensão 8 que, juntamente com os dados da carga, serão 12 componentes ($m=12$), ou seja, 3 bits para o dia da semana, 5 bits para a hora e 4 bits para os dados de carga (corrente mais três anteriores).

Já para o sistema predictor local, neste caso, composto por três módulos, funcionando de forma independente, o conjunto entrada/saída é diferente para as fases de treinamento e diagnóstico (previsão).

O treinamento de cada módulo é realizado praticamente da mesma forma que o treinamento do sistema predictor global, ou seja, considera-se para o treinamento, os mesmos dados históricos, com as componentes, dia da semana, hora e dados de carga atual ($L(h)$) de

cada módulo, ou seja, a diferença é que para o sistema predictor local, não é realizado o “janelamento”. Após o treinamento de cada módulo, o diagnóstico (previsão por barramento), é realizado considerando-se como entrada de cada módulo a saída do sistema predictor global ($Y(h)$) sendo este, um vetor composto por dados temporais e o dado da carga prevista, totalizando 9 componentes (3 para o dia da semana, 5 para a hora e 1 para o dado de carga prevista (global)), gerando as estimativas das cargas por barramento (locais). Assim, a previsão obtida em cada módulo tem a participação efetiva da carga global e esses fatores de participação são calculados conforme descrito no capítulo 3.

Os dados históricos foram obtidos de cargas elétricas de uma companhia do setor elétrico da Nova Zelândia, *Electricity Commission* da Nova Zelândia. Estes dados contêm valores das cargas horárias do ano de 2007, considerando os dados de carga global e de três subestações, este o fato para serem considerados apenas três módulos no sistema predictor local.

Para a aplicação da metodologia, foi utilizado um arquivo de dados que corresponde aos dados históricos de 15 dias (Apêndice A), considerou-se o período de 15 de outubro de 2007 a 29 de outubro de 2007 que, conforme dito acima compõem o vetor de entrada de dimensão 12 (dia da semana, hora e carga atual e três anteriores) para o sistema predictor global e dimensão 9 (dia da semana, hora e carga atual) para cada módulo do sistema local, totalizando 360 padrões de entrada para cada rede. Assim, realizou-se a previsão do dia 30 de outubro de 2007.

Os valores das cargas são inicialmente normalizados, uma vez que a saída pode variar, somente, entre 0 e +1. A série prevista será, finalmente, convertida aos valores reais, ou seja, multiplicados pelo valor da base preestabelecida. Em cada aplicação (sistema predictor), utilizam-se as seis funções de ativação mostradas na tabela 6.1.

6.6 – Critérios para Avaliação da Rede Neural

Para que seja feita a avaliação do desempenho das redes neurais, baseadas no algoritmo retropropagação, é realizada uma análise da precisão. Para tanto, são definidos o erro percentual absoluto médio (MAPE) e o erro máximo da previsão diária (SRINIVASAN et al., 1998), comparando-se os valores reais da carga com os valores estimados através da rede neural; sendo estes, apresentados da seguinte forma:

$$MAPE = \frac{1}{NT} \left\{ \sum_{h=1}^N \left(\frac{|L(h) - \underline{L}(h)|}{L(h)} \right) \right\} \times 100 \quad (6.7)$$

$$Erro \text{ Máximo } (\%) = \max_{h \in H_d} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100 \quad (6.8)$$

sendo:

$L(h)$: valor da carga real referente à hora h ;

$\underline{L}(h)$: valor da carga estimada pela rede neural referente à hora h ;

NT : número total de horas.

H_d : intervalo de horas ($1 \leq h \leq 24$).

De forma a analisar o desempenho do processamento da rede neural aplicada a diferentes funções de ativação, é definido o ganho de tempo de execução (processamento), considerando o tempo necessário para efetuar o treinamento e o diagnóstico, da seguinte forma (LOPES; MINUSSI, 2000):

$$GT = \frac{TRPFE}{TRPFA} \quad (6.9)$$

sendo:

GT : ganho de tempo;

$TRPFE$: tempo de execução do algoritmo retropropagação utilizando uma das funções de ativação (gaussiana);

$TRPFA$: tempo de execução do algoritmo retropropagação utilizando funções de ativação (multiquadrática recíproca, multiquadrática recíproca inversa, secante hiperbólica, secante hiperbólica recíproca e sigmoide).

O tempo de processamento, diz respeito apenas à execução do algoritmo, sendo excluídas as operações de leitura e saída dos dados.

6.7 – Conclusão

Neste capítulo apresentou-se a descrição da metodologia desenvolvida para a previsão de carga multinodal, via redes neurais artificiais, usando o algoritmo retropropagação e funções de base radial, mostrando de forma detalhada o funcionamento da rede *perceptron* e

do algoritmo retropropagação.

Apresentou-se, ainda, a aplicação da mesma considerando os dados históricos de uma companhia do setor elétrico de Nova Zelândia e os critérios para avaliação do desempenho da rede. No capítulo que segue (capítulo 7), serão apresentados os resultados obtidos da aplicação da metodologia desenvolvida.

Resultados Obtidos

7.1 - Introdução

Como as redes neurais artificiais nada mais são do que técnicas computacionais, a obtenção dos resultados só se torna possível, através da simulação do funcionamento da rede neural proposta em ambiente computacional, deste modo, a seguir, serão apresentados os resultados, gráficos e numéricos, obtidos através da previsão de carga multinodal realizada, utilizando redes neurais artificiais, com algoritmo retropropagação, para as diferentes funções de ativação.

Como a obtenção dos resultados só é possível através de simulação computacional, na aplicação da metodologia desenvolvida, a simulação foi realizada fazendo uso uma máquina com processador Centrino Duo (Intel T2250 de 1.73Hz) e 2GB de memória RAM. O *software* utilizado para a programação da metodologia desenvolvida foi o FORTRAN 4.0 e para análise dos resultados (numérica e gráfica) fez-se uso do *software* MATLAB 7.0.

Conforme visto anteriormente, foram consideradas seis funções de ativação, sendo as cinco funções de base radial e a função sigmoide, utilizada apenas a critério de comparação, pois, a idéia é mostrar, também, que mesmo modificando a arquitetura do *perceptron*, trocando as funções, o desempenho da rede ocorre de modo análogo, ou até melhor, se comparado ao tradicional.

Deste modo, os resultados apresentados a seguir são referentes à previsão multinodal, obtidos através da metodologia desenvolvida, levando em consideração cada uma das funções utilizadas.

7.2 - Parâmetros Utilizados

A escolha dos parâmetros utilizados na rede é realizada através de testes, ou seja, não se usa nenhum método determinístico para escolha de tais parâmetros. Esses parâmetros, referentes à rede, ao treinamento e às funções, são ajustados através da análise do comportamento dos resultados.

Deste modo, apesar de terem sido realizados inúmeros testes, usando as seis funções (gaussiana (G), multiquadrática recíproca (MR), multiquadrática recíproca inversa (MRI), secante hiperbólica (SH), secante hiperbólica recíproca (SHR) e sigmoide (S)), optou-se por representar apenas parâmetros referentes aos melhores resultados para cada função de ativação, tanto para o sistema predictor global (SPG), quanto para os módulos do sistema predictor local (SPL).

Estes resultados são apresentados nas tabelas 7.1, 7.2, 7.3 e 7.4, em que, NNC é número de neurônios por camada, γ é a taxa de treinamento, η é a constante momento, λ é a inclinação da função sigmoide, c é o centro das funções de base radial e tol é a tolerância empregada que foi considerada entre 0,02 e 0,06, pois, uma tolerância abaixo disso não leva à convergência, devido o fato da utilização das derivadas.

Pode-se observar, através das tabelas 7.1, 7.2, 7.3 e 7.4, que o número de neurônios na camada de entrada da rede é diferente para o sistemas predictor global (12 neurônios) e local (9 neurônios cada módulo), esta diferença ocorre, justamente, por não se considerar a técnica do movimento em janela no sistema local, conforme descrito nos capítulos 3 e 6.

Tabela 7.1 – Especificação dos parâmetros da rede neural do sistema predictor global.

Funções		Parâmetros da Rede Neural				
		NNC	γ	η	λ ou c	tol
Sistema Global	G	12-27-1	0,40	0,60	0,70	0,023
	MR	12-48-1	0,50	0,60	0,50	0,023
	MRI	12-33-1	0,40	0,90	0,90	0,023
	SH	12-51-1	1,00	0,70	0,40	0,020
	SHR	12-51-1	1,00	0,70	0,40	0,021
	S	12-30-1	4,50	0,90	0,90	0,023

Tabela 7.2 – Especificação dos parâmetros da rede neural do sistema predictor local – módulo 1.

Funções		Parâmetros da Rede Neural				
		NNC	γ	η	λ ou c	tol
Sistema Modular 1	G	9-12-1	0,50	0,50	1,10	0,050
	MR	9-25-1	0,50	0,50	1,10	0,060
	MRI	9-17-1	3,00	0,50	1,20	0,060
	SH	9-25-1	1,50	0,90	1,00	0,060
	SHR	9-12-1	0,60	0,50	0,40	0,060
	S	9-20-1	5,00	0,50	1,1	0,060

Tabela 7.3 – Especificação dos parâmetros da rede neural do sistema predictor local – módulo 2.

Funções		Parâmetros da Rede Neural				
		NNC	γ	η	λ ou c	tol
Sistema Modular 2	G	9-12-1	0,50	0,50	1,10	0,050
	MR	9-25-1	0,50	0,50	1,10	0,060
	MRI	9-17-1	3,00	0,50	1,20	0,060
	SH	9-25-1	1,50	0,90	1,00	0,060
	SHR	9-12-1	0,60	0,50	0,40	0,060
	S	9-20-1	5,00	0,50	1,1	0,060

Tabela 7.4 – Especificação dos parâmetros da rede neural do sistema predictor local – módulo 3.

Funções		Parâmetros da Rede Neural				
		NNC	γ	η	λ ou c	tol
Sistema Modular 3	G	9-12-1	0,50	0,90	0,50	0,023
	MR	9-25-1	5,00	0,70	1,00	0,040
	MRI	9-10-1	6,00	0,70	1,20	0,040
	SH	9-11-1	6,00	0,50	0,70	0,050
	SHR	9-15-1	0,90	0,50	0,20	0,050
	S	9-25-1	5,00	0,50	1,1	0,060

No que segue serão apresentados os resultados obtidos na simulação, tanto do sistema predictor global quanto local.

7.3 - Resultados

A análise dos resultados, gráfica e numérica, é realizada para cada função, considerando o sistema previsor global e cada módulo do sistema previsor local.

Nas tabelas 7.5, 7.6, 7.7 e 7.8, são apresentados os resultados comparativos para cada sistemas previsor, em que, TP o tempo de processamento, GT é o ganho de tempo de processamento, MAPE é o erro percentual absoluto médio, e EM o erro máximo (descritos no capítulo 6). As linhas destacadas (em negrito) correspondem aos melhores resultados, em relação aos erros (MAPE e EM), dentre as funções utilizadas.

Tabela 7.5 – Resultados obtidos, para cada função, no sistema previsor global.

Funções		Parâmetros da Rede Neural			
		TP (s)	GT	MAPE	EM
Sistema Global	G	96	1,00	1,84	5,80
	MR	85	1,13	1,81	7,49
	MRI	47	2,04	2,27	7,67
	SH	373	0,26	2,03	5,62
	SHR	84	1,14	1,43	4,51
	S	177	0,54	1,91	5,86

Para o sistema previsor global, é possível observar que dentre as funções utilizadas a que apresentou melhor resultado, considerando MAPE e EM, foi a função secante hiperbólica recíproca, porém, os resultados para as demais funções, inclusive a função de comparação, função sigmoide, mantiveram um mesmo patamar, com MAPE em torno de 2%, como mostra a tabela 7.5.

Para o sistema previsor local, pode-se observar, através das tabelas 7.6, 7.7 e 7.8, que o treinamento ocorre de forma bastante rápida, em poucos segundos, e são obtidos bons resultados. Os melhores resultados foram obtidos pela função multiquadrática recíproca, secante hiperbólica recíproca e gaussiana, para os módulos 1, 2 e 3, respectivamente.

Tabela 7.6 – Resultados obtidos, para cada função, no sistema previsor local – módulo 1.

Funções		Parâmetros da Rede Neural			
		TP (s)	GT	MAPE	EM
Sistema Local - Módulo 1	G	7	1,00	4,50	17,26
	MR	3	2,33	3,27	8,69
	MRI	2	3,50	3,56	12,18
	SH	7	1,00	6,81	20,49
	SHR	1	7,00	4,63	22,70
	S	2	3,50	5,56	18,34

Tabela 7.7 – Resultados obtidos, para cada função, no sistema previsor local – módulo 2.

Funções		Parâmetros da Rede Neural			
		TP (s)	GT	MAPE	EM
Sistema Local-Módulo 2	G	2	1,00	5,19	9,34
	MR	6	0,33	5,16	11,48
	MRI	1	2,00	4,39	10,82
	SH	5	0,40	5,27	25,45
	SHR	1	2,00	4,35	9,10
	S	22	0,09	5,49	12,29

Tabela 7.8 – Resultados obtidos, para cada função, no sistema previsor local – módulo 3.

Funções		Parâmetros da Rede Neural			
		TP (s)	GT	MAPE	EM
Sistema Local – Módulo 3	G	1	1,00	2,93	5,50
	MR	1	1,00	3,46	10,63
	MRI	1	1,00	3,12	7,94
	SH	1	1,00	4,58	18,07
	SHR	1	1,00	3,69	10,43
	S	1	1,00	3,81	13,73

Na análise gráfica (figura 7.1) a curva de carga real, representada pela curva azul, é composta pelas 24 cargas horárias reais, ou seja, as cargas reais referentes às 24 horas do dia; já a curva de carga aproximada, representada pela curva vermelha, nada mais é que a saí-

da rede neural, ou seja, os valores das 24 cargas previstos, tanto para o sistema predictor global, quanto local.

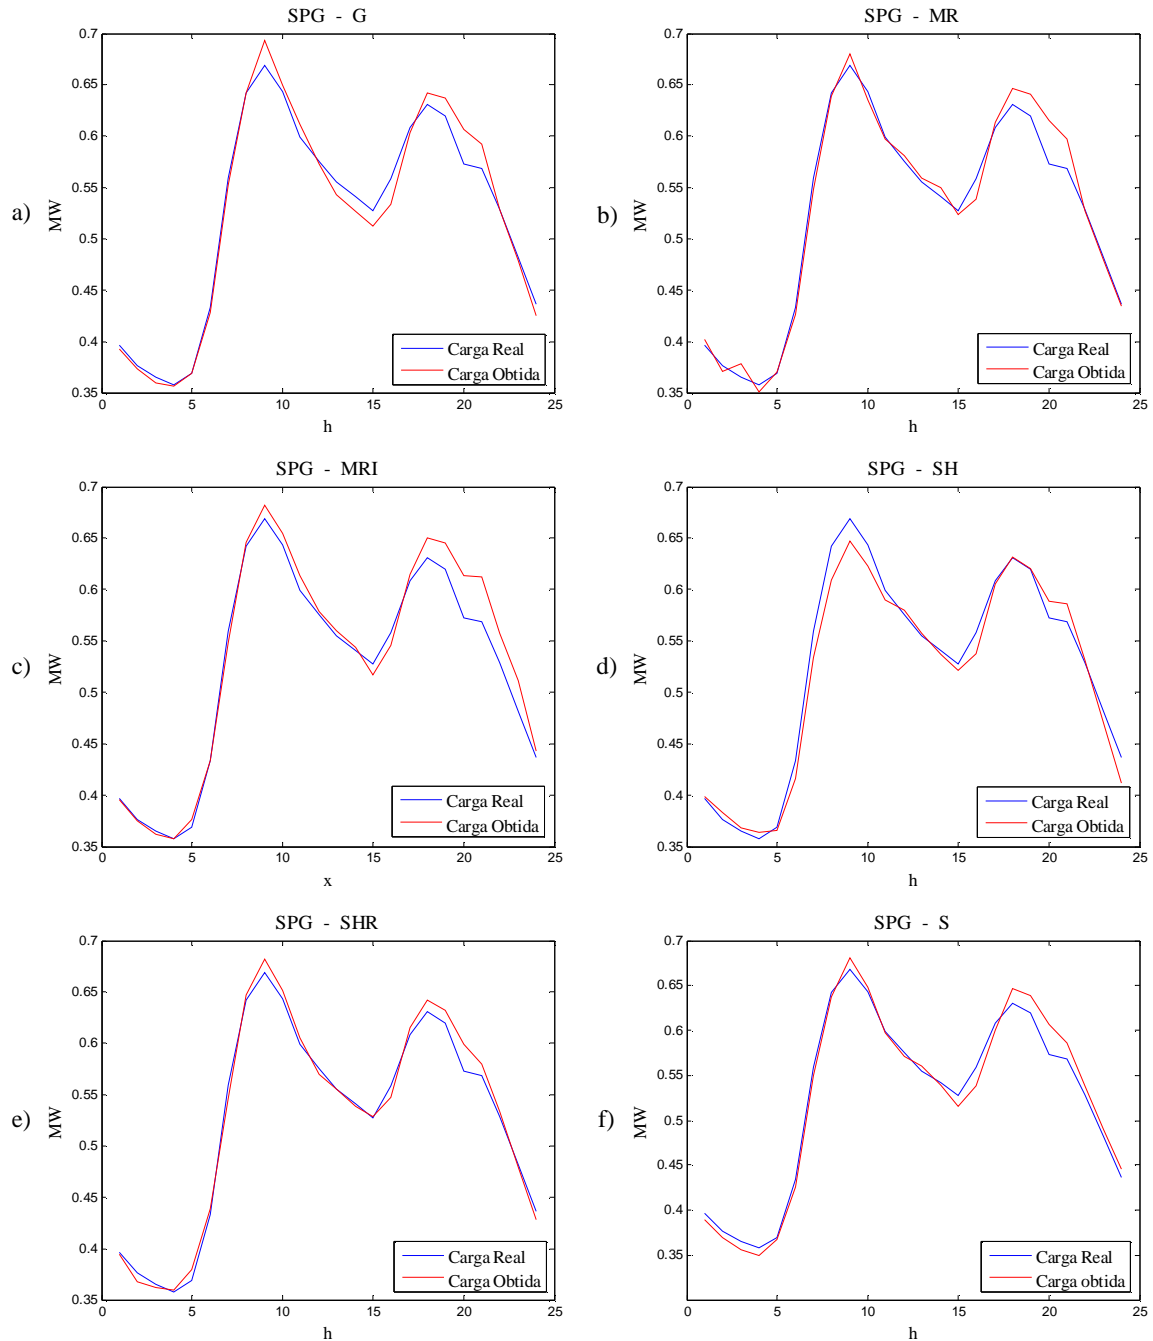


Figura 7.1 - Resultado para previsão de carga para o sistema predictor global utilizando as seis funções de ativação: a) gaussiana, b) multiquadrática recíproca, c) multiquadrática recíproca inversa, d) secante hiperbólica, e) secante hiperbólica recíproca e f) sigmoide.

A figura 7.1 apresenta os resultados de casa uma das funções para o sistema predictor global. Pode-se observar através dos gráficos, que a aproximação ocorreu de forma mui-

to parecida, apresentando um erro maior das 17 às 22 horas. Pode-se observar que o melhor resultado foi obtido pela função secante hiperbólica recíproca, conforme mostrado anteriormente na tabela 7.5.

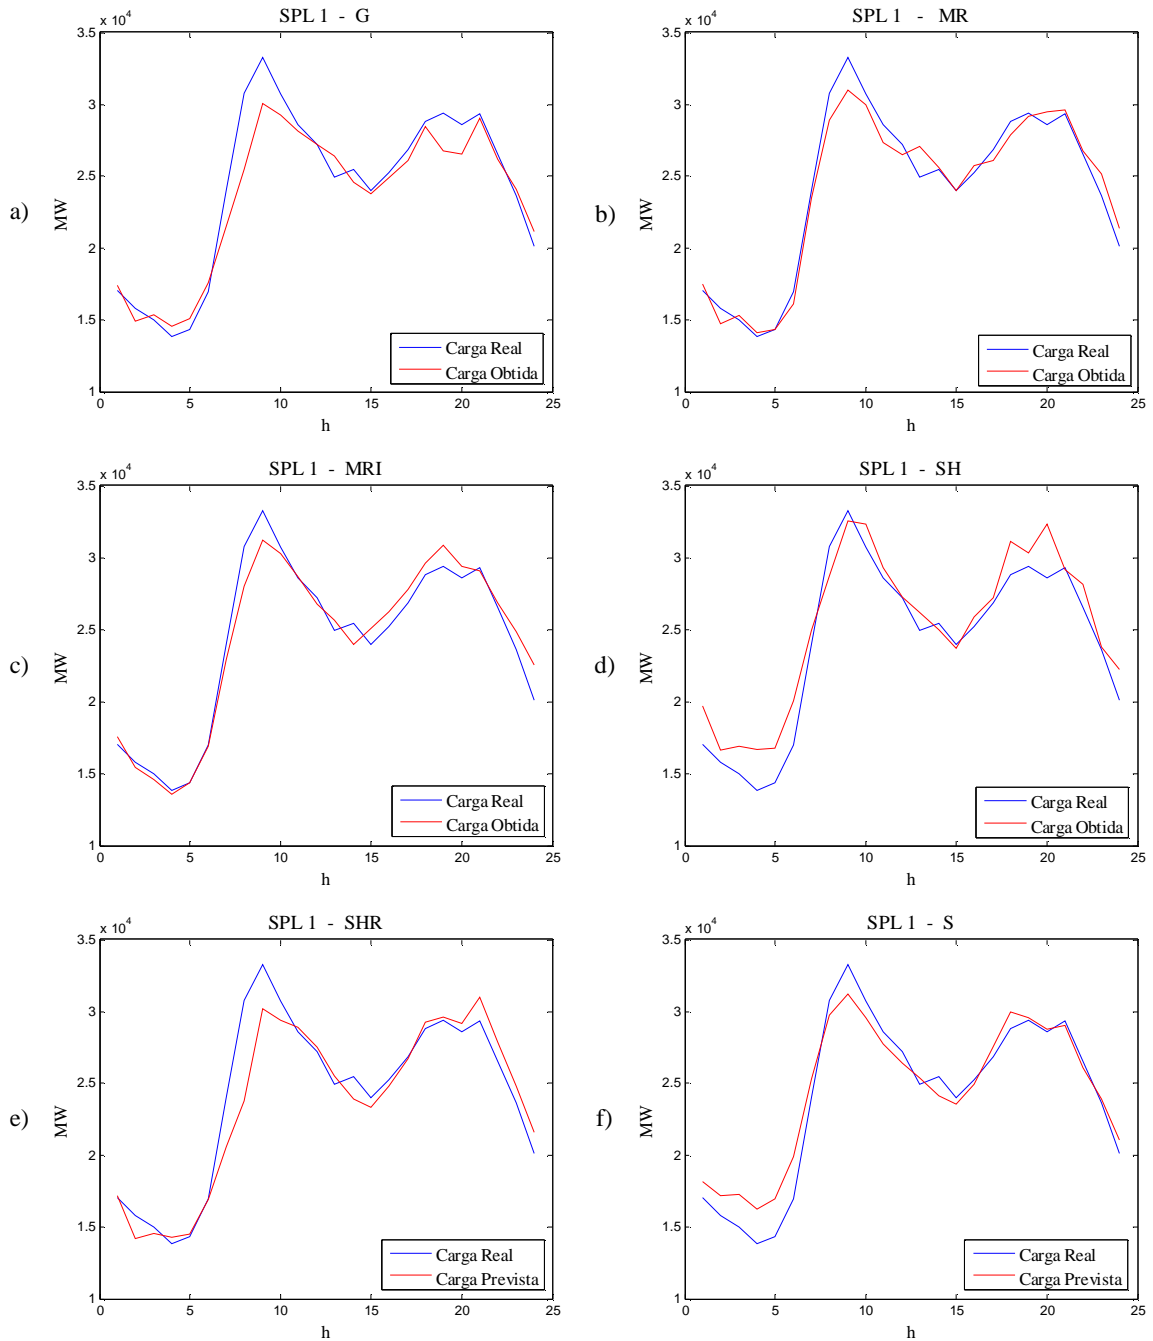


Figura 7.2 - Resultado para previsão de carga para primeiro módulo do sistema predictor local utilizando as seis funções de ativação: a) gaussiana, b) multiquadrática recíproca, c) multiquadrática recíproca inversa, d) secante hiperbólica, e) secante hiperbólica recíproca e f) sigmoide.

A figura 7.2 representa os resultados obtidos para o primeiro módulo do sistema predictor local e pode-se observar que as melhores aproximações foram obtidas pelas funções multiquadrática recíproca e multiquadrática recíproca inversa, porém, segundo a tabela 7.6 a função multiquadrática recíproca apresentou melhor resultado.

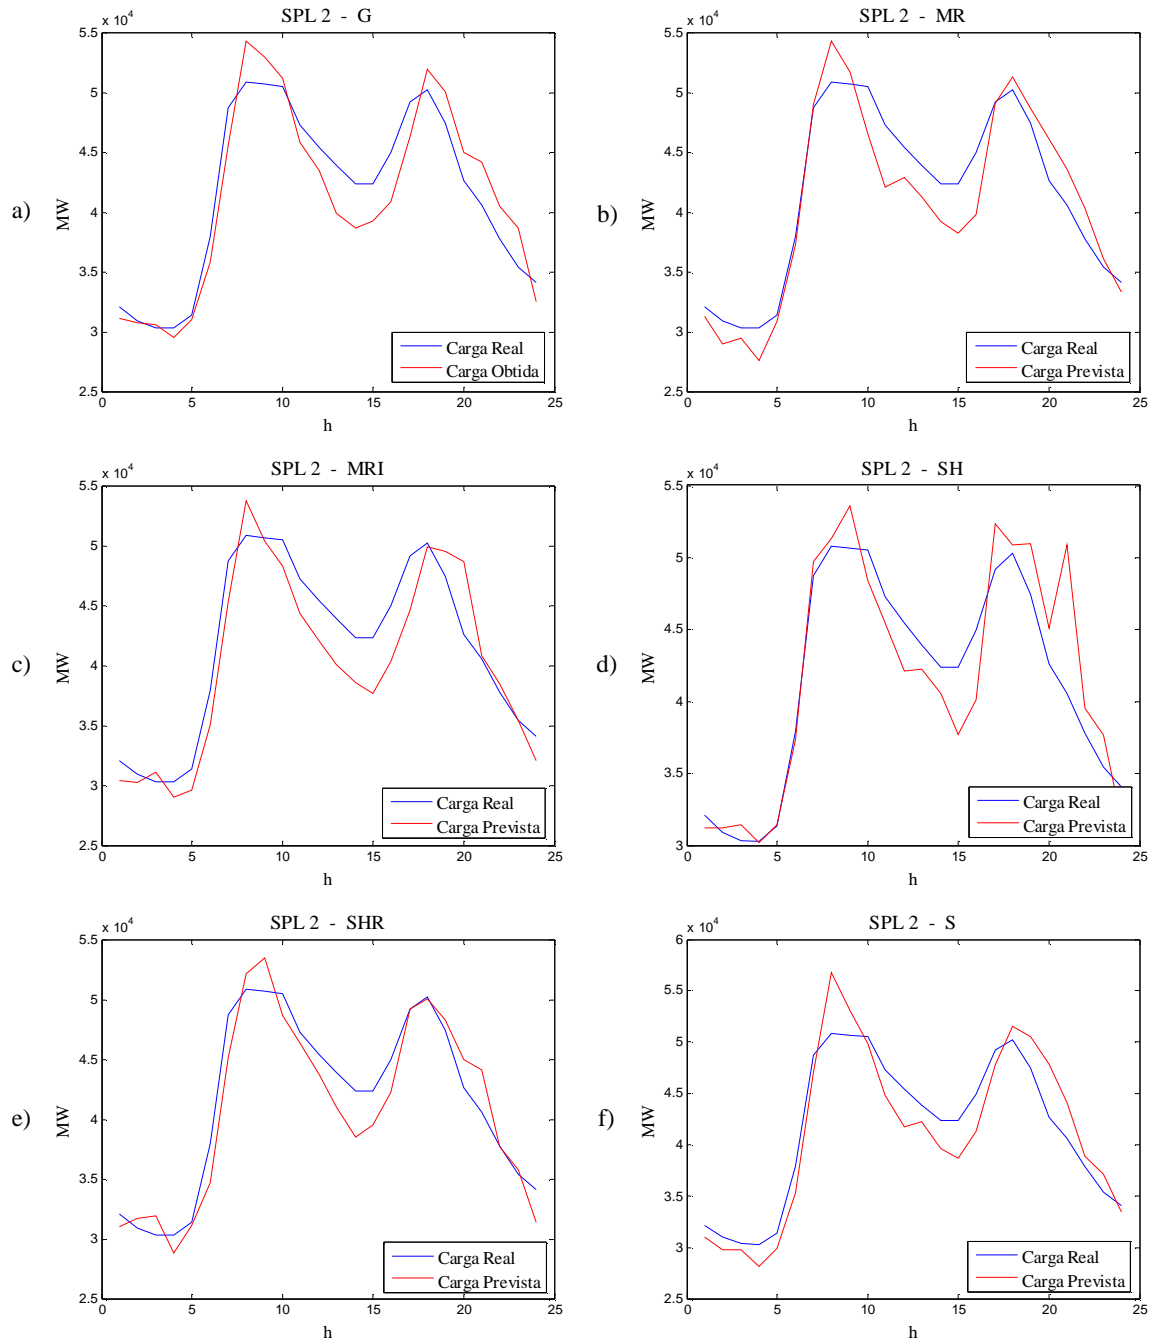


Figura 7.3 - Resultado para previsão de carga para segundo módulo do sistema predictor local utilizando as seis funções de ativação: a) gaussiana, b) multiquadrática recíproca, c) multiquadrática recíproca inversa, d) secante hiperbólica, e) secante hiperbólica recíproca e f) sigmoide.

A figura 7.3 representa os resultados obtidos para o segundo módulo do sistema predictor local. Para este módulo, a aproximação não foi tão eficiente como para o primeiro módulo, em razão de seus dados locais, e o melhor resultado foi obtido pela função secante hiperbólica recíproca.

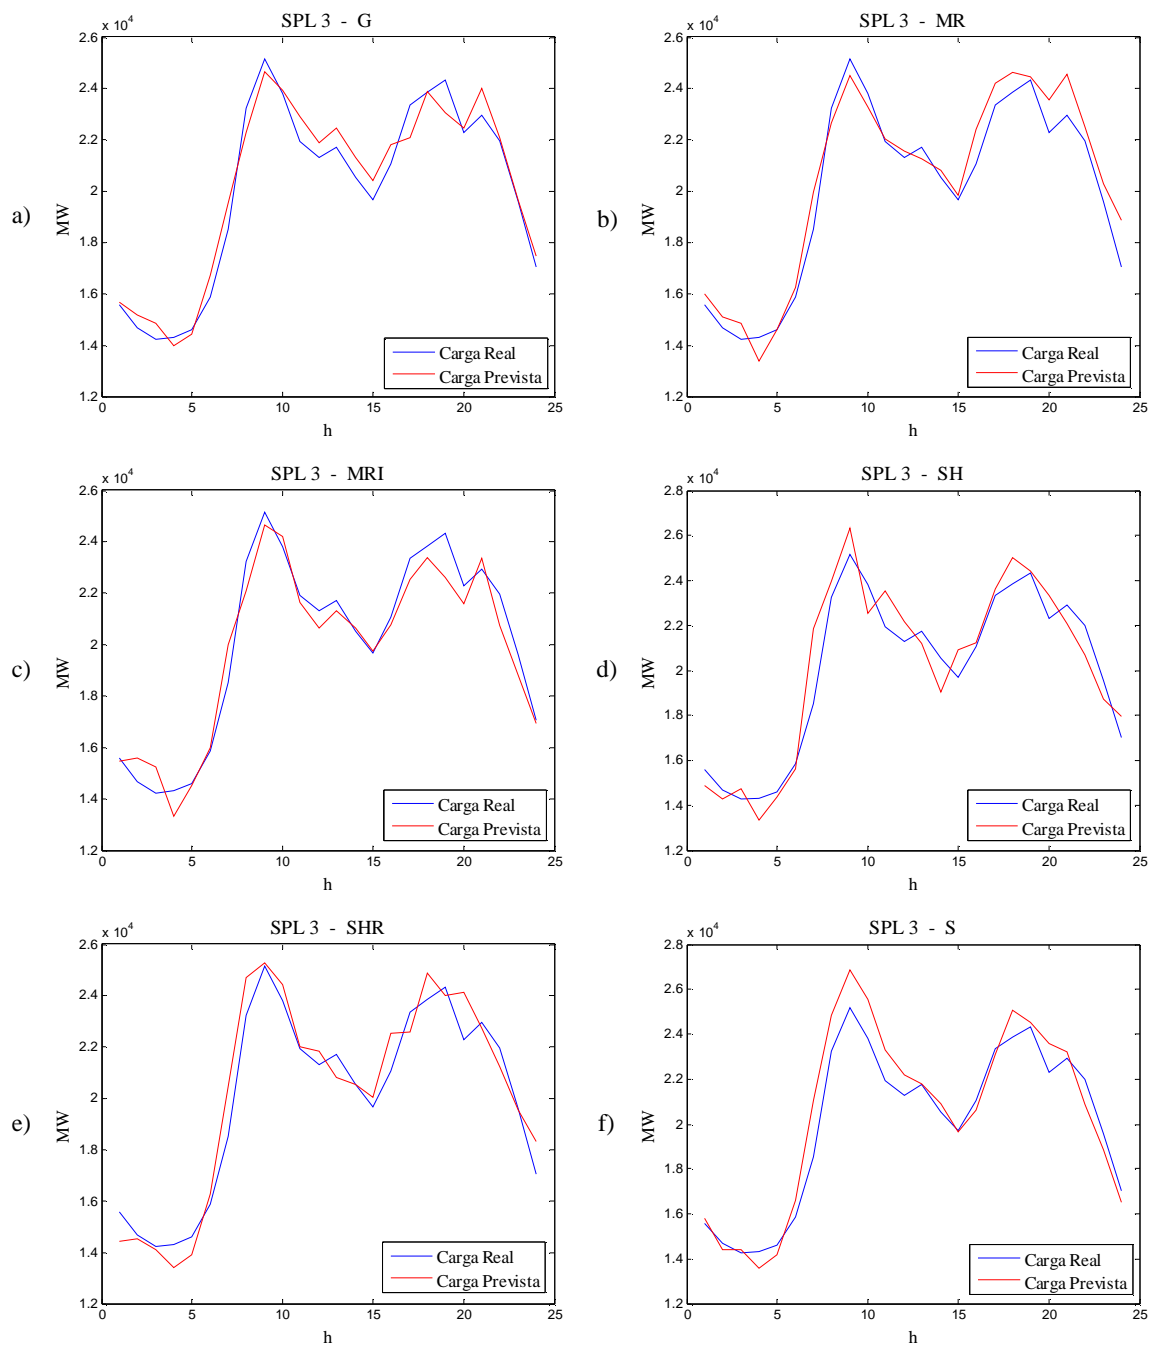


Figura 7.4 - Resultado para previsão de carga para terceiro módulo do sistema predictor local utilizando as seis funções de ativação: a) gaussiana, b) multiquadrática recíproca, c) multiquadrática recíproca inversa, d) secante hiperbólica, e) secante hiperbólica recíproca e f) sigmoide.

A figuras 7.4 representa os resultados obtidos para o terceiro módulo do sistema previsor local que em comparação com os demais foi o que obteve maior precisão na aproximação, e a melhor delas, foi obtida pela função gaussiana.

7.4 – Conclusão

Neste capítulo foram apresentados os resultados da previsão de carga multinodal realizada considerando os dados históricos de uma companhia do setor elétrico de Nova Zelândia.

A previsão multinodal foi desenvolvida considerando dois sistemas previsores, o sistema previsor global e o sistema previsor local, composto por três módulos. O sistema previsor local é responsável por realizar a previsão por barramento considerando a participação do sistema global.

Através de um grande número de testes realizados, percebeu-se que por menor que seja a variação dos parâmetros, sua ocorrência influencia drasticamente nos resultados, podendo chegar a erros absurdos, que podem ser contornados utilizando métodos determinísticos para a adaptação destes parâmetros. Observou-se, ainda, que os valores dos parâmetros usados para o treinamento, relativos aos melhores resultados, para as seis funções, permaneceram no mesmo patamar para os sistemas global e local.

Foi possível observar que a utilização de técnicas baseadas em inteligência artificial, neste caso, redes neurais artificiais, fornece resultados mais precisos se comparado aos métodos estatísticos encontrados na literatura que apresentam resultados de previsão com erro percentual absoluto médio em torno de 5%; melhor ainda, quando se trata da previsão multinodal.

O esquema previsor desenvolvido é capaz de realizar a previsão de cargas em vários pontos do sistema de energia elétrica em muito menos tempo, se comparado com a previsão realizada ponto a ponto (YALCINOZ ; EMINOGLU, 2005) e, mesmo ocorrendo alguma perda de precisão, a mesma não influencia nos bons resultados obtidos.

Conclusão

8.1 - Conclusão Geral

Muitos problemas em engenharia são dinâmicos e precisam de ferramentas capazes de modelá-los. Este trabalho teve como objetivo o desenvolvimento de uma metodologia para a previsão de cargas elétricas, via redes neurais artificiais, utilizando o algoritmo retropropagação como algoritmo de treinamento e funções de base radial como função de ativação.

A utilização de técnicas inteligentes, como redes neurais artificiais, tem se mostrado bastante eficaz para resolução de problemas de previsão de cargas elétricas; além das redes neurais artificiais serem consideradas como aproximador universal, apresentam grande habilidade de aprendizado e capacidade de generalização; qualidades que as tornam capazes de identificar e assimilar características marcantes das séries temporais, sem necessidade de uma trabalhosa formulação teórica, e modelagem prévia da carga, como exigem os procedimentos estatísticos encontrados na literatura.

Dessa forma, neste trabalho foi apresentado o desenvolvimento de uma metodologia que faz uso de redes neurais artificiais, para resolução do problema de previsão de carga multinodal, conforme procedimento descrito no capítulo 3.

A arquitetura apresentada se baseia na rede *perceptron* multicamadas, que utilizam o algoritmo retropropagação como algoritmo de treinamento, porém, foi realizada uma modificação nesta arquitetura, a função de ativação usual, função sigmoide, foi substituída por uma classe de funções que apresentam comportamento bastante diferenciado, as funções de base radial.

Não foram encontradas na literatura especializada aplicações utilizando o *perceptron* com essa modificação, pois, o que é tratado como rede de base radial, são as arquiteturas específicas, tais como, RBFN (*Radial Basis Function Network*) (POWELL, 1985) e GRNN (*Generalized Regression Neural Network*) (SPECHT, 1991) que, em geral, tem um desempenho melhor que as redes baseadas no algoritmo retropropagação, pois, o treinamento destas redes geralmente ocorre através de um único processo iterativo, e utilizam função gaussiana apenas na camada de entrada, nas demais camadas fazem uso de funções lineares, ao passo que as redes *perceptron* com algoritmo retropropagação necessitam de muitas, algumas vezes, milhares de iterações para chegar à convergência e, neste caso, todas as camadas fazem uso da função de base radial.

A principal contribuição desta pesquisa refere-se ao desenvolvimento de um sistema para previsão de carga considerando vários pontos da rede elétrica, a previsão multinodal. Via de regra, a previsão em vários pontos do sistema de energia elétrica, em geral, a previsão dos sistemas de distribuição (YALCINOZ ; EMINOGLU, 2005), pode ser realizada uma a uma, o que demanda muito tempo devido a manipulação e o processamento de diversos dados, já o sistema predictor desenvolvido é capaz de realizar a previsão em vários pontos da rede com o tempo de processamento muito próximo ao tempo de uma previsão convencional (previsão global), pois, para a previsão modular realizada, é utilizada como entrada dos módulos a saída da previsão global, o que diminui o esforço computacional e a quantidade de dados a serem manipulados.

Desta forma, pode-se afirmar que o sistema desenvolvido nesta pesquisa, é capaz de realizar a previsão de cargas em vários pontos do sistema de energia elétrica em muito menos tempo do que realizar a previsão de cada carga uma a uma, como se encontra na literatura, com pouca perda na precisão dos resultados e, mesmo ocorrendo estas perdas, as mesmas não impossibilitam validar a metodologia desenvolvida como um bom sistema de previsão de cargas multinodal.

8.2 - Sugestões para Trabalhos Futuros

É fato que a metodologia desenvolvida aqui pode ser melhorada em alguns aspectos, principalmente, em relação à arquitetura utilizada.

Pode-se dizer que com essa pesquisa, o *perceptron* multicamadas, com algoritmo retropropagação, foi explorado ao máximo. Porém, podem ser obtidos melhores resultados

para esta mesma metodologia se for utilizado um processo determinístico para estimar os parâmetros, pois, nesta pesquisa a escolha dos parâmetros utilizados para gerar o melhor resultado foi feita através de testes considerando as respostas obtidas.

Por outro lado, é possível obter melhores resultados aumentando a quantidade de dados utilizados no treinamento da rede, pois, foram nesta aplicação foram utilizados apenas 360 padrões, relativos a 15 dias, pois, como o objetivo era comprovar a eficácia da metodologia desenvolvida, não houve grande preocupação no tratamento dos dados utilizados, o que pode vir a ser realizado posteriormente.

Agora, como observado anteriormente, existem algumas desvantagens da utilização do *perceptron* com algoritmo retropropagação, tanto para previsão global, quanto para previsão multinodal, pois, o algoritmo retropropagação, mesmo sendo um referencial em termos de precisão, apresenta um desempenho muito baixo quando se refere ao tempo de treinamento, deste modo, uma forma de contribuir para melhoria da metodologia desenvolvida é a utilização de arquiteturas capazes de proporcionar resultados confiáveis e de alta velocidade de resolução como, por exemplo, as redes ART (*Adaptive Resonance Theory*) (CARPENTER, GROSSBERG ; REYNOLDS, 1991; WEENINK, 1997) que, segundo a literatura especializada pode chegar a ser cem vezes mais rápida que as demais arquiteturas.

Visando melhorar os resultados, propor e investigar outras estratégias locais baseadas, por exemplo, rede neural, lógica *fuzzy*, multiagente, fusão de dados (MITCHELL, 2007), entre outras técnicas, principalmente, com vistas ao avanço e maior disponibilidade de novas tecnologias da informação.

E ainda, usar o sistema previsor proposto (previsão multinodal) para estudar e melhorar caracterizar as diversas classes de consumidores: residencial, comercial, industrial, composição híbrida, ou seja, o comportamento dinâmico de tais classes.

Referências Bibliográficas

AL-KANDARI, A. M.; SOLIMAN, S. A. ; EL-HAWARY, M. E. Fuzzy short-term electric load forecasting. **Electrical Power & Energy Systems**, Guildford, v.26, n.2, p. 111-122, 2004.

ALTRAN, A. B.; MINUSSI, C. R.; VILLARREAL, F. Previsão de cargas elétricas usando redes neurais artificiais com função de base radial. In: CONGRESSO TEMÁTICO DE DINÂMICA CONTROLE E APLICAÇÕES, DINCON, 7, 2008, Presidente Prudente. **Anais...** Presidente Prudente: Unesp/FCT, 2008. p. 880-889.

ALTRAN, A. B.; LOTUFO, A. D. P.; LOPES, M. L. M. ; MINUSSI, C. R. Previsão de carga multinodal em sistemas elétricos de potência usando uma rede neural de base radial. In: LATIN-AMERICAN CONGRESS ON ELECTRICITY GENERATION AND TRANSMISSION, 8, 2009, Ubatuba. **Proceedings of the...** Ubatuba: [S.n.], 2009. p.18-22.

ALTRAN, A. B. **Aplicação de funções de base radial em problemas de previsão de cargas elétricas via redes neurais artificiais.** 2005. 95 f. Dissertação (Mestrado), - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

ASTORINO, M.; RIMONDO, R. **Interpolazione di curve e superfici tramite funzione implicite e loro triangolazione.** 2004. 75 f. Tesi (Tesi de Laurea di primo livello) - Facolta di Ingegneria dei Sistemi, Politecnico di Milano, Milano, 2004.

- BECKERT, A.; WENDLAND, H. Multivariate interpolation in fluid-structure-interaction using radial basis functions. **Aerospace Science and Technology**, Paris, v.5, p. 125-134, 2001.
- BENDER, E. A. **Mathematical methods in artificial intelligence**. Los Alamitos: IEEE Computer Society Press, 1996.
- BOX, G. E.; JENKINS, G. M. **Times series analysis: forecasting and control**. San Francisco: Holden-Day, 1976. 575p.
- BUHMANN, M. D. Radial basis function. **Acta Numerica**, Cambridge, v.9, p. 1-38, 2000.
- BUNN, D. W. ; FARMER, E. D. **Comparative models for electrical load forecasting**. Belfast: Wiley, 1985. 232p.
- CARPENTER, G. A.; GROSSBERG, S. ; REYNOLDS, J.H. ARTMAP: supervised real-learning and classification of non-stationary data by a self-organizing neural network. **Neural Network**, New York, v.14, n.5, p. 565-588, 1991.
- CHANDRASHEKARA, A. S.; ANANTHAPADMANABHA, T. ; KULKARNI, A. D. A neuro-expert system for planning and load forecasting of distribution system. **International Journal of Electrical Power & Energy Systems**, Oxford, v.21, n.5, p. 309-314, 1999.
- CHEN, T.; CHEN, H. **Approximation capability to functions of several variables, nonlinear functional and operators by radial basis function neural networks**. IEEE Transactions on Neural Networks, **New York**, v.6, n.4, p. 1439 – 1442, 1995.
- CHUI, C. C.; COOK, D. F.; KAO, J. L. ; CHOU, Y. C. Combining a neural network and a rule-based expert system for short-term load forecasting. **Computers & Industrial Engineering**, New York, v.32, n.4, p. 787-797, 1997.
- CYBENKO, G. Approximation by superpositions of sigmoidal function. **Mathematics of Control Signals, and Systems**, New York, v.2, p. 303-314, 1989.
- DJUKANOVIC, M.; RUZIC, S.; BABIC, B.; SOBAJIC, D. J.; PAO, Y.H. A neural-net based short term load forecasting using moving window procedure. **Electrical Power & Energy Systems**, Guildford, v.17, n.6, p. 391-397, 1995.

- DUNIN-KEPLICZ, B. M.; VERBRUGGE, R. **Teamwork in multi-agent systems: a formal approach**. New York: Willey, 2010. 244p. (Series in Agent Technology).
- FINE, T. L. **Feedforward neural network methodology**. New York: Springer-Verlag, 1999. 340p.
- FUKUSHIMA, K. ; MIYAKE, S.; ITO, T. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition unaffected by shift in position. **Biological Cybernetics**, New York, v.36, p. 193-202, 1980.
- GIROSI, F.; POGIO, T. Networks for learning: A view from the theory of approximation of functions. In: ANTOGNETTI, P.; MILUTINOVIC, V. (Ed.). **Neural Networks: concepts, applications and implementations**. Upper Saddle River: Prentice Hall, 1991. p. 110-154.
- GROSS, G. ; GALIANA, F. D. Short term load forecasting. **Proceedings of the IEEE**, New York, v.75, n.12, p. 1558-1573, 1987.
- GROSSBERG, S. Adaptive pattern classification and universal recoding I: Parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, n.3, p. 121-134, 1976.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. Upper Saddle River: Prentice-Hall, 1994. 768p.
- HEBB, D. O. **The organization of behavior: a neuropsychological theory**. New York: Wiley, 1949. 335p.
- HECHT-NIELSEN, R. Counterpropagation networks. **Proceedings of IEEE International Conference on Neural Networks**, New York, v.2, p. 19-32, 1987.
- HEIMES, F.; HEUVELN, B. V. The normalized radial basis function neural network. **IEEE International Conference on Systems, Man, and Cybernetics**, New York, v.2, p. 1609 – 1614, 1998.
- HIPPERT, H. S.; PEDREIRA, C. E. ; SOUZA, R. C. Neural networks for short term load forecasting: Are view and evaluation. **IEEE Transactions on Power Systems**, New York, v.16, n.1, p. 44-55, 2001.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences**, New York, v. 79, p. 2554-2558, 1982.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic: basic concepts and applications**. Piscataway: IEEE Press, 1996. 232p.

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

KOHONEN, T. Correlation matrix memories. **IEEE Transactions on Computers**, New York, v.21, p. 353-359, 1972.

KOSKO, B. Bidirectional associative memories. **IEEE Transactions on Systems, Man and Cybernetics**, New York, v.18, n.1, p. 49-60, 1988.

KROSE, B.; SMAGT, P. V. **An introduction to neural networks**. Amsterdam: University of Amsterdam, 1996. 135p.

LIAO, G.-C. ; TSAO, T.-P. Application of fuzzy neural networks and artificial intelligence for load forecasting. **Electric Power Systems Research**, Lausanne, v.70, n.3, p. 237-244, 2004.

LOPES, M.L.M.; LOTUFO, A.D.P.; MINUSSI, C.R.; Application of the fuzzy ART&ARTMAP neural network to the electrical load forecasting problem. In: ZHU, J.J.; FUNG, G.P.C. (Org.). **Forecasting models: methods and applications**, iConcept Press Pty Ltd., 2010, v.1, pp. 179-190.

LOPES, M.L.M.; MINUSSI, C.R.; LOTUFO, A.D.P. Electric load forecasting using a fuzzy ART&ARTMAP neural network. **Applied Soft Computing**, v.5, n.2, p. 235-244, 2005. Disponível em: <http://www.sciencedirect.com/science?_ob=MIImg&_imagekey=B6W86-4DCMC1D-3-1&_cdi=6646&_user=972052&_pii=S1568494604000717&_origin=search&_coverDate=01%2F01%2F2005&_sk=999949997&view=c&wchp=dGLzVlb-zSkzk&md5=a1fbdd9fc317dd31a8a1678947c9437b&ie=/sdarticle.pdf>. Acesso em: 20 jun. 2010.

- LOPES, M. L. M.; MINUSSI, C. R. ; LOTUFO, A. P. Electrical load forecasting formulation by a fast neural network. **Engineering Intelligent Systems for Electrical Engineering and Communications**, London, v.11, n.1, p. 51-57, 2003.
- LOPES, M. L. M.; MINUSSI, C. R. Treinamento de redes neurais via Back-Propagation com controlador nebuloso. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 18, 2000, Florianópolis. **Anais...** Florianópolis: Ed. UFSC, 2000. p. 1616 – 1621.
- MACHADO, R. J.; ROCHA, A. F. **Handling knowledge in high order neural networks: the combinatorial neural network**. Rio de Janeiro: IBM Rio Scientific Center, 1989 (Technical Report, CCR076).
- MAI-DUY, N.; TRAN-CONG, T. Approximation of function and its derivatives using radial basis function networks. **Applied Mathematical Modelling**, Guildford, v.27, p. 197-220, 2003.
- MALKI, H. A.; KARAYIANNIS, N. B.; BALASUBRAMANIAN, M. Short-term electric power load forecasting using feedforward neural networks. **Expert Systems**, New York, v.21, n.3, p. 157-167, 2004.
- MARK, J. L. O. **Introduction to Radial Basis Function Network**. Edinburgh: Centre For Cognitive Science, University of Edinburgh, 1996.
- MCCULLOCH, W. S.; PITTS, W. A. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, New York, v.5, p. 115-133, 1943.
- McNEIL, F. M.; THRO, E. **Fuzzy logic: a practical approach**. New York: Academic Press, 1994. 294p.
- MENDES FILHO, E. F. ; CARVALHO, A. C. P. L. Evolutionary design of MLP neural network architectures. SIMPÓSIO BRASILEIRO DE REDES NEURAIS, 4, 1997, Campos do Jordão. **Anais...** - São Paulo: SBRN, 1997. p. 58-65.
- METAXIOTIS, K.; KAGIANNAS, A.; ASKOUNIS, D.; PSARRAS, J. Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher. **Energy Conversion and Management**, Oxford, v.44, n.9, p. 1525-1534, 2003.

- MICCHELLI, C. A. Interpolation of scatter data: Distance matrices and conditionally positive definite functions. **Constructive Approximation**, New York, v.2, p. 11 – 22, 1986.
- MINSK, M.; PAPERT, S. **Perceptrons**. Cambridge, MA: MIT Press, 1969.
- MITCHELL, H. B. **Multi-sensor data fusion: an introduction**. New York: Springer, 2007. 282p.
- MOGHRAM, I. ;RAHMAN, S. Analysis and evaluation of five short-term load forecasting techniques. **IEEE Transactions on Power Systems**, New York, v.4, n.4, p.1484-1491, 1989.
- MULGREW, B. Applying radial basis function. **IEEE Signal Processing Magazine**, New York, v.13, n.2, p. 50 – 65, 1996.
- MURTO, P. **Neural network models for short-term load forecasting**. 1998. Thesis (Masters) - Department of Engineering Physics and Mathematics, Helsinki University of Technology, Helsinki, 1998.
- O'DONOVAN, T. M. **Short term forecasting: an introduction to the Box-Jenkins approach**. New York: John Wiley & Sons, 1983.
- PANDIAN, S. C.; DURAISWAMY, K.; RAJAN, C. C. A.; KANAGARAJ, N. Fuzzy approach for short term load forecasting. **Electric Power Systems Research**, Lausanne, v.76, n.6/7, p. 541-548, 2006.
- PARK, D. C.; EL-SHARKAWI, M. A. ;MARK II, R. J. Electric load forecasting an artificial neural network. **IEEE Transactions on Power Systems**, New York, v.6, n.2, p. 442-449, 1991.
- POGGIO, T.; GIROSI, F. Networks for approximation and learning. **Proceedings of the IEEE**, New York, v.78, n.9, p.1481-1497, 1990.
- POWELL, M. J. D. Radial basis functions for multivariable interpolation. In: CONFERENCE ON ALGORITHMS FOR THE APPROXIMATION OF FUNCTIONS AND DATA, RCMS, 1985, Shrivenham. **Proceedings of the...** Shrivenham: S.n., 1985. p.143-167, 1985.

- POWELL, M. J. D. **Radial basis function methods for interpolation to functions of many variables**. Cambridge: University of Cambridge, 2001. (NA 2001/11, Numerical Analysis Group, 2001).
- RANAWEERA, K. D.; KARADY, G. G.; FARNER, G. R. Economic impact analysis of load forecasting. **IEEE Transactions on Power Systems**, New York, v.12, n.3 , p. 1388-1392, 1997.
- ROSENBLATT, F. **Principles of neurodynamics**. New York: Spartan Books, 1962.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v.65, p. 386-408, 1958.
- RUMELHART, D. E.; HILTON, G. E.; WILLIAMS, R. J. Learning representations of Back-propagation errors. **Nature**, London, v.323, n.9, p. 533-536, 1986.
- SAINI, L. M.; SONI, M. K. Artificial neural network based peak load forecasting using Levenberg-Marquardt and Quasi-Newton methods. **IEEE Proceedings on Generation, Transmission & Distribution**, New York, v.149, n.5, p. 578- 584, 2002.
- SFETSOS, A. Short-term load forecasting with a hybrid clustering algorithm. **IEE Proceedings Generation, Transmission, and Distribution**, New York, v.150, n.3, p. 257-262, 2003.
- SIMPSON, P. K. **Artificial neural systems: foundations, paradigms, applications, and implementations**. New York: Pergamon Press, 1989.
- SKARMAN, S. E.; GEORGIPOULOS, M. ; GONZALEZ, A. J. Short-term electrical load forecasting using a fuzzy ARTMAP neural network. **Proceedings of the International Society for Optical Engineering**, New York, v.3390, p. 181-191, 1998.
- SOUZA, R. C. Modelos estruturais para previsão de séries temporais: abordagem clássica e bayesiana. In: COLÓQUIO BRASILEIRO DE MATEMÁTICA, 17, 1989, Rio de Janeiro. **Anais...** Rio de Janeiro: IMPA, 1989, 171p.
- SPECHT, F. D. A general regression neural network. **IEEE Transaction on Neural Network**, New York, v.2, n.6, p. 568 – 576, 1991.

SRINIVASAN, D.; TAN, S. S.; CHANG, C. S.; CHAN, E. K. Practical implementation of a hybrid fuzzy neural network for one-day-ahead load forecasting. **IEE Proceedings Generation, Transmission and Distribution**, New York, v.145, n.6, p. 687 – 692, 1998.

SWARUP, K. S. ; SATISH, B. Integrated ANN approach to forecast load. **IEEE Computer Applications in Power**, New York, v.15, n.1, p. 46-51, 2002.

TELBANY, M. E.; KARMI, F. E. Short-term forecasting of Jordanian electricity demand using particle swarm optimization. **Electric Power Systems Research**, Lausanne, v.78, n.3, p. 425-433, 2008.

TERANO, T.; ASAI, K. ;SUGENO, M. **Fuzzy systems theory and its applications**. Boston: Academic Press, 1991. 268p.

VEHVILÄINEN, I. ; KEPPO, J. Managing electricity market price risk. **European Journal of Operational Research**, Amsterdam, v.145, n.1, p. 136-147, 2003.

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

VON NEUMANN, J. **The computer and the brain**. New Haven: Yale University Press, 1958.

WANG, X.; HATZIARGYRIOU, N. ; TSOUKALAS, L. H. A new methodology for nodal load forecasting in deregulated power systems. **IEEE Power Engineering Review**, New York, v.22, n.5, p. 48-51, 2002.

WASSERMAN, P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 1989. 240p.

WEENINK, D. **Category ART: a variation on adaptive resonance theory neural networks**. p.117-129, 1997. (Institute of Phonetic Sciences – University of Amsterdam, Ifa Proceedings, 21). Disponível em: <<http://www.fon.hum.uva.nl/Proceedings/Proceedings21/DavidWeenink/DavidWeenink.html>>. Acesso em: 20 jun. 2010.

WENDLAND, H. On the smoothness of positive definite and radial functions. **Journal of Computational and Applied Mathematics**, Antwerpen, v.101, n.1, p. 177-188, 1999.

- WENDLAND, H.; SCHABACK, R. **Characterization and construction of radial basis functions**: multivariate approximation and applications. Cambridge: Cambridge University Press, 2001. Disponível em: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.34.8426>. Acesso em: 20 jun. 2010.
- WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. 1974. (Thesis) - Harvard University, Harvard, 1974.
- WHEELWRIGHT, S. C.; MAKRIDAKIS, S. **Forecasting methods for management**. 4.ed. New York: John Wiley & Sons Inc, 1985.
- WIDROW, B.; LEHR, M. A. 30 years of adaptative neural networks: Perceptron, madaline and backpropagation. **Proceedings of the IEEE**, New York, v.78, n.9, p. 1415-1442, 1990.
- WIDROW, B.; HOFF, M. E. **Adaptative switching circuits**. New York: IRE, 1960. Part 4, p. 96-104. (IRE WESCON Convention Record)
- YALCINOZ, T.;EMINOGLU, U. Short term and medium term power distribution load forecasting by neural networks. **Energy Conversion and Management**, Oxford, v.46, p. 1393-1405, 2005.
- YUN, Z.; QUAN, Z.; CAIXIN, S.; SHAOLAN, L.; YUMING, L.; YANG, S. RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment. **IEEE Transactions on Power Systems**, New York, v.23, n.3, p. 853- 858, 2008.
- ZADEH, L. Fuzzy sets. **Information and Control**, New York, v.8, p. 338-353, 1965.

APÊNDICE A

Dados Históricos de Carga

Este apêndice apresenta os arquivos de dados históricos de cargas elétricas fornecidos por uma companhia do setor elétrico da Nova Zelândia (*Electricity Commission* da Nova Zelândia), utilizados para realizar o treinamento da arquitetura da rede neural proposta.

Foram considerados os dados das cargas horárias de 15 dias, compreendidos entre os dias 15 e 29 do mês de outubro do ano de 2007, num total de 360 valores de entrada cada. O apêndice A1 corresponde aos dados de carga global e os apêndices A2, A3 e A4 correspondem aos dados de carga local (três subestações), relativos aos 15 dias.

A1 – Sistema Previsor Global

Dados de Potência Ativa em MW

Hora	Dias																							
	15/10	16/10	17/10	18/10	19/10	20/10	21/10	22/10	23/10	24/10	25/10	26/10	27/10	28/10	29/10	30/10								
01	60360	65244	64702	66986	69042	71376	70824	65020	59900	66864	64584	61982	65936	62554	60918	64748								
02	57670	62166	60912	63794	66154	66668	65184	61234	57088	64542	62114	59182	60876	59296	57144	61464								
03	56378	60580	59970	61100	65020	64224	63746	59756	56288	62324	60878	58494	59186	58336	56724	59592								
04	56128	59432	58472	59788	63284	63438	61334	59120	56946	60948	58610	58242	59010	57946	56364	58464								
05	57920	60802	59874	61176	61638	64866	61972	58868	58952	62278	59434	59030	59312	57958	57188	60300								
06	68182	70868	69584	71482	69992	73344	69608	66312	69490	72698	69614	69662	66534	65282	66768	70778								
07	88288	91250	91262	91782	92054	88362	84096	81556	90462	91750	90384	88764	82234	79020	88052	91248								
08	105480	104978	105748	105188	107450	101420	96036	90614	105872	105142	105708	104236	91870	87480	104484	104822								
09	112560	111078	109412	110518	114292	112488	107728	101554	112056	109718	109932	108716	96750	93712	110148	109114								
10	107506	103638	104920	106782	110442	110238	106358	107004	107186	100422	103578	107034	95080	94126	101554	105014								
11	98882	97036	100570	102006	102772	104854	105158	105812	98940	93608	97596	99042	90318	90144	96036	97812								
12	95002	92644	94440	94814	95724	95656	96604	99256	94574	92244	94006	95314	85792	78182	92292	93940								
13	91474	90100	91058	95206	91824	90496	90866	95916	91602	91946	90950	94612	82754	73100	88256	90600								
14	88226	86200	87522	91986	87752	87528	84860	89892	88906	88484	87906	90430	77504	68886	87838	88368								
15	87450	83194	86302	87664	86354	85418	80878	85488	86758	86072	85172	88058	75858	66420	85414	86056								
16	91508	87906	90806	92774	90016	89380	83476	87458	89350	89532	88990	90668	80106	70596	88386	91224								
17	104312	100566	100960	104728	100942	100110	94418	97122	99186	98474	98110	99144	90866	81498	99620	99378								
18	109462	106872	106220	110756	105538	111234	100724	102306	106276	104928	102426	102592	96458	99574	103892	102942								
19	107912	106114	105850	113356	104544	111140	102706	99416	106318	102392	100828	100390	93590	96672	104932	101194								
20	106062	103456	102246	111182	102040	108042	102548	93814	99672	100640	97664	94674	91162	91944	97114	93542								
21	102632	100066	98196	107230	107992	107196	104094	95828	98536	98686	97892	93714	90534	93244	96154	92840								
22	92022	89372	90498	97388	104066	104160	95998	88082	89620	87894	86860	87742	83756	85842	89086	86328								
23	81156	82238	81482	86506	93210	94458	84450	75662	81396	80140	76770	79122	76022	74844	80404	78650								
24	70868	71882	73050	76142	80724	82296	73302	66374	72672	70606	67818	71472	68660	66052	71128	71192								

A2 – Sistema Previsor Local – Módulo 1

Dados de Potência Ativa em MW

Hora	Dias																							
	15/10	16/10	17/10	18/10	19/10	20/10	21/10	22/10	23/10	24/10	25/10	26/10	27/10	28/10	29/10	30/10								
01	14674	16800	17110	17820	18316	20144	20596	17922	15296	17564	17492	16274	16608	15642	15390	17074								
02	13802	15474	15726	16454	16896	17712	17982	16358	14148	16466	16226	15570	14770	14400	14102	15844								
03	13408	15354	15438	15814	16238	16472	17134	15558	13778	15796	15570	14400	13826	13832	13958	15008								
04	13072	13898	13826	14602	14936	15992	15844	15296	13492	14484	14078	14578	13742	13158	13504	13874								
05	13414	14172	14148	14518	15414	16046	16034	14960	13658	14818	14268	17290	13814	13600	13898	14340								
06	16776	17026	17182	17314	17934	18088	17648	16502	16560	17660	17564	23344	15892	15534	16668	17014								
07	23606	23952	23726	24084	23844	22756	22088	20788	23774	24012	24920	29936	20652	19440	23630	24012								
08	30604	30450	30378	30820	31654	28752	27810	24742	30830	30676	31428	32970	24544	23082	29984	30784								
09	34188	33936	32730	33244	35166	34988	35334	31572	34080	33040	33650	31822	27966	26760	33208	33292								
10	31776	31428	31512	31752	33304	35990	36050	35882	32134	30850	31764	29316	28174	28468	30796	30700								
11	29840	29496	29338	30128	30736	33364	36324	35918	29566	28980	30462	28456	25954	27250	28510	28610								
12	29004	27428	27954	27882	28408	29722	32264	32360	27668	28312	29232	28910	24378	18544	27058	27214								
13	27392	26114	26748	28790	27620	28408	29948	30736	27250	27596	26844	26902	23194	15486	25380	24932								
14	26390	26096	26544	28838	26592	27810	27130	28384	26078	27226	26568	26234	21814	14328	26704	25482								
15	26032	25374	26044	26330	25924	26856	25160	26592	25374	25876	25232	25542	20764	13684	25420	24014								
16	26748	25732	26736	27356	26904	27572	25148	26640	25912	26318	25828	26306	21482	14424	25922	25254								
17	29052	27644	28336	29458	29100	30354	27602	28694	27166	28324	27058	27680	24514	16442	27200	26820								
18	32552	30462	31106	32862	30952	35084	30982	30080	30152	31452	29494	27732	26880	31142	29480	28826								
19	33328	31346	31058	34582	31692	36934	33352	29876	31130	30498	29542	27596	27482	29386	29826	29398								
20	31380	31728	31608	34092	32694	37400	34700	27966	30736	32014	29268	28420	27578	27692	29002	28608								
21	31632	30628	30592	33996	36528	37340	36372	29292	30986	31034	30080	26228	27674	28444	29564	29338								
22	27178	26520	26586	30186	34570	37064	32910	26402	27190	26808	26772	22640	24854	25578	27010	26556								
23	23870	24442	24186	26342	30150	34842	27572	21684	24216	24060	24348	19046	21822	21516	24108	23642								
24	19786	20024	20682	22042	24466	25636	22186	17660	20252	20228	20550	16274	18448	17516	20072	20108								

A3 – Sistema Previsor Local – Módulo 2

Dados de Potência Ativa em MW

Hora	Dias																							
	15/10	16/10	17/10	18/10	19/10	20/10	21/10	22/10	23/10	24/10	25/10	26/10	27/10	28/10	29/10	30/10								
01	30452	32502	31516	33166	33952	32614	29966	29904	28720	33196	31618	28174	32736	30406	29472	32076								
02	29370	31440	30076	31962	33178	31638	29292	28590	28118	32880	30922	27636	30556	29538	27952	30940								
03	28530	30414	29824	30492	33172	30884	29514	28332	27994	31618	30570	28168	30222	29594	27982	30334								
04	28674	30658	29938	30592	32770	30998	28508	28218	29090	31632	29852	29200	30330	29832	28096	30284								
05	29980	31650	30778	31654	33314	32340	28936	28454	30700	32446	30620	29716	30370	29402	28354	31366								
06	35724	37596	36364	37958	38786	37654	34146	33324	37036	38858	36186	36402	34572	33596	34112	37908								
07	45874	47996	48134	48554	48714	45450	42302	42168	47468	48794	46492	46506	43452	41784	45364	48714								
08	51316	50998	51714	50932	51338	48010	45230	44998	50764	50914	51054	51054	46886	44948	50806	50794								
09	50768	50910	50788	51132	50930	48950	45214	45150	50888	50832	50932	50244	45968	45150	51018	50674								
10	49588	47224	50516	50264	50012	45888	42396	43344	48938	47694	47554	50696	43688	42518	45754	50494								
11	44612	44390	48350	48536	46870	42796	40876	41486	44962	42988	44710	46786	42002	40404	43918	47266								
12	42562	42792	44406	44040	43506	39648	38618	39980	43258	41164	42848	43852	39880	38352	42744	45430								
13	40980	41342	42096	42720	41150	37714	36688	39722	41364	41372	41912	42906	38546	37132	41436	43932								
14	39642	38904	39736	41020	39148	35928	34982	37836	40576	39284	40080	41802	36258	35174	40116	42354								
15	39400	37614	39126	39980	38208	35526	34250	36472	39850	38862	39514	40528	36064	33906	39252	42362								
16	42622	41070	42440	43616	40726	38840	36774	38862	41314	41536	41770	43376	38876	36932	42018	44922								
17	50494	49312	49340	50838	46952	44980	43646	45460	48134	47180	48164	49534	45008	44046	49842	49196								
18	50996	51050	50702	51234	48394	47350	44498	47804	50928	49416	49146	50298	46714	46198	50358	50258								
19	51032	49418	50064	50968	46184	45588	42656	45108	48912	46980	46816	47776	43186	44298	50458	47446								
20	49362	47632	46894	50078	42476	42042	40740	42190	44046	43696	44204	44204	40324	41550	45602	42620								
21	46320	45294	43860	47044	43150	40970	39256	41894	42602	42312	43036	41522	39084	40856	43860	40562								
22	42200	40762	41622	43258	41680	38094	36630	38682	40418	38796	37856	38660	36372	37978	40618	37806								
23	37434	37878	37548	39132	38532	34630	33690	33906	37394	36372	32542	35932	34042	33582	37018	35432								
24	33784	34386	34666	35940	35268	31732	31466	31252	34948	33030	29796	33980	32176	31180	33948	34048								

A4 – Sistema Previsor Local – Módulo 3

Dados de Potência Ativa em MW

Hora	Dias																							
	15/10	16/10	17/10	18/10	19/10	20/10	21/10	22/10	23/10	24/10	25/10	26/10	27/10	28/10	29/10	30/10								
01	15234	15942	16076	16000	16774	18618	20262	17194	15884	16104	15474	16172	16592	16506	16056	15598								
02	14498	15252	15110	15378	16080	17318	17910	16286	14822	15196	14966	15272	15550	15358	15090	14680								
03	14440	14812	14708	14794	15610	16868	17098	15866	14516	14910	14738	14756	15138	14910	14784	14250								
04	14382	14876	14708	14594	15578	16448	16982	15606	14364	14832	14680	14642	14938	14956	14764	14306								
05	14526	14980	14948	15004	12910	16480	17002	15454	14594	15014	14546	14736	15128	14956	14936	14594								
06	15682	16246	16038	16210	13272	17602	17814	16486	15894	16180	15864	15970	16070	16152	15988	15856								
07	18808	19302	19402	19144	19496	20156	19706	18600	19220	18944	18972	18914	18130	17796	19058	18522								
08	23560	23530	23656	23436	24458	24658	22996	20874	24278	23552	23226	23246	20440	19450	23694	23244								
09	27604	26232	25894	26142	28196	28550	27180	24832	27088	25846	25350	25502	22816	21802	25922	25148								
10	26142	24986	22892	24766	27126	28360	27912	27778	26114	21878	24260	24516	23218	23140	25004	23820								
11	24430	23150	22882	23342	25166	28694	27958	28408	24412	21640	22424	22940	22362	22490	23608	21936								
12	23436	22424	22080	22892	23810	26286	25722	26916	23648	22768	21926	23006	21534	21286	22490	21296								
13	23102	22644	22214	23696	23054	24374	24230	25458	22988	22978	22194	22796	21014	20482	21440	21736								
14	22194	21200	21242	22128	22012	23790	22748	23672	22252	21974	21258	21726	19432	19384	21018	20532								
15	22018	20206	21132	21354	22222	23036	21468	22424	21534	21334	20426	21296	19030	18830	20742	19680								
16	22138	21104	21630	21802	22386	22968	21554	21956	22124	21678	21392	21750	19748	19240	20446	21048								
17	24766	23610	23284	24432	24890	24776	23170	22968	23886	22970	22888	23304	21344	21010	22578	23362								
18	25914	25360	24412	26660	26192	28800	25244	24422	25196	24060	23786	24614	22864	22234	24054	23858								
19	23552	25350	24728	27806	26668	28618	26698	24432	26276	24914	24470	24882	22922	22988	24648	24350								
20	25320	24096	23744	27012	26870	28600	27108	23658	24890	24930	24192	22874	23260	22702	22510	22314								
21	24680	24144	23744	26190	28314	28886	28466	24642	24948	25340	24776	23772	23776	23944	22730	22940								
22	22644	22090	22290	23944	27816	29002	26458	22998	22012	22290	22232	22854	22530	22286	21458	21966								
23	19852	19918	19748	21032	24528	24986	23188	20072	19786	19708	19880	20550	20158	19746	19278	19576								
24	17298	17472	17702	18160	20990	24928	19650	17462	17472	17348	17472	18446	18036	17356	17108	17036								

Trabalhos Publicados

Neste apêndice são relacionados os artigos (*full papers*) que foram publicados ao longo do desenvolvimento desta pesquisa.

ALTRAN, A. B.; NOSE FILHO, K.; MINUSSI, C. R.; LOTUFO, A. D. P. “Previsão de carga multinodal em sistemas de energia elétrica usando redes neurais artificiais”, Congresso Brasileiro de Automática, Bonito – MS, 2010.

ALTRAN, A. B.; LOTUFO, A. D. P.; LOPES, M. L. M. and MINUSSI, C. R. “Previsão de carga multinodal em sistemas elétricos de potência usando uma rede neural de base radial” The 8th Latin-American Congress on Electricity Generation and Transmission, Ubatuba - São Paulo, pp. 18-22, 2009.

ALTRAN, A. B.; MINUSSI, C. R. “Formulação do problema de previsão de carga multinodal por Redes Neurais Artificiais”. II Simpósio Regional de Matemática e suas Aplicações de Ilha Solteira, Ilha Solteira – SP, 2009.

ALTRAN, A. B.; VILLARREAL, F.; MINUSSI, C. R. “Aproximação de funções na previsão de cargas elétricas”, 69^o Seminário Brasileiro de Análise - 69^o SBA, Florianópolis – SC, pp. 59-70, 2009.

ALTRAN, A. B.; MINUSSI, C. R.; VILLARREAL, F. “Aplicação das funções de base radial na resolução do problema de previsão de carga à curto-prazo via redes neurais artificiais”, IV Simpósio de Matemática – IV SMAT, Presidente Prudente – SP, 2009.

- ALTRAN, A. B.; MINUSSI, C. R.; VILLARREAL, F. “Análise de funções de base radial aplicadas à resolução de problemas de previsão de cargas elétricas utilizando redes neurais artificiais”, Congresso Nacional de Matemática Aplicada e Computacional - XXXI CNMAC, Belém – PA, 2008.
- ALTRAN, A. B.; MINUSSI, C. R.; VILLARREAL, F. “Previsão de cargas elétricas usando redes neurais artificiais com função de base radial”, 7º Congresso Temático de Dinâmica, Controle e aplicações - DINCON 2008, Presidente Prudente – SP, pp. 880 – 889, 2008.
- ALTRAN, A. B.; MINUSSI, C. R.; VILLARREAL, F. “Funções de base radial: Uma aplicação em previsão de cargas elétricas utilizando redes neurais”, 1º Encontro Regional de Matemática Aplicada e Computacional - ERMAC 2008, Bauru – SP, pp. 517 - 521, 2008.
- ALTRAN, A. B.; MINUSSI, C. R.; LOPES, M. L. M. “Introdução às redes neurais artificiais”, Simpósio Regional de Matemática e suas Aplicações de Ilha Solteira, Ilha Solteira – SP, pp. 151 - 154, 2007.
- ALTRAN, A. B.; MINUSSI, C. R.; LOPES, M. L. M.; VILLARREAL, F. “Análise de funções de base radial aplicadas à resolução de problemas de previsão de cargas elétricas utilizando redes neurais artificiais”, Simpósio Regional de Matemática e suas Aplicações de Ilha Solteira, Ilha Solteira – SP, pp. 155 – 158, 2007.
- ALTRAN, A. B.; MINUSSI, C. R.; LOPES, M. L. M. “Introdução à lógica nebulosa”, Simpósio Regional de Matemática e suas Aplicações de Ilha Solteira, Ilha Solteira – SP, pp. 159 - 162, 2007.
- ALTRAN, A. B.; MINUSSI, C. R.; LOPES, M. L. M. “Previsão de cargas elétricas por redes neurais baseadas na teoria da ressonância adaptativa”, Simpósio Regional de Matemática e suas Aplicações de Ilha Solteira, Ilha Solteira – SP, p. 121 - 126, 2007.
- ALTRAN, A. B.; MINUSSI, C. R.; VILLARREAL, F. “Aplicação de funções de base radial em problemas de previsão de cargas elétricas através de redes neurais artificiais”, Congresso Nacional de Matemática Aplicada e Computacional - XXIX CNMAC, Campinas – SP, 2006.

ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R.; VILLARREAL, F. “Um estudo das funções de base radial aplicadas à previsão de cargas elétricas via redes neurais artificiais”, Congresso Nacional de Matemática Aplicada e Computacional – XXVIII CNMAC, São Paulo – SP, 2005.

ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R.; VILLARREAL, F. “Um estudo de previsão de cargas elétricas por redes neurais artificiais”, IV Congresso Temático de Dinâmica, Controle e Aplicações – DINCON 2005, Bauru - SP, pp. 878 – 885, 2005.

O artigo a seguir foi aceito para publicação nos anais da conferência internacional, ICHPSM 2011 (Session: *Neural networks and Applications*), e no periódico *Advanced Materials Research* indexado por Elsevier e Ei Compendex.

ALTRAN, A. B.; MINUSSI, C. R.; LOPES, CHAVARETTE, F. R., PERUZZI, N. J. “Multinodal load forecasting in power electric systems using a neural network with radial basis function”, 2011 International Conference on High Performance Structures and Materials Engineering – ICHPSM 2011, Beijing, China, 2011.