

**UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**“Aplicação de Funções de Base Radial em Problemas de
Previsão de Cargas Elétricas via Redes Neurais
Artificiais”**

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE ESTADUAL
PAULISTA – UNESP PARA OBTENÇÃO DO TÍTULO DE MESTRE EM
ENGENHARIA ELÉTRICA.

ALESSANDRA BONATO ALTRAN

ILHA SOLTEIRA – SP, AGOSTO DE 2005.

ALESSANDRA BONATO ALTRAN

**APLICAÇÃO DE FUNÇÕES DE BASE RADIAL EM
PROBLEMAS DE PREVISÃO DE CARGAS
ELÉTRICAS VIA REDES NEURASIS ARTIFICIAIS**

Dissertação submetida ao Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP, para obtenção de título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Francisco Villarreal Alvarado

ILHA SOLTEIRA – SP, AGOSTO DE 2005.

Ao Pai do Céu.

Aos meus pais Alziro e Luiza.

AGRADECIMENTOS

Venho externar meus sinceros agradecimentos a todos aqueles que, de alguma forma, fizeram parte de minha vitória. Primeiramente a meus pais, Alziro e Luiza, pelo exemplo de vida, luta e amor, que me tornou a pessoa que hoje sou, longe de um modelo de perfeição, mas, com muita força e vontade de viver.

Agradeço a meu orientador, professor Dr. Francisco Villarreal Alvarado, pela paciência, disposição, compreensão e, acima de tudo, pela confiança que sempre demonstrou ter por minha pessoa a todo o momento.

Agradeço, ainda, aos professores Dr. Nobuo Oki e Dr. Carlos Roberto Minussi, pela colaboração durante todo o trabalho e predisposição, como membros da banca examinadora, em analisar o trabalho, assim como o professor Dr. Walmir de Freitas Filho.

Não poderia deixar de agradecer a todos os “amigos do coração”, por estarem sempre presentes, auxiliando, incentivando e, o principal, provando o valor de uma verdadeira amizade.

À professora Dr^a Dalva Maria de Oliveira Villarreal por participar direta, ou indiretamente, de minha caminhada, sempre apoiando, incentivando e permitindo meu crescimento no âmbito de minha profissão.

Agradeço aos funcionários do departamento de engenharia elétrica, Deoclécio e Cristina, e, aos funcionários da biblioteca, em especial à Neide, pelo auxílio constante.

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

RESUMO

Este trabalho tem por objetivo o desenvolvimento de uma metodologia para o treinamento de redes neurais artificiais baseado no algoritmo Retropropagação utilizando diferentes funções de ativação aplicada ao problema de previsão de cargas elétricas a curto-prazo (24 horas à frente). A escolha pela utilização do algoritmo Retropropagação se dá pelo fato deste ser considerado um “referencial” em termos de precisão, o que o torna uma das principais ferramentas a serem utilizadas para resolver problemas reais, neste caso, a previsão de cargas elétricas. Sendo assim, a proposta central é modificar a função de ativação da rede perceptron multicamadas utilizando algoritmo Retropropagação, de forma a identificar como as novas funções de ativação atuam na saída da rede neural, ou seja, dependendo da função de não-linearidade utilizada no algoritmo, como a saída da rede neural é processada. Para substituir a função de ativação usual, função sigmóide, utiliza-se uma classe especial de funções, as funções de base radial. Como forma de ilustração da metodologia proposta, são apresentados os resultados (análise comparativa) da previsão de cargas elétricas, considerando-se os dados históricos de uma companhia do setor elétrico brasileiro.

Palavras-Chave: Previsão de Cargas Elétricas, Redes Neurais Artificiais, Algoritmo Retropropagação, Funções de Base Radial.

ABSTRACT

The objective of this work is to develop a methodology for training artificial neural networks based on backpropagation algorithm using different activation functions applied to the problem of short term load forecasting (24 hours ahead). The choice of backpropagation algorithm is due to be a benchmark in terms of precision, and also an important tool to solve real problems, for example electrical load forecasting. Therefore, the principal proposal is to modify the activation function of the multilayer perceptron using backpropagation algorithm, to identify how the new activation functions behaves on the output of the neural network, i.e., depending on the non-linearity function used how the neural network is processed. To substitute the sigmoid function, it is used a special class of functions, the radial basis functions. Results are presented considering historic data from a Brazilian power company.

Keywords: Load Forecasting, Neural Networks, Backpropagation Algorithm, Radial Basis Function.

SUMÁRIO

1 – INTRODUÇÃO	1
1.1 – Introdução Geral	1
1.2 – Objetivo do Trabalho	3
1.3 – Organização do Trabalho	3
2 – REDES NEURAS ARTIFICIAIS	6
2.1 – Introdução	6
2.2 – Modelo Biológico	8
2.3 – Modelo Neural Artificial	9
2.4 – Arquitetura de Redes Neurais Artificiais	14
2.5 – Aprendizado em Redes Neurais Artificiais	15
2.6 – Tipos de Redes Neurais Artificiais	18
2.7 – Conclusão	20

3 – FUNÇÕES DE BASE RADIAL	22
3.1 – Introdução	22
3.2 – Função de Base Radial	23
3.3 – Principais Funções de Base Radial	25
3.4 – Conclusão	29
4 – PREVISÃO DE CARGAS ELÉTRICAS	30
4.1 – Introdução	30
4.2 – Objetivos da Previsão de Carga	31
4.3 – Horizontes de Previsão	32
4.4 – Procedimentos de Previsão	34
4.5 – Redes Neurais Artificiais na Previsão de Carga	36
4.6 – Conclusão	38
5 – APLICAÇÃO	39
5.1 – Introdução	39
5.2 – Perceptron Multicamadas	40
5.2.1 – Estratégias para Treinamento da rede Perceptron Multicamadas	41
5.2.2 – Algoritmo Retropropagação	42
5.2.3 – Algoritmo Retropropagação com Momento	47
5.2.3 – Vantagens e Desvantagens do Algoritmo Retropropagação	50
5.3 – O Algoritmo Retropropagação na Previsão de Carga	52
5.4 – Critérios para Avaliação das Redes Neurais	56
5.5 – Conclusão	57

6 – RESULTADOS	58
6.1 – Introdução	58
6.2 – Resultados da Previsão de Cargas Elétricas	59
6.2.1 – Resultados obtidos para o Primeiro Sistema Previsor	60
6.2.2 – Resultados obtidos para o Segundo Sistema Previsor	65
6.2.3 – Resultados obtidos para o Terceiro Sistema Previsor	70
6.3 – Conclusão	76
7 – CONCLUSÃO	77
7.1 – Conclusão Geral	77
REFERÊNCIAS BIBLIOGRÁFICAS	81
APÊNDICE A – Sistemas Previsores	88
A1 – Primeiro Sistema Previsor (SP1)	89
A2 – Segundo Sistema Previsor (SP2)	90
A3 – Terceiro Sistema Previsor (SP3)	92

LISTA DE FIGURAS

2.1	–	Representação de uma rede neural como caixa de processamento.	7
2.2	–	Componentes de um neurônio biológico.	8
2.3	–	Modelo não-linear de um neurônio.	10
2.4	–	Outro modelo não-linear de um neurônio.	12
2.5	–	Tipos de função de ativação.	13
2.6	–	Aprendizado supervisionado.	16
2.7	–	Aprendizado não-supervisionado.	17
3.1	–	Função multiquadrática.	26
3.2	–	Função multiquadrática recíproca.	26
3.3	–	Função multiquadrática recíproca inversa.	27
3.4	–	Função gaussiana.	27
3.5	–	Função secante hiperbólica.	28
3.6	–	Função splines de placas finas.	28

5.1	– Perceptron multicamada.	40
5.2	– Esquema de adaptação de pesos do algoritmo Retropropagação	46
5.3	– Treinamento de um neurônio situado na última camada.	48
5.4	– Treinamento de um neurônio situado nas demais camadas.	49
5.5	– Variação das taxas de treinamento no algoritmo gradiente descendente.	50
6.1	– Resultado da previsão de carga utilizando a função de ativação gaussiana, para o primeiro sistema previsor.	61
6.2	– Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca, para o primeiro sistema previsor.	62
6.3	– Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca inversa, para o primeiro sistema previsor.	62
6.4	– Resultado da previsão de carga utilizando a função de ativação secante hiperbólica, para o primeiro sistema previsor.	63
6.5	– Resultado da previsão de carga utilizando a função de ativação sigmóide, para o primeiro sistema previsor.	63
6.6	– Resultado da previsão de carga utilizando a função de ativação gaussiana, para o segundo sistema previsor.	67
6.7	– Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca, para o segundo sistema previsor.	67
6.8	– Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca inversa, para o segundo sistema previsor.	68

6.9	– Resultado da previsão de carga utilizando a função de ativação secante hiperbólica, para o segundo sistema previsor.	68
6.10	– Resultado da previsão de carga utilizando a função de ativação sigmóide, para o segundo sistema previsor.	69
6.11	– Resultado da previsão de carga utilizando a função de ativação gaussiana, para o terceiro sistema previsor.	72
6.12	– Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca, para o terceiro sistema previsor.	73
6.13	– Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca inversa, para o terceiro sistema previsor.	73
6.14	– Resultado da previsão de carga utilizando a função de ativação secante hiperbólica, para o terceiro sistema previsor.	74
6.15	– Resultado da previsão de carga utilizando a função de ativação sigmóide, para o terceiro sistema previsor.	74

LISTA DE TABELAS

5.1 – Funções de ativação e suas respectivas derivadas.	55
6.1 – Especificação das funções de ativação referente ao primeiro sistema previsor (SP1).	60
6.2 – Resultados comparativos para o primeiro sistema previsor.	64
6.3 – Especificação das funções de ativação referente ao segundo sistema previsor (SP2).	65
6.4 – Resultados comparativos para o segundo sistema previsor.	69
6.5 – Especificação das funções de ativação referente ao terceiro sistema previsor (SP3).	71
6.6 – Resultados comparativos para o terceiro sistema previsor.	75

LISTA DE SÍMBOLOS

x	–	entradas da rede neural artificial
y	–	saídas da rede neural artificial
w	–	pesos sinápticos
b	–	peso <i>bias</i>
s	–	soma das entradas e respectivos pesos
d	–	saída desejada
V	–	vetor contendo os pesos
X	–	vetor contendo as entradas
Y	–	vetor contendo as saídas
ϕ	–	funções de ativação
σ	–	derivada das funções de ativação
c	–	centro das funções de base radial
λ	–	inclinação da função sigmóide

ε	–	erro da rede neural
ε^2	–	erro quadrático da rede neural
∇	–	gradiente do erro quadrático relacionado aos pesos
γ	–	taxa de treinamento
β	–	constante de adaptação dos pesos
η	–	constante momento
t	–	vetor de tempo
L	–	valor real da carga
\underline{L}	–	valor estimado da carga
N_t	–	número total de horas

INTRODUÇÃO

1.1 – Introdução Geral

Este trabalho tem por objetivo apresentar uma aplicação de Redes Neurais Artificiais (RNA), baseadas nas Funções de Base Radial (RBF), para a resolução do problema de Previsão de Cargas Elétricas. A previsão de carga constitui-se numa rotina de grande relevância no planejamento e na operação dos sistemas elétricos de potência.

Encontram-se, na literatura, vários métodos estatísticos utilizados na previsão de cargas elétricas; porém, em todos ocorre a necessidade de que seja realizada uma modelagem prévia da carga, para que esta possa ser aplicada posteriormente. 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 a utilização de técnicas inteligentes, no caso, a utilização de redes neurais artificiais.

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 e 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.

Os trabalhos [Altran et al., 2005a; Altran et al., 2005b] fortalecem a proposta, enfatizando a aplicabilidade das diferentes funções, em específico, as funções de base radial, na rede neural utilizada para o problema de previsão de cargas elétricas a curto prazo.

1.2 – Objetivos do Trabalho

Os principais objetivos do trabalho são:

- Análise da utilização de técnicas de inteligência computacional, em específico, redes neurais artificiais, em previsão de cargas elétricas;
- Estudo das principais características de uma rede perceptron multicamadas (MLP) com a utilização do algoritmo Retropropagação como algoritmo de treinamento;
- Análise das principais características das funções de base radial e a utilização dessas funções como função de ativação de uma rede perceptron multicamadas;
- Apresentação da comparação do desempenho da rede perceptron multicamadas, com algoritmo Retropropagação, tendo como função de ativação, funções de base radial e a função sigmóide.

1.3 – Organização do Trabalho

O trabalho está dividido em mais seis capítulos; os quais buscam, de forma significativa, o bom entendimento da proposta central, através da apresentação da teoria envolvida.

No capítulo 2, é realizado um estudo sobre redes neurais artificiais, desde o 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 3 tem a finalidade de apresentar as funções de base radial, que serão utilizadas posteriormente como função de ativação da rede neural proposta. Inicia-se com a definição formal e apresentação de propriedades dessa classe de funções. Em seguida, faz-se uma apresentação gráfica e uma breve análise de suas principais características.

No capítulo 4, é realizado um estudo sobre previsão de cargas elétricas, ressaltando a importância da previsão de carga para a operação do sistema elétrico. Apresentam-se os objetivos e horizontes de previsão, enfatizando a utilização de técnicas inteligentes na previsão. 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 5 apresenta a metodologia utilizada para a aplicação de redes neurais artificiais na previsão de cargas elétricas. Para tanto, é realizado um estudo sobre as redes perceptron multicamadas, fazendo descrição das estratégias de treinamento, ou seja, do algoritmo Retropropagação, e Retropropagação com Momento, apresentando algumas vantagens e desvantagens de sua utilização. É realizada a apresentação detalhada do método utilizado para resolução do problema proposto, explicitando a utilização de três sistemas previsores, cujos dados foram fornecidos por uma companhia do setor elétrico brasileiro, 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 6, é realizada a apresentação dos resultados da aplicação das redes neurais artificiais na previsão de cargas elétricas a curto prazo; sendo analisado a utilização de diferentes funções de ativação no algoritmo Retropropagação; observando ainda, a originalidade de tal aplicação.

No capítulo 7 é apresentada a conclusão geral deste trabalho, enaltecendo a obtenção de resultados significativos para o problema de previsão de cargas elétricas, cuja formulação se deu através das redes neurais artificiais com função de base radial.

O trabalho contém, ainda, um apêndice, o Apêndice A. Neste, são apresentados os arquivos de dados históricos de cargas elétricas, utilizados como entrada da rede neural artificial.

REDES NEURAIS ARTIFICIAIS

2.1 - Introdução

Um dos mais impressionantes fenômenos da natureza é o princípio da Inteligência. Apesar de toda tecnologia atual, ainda não se conseguiu produzir uma máquina verdadeiramente inteligente, pois, o cérebro processa informações de uma forma inteiramente diferente de um computador digital convencional. O cérebro é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo [Haykin, 1994].

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, ainda que de modo simplificado, a mais básica das estruturas cerebrais: o neurônio.

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.

Uma rede neural pode ser considerada como uma caixa de processamento, que pode ser treinada para aceitar uma série de dados de entrada e produzir uma ou mais saídas, como representada na figura 2.1.




Figura 2.1 - Representação de uma rede neural como caixa de processamento.

Assim, o intuito deste capítulo é apresentar, de forma sucinta, as características principais das redes neurais artificiais. Para tanto, inicia-se com a comparação entre o modelo de um neurônio biológico e o modelo de um neurônio artificial; em seguida, comenta-se sobre a arquitetura e o aprendizado/treinamento de uma rede neural artificial e, por fim, apresentam-se os principais tipos de redes neurais artificiais.

2.2 - Modelo Biológico

O sistema nervoso humano é formado por cerca de 100 bilhões de neurônios, onde 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 (o termo *neuronal* geralmente é utilizado como referência ao neurônio natural, enquanto o termo *neural* aos neurônios artificiais). Cada módulo, ou área de especialização da rede 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, uma célula que recebe e envia informação para várias partes do organismo [Haykin, 1994].

Na figura 2.2 são mostrados os componentes mais comuns de um neurônio biológico.

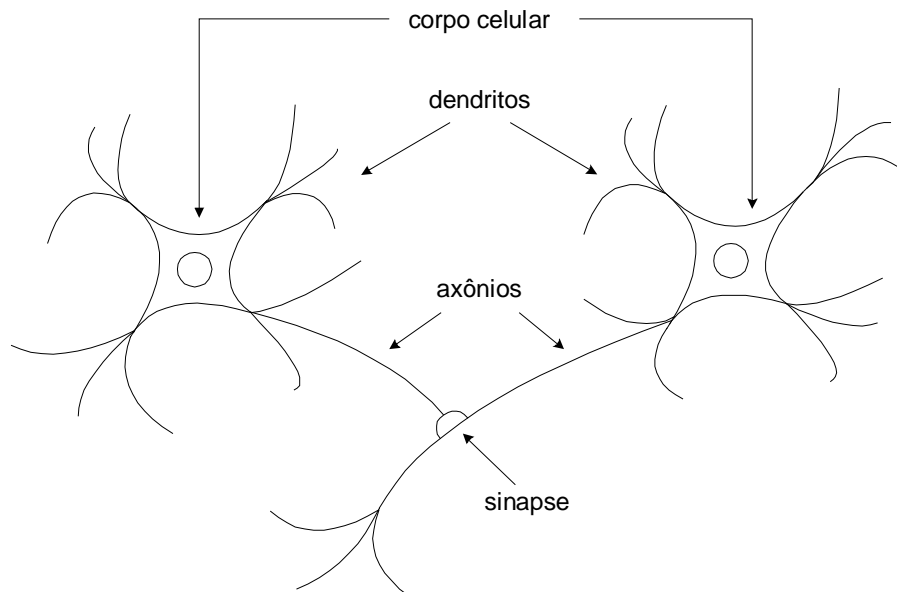


Figura 2.2: Componentes de um neurônio biológico.

O neurônio é formado pelo *corpo celular* ou *sôma*, responsável pela recepção e geração de impulsos nervosos; 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 entre 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].

2.3 - Modelo Neural Artificial

Com o desenvolvimento da inteligência artificial, surgiram idéias de como representar, através de determinados programas, o funcionamento do processo de aprendizagem do cérebro humano. A partir dos estudos com redes biológicas foi que surgiu o campo das *redes neurais artificiais* que, nada mais são do que tentativas de reproduzir a capacidade de processamento do cérebro.

Semelhante ao cérebro humano, a rede neural possui um neurônio artificial que foi designado a imitar as características do neurônio biológico. Dentre essas características destacam-se:

- ***Processamento paralelo maciço***: armazenamento do conhecimento através do treinamento.
- ***Interligações entre neurônios feitas por conexões sinápticas***: utilizadas para o armazenamento de informação.

- **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 é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural. Na figura 2.3 é mostrado o modelo de um neurônio artificial que forma a base para um projeto de redes neurais artificiais.

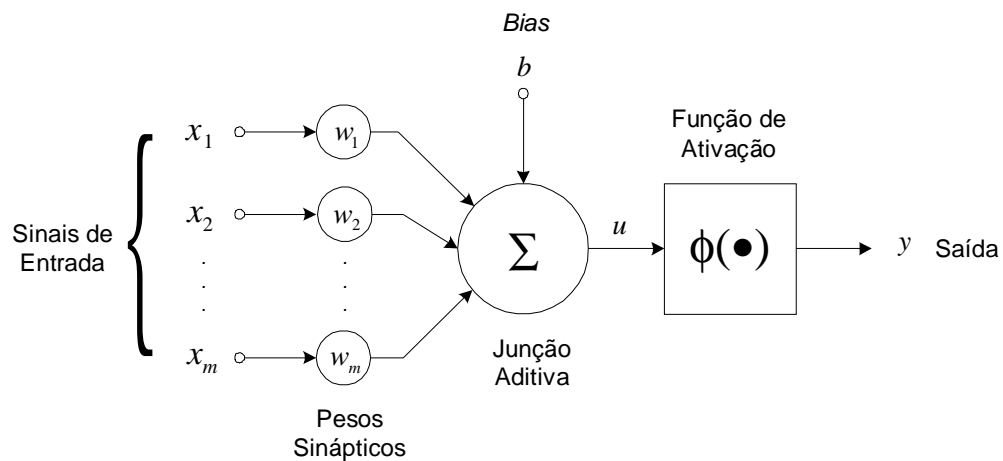


Figura 2.3: Modelo não-linear de um neurônio.

É possível identificar três elementos básicos de um modelo neural:

- Um conjunto de *sinapses* ou *elos* de conexão, cada uma caracterizada por um *peso* ou *força* própria. Especificamente um sinal x_j , na entrada, é multiplicado pelo peso sináptico w_j . 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* para 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 2.3 é incluído um *bias* aplicado externamente, representado por b ; o mesmo tem efeito de aumentar ou diminuir a entrada da função de ativação, caso seja, positivo ou negativo, respectivamente [Haykin, 1994].

Em termos matemáticos, pode-se escrever o neurônio da figura 2.3 através das seguintes equações:

$$u = \sum_{j=1}^m w_j x_j \quad (2.1)$$

e

$$y = \phi(u + b) \quad (2.2)$$

Sendo, x_1, x_2, \dots, x_m sinais de entrada; w_1, w_2, \dots, w_m pesos sinápticos do neurônio; u a saída do combinador linear em consequência dos sinais de entrada; b o *bias*; $\phi(\bullet)$ a função de ativação e y o sinal de saída do neurônio.

A utilização do *bias* b tem o efeito de aplicar uma transformação afim à saída do combinador linear no modelo da figura 2.3, como mostrado por:

$$s = u + b \quad (2.3)$$

O *bias* é um parâmetro externo do neurônio artificial. Pode-se considerar sua presença como na equação (2.2). Equivalentemente, pode-se formular a combinação das equações (2.1) e (2.3) como segue:

$$s = \sum_{j=0}^m w_j x_j \quad (2.4)$$

e

$$y = \phi(s) \quad (2.5)$$

Na equação (2.4) adiciona-se uma nova sinapse. Sua entrada e seu peso são, respectivamente:

$$x_0 = +1 \quad (2.6)$$

e

$$w_0 = b \quad (2.7)$$

Pode-se, então, reformular o modelo do neurônio artificial, como na figura 2.4:

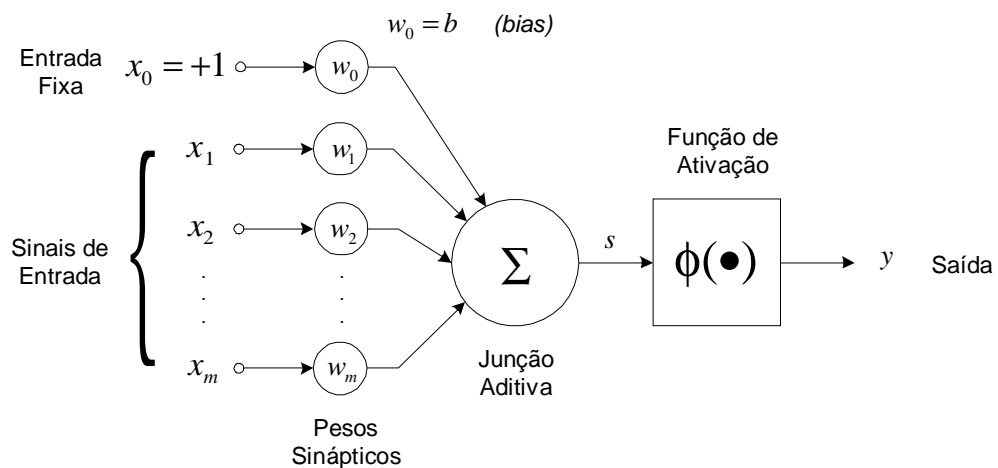


Figura 2.4 – Outro modelo não-linear de um neurônio.

A ativação do neurônio é feita por uma função denominada *função de ativação*, mencionada anteriormente.

As formas mais utilizadas desta função de ativação são as seguintes:

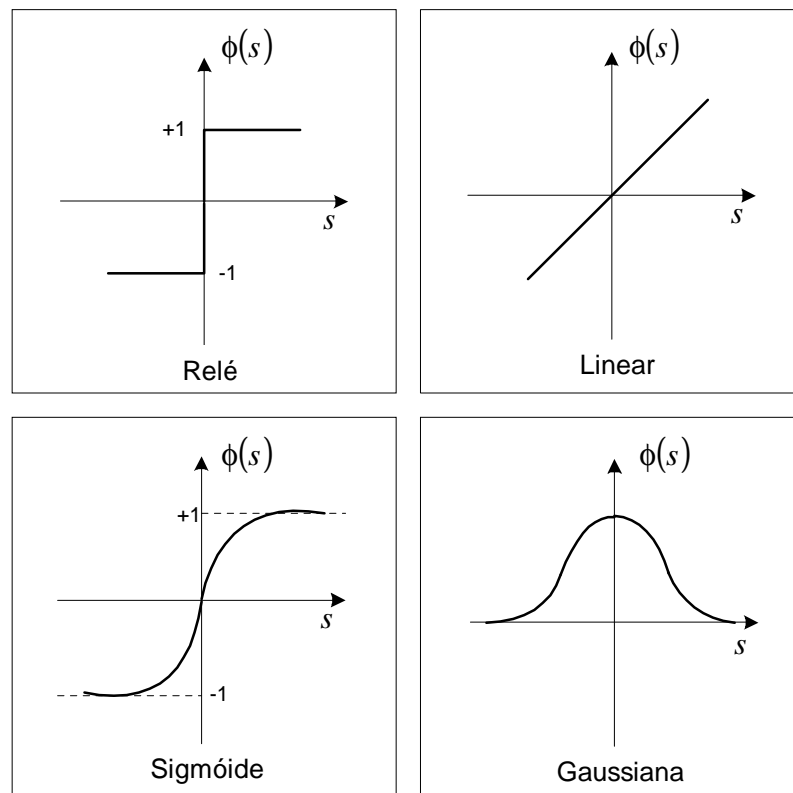


Figura 2.5 – Tipos de funções de ativação.

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 utilizada na literatura é a função sigmóide; devido o fato de ser a única a ter similaridade com o neurônio biológico, além de ser contínua e apresentar derivada simples.

2.4 - 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 (cada neurônio pode ter várias entradas, porém somente uma saída). Entre a camada de entrada e a camada de saída, existe um número variável de camadas intermediárias. Cada saída pode ser utilizada 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].

As redes neurais podem ser classificadas em dois tipos quanto a sua estrutura: redes recorrentes e redes não-recorrentes.

Uma rede neural é dita *recorrente* ou *feedback*, se ela contém laço de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma camada ou de camadas anteriores, elas partem e chegam a um mesmo neurônio.

Já a rede neural que não contém laço de realimentação é dita *não-recorrente* ou *feedforward*, ou seja, 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].

Em síntese, as redes *feedforward* permitem que a informação flua entre os neurônios em apenas uma direção, ao passo que, as redes *feedback* possibilitam a informação fluir em uma direção e/ou recursivamente.

2.5 – Aprendizado em Redes Neurais Artificiais

A propriedade mais importante das redes neurais é a habilidade 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 da aprendizagem ou treinamento é fazer com que a aplicação de um conjunto de entradas, produza um conjunto de saídas desejado. O treinamento torna-se completo a partir do momento em que aplicando um conjunto de entradas (vetores), seqüencialmente, os pesos da rede se ajustam de acordo com o procedimento predeterminado. Os pesos da rede convergem gradualmente a determinados valores, à medida que o vetor de entrada produz o vetor de saída desejado [Haykin, 1994].

Em outras palavras, aprendizado é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado através da maneira que a modificação dos parâmetros ocorre.

Esta definição do processo de aprendizagem implica a seguinte seqüência de eventos [Haykin, 1994]; a rede neural é estimulada por um ambiente, sofre modificações nos seus parâmetros livres como resultado desta estimulação, responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

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:

Aprendizado supervisionado ou treinamento associativo: A rede é treinada proporcionada pela combinação dos padrões de entrada e saída. Este processo utiliza um agente externo (*teacher*) que indica à rede um comportamento bom ou ruim de acordo com o padrão de entrada, ou seja, avalia e informa à rede sobre seu desempenho. 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 que tende a minimizar este erro. 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].

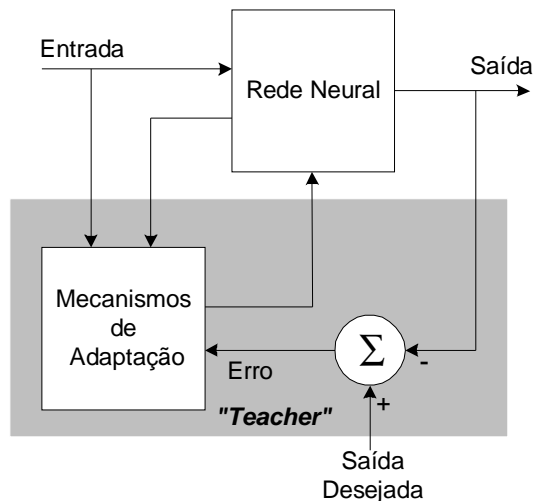


Figura 2.6 – Aprendizado supervisionado.

Aprendizado não-supervisionado (Auto-organização): O conjunto de treinamento consiste, exclusivamente, de vetores de entrada. Este processo não utiliza um agente externo (*teacher*) indicando a resposta desejada para os padrões de entrada, ou seja, é uma rede autônoma; utiliza-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. O conjunto de treinamento consiste apenas de vetores de entrada. O algoritmo de treinamento modifica a rede de forma a produzir vetores de saída, os quais são consistentes (tanto a aplicação de um dos vetores de treinamento quanto à de um vetor suficientemente similar irão produzir o mesmo padrão de saída da rede). O processo de treinamento extrai propriedades estatísticas do conjunto de treinamento e agrupa vetores similares em classes [Haykin, 1994].

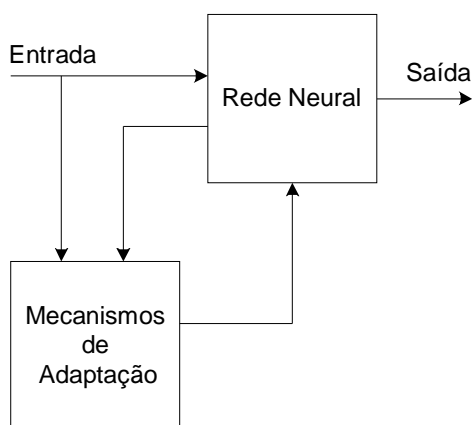


Figura 2.7 – Aprendizado não-supervisionado.

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;
- *Feedforward*;
- Algoritmo de aprendizagem **Retropropagação**.

2.6 – Tipos de Redes Neurais Artificiais

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

- **Rede Neural de McCulloch-Pitts (MCP)** - Foi desenvolvida em 1943 e representa o neurônio como uma unidade de limite binário que pode executar operações lógicas básicas (NOT, AND e OR), por meio do ajuste adequado de pesos [McCulloch e Pitts, 1943].
- **Perceptron de Camada Simples (SLP – Simple Layer Perceptron)** - Proposta por *Frank Rosenblatt*, em 1958, é utilizada para o conhecimento e classificação de padrões e também é usada para resolução de problemas lógicos que envolvem os operadores AND e OR [Rosenblatt, 1958, 1962].
- **Perceptron Multicamadas (MLP - Multi Layer Perceptron)** - Realiza operações lógicas complexas [Hebb, 1949].
- **Rede Neural ADALINE** - Desenvolvida em 1960 por *Widrow e Hoff* é utilizada para reconhecimento de padrões, porém só reconhece os padrões nos quais foi treinada. A partir do momento em que é generalizada para uma rede Retropropagação Multicamada, se torna rede neural **MADALINE (Multilayer ADALINE)** e apresenta um alto grau de tolerância a falhas [Widrow e Hoff, 1960].
- **Rede Neural Feedforward (MLFF - Multi Layer Feedforward)** - Proposta em 1969 por *Minsky e Papert*. Uma rede MLP com aprendizagem feedforward. A rede é utilizada para a classificação de padrões e o controle de robôs [Minsky e Papert, 1969].
- **SOM (Self Organizing Map) de Kohonen** - Desenvolvida por *Teuvo Kohonen* em 1972. Rede competitiva com a habilidade de fazer mapeamentos entre dados de en-

trada (*input*) e saída (*output*). Capaz de equilibrar um bastão aplicando forças na sua base [Kohonen, 1972].

- **Rede Neural Retropropagação (BPN - Backpropagation Network)** - Em 1974, *Werbos* apresentou a primeira concepção do algoritmo Retropropagação. Porém, foi a partir de 1986 que *E. Rumelhart*, *G. E. Hilton* e *R. J. Williams* informados sobre o trabalho de *Werbos* tiveram uma idéia. Uma rede Perceptron Multicamadas com aprendizagem Retropropagação. Utilizada, por exemplo, na previsão anual de aparelhos de manchas solares, em operações lógicas complexas e classificação de padrões [Rumelhart, Hilton e Williams, 1986].
- **Rede de Hopfield** - Desenvolvida em 1982 por *J. J. Hopfield* sendo uma rede utilizada, por exemplo, para reconhecimento de imagens [Hopfield, 1982].
- **Rede ART (Adaptive Resonance Theory)** – Foi desenvolvida em 1976 por *Grossberg*. Tem por base características da teoria da ressonância adaptativa. É utilizada para reconhecimento de sinais de radar e processamento de imagens [Grossberg, 1976].
- **Rede CNM (Combinatorial Neural Model)** – Uma rede apropriada para o processamento de reconhecimento, análise e classificação de dados [Machado e Rocha, 1989].
- **Rede CPN (Counterpropagation Network)** – Esta rede é composta por duas redes neurais em série; a rede de *Kohonen*, com treinamento não-supervisionado, e a rede de *Grossberg*, como treinamento supervisionado. Uma rede competitiva projetada para funcionar como uma tabela de consulta autoprogramável com a habilidade de interpolar dados de entrada. Ela pode, por exemplo, determinar a rotação angular de um objeto na forma de foguete que lhe é apresentada como um padrão bitmap [Hecht-Nielsen, 1987].

- **Rede BAM (Bidirectional Associative Memory)** - Uma memória associativa bidirecional capaz de fornecer, por exemplo, o número do telefone associado ao nome que lhe foi fornecido e vice-versa. Permite um certo grau de tolerância a erros, quando os dados fornecidos possuem um padrão corrompido [Kosko, 1988].
- **Rede Neocognitron** - Uma rede de múltiplas camadas com conexões parciais entre as unidades das várias camadas. Foi desenvolvida para reconhecer caracteres alfabéticos escritos a mão. É de treinamento difícil, mas possui boa tolerância a erros, pois reconhece os caracteres mesmo com certa inclinação na escrita ou pequena distorção na imagem [Fukushima, Miyake e Ito, 1980].
- **Rede RBFN (Radial Basis Function Network)** – É uma rede composta por três camadas, apenas uma camada escondida, utilizando funções radiais. O treinamento é supervisionado. Este tipo de rede é considerado como aproximador universal [Powell, 1985].

2.7 – Conclusão

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

As redes neurais artificiais são aplicadas a problemas de relações dinâmicas ou não-lineares. Elas suprem uma alternativa analítica que as técnicas convencionais limitam-se, muitas vezes, por suposições estritas de normalidade, linearidade, independência de variável, etc. As redes neurais podem capturar vários tipos de informação que permi-

tem ao usuário, com maior rapidez e facilidade, explicar os problemas que, por outro lado, podem ter sido difíceis ou impossíveis de serem resolvidos.

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 aprendizado. Por fim, foram apresentados vários tipos de redes neurais, sendo descritas suas respectivas características.

FUNÇÕES DE BASE RADIAL

3.1 - Introdução

Como visto no capítulo anterior, 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 Sig-móide, por ter maior similaridade com neurônio biológico. Neste capítulo será apresentado o estudo das Funções de Base Radial, a fim de analisar a possibilidade de utilizá-las como função de ativação.

Na década de 80, na tentativa de suprir algumas necessidades relativas às redes neurais do tipo perceptron multicamadas, tais como, simplicidade do processo de treinamento, a eficiência computacional, eficiência em aproximação de funções, surgem as Redes Neurais com Função de Base Radial (RBFN) [Powell, 1985].

A proposta central deste trabalho é a utilização de funções de base radial como função de ativação, mas não em redes neurais do tipo RBFN como mostra a literatura [Bors, 2001; Fernandes, Neto e Bezerra, 1999], e sim, em redes neurais do tipo perceptron multicamadas, com algoritmo Retropropagação [Rumelhart, Hilton e Willians,

1986], como algoritmo de treinamento, que será apresentado com riqueza de detalhes mais adiante.

O que se propõe, na verdade, é a troca da função de ativação da rede perceptron multicamadas com função sigmoidal, por funções de base radial.

Sendo assim, este capítulo apresenta uma definição mais formal das funções de base radial e suas principais características; além da apresentação (equação e gráfico) de algumas funções de base radial.

3.2 – 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 e 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 e Heuveln, 1998].

A utilização 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 $X = \{x_1, x_2, \mathbf{L}, x_m\} \subset \Omega \subset R^n$ são conhecidos. Esse conjunto de pontos é, normalmente, chamado de centro. Sendo assim, a solução procurada é da forma [Buhmann, 2000; Poggio e Girosi, 1990; Wendland, 1999]:

$$f(x) = \sum_{i=1}^m \mu_i \Phi(x, x_i) + p(x) . \quad (3.1)$$

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 e Wendland, 2001]:

$$\|x\| = \sqrt{x_1^2 + \mathbf{L} + x_n^2} \quad (3.2)$$

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 e Schaback, 2001]:

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

sendo, $\|x - x_i\|$ a distância entre x e x_i [Chen e Chen, 1995; Mulgrew, 1996], como visto anteriormente.

Em 1986, Micchelli [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.

3.3 – Principais Funções de Base Radial

Na literatura, encontram-se diversas funções de base radial, porém, nem todas podem ser utilizadas como função de ativação pelo o fato de apresentarem características que não se enquadram nas condições exigidas pelas redes neurais artificiais.

Para ilustrar o comportamento de algumas das funções de base radial, apresentam-se alguns exemplos. As Figuras 3.1, 3.2, 3.3, 3.4, 3.5 e 3.6, representam as funções Multiquadrática; Multiquadrática Recíproca, Multiquadrática Recíproca Inversa (foi realizada uma modificação na função multiquadrática recíproca e, a essa nova função, deu-se o nome de multiquadrática recíproca inversa), Gaussiana, Secante Hiperbólica e Spline de Placas Finas, respectivamente [Astorino e Rimondo, 2004; Fernandes e Leitão, 2002; Mai-Duy e Tran-Cong, 2003]:

- Multiquadrática (M): $\phi(x) = \sqrt{x^2 + c^2}$, $c > 0$.




Figura 3.1 – Função multiquadrática.

- Multiquadrática Recíproca (MR): $\phi(x) = \frac{1}{\sqrt{x^2 + c^2}}$, $c > 0$.




Figura 3.2 – Função multiquadrática recíproca.

- Multiquadrática Recíproca Inversa (MRI): $\phi(x) = \frac{1}{c} - \frac{1}{\sqrt{x^2 + c^2}}$, $c > 0$.




Figura 3.3 – Função multiquadrática recíproca inversa.

- Gaussiana (G): $\phi(x) = \exp(-c x^2)$, $c > 0$.




Figura 3.4 – Função gaussiana.

- Secante Hiperbólica (SH): $\phi(x) = \frac{2}{e^{cx} + e^{-cx}}$, $c > 0$.




Figura 3.5 – Função secante hiperbólica.

- Splines de Placas Finas (SPF): $\phi(x) = x^{2b} \ln x$, $b \in N$




Figura 3.6 – Função spline de placas finas.

Algumas dessas funções apresentam particularidades interessantes; são ilimitadas, ou não-diferenciáveis, como a função multiquadrática e spline de placas finas, respectivamente; o que inviabiliza sua utilização em algumas aplicações, neste caso, as redes neurais artificiais.

Assim, as funções de base radial, que serão utilizadas como função de ativação da rede neural artificial, são as funções Multiquadrática Recíproca, Multiquadrática Recíproca Inversa, Gaussiana, Secante Hiperbólica, em conjunto com suas respectivas derivadas, cuja utilização é exigida pelo algoritmo de treinamento proposto.

3.4 – Conclusão

Neste capítulo foi realizada a apresentação das Funções de Base Radial, iniciando com uma definição formal da mesma. Em seguida, foram apresentadas algumas das funções de base radial mais utilizadas na literatura, em forma equações e gráficos.

Observa-se que, algumas destas funções não podem ser utilizadas como função de ativação da rede neural artificial proposta, como é o caso da função multiquadrática e spline de placas finas, pois estas são ilimitadas ou não-diferenciáveis. As funções de ativação não podem ser ilimitadas, pois estas tem por objetivo restringir o intervalo de amplitude do sinal de saída a um valor finito, geralmente $[0, 1]$; e, também, têm de ser diferenciáveis, pois o algoritmo de treinamento utiliza a derivada da função de ativação.

PREVISÃO DE CARGAS ELÉTRICAS

4.1 - Introdução

A previsão de carga é de fundamental importância para manter estabilidade do sistema elétrico, fornecer meios que atinjam uma operação econômica, além de subsídios para o planejamento de expansão do sistema, etc.

A utilização de redes neurais artificiais na previsão de carga tem se mostrado bastante eficaz devido o fato destas realizarem um mapeamento não-linear da carga elétrica, permitindo a extração de características complexas das séries, o que possibilita, muitas vezes, maior confiabilidade nas previsões.

Visando o bom entendimento deste tipo de aplicação das redes neurais artificiais, neste capítulo serão apresentados os principais objetivos da previsão de carga, enfatizando sua importância para o sistema elétrico; horizontes e procedimentos de previsão de cargas elétricas, e utilização de redes neurais artificiais na previsão de carga.

4.2 – Objetivos da Previsão de Carga

O principal objetivo da operação de um sistema elétrico de potência é suprir o seu mercado de energia elétrica evitando interrupções e mantendo a qualidade da energia oferecida (mantendo os níveis de tensão e frequência em limites adequados). Já a previsão de carga tem como principal objetivo, nos diversos horizontes temporais do planejamento da operação, minimizar os desvios entre os valores previstos em relação aos verificados, otimizando os recursos disponíveis, bem como as decisões de futuras obras de expansão de usinas, equipamentos ou instalações.

No planejamento da operação de médio e curto prazo e na programação diária, a previsão de carga influencia diretamente nos despachos das usinas, de forma a garantir o suprimento à carga estabelecendo, desta maneira, a confiabilidade do sistema, visando o atendimento ao consumidor final.

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, e essas decisões são produto da previsão de carga a ser atendida. Assim sendo, a minimização do desvio da previsão de carga é sempre de suma importância.

A inércia das usinas hidráulicas para as tomadas de carga, momento em que ocorre uma variação brusca de carga, e a necessidade prévia do despacho de uma usina térmica também são fatores cuja decisão antecipada é requerida no horizonte da programação diária. A necessidade de antecipação das variações bruscas que a carga sofre na operação dia a dia é, portanto, determinante, tanto sob o aspecto econômico face ao preço da geração térmica, como também pelo aspecto da garantia do atendimento dentro dos níveis de confiabilidade do setor.

A previsão de carga para a programação diária da operação tem como principal objetivo, antecipar quando ocorrem e de quanto serão as variações de carga ao longo do dia. Mais uma vez, esse processo procura minimizar os desvios de previsão, através de ações coordenadas de manutenção de equipamentos, desligamentos programados e gerenciamento dos recursos de geração, procedam ou adotem providências operativas que assegurem o atendimento a essa carga, sem perda da confiabilidade do sistema interligado brasileiro, bem como a das áreas que o compõem.

Os objetivos citados até agora dizem respeito ao planejamento da operação, mas a previsão de carga também é utilizada no planejamento da expansão. A possibilidade de se prever a carga que será necessária para atender ao consumidor no futuro, em horizontes de médio e longo prazos, é uma informação muito importante para que uma empresa de energia elétrica possa planejar a expansão do seu parque gerador, como também a necessidade de um maior intercâmbio de energia com outras empresas. A necessidade de expansão de um sistema de transmissão também é possível baseada em previsões do crescimento do consumo de energia elétrica. Pode-se classificar, então, os objetivos da previsão de carga em objetivos econômicos, objetivos de segurança e objetivos de planejamento da expansão, sendo os dois primeiros utilizados no planejamento da operação e o último no planejamento da expansão.

4.3 – Horizontes de Previsão

A previsão de carga pode ser realizada em diferentes intervalos de tempo, tendo finalidades diferentes para cada horizonte [Mohamed, 1998]. Os horizontes utilizados na previsão de carga são *longo, médio, curto* e *curtíssimo prazo* para cada horizonte pode-se associar objetivos distintos.

A previsão de *longo prazo* utiliza intervalos *anuais*; é importante para o processo decisório do aumento da capacidade de atendimento ao mercado consumidor, ou seja,

seu objetivo é o planejamento da expansão. 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.

No caso da construção de uma usina hidrelétrica, por exemplo, se desde a tomada da decisão até a entrada em operação dos geradores houver um período de aproximadamente oito anos, isto significa que seria necessário um estudo das necessidades de atendimento ao mercado consumidor com uma antecedência de aproximadamente 15 anos, para que se possam tomar as decisões necessárias para o atendimento à demanda prevista.

A previsão de *médio prazo* utiliza intervalos *mensais*; sua principal aplicação é na otimização da alocação das máquinas geradoras, com o objetivo de se ter uma operação econômica. Existe também a utilização da previsão de médio prazo para se executar estudos elétricos de situações de instabilidade da rede elétrica, objetivando manter uma segurança do sistema.

A previsão de carga em *curto prazo* é feita em intervalos *semanais* e, assim como a de médio prazo, 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.

A previsão de carga em *curtíssimo prazo* é feita em intervalos *inferiores a uma hora*, tentando 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 [Velasco, 1999]:

- Realocação de manutenções de unidades geradoras hidráulicas/térmicas;
- Partida de unidades térmicas para atendimento à demanda;
- Realocação das folgas de potência entre empresas visando otimizar a utilização de potência em função da diversidade da carga;
- Gerenciamento da carga de demanda no período de ponta.

4.4 – Procedimentos de Previsão

Os procedimentos de previsão utilizados 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, pode-se destacar alguns modelos, tais como [Souza, 1989]:

- **Box-Jenkins** - propostos no início da década de 70, consistindo de uma classe geral de modelos lineares conhecidos como **ARIMA** [Box, 1976];
- **Bayesianos** - também introduzidos na década de 70 caracterizam-se pela possibilidade de incorporação de informações subjetivas no processo de modelagem da série;
- **Automáticos ou da Caixa-preta** - surgiram na década de 60 e incluem os modelos de regressão, média-móveis, ajustamento sazonal e alisamento exponencial [Wheelwright e Makridakis, 1985];
- **Decomposição por componentes não-observáveis** - modelo mais utilizado até a década de 60.

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. As redes neurais artificiais, dentre as muitas técnicas que surgiram, ganharam especial atenção pela sua habilidade de aprendizado e sua capacidade de generalização, associação e busca paralela. Estas qualidades 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 procedimento baseado em redes neurais artificiais, as previsões podem ser classificadas em dois tipos [Chakraborty, 1992]:

- Previsões "multi-step";
- Previsões "single-step".

As previsões *multi-step* são aquelas que se caracterizam por possuir realimentação das saídas das redes neurais artificiais para as entradas das mesmas. Neste tipo de previsão, o sistema neural utiliza um conjunto de valores correntes da série para prever os valores futuros, desta série, por um período fixo. Em seguida, esta previsão é realimentada na entrada do sistema para prever o próximo período. Esse tipo de previsão é muito utilizado para identificar tendências e pontos de mudanças preponderantes nas séries. E, ainda, devido o fato do erro ser inserido a cada nova previsão, elas são utilizadas para prever apenas alguns passos à frente, em média de 15 a 20 passos, quando o erro ainda é aceitável. Por utilizarem realimentação das saídas, as previsões *multi-step* ficam restritas a previsões que se baseiam em uma única série histórica.

Nas previsões *single-step* não existe realimentação. As redes neurais artificiais utilizam apenas os valores anteriores da série para prever um passo à frente. Todavia, este passo tanto pode ser para previsões de curto prazo como para previsões de médio e

longo prazo, bastando que se tenha dados suficientes para treinar a rede. Este tipo de previsão, também serve para avaliar a adaptabilidade e a robustez do sistema, mostrando que mesmo quando as redes neurais artificiais fazem previsões erradas, elas são capazes de se autocorrigir e fazer as próximas previsões corretamente. Como esse tipo de previsão, não utiliza realimentação, podem se basear em uma ou mais séries históricas, tornando-se neste aspecto, muito mais poderosa que as previsões "*multi-step*".

4.5 – Redes Neurais Artificiais na Previsão de Carga

A utilização de redes neurais em previsão de carga tem se mostrado bastante eficaz; o interesse se dá devido o fato da rede neural artificial apresentar maior facilidade de utilização, realizar um mapeamento não-linear da carga elétrica, permitindo a extração de características mais complexas das séries e, por serem capazes de se autocorrigirem mesmo depois de previsões errôneas.

Algumas modelagens podem ser comparadas sob vários aspectos, tais como, tipos de entradas, horizontes de previsão, conjuntos de treinamento e arquitetura da rede. Em alguns casos são utilizadas, como entradas das redes neurais na previsão de carga, somente o histórico da carga. Devido à grande correlação entre a temperatura e o consumo de energia elétrica, tem-se também estudado a utilização de variáveis climáticas na entrada, tais como temperatura, umidade relativa, luminosidade e índices de precipitação.

Através de uma curva de carga pode-se notar que o consumo de energia elétrica é bastante dependente da hora do dia. Observa-se que o horário de maior consumo de energia (horário de pico) ocorre normalmente no mesmo horário para todos os dias da semana. Por isso, um artifício utilizado para melhorar o desempenho das previsões horárias, é fornecer informações sobre a hora do dia como entrada para a rede neural. Assim como a hora do dia, outro fator de grande importância para a previsão de carga é o dia da

semana. A curva de carga tem um comportamento diferente nos fins de semana e nos dias úteis. Portanto, a utilização desta informação na entrada da rede pode apresentar melhores resultados. Para que não seja necessário informar o tipo de dia, pode-se separar os dados de acordo com o perfil identificado da carga e utilizar uma rede para cada tipo encontrado.

No que se refere ao horizonte de previsão, a grande maioria utiliza-se da previsão de carga horária. Para a previsão de carga mensal, é comum a utilização da informação do mês juntamente com o histórico de carga na entrada da rede. Esta informação se torna importante para que a rede neural consiga aprender o comportamento sazonal da série. Os conjuntos de treinamento variam para cada problema; não existe um consenso quanto ao tamanho adequado do conjunto de treinamento para a previsão de carga.

Existem alguns aspectos relevantes a serem analisados quanto a arquitetura da rede neural utilizada, tais como:

- ***Número de camadas escondidas*** - A maioria dos trabalhos utiliza apenas uma camada intermediária nas redes. Lee realizou alguns testes utilizando duas camadas intermediárias, porém, verificou que a utilização de apenas uma camada intermediária levava a melhores resultados [Lee e Park, 1992].
- ***Número de processadores na camada escondida*** - Este parâmetro deve ser escolhido adequadamente, uma vez que tem grande influência sobre o desempenho da rede. A escolha de um número muito elevado de neurônios para a camada escondida faz com que a rede leve muito tempo para treinar e possa ficar muito especializada, perdendo capacidade de generalização. Por outro lado, se o número de neurônios for pequeno demais, a rede poderá não ser capaz de aprender adequadamente o comportamento da série. A determinação deste parâmetro está intimamente ligada ao número de entradas da rede e ao número de padrões de treinamento. Arquiteturas utilizando um número de neurônios na camada escondida maior que o número de entradas

da rede (podendo chegar ao dobro do número de entradas) são as mais encontradas na literatura [Park, El-Sharkawi e Mark, 1991; Peng, Hubele e Karady, 1993]. Pode ocorrer, ainda, a utilização de um número de processadores na camada escondida inferior ao número de entradas da rede.

- **Número de neurônios na camada de saída** – Este número está relacionado ao horizonte da previsão. Quando se deseja, por exemplo, prever a carga horária para um dia inteiro, pode-se utilizar 24 saídas na rede neural. Entretanto, se a opção escolhida for à utilização de apenas uma saída para a rede, pode-se proceder de duas maneiras: realizar as 24 previsões utilizando na entrada da rede apenas dados do histórico de carga – previsão *single-step*; e realimentar a rede com a previsão realizada para fazer uma nova previsão – previsão *multi-step*.

4.6 - Conclusão

A utilização das redes neurais artificiais na previsão de cargas elétricas tem ocorrido, freqüentemente, devido sua habilidade de aprendizado e sua capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, tais como, sazonalidade, periodicidade, tendências, entre outras, sem necessitar da trabalhosa formulação teórica, imprescindível para os procedimentos estatísticos; destacando ainda sua eficácia ao realizar um mapeamento não-linear da carga elétrica, permitindo a extração de características mais complexas das séries.

Neste capítulo, apresentou-se o objetivo da previsão de carga, ressaltando sua importância para o sistema elétrico; horizontes e procedimentos de previsão e, os principais aspectos da utilização de redes neurais artificiais na previsão de cargas elétricas.

APLICAÇÃO

5.1 – Introdução

O algoritmo Retropropagação é considerado, na literatura, um referencial em termos de precisão; logo, vem se tornando uma das principais ferramentas utilizadas para resolver problemas reais, neste caso, 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 utilizada no algoritmo, como a saída da rede neural é processada e, principalmente, qual o tempo de processamento gerado por elas, já que umas das desvantagens do algoritmo é apresentar convergência lenta.

Neste capítulo 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 cargas elétricas. Descreve-se, ainda, todo procedimento utilizado para previsão e análise dos resultados.

5.2 – 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 utilizando 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 5.1.




Figura 5.1 – 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, é necessário, 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].

5.2.1 - Estratégias para Treinamento da rede Perceptron Multicamadas

O treinamento de uma rede perceptron multicamadas, utilizando 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 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 utilizada como uma ferramenta para classificação de novos dados. Para isso, a rede deverá ser utilizada 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.

De forma a entender melhor o funcionamento do algoritmo Retropropagação, a seguir, será apresentada a formulação detalhada do método.

5.2.2 - Algoritmo Retropropagação

A primeira concepção do algoritmo Retropropagação foi apresentada em 1974 por Werbos [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 escondida 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.

O algoritmo Retropropagação é um procedimento sistemático de adaptação de pesos das redes neurais, baseado no método do gradiente descendente [Krose e Smagt, 1996; Wasserman, 1989]. A adaptação de pesos é realizada de tal forma que o erro quadrático da rede seja minimizado. A soma dos erros quadráticos instantâneos de cada neurônio da última camada (saída da rede) é dada por [Widrow e Lehr, 1990]:

$$\varepsilon^2 = \sum_{i=1}^{NS} \varepsilon_i^2 \quad (5.1)$$

em que:

$$\varepsilon_i = d_i - y_i \quad (5.2)$$

sendo:

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.

A saída y_i é dada através da soma das entradas relacionadas aos respectivos pesos:

$$y_i = \phi(s_i) \quad (5.3)$$

em que:

$$s_i = \sum x_i V_i \quad (5.4)$$

sendo:

x_i = entradas do neurônio i ;

V_i = vetor contendo os pesos do neurônio i .

Considerando o i -ésimo neurônio da rede, e utilizando o método do gradiente descendente, o ajuste de pesos pode ser formulado da seguinte forma [Widrow e Lehr,1990]:

$$V_i(h+1) = V_i(h) - \theta_i(h) \quad (5.5)$$

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 ;

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

A direção adotada na equação (5.5), para minimização do erro quadrático, corresponde à direção contrária ao gradiente. O parâmetro g determina o comprimento do vetor $\theta_i(h)$.

O gradiente $\nabla_i(h)$ pode ser representado da seguinte forma [Widrow e Lehr, 1990]:

$$\nabla_i(h) = \frac{\partial \varepsilon_i^2}{\partial V_i(h)} = 2 \varepsilon_i \frac{\partial \varepsilon_i}{\partial V_i(h)}. \quad (5.6)$$

Diferenciando a equação (5.2), com relação ao vetor V_i , obtém-se:

$$\frac{\partial e_i}{\partial V_i(h)} = - \frac{\partial y_i}{\partial V_i(h)} \quad (5.7)$$

em que:

$$\frac{\partial y_i}{\partial V_i(h)} = \frac{\partial y_i}{\partial s_i} \frac{\partial s_i}{\partial V(h)_i} = \sigma_i \frac{\partial s_i}{\partial V(h)_i}. \quad (5.8)$$

Na equação (5.8), σ_i é definido como sendo a derivada da função de ativação, relativa a s_i . É possível, ainda, observar que:

$$\frac{\partial s_i}{\partial V_i(h)} = X_i, \quad (5.9)$$

sendo X_i , definido como sendo o vetor padrão; $X_i = [x_{0i} \ x_{1i} \ x_{2i} \ \mathbf{L} \ x_{mi}]^T$.

Desta maneira, utilizando o método do gradiente descendente, obtém-se o seguinte esquema para adaptação dos pesos [Widrow e Lehr, 1990]:

$$V_i(h+1) = V_i(h) + 2\gamma \beta_i X_i . \quad (5.10)$$

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

$$\beta_i = \sigma_i \varepsilon_i . \quad (5.11)$$

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

$$\beta_i = \sigma_i \sum_{j \in Q(i)} w_{ij} \beta_j \quad (5.12)$$

em que:

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

O treinamento, via algoritmo Retropropagação, é iniciado pela apresentação de um padrão X à rede, o qual produzirá uma saída Y . Em seguida calcula-se o erro de cada saída (diferença entre o valor desejado e saída). O próximo passo consiste na determinação do erro propagado no sentido inverso, utilizando a derivada parcial do erro quadrático de cada elemento com relação aos pesos e, finalmente, ajustando os pesos de cada elemento. Assim, um novo padrão é apresentado; dessa forma, o processo é repetido para todos os padrões até a convergência ($|\text{erro}| \leq \text{tolerância preestabelecida}$). Os pesos iniciais são normalmente adotados como números randômicos, visto que a iniciação nula quase sempre proporciona baixa convergência [Widrow e Lehr, 1990]; estes são iniciados randomicamente considerando-se o intervalo $[0,1]$.

A figura 5.2 ilustra o esquema de adaptação de pesos, utilizado pelo algoritmo retropropagação, na rede perceptron multicamadas.

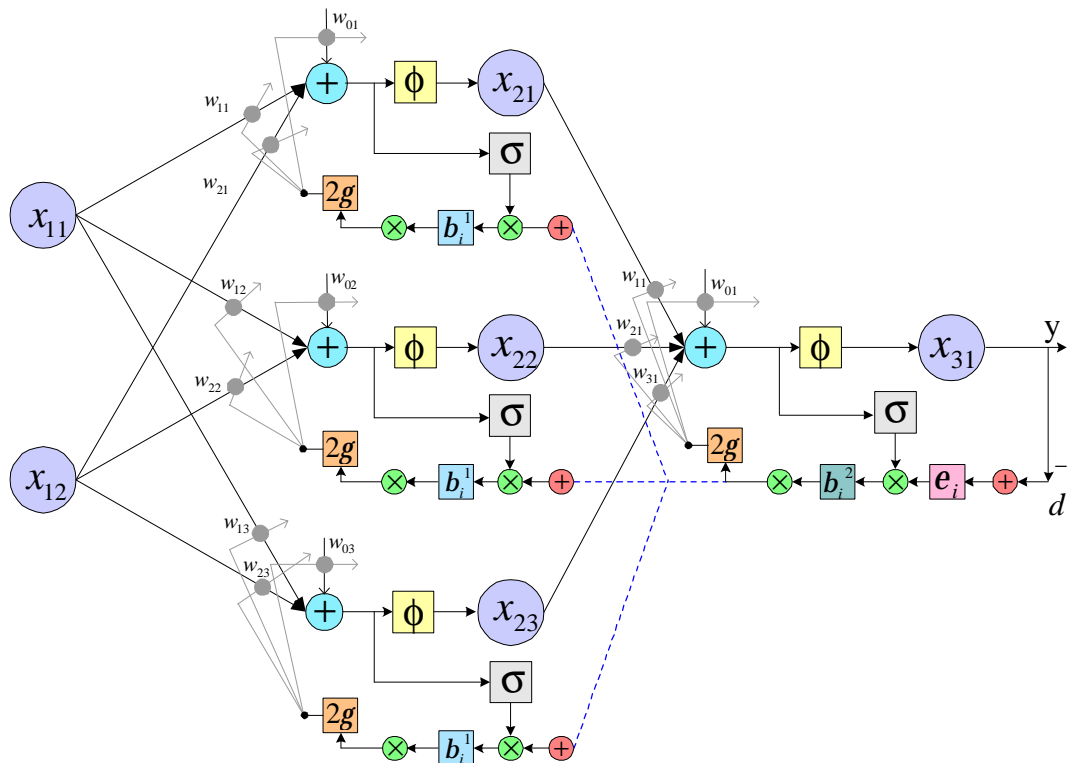


Figura 5.2 – Esquema de adaptação de pesos do algoritmo Retropropagação.

O treinamento, via Retropropagação esquematizado pela figura 5.2, pode ser efetuado, basicamente, de duas formas [Minussi e Silveira, 1995]:

- **Convergência por Padrão:** Consiste em ajustar os pesos da rede (considerando-se todas as camadas), fazendo com que haja convergência para cada padrão, até que se complete o conjunto de padrões de entrada. O processo deverá ser repetido até a total convergência, isto é, o erro quadrático seja inferior a uma tolerância preestabelecida para os padrões considerados.
- **Uma Iteração por Padrão:** Este procedimento é idêntico ao primeiro, porém, fazendo-se somente uma iteração (ajuste de pesos) por padrão.

5.2.3 - Algoritmo Retropropagação com Momento

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 e Lehr, 1990]. O processo de aprendizagem exige que a mudança nos pesos seja proporcional a $\partial \varepsilon_i / \partial V_i$. O gradiente descendente requer que uma infinidade de passos sejam tomados. Considera-se, por exemplo, uma taxa de treinamento grande o possível para que haja oscilação sem direção. Assim, um meio de evitar a oscilação para um valor grande de γ , é tomar uma variação no peso, dependente da variação do peso passado, acrescentando o termo momento. Este procedimento se constitui no algoritmo Retropropagação com Momento [Krose e Smagt, 1996].

A adaptação dos pesos, neste caso, pode ser expressa da seguinte forma [Widrow e Lehr, 1990]:

$$v_{ij}(h+1) = v_{ij}(h) + \Delta v_{ij}(h) \quad (5.13)$$

em que:

$$\nabla v_{ij}(h) = 2\gamma(1-\eta)\beta_j x_i + \eta \Delta v_{ij}(h-1) \quad (5.14)$$

onde:

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

γ = taxa de treinamento;

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

Se o neurônio a ser treinado estiver situado na última camada, ou seja, o elemento j se encontrar na última camada, como mostra a figura 5.3, então:

$$\beta_j = \sigma_j \varepsilon_j \quad (5.15)$$

em que σ_j é a derivada da função de ativação.

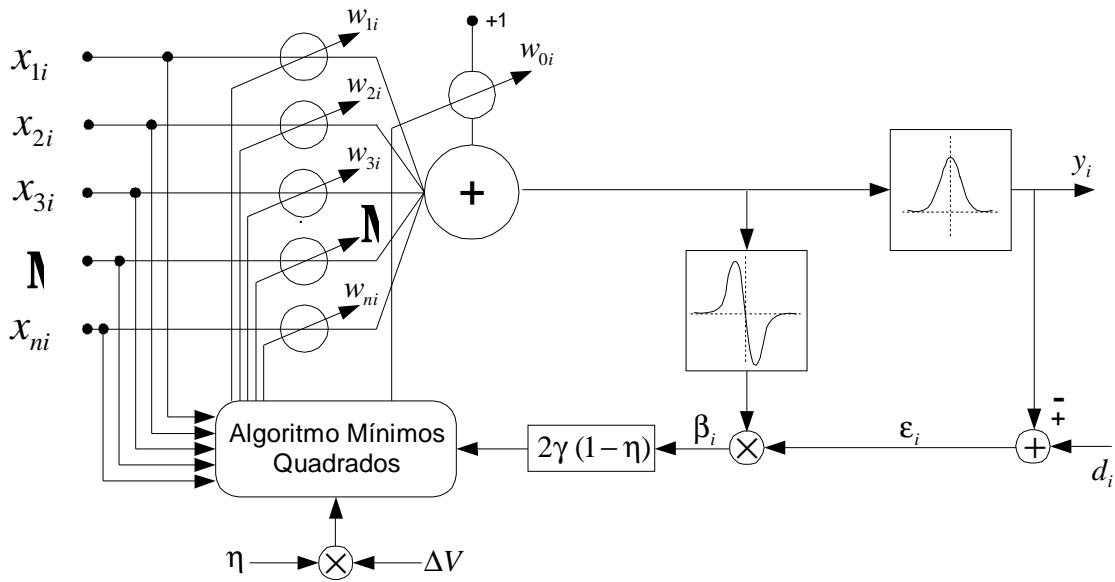


Figura 5.3: Treinamento de um neurônio situado na última camada.

Agora, se o neurônio a ser treinado se encontrar nas demais camadas, ou seja, se o elemento j estiver nas demais camadas, como mostra a figura 5.4, obtém-se:

$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (5.16)$$

sendo:

$R(j)$ = conjunto dos índices dos elementos que se encontram na fileira seguinte à fileira do elemento j e que estão interligados ao elemento j .

Observa-se que o parâmetro γ é tido como controlador de estabilidade do processo iterativo.

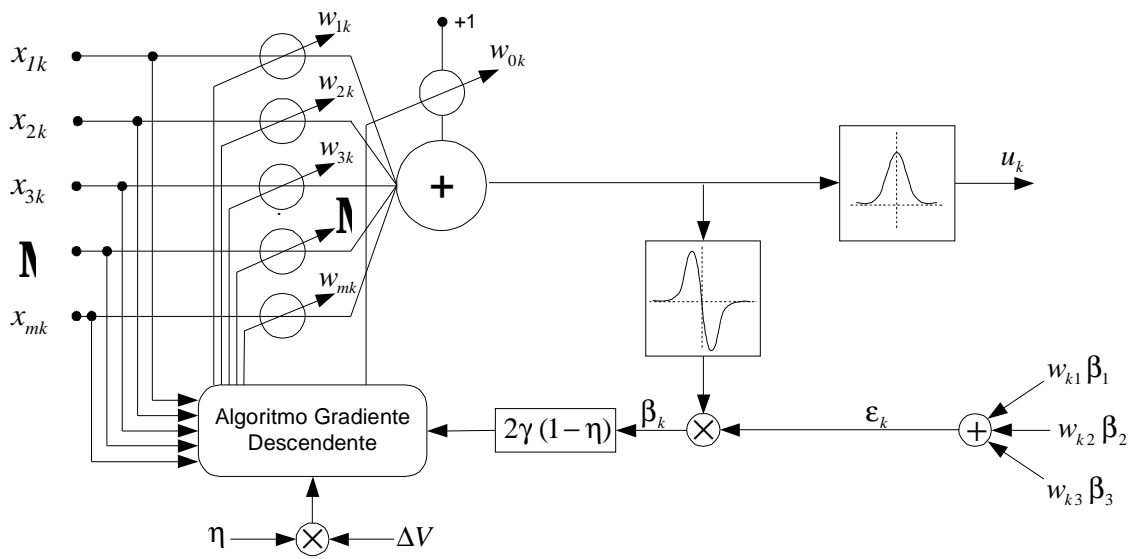


Figura 5.4: Treinamento de um neurônio situado nas demais camadas.

As funções (e derivadas), representadas nas figuras 5.3 e 5.4, descrevem o comportamento das funções de base radial que substituíram a função sigmóide e sua derivada, que vinham sendo utilizadas na literatura.

A figura 5.5 mostra o algoritmo do gradiente descendente no espaço dos pesos, explicitando o comportamento gráfico da taxa de treinamento, exaltando a importância da introdução do termo momento.

A constante a representa uma taxa de treinamento pequena, b uma taxa de treinamento grande (notar oscilações) e c uma taxa de treinamento grande, mas com o termo momento adicionado.




Figura 5.5: Variação das taxas de treinamento no algoritmo gradiente descendente.

Através da figura 5.5, é possível verificar o significado do termo momento; quando este não é utilizado, o algoritmo toma um longo tempo até o mínimo ser alcançado com uma taxa de treinamento baixa, enquanto que para uma taxa de treinamento alta o mínimo nunca é alcançado em consequência das oscilações. Com o momento, o mínimo será obtido rapidamente, a princípio [Krose e Smagt, 1996].

O termo momento promove movimentos em uma direção fixa, de maneira que se vários passos forem tomados na mesma direção, o algoritmo “ganha velocidade” dando a ele capacidade (algumas vezes) de escapar dos mínimos locais e deslocar-se rapidamente sobre lugares planos e planaltos [Statsoft, 2005].

5.2.4 – Vantagens e Desvantagens do Algoritmo Retropropagação

As redes neurais artificiais são aplicadas a problemas de relações dinâmicas ou não-lineares. Elas suprem uma alternativa analítica que as técnicas convencionais limitam-se, muitas vezes, por suposições estritas de normalidade, linearidade, independência de variável, entre outros. Dependendo da natureza da aplicação e da coerência dos padrões de dados internos, em geral, pode-se contar com uma rede que treine muito bem.

As redes neurais artificiais são capazes de adquirir informações que possibilitam, com maior rapidez e facilidade, explicar problemas que vêm sendo difíceis, ou impossíveis, de serem resolvidos. Dentre inúmeras vantagens na utilização das redes neurais artificiais, pode-se citar a inferência de múltiplas variáveis, a grande tolerância à falhas, a modelagem direta do problema e o paralelismo inerente.

Em contrapartida, apesar do sucesso aparente do algoritmo de aprendizado Retropropagação, existem alguns problemas que afeta o seu desempenho. A maior parte dos problemas é devido o processo de treinamento ser bastante longo, podendo assim, causar um resultado de momento e uma taxa de treinamento não ótimos.

Outros fatores que impossibilitam o treinamento do algoritmo Retropropagação podem ser dispostos em duas formas [Krose e Smagt, 1996]:

- **Paralisia da rede:** No decorrer do treinamento, os pesos podem ser ajustados por valores muito grandes. A entrada total de uma unidade (camada) escondida ou unidade de saída pode, assim, alcançar valores muito elevados (positivo ou negativo) e, em consequência da função de ativação, a unidade terá uma ativação muito próxima de zero. Portanto, os pesos ajustados estarão próximos de zero, e o processo de treinamento pode chegar a uma paralisação, ou efeito de paralisia.
- **Mínimos locais:** O erro de superfície de uma rede complexa é cheio de “morros” e “vales”. Em consequência do gradiente descendente, a rede pode ficar confinada em um mínimo local quando existir um mínimo próximo muito profundo. Os métodos probabilísticos podem ajudar a evitar esta adversidade; mas estes, por sua vez, tendem a serem lentos. Outra possibilidade sugerida é aumentar o número de unidades escondidas, aumentando assim, a dimensionalidade do espaço de erro. Isto ocorre, devido o fato de existir limites superiores do número de unidades escondidas que, quando excedida, novamente resultam no sistema sendo apanhado em um mínimo local.

5.3 – O Algoritmo Retropropagação na Previsão de Carga

Para melhor compreensão do algoritmo proposto, com relação à previsão de cargas elétricas, faz-se necessário a apresentação de algumas características importantes.

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.

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 $(h + 1)$.

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 [Lopes, Minussi e Lotufo, 2000]:

$$X(h) = [L(h-3) L(h-2) L(h-1) L(h)]^T, \quad X \in R^m \quad (5.17)$$

$$Y(h) = [L(h+1)], \quad Y \in R^1 \quad (5.18)$$

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 (mês, dia da semana, feriado, hora, etc.) representados de modo similar ao código binário $(-1,+1)$;
 m = dimensão do vetor X .

A escolha desta representação binária 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 sendo mais eficiente.

As cargas elétricas $L(h-3), \mathbf{L}, L(h-1)$ 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. 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 18 que, juntamente com os dados da carga, serão 22 componentes ($m = 22$), ou seja, 4 componentes para o mês, 5 para o dia do mês, 3 para o dia da semana, 1 para o feriado, 5 para a hora e 4 para os dados de carga (corrente mais três anteriores). Os dados históricos foram obtidos de cargas elétricas de uma companhia do setor elétrico brasileiro. Estes dados contêm valores das cargas horárias do ano de 1998, estando eles, relacionados a dias atípicos (feriados), dias especiais (sábados e domingos) e dias de uma semana típica.

Neste trabalho, são consideradas três aplicações, sendo que os arquivos de dados possuem, respectivamente, dados históricos de 21 (Apêndice A1), 42 (Apêndice A2) e 84 dias (Apêndice A3).

Utilizou-se um vetor de entrada de dimensão 12, composto pelo dia da semana e hora do dia, codificados na representação binária, mais a carga horária corrente e os valores de cargas considerando-se três horas anteriores [Altran et al., 2005a; Altran et al., 2005b].

O esquema de previsão de cargas elétricas utilizado é efetuado para três sistemas previsores:

- O primeiro sistema previsor (SP1), contém dados históricos de 21 dias, sendo estes compreendidos entre o dia 8 de julho de 1998 e o dia 28 de julho de 1998. Logo, o arquivo de dados está representado por um vetor de 504 padrões de entrada, com suas respectivas saídas, correspondentes às cargas horárias neste período (21 dias).
- O segundo sistema previsor (SP2), contém dados históricos de 42 dias, estando esses compreendidos entre o dia 17 de junho de 1998 e o dia 28 de julho de 1998. Assim, o arquivo de dados está composto por um vetor de 1008 entradas e respectivas saídas, correspondentes às cargas horárias neste período (42 dias).
- O terceiro sistema previsor (SP3), é composto por dados históricos num total de 84 dias, compreendidos entre o dia 4 de maio de 1998 e o dia 27 de julho de 1998. Portanto, o arquivo de entrada é composto por um vetor de 2016 padrões de entradas e respectivas saídas, correspondentes às cargas horárias neste período (84 dias). É importante ressaltar que o dia 11 de junho de 1998 foi excluído do arquivo de dados, pelo fato de ser um dia atípico (feriado) que, se utilizado, interfere, consideravelmente, nos resultados da previsão.

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 previsor), utilizam-se cinco funções de ativação diferentes; quatro funções de base radial, sendo estas, Gaussiana (G) e Multiquadrática Recíproca (MR), Multiquadrática Recíproca Inversa (MRI), Secante Hiperbólica (SH); e a função Sigmóide (S); e ainda, suas derivadas, que são utilizadas no algoritmo de treinamento. Na tabela 5.1 estão representadas as funções e respectivas derivadas [Altran et al., 2005b].

Tabela 5.1 – 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	$\phi(s) = \frac{2}{e^{cs} + e^{-cs}}$	$\sigma(s) = -\frac{2 (ce^{cs} - ce^{-cs})}{(e^{cs} + e^{-cs})^2}$
	S	$\phi(s) = \frac{1}{1 + e^{-\lambda s}}$	$\sigma(s) = \frac{\lambda}{1 + e^{-\lambda s}} \left[1 - \frac{1}{1 + e^{-\lambda s}} \right]$

Algumas outras funções de base radial, citadas anteriormente (capítulo 3), não foram utilizadas, pois não atendem as exigências (serem limitadas, definidas em todo domínio, etc.) impostas pelo método.

5.4 – 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:

$$MAPE = \frac{1}{N_t} \left\{ \sum_{h=1}^N \left(\frac{|L(h) - \underline{L}(h)|}{L(h)} \right) \right\} \times 100 \quad (5.19)$$

$$Erro \ Máximo \ (%) = \max_{h \in H_d} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100 \quad (5.20)$$

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 ;

N_t = 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 e Minussi, 2000]:

$$GT = \frac{TRPFE}{TRPFA} \quad (5.21)$$

sendo:

TRPFE = tempo de execução do algoritmo Retropropagação utilizando uma das funções de ativação (fixada);

TRPFA = tempo de execução do algoritmo Retropropagação utilizando funções de ativação (gaussiana, multiquadrática recíproca, multiquadrática recíproca inversa, secante hiperbólica e sigmóide).

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

5.5 – Conclusão

O problema da previsão de cargas elétricas é bastante abordado na literatura e, usualmente, sua formulação se dá através de redes neurais artificiais. Trata-se de uma solução baseada no treinamento, considerando dados históricos como, valores da carga, informações sobre o clima, tempo; entre outros.

Neste capítulo foi apresentada a metodologia utilizada, descrevendo o funcionamento do algoritmo Retropropagação, enfatizando a troca da função de ativação convencional, sigmóide, por funções de base radial, para resolução do problema de previsão de cargas elétricas a curto prazo.

Foram descritos os três sistemas previsores, sendo estes, baseados em dados de carga fornecidos por uma empresa do setor elétrico brasileiro. E, por fim, foram apresentados os critérios de avaliação de desempenho, utilizados para realizar a análise de precisão e processamento dos resultados obtidos através do método proposto.

RESULTADOS

6.1 – Introdução

Este capítulo tem por finalidade apresentar os principais resultados obtidos na utilização das redes neurais artificiais na previsão de cargas elétricas a curto prazo (24 horas a frente).

A proposta central foi trabalhar com funções de base radial, como função de ativação de uma rede do tipo perceptron multicamadas, utilizando o algoritmo Retropropagação como algoritmo de treinamento e, não mais a função sigmóide.

Será apresentada uma análise dos resultados obtidos para os três sistemas previsores propostos, tanto em nível de precisão, quanto de processamento. Para tanto, será realizada a comparação, tanto de forma numérica quanto gráfica, entre o método proposto, que utiliza funções de base radial como função de ativação, e o método convencional, que utiliza a função sigmóide como função de ativação.

6.2 – Resultados da Previsão de Cargas Elétricas

A seguir, serão apresentados os resultados, gráficos e numéricos, obtidos através da previsão de cargas elétricas realizada, utilizando redes neurais artificiais, com algoritmo retropropagação, para as diferentes funções de ativação. 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. Para o treinamento e diagnóstico da rede neural, realizou-se uma programação em linguagem Fortran 90, e para análise de resultados de previsão (numéricos e gráficos) utilizou-se programação em Matlab 6. Foi previsto o dia 29 de julho de 1998.

Na rede neural são utilizados os seguintes parâmetros:

- Número de camadas;
- Número de neurônios por camadas;
- Tolerância;
- Taxa de treinamento γ ;
- Momento η ;
- Centro c (para as funções de base radial);
- Inclinação λ (para a função sigmóide).

A escolha dos parâmetros utilizados na rede (tabelas 6.1, 6.3 e 6.5) é realizada através de testes, ou seja, não se utiliza 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.

A análise dos resultados é realizada considerando cada sistema predictor, ou seja, realiza-se a comparação entre os resultados da utilização de cada função para o primeiro, segundo e terceiro sistema predictor.

6.2.1 – Resultados obtidos para o Primeiro Sistema Previsor

Para o primeiro sistema previsor, composto por 504 padrões de entrada, foram realizados vários testes. Porém, optou-se por representar apenas os parâmetros referentes aos melhores resultados para cada função de ativação, como mostra a tabela 6.1.

Tabela 6.1 – Especificação das funções de ativação referente ao primeiro sistema previsor (SP1).

Parâmetro	Função de ativação				
	G	MR	MRI	SH	S
Número de Vetores Padrão	504	504	504	504	504
Número de Camadas	3	3	3	3	3
Número de Neurônios por Camada	12-50-1	12-15-1	12-20-1	12-50-1	12-30-1
Tolerância	0,035	0,030	0,029	0,029	0,020
Taxa de Treinamento γ	1,10	0,99	0,50	1,10	4,50
Termo Momento η	0,70	0,90	0,90	0,90	0,90
Centro c ou Inclinação λ	0,50	0,50	1,25	0,90	0,30

É possível notar, na tabela 6.1, que o número de vetores padrão e o número de camadas são os mesmos para todas as funções de ativação. Quanto ao número de neurônios por camada, foram consideradas fixas as camadas de entrada e saída, com 12 e 1 neurônios, respectivamente; só houve variação do número de neurônios da camada intermediária. Tal variação foi entre 15 e 50 neurônios. A tolerância, relativa ao erro máximo permitido na saída de cada neurônio da última camada, esteve compreendida entre 0,02 e 0,035. A taxa de treinamento da rede neural ficou no intervalo de 0,5 a 1,10, para as funções de base radial e, para a função sigmóide, observou-se que este valor foi con-

sideravelmente maior, 4,50. E, por fim, o centro ou inclinação, ficou em torno de 0,50 a 1,25.

A representação gráfica desses resultados (melhores resultados) é mostrada através das figuras 6.1, 6.2, 6.3, 6.4 e 6.5, para as funções de ativação, Gaussiana (G), Multiquadrática Recíproca (MR), Multiquadrática Recíproca Inversa (MRI), Secante Hiperbólica (SH) e Sigmóide (S), respectivamente.

A curva de carga real, representada graficamente 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 graficamente pela curva vermelha, nada mais é que a saída da rede neural, ou seja, os valores das 24 cargas previstos. O erro percentual da aproximação é representado, numericamente, pelo erro percentual absoluto médio (MAPE) e, também, pelo erro máximo, mostrados pela tabela 6.2.




Figura 6.1 – Resultado da previsão de carga utilizando a função de ativação gaussiana, para o primeiro sistema predictor.




Figura 6.2 – Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca, para o primeiro sistema predictor.




Figura 6.3 – Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca inversa, para o primeiro sistema predictor.




Figura 6.4 – Resultado da previsão de carga utilizando a função de ativação secante hiperbólica, para o primeiro sistema predictor.




Figura 6.5 – Resultado da previsão de carga utilizando a função de ativação sigmóide, para o primeiro sistema predictor.

Através das figuras 6.2 a 6.5, foi possível observar que as aproximações foram boas; o comportamento de ambas as curvas (real e obtida) foi muito parecido, exceto em torno de determinadas horas do dia onde apresentaram um maior erro.

Tabela 6.2 – Resultados comparativos para o primeiro sistema previsor.

Item	Função de ativação				
	G	MR	MRI	SH	S
Número de Iterações	524	1061	2225	1645	1878
Tempo de Processamento (s)	11	7	40	57	33
Ganho GT	3,00	4,71	0,83	0,58	1,00
MAPE (%)	1,30	1,30	1,28	1,11	1,35
Erro Máximo (%)	4,46	3,69	2,72	2,85	3,98

A tabela 6.2 mostra que os resultados das funções permaneceram num mesmo patamar. O número de iterações esteve entre 524 e 2225; o tempo de processamento entre 7 e 57 segundos, ou seja, o tempo gasto para o treinamento e diagnóstico foi, consideravelmente pequeno, sendo assim a função que proporcionou um maior ganho de tempo igual a 4,71 (7 segundos de tempo de processamento) foi a função multiquadrática recíproca. O erro percentual médio absoluto (MAPE), item fundamental na análise dos resultados da previsão, esteve em torno de 1,11 % e 1,30 %, podendo ser considerado um bom resultado, já que os métodos estatísticos utilizados na literatura, apresentam seus melhores resultados em torno de 4 %. E, o erro máximo, ou seja, o erro obtido em algum ponto da curva, esteve entre 2,72 % e 4,46 %.

Assim, foi possível observar que a função de base radial, secante hiperbólica, obteve o melhor resultado entre as funções de ativação utilizadas. Esta apresentou um

MAPE de 1,11 %, melhor resultado entre as funções de base radial, e melhor que o resultado apresentado pela função sigmóide (1,35 %).

Sendo assim, para o primeiro sistema predictor, as funções de base radial apresentaram melhor desempenho se comparadas à função sigmóide, já que todas apresentaram MAPE menor que o obtido pela função sigmóide; mesmo, em alguns casos, apresentando maior tempo de processamento.

6.2.2 – Resultados obtidos para o Segundo Sistema Predictor

Do mesmo modo, para o segundo sistema predictor, composto por 1008 padrões de entrada, também se realizou vários testes, porém, foram representados apenas os parâmetros referentes aos melhores resultados para cada função de ativação, como mostra a tabela 6.3.

Tabela 6.3 – Especificação das funções de ativação referente ao segundo sistema predictor (SP2).

Parâmetro	Função de ativação				
	G	MR	MRI	SH	S
Número de Vetores Padrão	1008	1008	1008	1008	1008
Número de Camadas	3	3	3	3	3
Número de Neurônios por Camada	12-15-1	12-45-1	12-20-1	12-55-1	12-30-1
Tolerância	0,029	0,029	0,029	0,030	0,025
Taxa de Treinamento γ	1,10	0,90	0,82	1,10	5,50
Termo Momento η	0,70	0,75	0,90	0,90	0,90
Centro c ou Inclinação λ	0,40	1,30	1,20	1,00	0,30

Através da tabela 6.3, é possível notar que, do mesmo modo que para o primeiro sistema previsor, o número de vetores padrão e o número de camadas são os mesmos para todas as funções de ativação. Também se fixou o número de neurônios das camadas de entrada e saída, com 12 e 1 neurônios, respectivamente; só houve variação para os neurônios da camada intermediária, tal variação esteve entre 15 e 55 neurônios. A tolerância, esteve compreendida entre 0,025 e 0,030, valores muito parecidos com os assumidos para o primeiro sistema previsor. A taxa de treinamento esteve entre 0,82 e 1,10, para as funções de base radial e, para a função sigmóide, observou-se que este valor foi, novamente bem maior, 5,50. Por fim, o centro ou inclinação, ficou em torno de 0,30 a 1,30.

De forma análoga, a representação gráfica dos resultados obtidos para o segundo sistema previsor é mostrada através das figuras 6.6, 6.7, 6.8, 6.9 e 6.10, para as funções, Gaussiana (G), Multiquadrática Recíproca (MR), Multiquadrática Recíproca Inversa (MRI), Secante Hiperbólica (SH) e Sigmóide (S), respectivamente.

Vale lembrar que a curva de carga real, representada graficamente pela curva azul, é composta pelas 24 cargas horárias reais, ou seja, as cargas reais referentes às 24 horas do dia a ser previsto; já a curva de carga aproximada, representada graficamente pela curva vermelha, nada mais é que a saída da rede neural, ou seja, os valores das 24 cargas previstas.

A análise da previsão é realizada calculando o erro percentual da curva, representado pelo erro percentual absoluto médio (MAPE) e, também, pelo erro máximo; os resultados numéricos estão representados na tabela 6.4.




Figura 6.6 – Resultado da previsão de carga utilizando a função de ativação gaussiana, para o segundo sistema predictor.




Figura 6.7 – Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca, para o segundo sistema predictor.




Figura 6.8 – Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca inversa, para o segundo sistema previsor.




Figura 6.9 – Resultado da previsão de carga utilizando a função de ativação secante hiperbólica, para o segundo sistema previsor.




Figura 6.10 – Resultado da previsão de carga utilizando a função de ativação sigmóide, para o segundo sistema previsor.

Novamente, através das figuras 6.6 a 6.10, foi possível observar que as aproximações foram boas; o comportamento de ambas as curvas (real e obtida) foi muito parecido, melhor do que para o primeiro sistema previsor.

Tabela 6.4 – Resultados comparativos para o segundo sistema previsor.

Item	Função de ativação				
	G	MR	MRI	SH	S
Número de Iterações	9442	1162	661	3228	1019
Tempo de Processamento (s)	110	43	25	243	39
Ganho GT	0,35	0,91	1,56	0,16	1,00
MAPE (%)	0,96	1,06	1,16	1,10	1,12
Erro Máximo (%)	3,89	3,10	3,62	4,00	3,45

Na tabela 5.4 pode-se observar que os resultados permaneceram muito próximos. O número de iterações esteve entre 661 e 9442; o tempo de processamento entre 25 e 243 segundos, sendo assim a função que obteve um maior ganho de tempo, 1,56 (25 segundos de tempo de processamento), foi a função multiquadrática recíproca inversa.

O erro percentual médio absoluto (MAPE), esteve em torno de 0,96 % e 1,16 %, podendo ser considerado um bom resultado, já que, os métodos estatísticos utilizados na literatura, apresentam seus melhores resultados em torno de 4 %, ou mais. O erro máximo, ou seja, o erro obtido em algum ponto da curva, esteve entre 3,10 % e 4,00 %.

Portanto, foi possível observar que a função de base radial, gaussiana, obteve o melhor resultado entre as funções de ativação utilizadas. A mesma, apresentou um MAPE de 0,96 %, melhor resultado entre as funções de base radial, e melhor que o resultado apresentado pela função sigmóide (1,12 %).

Assim, para o segundo sistema predictor, as funções de base radial apresentaram melhor desempenho que a função sigmóide, exceto a função multiquadrática recíproca inversa.

6.2.3 – Resultados obtidos para o Terceiro Sistema Predictor

Da mesma forma que os outros dois sistemas predictors, para o terceiro sistema predictor, composto por 2016 padrões de entrada, foram realizados vários testes, mas, optou-se por representar apenas os parâmetros referentes aos melhores resultados para cada função de ativação, como mostra a tabela 6.5.

Tabela 6.5 – Especificação das funções de ativação referente ao terceiro sistema predictor (SP3).

Parâmetro	Função de ativação				
	G	MR	MRI	SH	S
Número de Vetores Padrão	2016	2016	2016	2016	2016
Número de Camadas	3	3	3	3	3
Número de Neurônios por Camada	12-20-1	12-25-1	12-20-1	12-15-1	12-33-1
Tolerância	0,029	0,029	0,030	0,030	0,030
Taxa de Treinamento γ	0,50	0,90	1,10	1,10	6,50
Termo Momento η	0,90	0,73	0,70	0,90	0,70
Centro c ou Inclinação λ	0,65	0,65	1,20	1,00	0,50

Assim como para os demais casos, na tabela 6.5 encontram-se os parâmetros referentes aos melhores resultados da previsão de cargas elétricas para o terceiro sistema predictor. Também pode-se notar que o número de vetores padrões e o número de camadas são os mesmos para todas as funções de ativação. Analogamente, o número de neurônios das camadas de entrada e saída foram fixados, 12 e 1 neurônios, respectivamente; só houve variação para os neurônios da camada intermediária, tal variação esteve entre 15 e 33 neurônios. A tolerância, relativa ao erro máximo permitido na saída de cada neurônio da última camada, foi de 0,029 e 0,030. A taxa de treinamento esteve entre 0,50 e 1,10, para as funções de base radial e, para a função sigmóide, observou-se que este valor foi maior, 6,50, do mesmo modo que para os outros sistemas predictors. Por fim, o centro ou inclinação, ficou em torno de 0,50 a 1,20.

Novamente, a representação gráfica dos resultados obtidos para o segundo sistema predictor, é mostrada através das figuras 6.11, 6.12, 6.13, 6.14 e 6.15, para as funções, Gaussiana (G), Multiquadrática Recíproca (MR), Multiquadrática Recíproca Inversa (MRI), Secante Hiperbólica (SH) e Sigmóide (S), respectivamente.

Do mesmo modo, a curva de carga real, representada graficamente pela curva azul, é composta pelas 24 cargas horárias reais; já a curva de carga aproximada, representada graficamente pela curva vermelha, nada mais é que a saída da rede neural, ou seja, os valores das 24 cargas previstas.

O erro percentual da aproximação é representado, numericamente, pelo erro percentual absoluto médio (MAPE) e, também, pelo erro máximo, esses resultados numéricos estão representados na tabela 6.6.




Figura 6.11 – Resultado da previsão de carga utilizando a função de ativação gaussiana, para o terceiro sistema previsor.




Figura 6.12 – Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca, para o terceiro sistema predictor.




Figura 6.13 – Resultado da previsão de carga utilizando a função de ativação multiquadrática recíproca inversa, para o terceiro sistema predictor.




Figura 6.14 – Resultado da previsão de carga utilizando a função de ativação secante hiperbólica, para o terceiro sistema previsor.




Figura 6.15 – Resultado da previsão de carga utilizando a função de ativação sigmóide, para o terceiro sistema previsor.

Da mesma forma, as figuras 6.11 a 6.15, mostraram que as aproximações foram boas também; ambas as curvas (real e obtida) tiveram comportamento muito parecido, apresentando também um erro maior em torno apenas algumas horas do dia.

Tabela 6.6 – Resultados comparativos para o terceiro sistema previsor.

Item	Função de ativação				
	G	MR	MRI	SH	S
Número de Iterações	30333	68379	2193	20880	5253
Tempo de Processamento (s)	1042	2048	163	800	231
Ganho GT	0,22	0,11	1,42	0,29	1,00
MAPE (%)	1,03	1,26	1,16	1,24	1,22
Erro Máximo (%)	2,57	3,63	3,81	4,74	3,39

Através da tabela 6.6. pode-se observar que os resultados, para todas as funções envolvidas, permaneceram muito próximos. O número de iterações esteve entre 2193 e 68379; o tempo de processamento entre 163 e 2048 segundos, sendo assim a função que obteve um maior ganho de tempo, 1,42 (163 segundos de tempo de processamento), foi a função multiquadrática recíproca inversa, como para o segundo sistema previsor. O erro percentual médio absoluto (MAPE), item fundamental na análise dos resultados da previsão, esteve em torno de 1,03 % e 1,26 %, podendo ser considerado um bom resultado, já que, os métodos estatísticos utilizados na literatura, apresentam seus melhores resultados em torno de 4 %. E, o erro máximo, ou seja, o erro obtido em algum ponto da curva, esteve entre 2,57 % e 4,74 %.

Portanto, foi possível observar que, novamente, a função gaussiana, obteve o melhor resultado entre as funções de ativação utilizadas, apresentando MAPE de 1,03 %, melhor resultado entre as funções de base radial, e melhor que o resultado apresentado pela função sigmóide (1,22 %).

Assim, para o terceiro sistema predictor, apenas as funções de base radial, gaussiana e multiquadrática recíproca inversa, apresentaram melhor desempenho que a função sigmóide, apesar de todas estarem num mesmo patamar de resultado.

6.3 – Conclusão

O problema da previsão de cargas elétricas é bastante abordado na literatura e, usualmente, sua formulação se dá através de redes neurais artificiais. Trata-se de uma solução baseada no treinamento, considerando-se os dados históricos como: valores da carga, informações sobre o clima, tempo, entre outros.

Neste capítulo, como forma de ilustração da metodologia proposta, foram apresentados os resultados (análise comparativa) da previsão de cargas elétricas, considerando-se os dados históricos de uma companhia do setor elétrico brasileiro. A previsão de carga, a curto-prazo, foi realizada considerando-se 24 horas à frente.

Verificou-se a precisão calculando o erro médio e erro máximo ocorrido, considerando o horizonte de previsão. O cálculo do erro foi realizado tomando a diferença entre a série prevista e os valores conhecidos das cargas (valores de referência). Os resultados foram observados através das tabelas 6.2, 6.4 e 6.6.

Para os três sistemas predictors, observou-se que os resultados estiveram muito próximos, sempre em torno de 1 %, tanto para as funções de base radial quanto para a função sigmóide. Esses resultados são considerados bons para a previsão, visto que, os métodos estatísticos, apresentam os melhores resultados em torno de 4 %.

Sendo assim, a utilização de técnicas baseadas em inteligência artificial se mostrou eficiente para resolução do problema de previsão de cargas elétricas, principalmente quando são aplicadas funções de base radial.

CONCLUSÃO

Este capítulo apresenta as conclusões finais relacionadas ao trabalho desenvolvido, que corresponde à previsão de cargas elétricas, formulada através de redes neurais artificiais com utilização das funções de base radial.

7.1 – 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.

Durante a pesquisa, recebeu maior atenção uma classe especial de funções, as funções de base radial. No contexto de redes neurais artificiais, quando se fala de função de base radial, implicitamente, diz respeito à função Gaussiana, que é utilizada apenas numa rede específica, a rede RBFN (*Radial Basis Function Network*), composta por três camadas apenas, ou seja, uma única camada escondida [Powell, 1985]. Sendo assim, foram pesquisadas outras funções pertencentes a esta classe, tais como as funções Multi-quadrática, Multiquadrática Recíproca, Multiquadrática Recíproca Inversa, Secante Hipérbolica, Spline de Placas Finas. A partir deste fato, surgiu a proposta de analisar o funcionamento desse tipo de funções nas redes neurais artificiais.

Para o problema de previsão de cargas elétricas, com exceção da rede RBFN, todas as outras redes utilizadas, têm a função sigmóide como função de ativação, sendo assim, surgiu a idéia trocar a função sigmóide por funções de base radial e analisar o desempenho das redes neurais artificiais para o referido problema.

A rede neural artificial escolhida para tal proposta foi a rede do tipo perceptron multicamadas, com o algoritmo Retropropagação como algoritmo de treinamento. Isto se deu pelo fato deste algoritmo ser considerado um “referencial” em termos de precisão, sendo uma das principais ferramentas para solução de problemas reais como o de previsão de cargas elétricas.

Para a previsão foram utilizados dados históricos de carga de uma companhia do setor elétrico brasileiro, referentes ao ano de 1998, divididos em três sistemas previsores; o primeiro com 21 dias (504 padrões de entrada), o segundo com 42 dias (1008 padrões de entrada) e o terceiro com 84 dias (2016 padrões de entrada). A previsão de carga realizada foi a curto prazo (previsão diária), considerando-se 24 horas à frente. É de fundamental importância ressaltar que houve uma adaptação nos dados de entrada para

melhor desempenho da rede. Os dados referentes ao tempo (dia da semana e hora) foram representados de forma binária; e relativos à carga, foram normalizados.

Foram realizados inúmeros testes, com diversas variações dos parâmetros utilizados, tanto da rede quanto das funções. Foram utilizadas cinco funções de ativação, sendo quatro funções de base radial, Gaussiana, Multiquadrática Recíproca, Multiquadrática Recíproca Inversa, Secante Hiperbólica; e a função Sigmóide; esta foi utilizada apenas a critério de comparação de dados para que se tornasse possível analisar o desempenho do método.

A análise dos resultados foi realizada através da comparação dos valores reais da carga com os valores estimados obtidos através da rede neural. Isto se deu de duas formas, através dos gráficos das curvas de carga (real e obtida) e através da análise de precisão utilizando o erro percentual absoluto médio (MAPE) e máximo e o erro máximo da previsão. O desempenho do processamento da rede foi analisado através do ganho de tempo de execução (GT), considerando o tempo necessário para o treinamento e diagnóstico, sendo excluídas as operações de leitura e impressão de dados. Toda essa análise é representada no capítulo 6, através de gráficos e tabelas para as referidas funções e sistemas previsores.

Sendo assim, foi possível observar que, para os três sistemas previsores, que a utilização de técnicas baseadas em inteligência artificial, neste caso, redes neurais artificiais, fornecem resultados mais precisos se comparado aos métodos estatísticos encontrados na literatura. Outra observação importante é o fato da rede proposta, perceptron multicamadas com algoritmo Retropropagação, utilizando funções de base radial, apresentar ótimos resultados, ou seja, maior precisão, se comparado ao desempenho da usual, perceptron multicamadas com algoritmo Retropropagação, utilizando a função Sigmóide.

Observou-se, ainda, que os valores dos parâmetros utilizados para o treinamento, relativos aos melhores resultados, para as cinco funções, permaneceram no mesmo patamar para os três sistemas previsores; a não ser, a taxa de treinamento que se apresentou, consideravelmente, maior para a função sigmóide. O mesmo acontece com os parâmetros comparativos, referentes aos resultados, acontece exceto para o tempo de processamento, que foi bem mais elevado, em alguns casos, para as funções de base radial, o que não influenciou para que estas obtivessem melhores resultados para previsão, que a função sigmóide.

Através da infinidade 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. O melhor resultado de previsão foi obtido pela função gaussiana considerando o segundo sistema predictor, apresentando erro percentual absoluto médio de 0,96.

Notou-se que uma modelagem correta das redes neurais artificiais, é um fator essencial para a obtenção de sucesso nas aplicações. O ambiente de simulação desenvolvido atendeu aos propósitos e possibilitou a realização de testes com uma consistente obtenção de resultados. A falta de maior conhecimento das complexas inter-relações entre os diversos parâmetros que influenciam no desempenho da rede, faz com que o sucesso de uma aplicação seja dependente da experimentação prática, o que ocorreu com grande frequência neste trabalho. É importante ressaltar, ainda, que se forem tomados dados históricos coerentes, mais refinados, a rede neural utilizada, provavelmente, fornecerá bons resultados, ou seja, realizará boas previsões, tomando com referência aos resultados obtidos.

Assim, constatou-se que a utilização de redes neurais do tipo perceptron multicamadas, com o algoritmo Retropropagação, como algoritmo de treinamento e, funções de base radial, como função de ativação, é uma ótima escolha para a resolução do problema de previsão de cargas elétricas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R.; VILLARREAL, F. “Um Estudo de Previsão de Cargas Elétricas por Redes Neurais Artificiais”, 4º Congresso Temático de Dinâmica Controle e Aplicações, DINCON 2005, Bauru – SP, 2005.

ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R.; VILLARREAL, F. “Um Estudo de 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.

ASTORINO, M.; RIMONDO, R. “Interpolazione di Curve e Superfici Tramite Funzione Implicite e Loro Triangolazione”, Tesi de Laurea di primo livello - Facolta di Ingegneria dei Sistemi, Politecnico di Milano, Milano, 75p, 2004.

BECKERT, A.; WENDLAND, H. “Multivariate Interpolation in Fluid-Structure-Interaction Using Radial Basis Functions”, Aerospace Science and Technology 5, pp. 125-134, 2001.

BORS, A. G. “Introduction of the Radial Basis Function (RBF) Networks”, Online Symposium for Electronics Engineers, DSP Algorithms: Multimedia, Issue 1, Vol. 1, pp. 1-7, Feb. 2001.

BOX, G. E.; JENKINS, G. M. “Times Series Analysis: Forecasting and Control”, Holden-Day, San Francisco, 1976.

BUHMANN, M. D. “Radial Basis Function”, Cambridge University Press, Acta Numérica, pp. 1-38, 2000.

CHAKRABORTY, K.; MOHAN, C. K.; MEHROTRA, K.; RANKA, S. “Forecasting the Behavior of Multivariate Time Series Using Neural Networks”, Neural Networks E.U.A., No 5, pp. 961-970, 1994.

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, Vol. 6, No 4, pp. 1439 – 1442, July 1995.

CYBENKO, G. “Approximation by Superpositions of Sigmoidal Function Mathematics of Control, Signals, and Systems”, Vol. 2, pp. 303-314, 1989.

FERNANDES, M. A. C.; NETO, A. D. D.; BEZERRA, J. B. “Aplicação das Redes RBF na Detecção Inteligente de Sinais Digitais”, Proceedings of the IV Brazilian Conference on Neural Networks - IV Congresso Brasileiro de Redes Neurais - ITA, São José dos Campos – SP, pp. 226-230, Julho 1999.

FERNANDES, C. M. T. T.; LEITÃO, V. M. A. “Utilização de Funções de Base Radial em Problemas Unidimensionais de Análise Estrutural”, Métodos Numéricos em Ingeniería V, Madrid, Espanha, pp. 338-354, 2002.

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*, Vol. 36, pp. 193-202, 1980.

GIROSI, F.; POGIO, T. “Networks for Learning: A View from the Theory of Approximation of Functions”, *Neural Networks: Concepts, Applications and Implementations*, pp. 110-154, 1991.

GROSSBERG, S. “Adaptive Pattern Classification and Universal Recoding, I: Parallel Development and Coding of Neural Feature Detectors”, *Biological Cybernetics*, Vol. 23, No 3, pp. 121-134, 1976.

GROSSBERG, S. “Adaptive Pattern Classification and Universal Recoding, II: Feedback, Expectation, Olfaction, and Illusions”, *Biological Cybernetics*, Vol. 23, No 4, pp. 187-202, 1976.

HAYKIN, S. “Neural Networks: A comprehensive foundation”, Prentice-Hall, Upper Saddle River, New Jersey, USA, 1994.

HEBB, D. O. “The Organization of Behavior: A Neuropsychological Theory”, Wiley, New York, 1949.

HECHT-NIELSEN, R. “Counterpropagation Networks”, *Proceedings of IEEE International Conference on Neural Networks, II*, IEEE Press, New York, NY, pp. 19-32, 1987

HEIMES, F.; HEUVELN, B. V. “The Normalized Radial Basis Function Neural Network”, *IEEE International Conference on Systems, Man, and Cybernetics*, Vol 2, pp. 1609 – 1614, Oct. 1998.

HOPFIELD, J. J. “Neural Networks and Physical Systems with Emergent Collective Computational Abilities”, Proceedings of the National Academy of Sciences, USA, Vol. 79, pp. 2554-2558, 1982.

KOHONEN, T. “Correlation Matrix Memories”, IEEE Transactions on Computers, Vol. 21, pp. 353-359, 1972.

KOSKO, B. “Bidirectional Associative Memories”, IEEE Transactions on Systems, Man and Cybernetics. Vol. 18, No 1, pp. 49-60, 1988.

KROSE, B.; SMAGT, P. V. “An Introduction to Neural Networks”, University of Amsterdam, Nov. 1996.

LEE, K. Y., PARK, J. H. “Short-Term Load Forecasting Using An Artificial Neural Network”, IEEE Transaction On Power System, Vol. 7, No 1, Feb. 1992.

LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. P. “A Fast Electric Load Forecasting Using Neural Networks”, 43rd Midwest Symposium on Circuits and Systems, Lansing – Michigan, USA, August 2000.

LOPES, M. L. M.; MINUSSI, C. R. “Treinamento de Redes Neurais via Back-Propagation com Controlador Nebuloso”, XVIII Congresso Brasileiro de Automática, UFSC, pp. 1616 – 1621, Setembro 2000.

MACHADO, R. J.; ROCHA, A. F. “Handling Knowledge in High Order Neural Networks: The Combinatorial Neural Network”, Rio de Janeiro: IBM Rio Scientific Center, Brazil, 1989 (Technical Report CCR076).

MARK, J. L. O. “Introduction to Radial Basis Function Network”, Centre For Cognitive Science, University of Edinburgh, Scotland, Apr. 1996.

MAI-DUY, N.; TRAN-CONG, T. “Approximation of Function and its Derivatives Using Radial Basis Function Networks”, Elsevier Applied Mathematical Modelling, Vol. 27, pp. 197-220, Sept. 2003.

MCCULLOCH, W. S.; PITTS, W. A. “A Logical Calculus of the Ideas Immanent in Nervous Activity”, Bull Math Biophys, Vol. 5, pp. 115-133, 1943.

MICCHELLI, C. A. “Interpolation of Scatter Data: Distance Matrices and Conditionally Positive Definite Functions”, Constructive Approximation, Vol. 2, pp. 11 – 22, 1986.

MINSK, M.; PAPERT, S. “Perceptrons”, Cambridge, MA: MIT Press, 1969.

MINUSSI, C. R.; SILVEIRA, M, C. G. “Electric Power System Transient Stability by Neural Networks”, 38th Midwest Symposium on Circuits and System, Rio de Janeiro – RJ, pp. 1305 – 1308, 1995.

MOHAMED, E. A.; MANSOUR, M. M.; EL-DEBEIKY, S.; MOHAMED, K. G. “Egyptian Unified Grid Hourly Load Forecasting Using Artificial Neural Network”, Electrical Power & Energy Systems, Vol. 20, No 7, pp. 495 – 500, 1998.

MULGREW, B. “Applying Radial Basis Function”, IEEE Signal Processing Magazine, Vol. 13, No 2, pp. 50 – 65, March 1996.

PARK, D. C.; EL-SHARKAWI, R. J.; MARKS II, L. E. “Electric Load Forecasting Using an Artificial Neural Network”, IEEE Transaction on Power System, Vol. 6, No 2, May 1991.

PENG, T. M.; HUBELE, N. F.; KARADY, G. G. “An Adaptive Neural Network Approach to One-Week Ahead Load Forecasting”, IEEE Transaction on Power System, Vol. 8, No 3, Aug. 1993.

POGGIO, T.; GIROSI, F. "Networks for Approximation and Learning", Proceedings of the IEEE, Vol. 78, No 9, Sept. 1990.

POWELL, M. J. D. "Radial Basis Functions for Multivariable Interpolation", IMA Conference on Algorithms for the Approximation of Functions and Data, RCMS Shrivvenham, UK, pp. 143-167, 1985.

POWELL, M. J. D. "Radial Basis Function Methods for Interpolation to Functions of Many Variables", NA 2001/11, DAMTP, University of Cambridge – Numerical Analysis Group, 2001.

ROSENBLATT, F. "Principles of Neurodynamics", DC: Spartan Books, New York, 1962.

ROSENBLATT, F. "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain", Psychological Review, Vol. 65, pp. 386-408, 1958.

RUMELHART, D. E.; HILTON, G. E.; WILLIAMS, R. J. "Learning Representations of Back-propagation Errors", Nature, No 323, pp. 533-536, 1986.

SOUZA, R. C. "Modelos Estruturais para Previsão de Séries Temporais: Abordagem Clássica e Bayesiana", 17º Colóquio Brasileiro de Matemática, RJ: IMPA, 1989.

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, Vol. 145, No 6, pp. 687 – 692, November 1998.

STATSOFT R. "Eletronic Text Book Statsoft – Neural Networks", Disponível em: <<http://www.statsoft.com/textbook/stathome.html>>. Acesso em: 05 de Janeiro de 2005.

VELLASCO, M.; PACHECO, M. A. C.; FIGUEIREDO, K.; RIBEIRO NETO, L. S. "Modeling Neural Nets to Very Short-Term Load Forecasting", *International Journal of Forecasting*, 1999.

WASSERMAN, P. D. "Neural Computing – Theory and Practice", Van Nostrand Reinhold, 1989.

WENDLAND, H. "On the Smoothness of Positive Definite and Radial Functions", *Journal of Computational and Applied Mathematics* (101), pp. 177-188, 1999.

WENDLAND, H.; SCHABACK, R. "Characterization and Construction of Radial Basis Functions", *Multivariate Approximation and Applications*, Cambridge University Press, Cambridge, 2001.

WERBOS, P. J. "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences", PHD Thesis - Harvard University, 1974.

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. "Forecasting Methods for Management", 4th edition, New York: John Wiley & Sons Inc, 1985.

WIDROW, B; LEHR, M. A. "30 Years of Adaptive Neural Networks: Perceptron, Madaline and Backpropagation", *Proceedings of the IEEE*, Vol. 78, No 9, pp. 1415-1442, Sept. 1990.

WIDROW, B.; HOFF, M. E. "Adaptive Switching Circuits", *IRE WESCON Convention Record*, New York: IRE, Part 4, pp. 96-104, 1960.

APÊNDICE A

Este apêndice apresenta os arquivos de dados históricos de cargas elétricas fornecidos por uma companhia do setor elétrico brasileiro, utilizados para realizar o treinamento da arquitetura da rede neural proposta.

Estes dados contêm valores das cargas horárias do ano de 1998. No apêndice A1, está a composição de um arquivo de dados composto por dados históricos de 21 dias, compreendido entre os dias 8 e 28 de julho de 1998, num total de 504 vetores de entrada. O apêndice A2 compõe um arquivo de 42 dias e os dados históricos estão compreendidos entre o dia 17 de junho de 1998 e o dia 28 de julho de 1998 resultando num arquivo de entradas formado por 1008 vetores. E, finalmente, o apêndice A3 contém 84 dias, compreendidos entre o dia 4 de maio de 1998 e o dia 27 de julho de 1998, dando origem ao vetor de entrada composto por 2016 vetores.

A1 – Primeiro Sistema Previsor (SP1)

Dados de Potência Ativa em MVA

Hora	Dias																				
	08/7	09/7	10/7	11/7	12/7	13/7	14/7	15/7	16/7	17/7	18/7	19/7	20/7	21/7	22/7	23/7	24/7	25/7	26/7	27/7	28/7
01	2588,5	2615,6	2580,1	2612,3	2442,1	2300,0	2459,6	2469,9	2554,7	2552,2	2666,6	2626,6	2371,0	2578,7	2572,2	2613,1	2603,5	2600,7	2537,5	2461,2	2615,5
02	2450,4	2477,3	2478,4	2467,2	2325,6	2194,3	2303,6	2377,2	2416,5	2419,8	2505,7	2504,2	2357,8	2421,4	2437,3	2468,9	2465,3	2466,2	2400,4	2355,1	2471,1
03	2396,6	2428,2	2423,2	2386,5	2277,4	2157,0	2273,3	2311,9	2348,4	2353,3	2434,4	2388,4	2256,4	2411,1	2388,4	2417,1	2420,4	2348,4	2329,4	2284,3	2382,8
04	2343,9	2402,0	2376,6	2325,7	2227,3	2114,7	2232,2	2279,2	2303,9	2347,0	2373,2	2337,7	2246,7	2368,5	2368,2	2380,1	2367,5	2361,1	2280,4	2237,1	2381,3
05	2364,3	2423,1	2384,1	2329,0	2195,4	2164,1	2257,4	2284,4	2336,2	2350,2	2391,2	2345,0	2254,1	2398,2	2403,1	2410,0	2398,0	2356,3	2240,8	2263,8	2406,4
06	2442,7	2508,9	2464,8	2344,4	2211,2	2227,5	2388,6	2406,0	2412,9	2446,1	2400,1	2323,3	2353,1	2468,3	2498,5	2502,2	2502,9	2379,3	2260,1	2359,8	2491,7
07	2663,8	2727,4	2746,5	2381,4	2189,7	2462,5	2550,0	2559,2	2592,6	2646,9	2395,7	2279,2	2530,4	2625,1	2639,7	2648,3	2674,3	2363,1	2177,9	2508,7	2623,7
08	2792,0	2892,1	2844,8	2413,2	2183,4	2682,2	2667,2	2702,2	2764,5	2777,2	2427,0	2255,9	2763,2	2812,2	2814,0	2831,5	3016,2	2442,3	2185,1	2705,8	2775,3
09	3027,1	3152,7	3009,1	2598,8	2265,7	2892,8	2854,6	2928,1	2950,7	3022,9	2693,0	2313,7	2990,9	3029,8	3086,8	3098,6	3145,1	2558,9	2286,8	2980,2	3041,2
10	3176,8	3250,1	3154,1	2708,8	2367,6	3047,1	2969,6	3038,5	3077,6	3143,3	2730,2	2336,1	3157,4	3211,7	3248,7	3146,3	3259,3	2677,9	2328,5	3151,7	3168,7
11	3250,9	3332,2	3216,9	2733,6	2400,8	3125,4	3034,7	3071,7	3159,6	3192,1	2758,2	2358,1	3232,1	3262,5	3264,9	3211,9	3303,6	2747,8	2367,9	3242,9	3249,9
12	3366,2	3347,4	3221,7	2716,7	2382,6	3072,7	3063,4	3170,4	3169,0	3224,8	2741,8	2415,9	3236,2	3280,3	3248,9	3289,8	3290,4	2748,7	2381,5	3269,0	3269,0
13	3351,0	3334,5	3192,6	2721,5	2394,8	3093,6	3031,3	3121,7	3143,6	3198,3	2759,3	2438,9	3165,7	3388,8	3232,8	3290,5	3259,9	2747,8	2421,9	3271,9	3237,5
14	3349,0	3359,5	3179,5	2710,2	2373,6	3110,2	3056,9	3123,0	3154,7	3246,8	2781,9	2392,0	3213,1	3412,8	3257,3	3324,9	3326,3	2726,7	2387,7	3340,5	3325,6
15	3429,4	3284,7	3210,8	2689,6	2336,6	3087,8	3085,0	3145,8	3211,6	3254,5	2745,7	2360,9	3262,1	3435,4	3262,6	3314,1	3336,1	2673,6	2367,9	3340,0	3336,7
16	3447,8	3295,4	3239,7	2719,7	2304,6	3113,4	3052,9	3178,8	3206,5	3237,8	2673,4	2339,1	3279,7	3464,0	3289,2	3311,7	3273,6	2675,9	2312,2	3292,7	3353,4
17	3400,9	3403,6	3161,7	2728,7	2111,4	3195,1	3099,0	3204,7	3270,3	3260,9	2699,0	2429,6	3365,7	3374,4	3334,2	3336,2	3301,3	2637,6	2396,5	3330,2	3347,0
18	3531,4	3569,2	3300,4	3014,4	2383,6	3345,3	3313,8	3349,5	3390,2	3380,8	3017,3	2871,9	3466,5	3489,9	3379,2	3447,2	3434,4	2979,3	2717,2	3390,5	3382,0
19	3803,1	3715,9	3594,8	3376,2	2932,4	3553,4	3567,3	3654,3	3682,3	3667,5	3451,0	3247,6	3643,4	3757,2	3626,6	3586,4	3567,5	3409,3	3218,9	3655,2	3667,4
20	3589,6	3512,6	3461,3	3316,3	3006,1	3401,8	3424,2	3457,8	3502,2	3498,2	3423,9	3182,6	3510,0	3613,3	3446,9	3448,9	3421,4	3310,8	3176,4	3490,9	3508,6
21	3503,7	3438,2	3349,8	3254,3	2964,0	3305,5	3322,1	3389,9	3415,7	3431,6	3339,0	3161,7	3472,1	3514,7	3420,4	3418,0	3338,2	3250,2	3134,5	3411,8	3421,2
22	3524,5	3449,0	3341,2	3157,4	2862,2	3304,7	3325,2	3392,1	3414,0	3374,8	3227,0	3110,8	3446,0	3427,0	3385,6	3352,8	3322,9	3216,9	3053,9	3395,3	3425,7
23	3223,4	3175,5	3149,8	2967,2	2705,5	3027,5	3045,1	3153,1	3149,3	3205,5	3095,2	2960,6	3182,9	3200,5	3181,7	3188,6	3113,6	2977,2	2939,6	3206,3	3210,5
24	2934,4	2822,2	2893,2	2713,0	2496,2	2728,5	2736,0	2830,2	2885,9	2961,9	2879,4	2754,4	2910,5	2856,1	2898,1	2910,8	2860,1	2766,9	2704,0	2882,2	2941,4

A2 – Segundo Sistema Previsor (SP2)

Dados de Potência Ativa em MVA

Hora	Dias																				
	17/6	18/6	19/6	20/6	21/6	22/6	23/6	24/6	25/6	26/6	27/6	28/6	29/6	30/6	01/7	02/7	03/7	04/7	05/7	06/7	07/7
01	2541,6	2605,6	2620,4	2630,9	2438,8	2264,9	2440,4	2513,4	2588,8	2499,3	2581,7	2478,0	2435,4	2574,6	2515,5	2575,1	2665,7	2613,8	2582,3	2480,3	2619,2
02	2399,8	2450,1	2462,3	2474,6	2317,7	2163,3	2305,7	2366,2	2387,1	2367,6	2405,1	2357,3	2302,6	2396,7	2345,4	2460,9	2511,6	2487,7	2418,9	2354,9	2488,9
03	2366,2	2388,2	2435,1	2383,2	2259,9	2110,3	2267,7	2312,1	2348,3	2315,8	2340,9	2274,0	2284,2	2287,3	2350,6	2364,7	2440,8	2406,7	2342,3	2293,1	2402,9
04	2329,3	2396,3	2371,6	2342,9	2187,3	2094,4	2231,9	2299,9	2370,6	2300,6	2324,8	2236,9	2254,8	2241,1	2318,9	2350,6	2423,3	2368,4	2302,8	2260,5	2335,2
05	2364,7	2388,5	2394,3	2359,2	2187,7	2137,5	2271,2	2301,7	2396,9	2347,5	2290,9	2189,7	2282,5	2286,7	2334,9	2360,7	2425,9	2335,7	2262,5	2282,8	2414,7
06	2492,1	2478,5	2508,8	2386,0	2183,2	2237,1	2356,4	2408,1	2488,5	2427,4	2317,4	2169,7	2390,2	2384,3	2429,0	2440,6	2501,6	2381,4	2241,5	2410,4	2490,1
07	2729,8	2731,3	2718,5	2439,4	2166,3	2489,3	2595,7	2605,6	2722,4	2668,1	2321,5	2158,8	2626,8	2580,4	2616,4	2684,7	2639,8	2446,1	2231,7	2628,4	2714,7
08	2831,8	2835,3	2832,5	2488,8	2133,3	2689,7	2728,0	2789,7	2889,2	2772,6	2393,1	2144,0	2797,7	2720,7	2778,1	2781,7	2805,6	2455,9	2181,8	2786,3	2841,6
09	3027,0	3024,5	3082,8	2656,7	2205,1	2896,1	2948,4	3034,8	3063,8	2956,4	2581,4	2283,0	2949,1	2912,5	2969,1	3000,7	3016,2	2598,0	2293,2	2976,2	3083,9
10	3141,9	3168,4	3251,1	2788,7	2339,3	3057,1	3099,4	3122,5	3225,2	3105,4	2697,9	2313,3	3124,0	3068,9	3090,0	3146,7	3163,4	2731,0	2337,7	3153,4	3171,5
11	3194,8	3238,7	3381,0	2837,9	2410,8	3154,5	3150,5	3206,2	3280,0	3199,6	2738,4	2377,6	3194,4	3147,3	3201,8	3212,6	3259,2	2763,4	2348,7	3279,4	3215,2
12	3258,8	3247,0	3381,6	2831,1	2439,7	3201,8	3153,1	3253,4	3304,3	3151,1	2734,6	2412,3	3258,4	3190,5	3261,9	3330,7	3239,3	2803,0	2402,7	3294,9	3206,1
13	3256,6	3178,5	3363,6	2790,8	2451,0	3149,5	3148,4	3255,7	3291,9	3173,2	2717,7	2441,8	3264,7	3161,8	3240,2	3333,4	3205,6	2822,3	2392,4	3289,0	3183,6
14	3236,5	3174,7	3374,1	2809,1	2455,9	3140,3	3092,7	3285,5	3283,4	3192,1	2660,9	2432,4	3264,4	3156,0	3241,3	3345,3	3163,2	2767,3	2388,4	3314,5	3133,8
15	3265,1	3207,4	3379,2	2796,3	2433,5	3132,3	2922,4	3296,2	3243,9	3205,3	2616,2	2409,1	3256,2	3205,8	3251,9	3330,7	3010,5	2745,7	2351,6	3331,5	2968,2
16	3263,4	3211,7	3376,1	2751,1	2420,0	3129,3	2791,6	3309,6	3225,5	3190,0	2536,7	2351,9	3249,0	3202,9	3237,9	3348,6	2830,4	2737,2	2339,7	3339,7	2805,8
17	3331,3	3287,9	3364,4	2792,7	2471,1	3176,7	2479,9	3332,5	3224,5	3163,1	2307,6	2401,3	3271,8	3228,6	3301,4	3387,1	2538,7	2738,0	2412,4	3333,2	2549,6
18	3606,7	3538,4	3602,9	3181,5	2914,5	3348,6	2698,6	3598,5	3389,4	3432,1	2658,7	2858,7	3476,3	3432,2	3450,8	3552,1	2718,5	3127,4	2884,9	3476,5	2671,6
19	3718,4	3695,9	3730,3	3328,9	3136,1	3513,0	3272,8	3741,8	3556,8	3558,3	3289,2	3232,5	3673,1	3610,7	3706,5	3712,3	3298,9	3487,4	3261,2	3699,0	3062,1
20	3517,3	3519,3	3536,5	3240,2	3038,5	3383,2	3223,3	3540,6	3463,2	3400,8	3255,3	3158,5	3528,9	3484,1	3518,5	3534,1	3262,8	3376,2	3174,8	3489,7	3192,9
21	3434,1	3472,8	3488,4	3165,1	2971,4	3345,0	3194,2	3446,0	3320,6	3364,0	3152,4	3100,9	3384,9	3450,6	3444,3	3503,0	3229,2	3286,3	3152,7	3415,0	3248,9
22	3414,3	3393,9	3360,0	3028,3	2889,9	3230,9	3246,8	3434,9	3252,7	3305,8	3075,3	3006,2	3335,7	3339,9	3413,9	3425,1	3261,7	3181,8	3045,2	3519,4	3296,7
23	3222,0	3193,6	3242,5	2873,0	2726,3	3024,5	3052,5	3207,6	3024,0	3097,5	2938,9	2903,1	3147,3	3160,4	3191,3	3212,3	3160,4	2964,1	2908,2	3180,2	3160,0
24	2880,7	2917,0	2941,9	2694,1	2516,7	2671,9	2793,5	2878,8	2756,6	2852,0	2723,6	2672,9	2841,6	2839,5	2899,1	2947,6	2884,8	2765,7	2699,8	2898,7	2854,0

Hora	Dias																				
	08/7	09/7	10/7	11/7	12/7	13/7	14/7	15/7	16/7	17/7	18/7	19/7	20/7	21/7	22/7	23/7	24/7	25/7	26/7	27/7	28/7
01	2588,5	2615,6	2580,1	2612,3	2442,1	2300,0	2459,6	2469,9	2554,7	2552,2	2666,6	2626,6	2371,0	2578,7	2572,2	2613,1	2603,5	2600,7	2537,5	2461,2	2615,5
02	2450,4	2477,3	2478,4	2467,2	2325,6	2194,3	2303,6	2377,2	2416,5	2419,8	2505,7	2504,2	2357,8	2421,4	2437,3	2468,9	2465,3	2466,2	2400,4	2355,1	2471,1
03	2396,6	2428,2	2423,2	2386,5	2277,4	2157,0	2273,3	2311,9	2348,4	2353,3	2434,4	2388,4	2256,4	2411,1	2388,4	2417,1	2420,4	2348,4	2329,4	2284,3	2382,8
04	2343,9	2402,0	2376,6	2325,7	2227,3	2114,7	2232,2	2279,2	2303,9	2347,0	2373,2	2337,7	2246,7	2368,5	2368,2	2380,1	2367,5	2361,1	2280,4	2237,1	2381,3
05	2364,3	2423,1	2384,1	2329,0	2195,4	2164,1	2257,4	2284,4	2336,2	2350,2	2391,2	2345,0	2254,1	2398,2	2403,1	2410,0	2398,0	2356,3	2240,8	2263,8	2406,4
06	2442,7	2508,9	2464,8	2344,4	2211,2	2227,5	2388,6	2406,0	2412,9	2446,1	2400,1	2323,3	2353,1	2468,3	2498,5	2502,2	2502,9	2379,3	2260,1	2359,8	2491,7
07	2663,8	2727,4	2746,5	2381,4	2189,7	2462,5	2550,0	2559,2	2592,6	2646,9	2395,7	2279,2	2530,4	2625,1	2639,7	2648,3	2674,3	2363,1	2177,9	2508,7	2623,7
08	2792,0	2892,1	2844,8	2413,2	2183,4	2682,2	2667,2	2702,2	2764,5	2777,2	2427,0	2255,9	2763,2	2812,2	2814,0	2831,5	3016,2	2442,3	2185,1	2705,8	2775,3
09	3027,1	3152,7	3009,1	2598,8	2265,7	2892,8	2854,6	2928,1	2950,7	3022,9	2693,0	2313,7	2990,9	3029,8	3086,8	3098,6	3145,1	2558,9	2286,8	2980,2	3041,2
10	3176,8	3250,1	3154,1	2708,8	2367,6	3047,1	2969,6	3038,5	3077,6	3143,3	2730,2	2336,1	3157,4	3211,7	3248,7	3146,3	3259,3	2677,9	2328,5	3151,7	3168,7
11	3250,9	3332,2	3216,9	2733,6	2400,8	3125,4	3034,7	3071,7	3159,6	3192,1	2758,2	2358,1	3232,1	3262,5	3264,9	3211,9	3303,6	2747,8	2367,9	3242,9	3249,9
12	3366,2	3347,4	3221,7	2716,7	2382,6	3072,7	3063,4	3170,4	3169,0	3224,8	2741,8	2415,9	3236,2	3280,3	3248,9	3289,8	3290,4	2748,7	2381,5	3269,0	3269,0
13	3351,0	3334,5	3192,6	2721,5	2394,8	3093,6	3031,3	3121,7	3143,6	3198,3	2759,3	2438,9	3165,7	3388,8	3232,8	3290,5	3259,9	2747,8	2421,9	3271,9	3237,5
14	3349,0	3359,5	3179,5	2710,2	2373,6	3110,2	3056,9	3123,0	3154,7	3246,8	2781,9	2392,0	3213,1	3412,8	3257,3	3324,9	3326,3	2726,7	2387,7	3340,5	3325,6
15	3429,4	3284,7	3210,8	2689,6	2336,6	3087,8	3085,0	3145,8	3211,6	3254,5	2745,7	2360,9	3262,1	3435,4	3262,6	3314,1	3336,1	2673,6	2367,9	3340,0	3336,7
16	3447,8	3295,4	3239,7	2719,7	2304,6	3113,4	3052,9	3178,8	3206,5	3237,8	2673,4	2339,1	3279,7	3464,0	3289,2	3311,7	3273,6	2675,9	2312,2	3292,7	3353,4
17	3400,9	3403,6	3161,7	2728,7	2111,4	3195,1	3099,0	3204,7	3270,3	3260,9	2699,0	2429,6	3365,7	3374,4	3334,2	3336,2	3301,3	2637,6	2396,5	3330,2	3347,0
18	3531,4	3569,2	3300,4	3014,4	2383,6	3345,3	3313,8	3349,5	3390,2	3380,8	3017,3	2871,9	3466,5	3489,9	3379,2	3447,2	3434,4	2979,3	2717,2	3390,5	3382,0
19	3803,1	3715,9	3594,8	3376,2	2932,4	3553,4	3567,3	3654,3	3682,3	3667,5	3451,0	3247,6	3643,4	3757,2	3626,6	3586,4	3567,5	3409,3	3218,9	3655,2	3667,4
20	3589,6	3512,6	3461,3	3316,3	3006,1	3401,8	3424,2	3457,8	3502,2	3498,2	3423,9	3182,6	3510,0	3613,3	3446,9	3448,9	3421,4	3310,8	3176,4	3490,9	3508,6
21	3503,7	3438,2	3349,8	3254,3	2964,0	3305,5	3322,1	3389,9	3415,7	3431,6	3339,0	3161,7	3472,1	3514,7	3420,4	3418,0	3338,2	3250,2	3134,5	3411,8	3421,2
22	3524,5	3449,0	3341,2	3157,4	2862,2	3304,7	3325,2	3392,1	3414,0	3374,8	3227,0	3110,8	3446,0	3427,0	3385,6	3352,8	3322,9	3216,9	3053,9	3395,3	3425,7
23	3223,4	3175,5	3149,8	2967,2	2705,5	3027,5	3045,1	3153,1	3149,3	3205,5	3095,2	2960,6	3182,9	3200,5	3181,7	3188,6	3113,6	2977,2	2939,6	3206,3	3210,5
24	2934,4	2822,2	2893,2	2713,0	2496,2	2728,5	2736,0	2830,2	2885,9	2961,9	2879,4	2754,4	2910,5	2856,1	2898,1	2910,8	2860,1	2766,9	2704,0	2882,2	2941,4

A3 – Terceiro Sistema Previsor (SP3)

Dados de Potência Ativa em MVA

Hora	Dias																				
	04/5	05/5	06/5	07/5	08/5	09/5	10/5	11/5	12/5	13/5	14/5	15/5	16/5	17/5	18/5	19/5	20/5	21/5	22/5	23/5	24/5
01	2630,9	2683,4	2562,3	2597,4	2588,5	2588,0	2547,1	2374,9	2604,9	2724,3	2728,1	2833,2	3160,0	2880,5	2498,9	2658,7	2603,6	2662,4	2764,2	2912,0	2816,5
02	2577,2	2527,8	2460,4	2424,8	2449,5	2427,6	2396,1	2282,6	2485,9	2601,2	2572,9	2708,7	2995,3	2746,3	2398,0	2514,5	2512,8	2536,4	2623,2	2760,0	2672,5
03	2483,4	2436,1	2403,7	2392,8	2368,9	2350,0	2305,7	2226,1	2433,1	2525,5	2563,9	2616,0	2891,6	2641,8	2325,3	2449,9	2446,2	2505,9	2574,8	2628,4	2599,9
04	2503,5	2420,3	2354,8	2374,2	2368,9	2332,1	2236,9	2210,8	2415,4	2495,1	2537,5	2627,1	2872,9	2559,5	2316,0	2422,1	2408,0	2457,5	2527,8	2615,3	2510,8
05	2432,7	2377,0	2373,4	2389,7	2373,7	2328,3	2217,6	2225,2	2430,5	2518,9	2500,7	2626,1	2802,2	2532,6	2355,9	2432,0	2452,0	2461,1	2564,4	2582,6	2487,4
06	2559,8	2518,4	2484,9	2513,9	2459,0	2361,4	2227,1	2349,1	2547,0	2592,5	2625,2	2701,9	2787,9	2506,1	2442,7	2540,7	2541,3	2566,8	2651,5	2601,0	2496,1
07	2771,7	2719,0	2664,8	2684,4	2617,5	2316,3	2161,1	2531,1	2694,8	2735,0	2774,6	2889,5	2764,8	2498,2	2649,9	2773,2	2752,9	2747,9	2829,6	2603,5	2444,1
08	2959,6	2913,3	2830,1	2761,2	2761,8	2391,5	2178,7	2706,6	2827,2	2925,6	2964,5	3027,8	2782,9	2489,3	2832,4	2896,6	2872,0	2941,1	3000,0	2651,9	2381,9
09	3185,8	3154,8	3080,1	3047,0	2990,0	2566,5	2269,7	2948,2	3035,9	3143,8	3177,2	3327,2	2897,3	2536,4	3090,2	3118,3	3140,5	3155,4	3234,8	2763,0	2474,0
10	3469,2	3291,6	3199,2	3192,0	3163,5	2665,3	2311,9	3111,9	3224,7	3299,3	3340,0	3464,4	2986,0	2603,4	3258,7	3237,5	3283,8	3329,2	3373,0	2880,5	2522,6
11	3555,7	3386,8	3293,4	3259,9	3278,7	2724,1	2359,5	3218,5	3312,9	3405,6	3532,7	3588,7	3041,8	2644,9	3359,8	3292,0	3361,2	3417,2	3490,3	2957,5	2493,2
12	3552,6	3416,0	3366,8	3250,4	3280,8	2701,5	2425,3	3272,2	3346,5	3433,9	3461,6	3616,7	3008,2	2638,8	3351,6	3314,8	3409,9	3450,3	3505,9	2949,8	2540,1
13	3450,4	3335,5	3326,8	3226,1	3245,8	2740,3	2405,8	3254,5	3343,3	3433,8	3470,1	3630,4	3012,8	2640,9	3325,9	3279,7	3353,7	3445,8	3499,4	2963,1	2542,6
14	3434,4	3338,3	3309,5	3245,7	3249,3	2690,7	2376,9	3273,9	3392,4	3510,6	3497,7	3733,4	3011,9	2558,8	3357,6	3292,1	3317,4	3451,1	3497,9	2958,8	2565,5
15	3447,7	3325,5	3303,2	3207,9	3241,0	2698,1	2287,4	3295,3	3451,6	3534,9	3521,1	3764,0	2993,3	2495,4	3342,3	3265,1	3405,9	3447,2	3463,2	2897,8	2553,0
16	3477,7	3286,4	3259,4	3234,3	3198,8	2671,3	2313,3	3284,3	3482,1	3542,2	3546,9	3732,6	2987,2	2496,5	3363,1	3244,8	3417,2	3420,8	3487,5	2866,1	2557,5
17	3559,3	3322,4	3328,1	3266,0	3201,3	2684,8	2341,2	3300,9	3483,0	3500,4	3538,0	3715,4	3088,8	2565,8	3448,9	3352,6	3424,4	3495,5	3470,3	2915,5	2625,9
18	3694,7	3541,7	3523,8	3440,7	3348,2	3065,3	2712,3	3499,3	3631,7	3659,5	3779,1	3863,7	3488,8	2993,5	3680,9	3625,2	3631,2	3701,3	3683,3	3326,2	3063,5
19	3622,3	3632,0	3604,7	3587,6	3571,7	3425,9	3154,4	3675,9	3787,0	3815,0	3822,6	4015,9	3593,3	3224,6	3650,8	3645,3	3762,4	3781,7	3777,9	3675,4	3394,1
20	3497,6	3429,3	3460,6	3438,3	3405,8	3319,3	3060,3	3535,0	3697,7	3669,7	3726,1	3780,7	3507,5	3137,6	3489,3	3487,0	3583,2	3594,0	3621,5	3593,9	3378,5
21	3435,9	3342,7	3375,4	3374,4	3332,3	3264,7	3068,4	3431,9	3541,2	3527,2	3605,8	3710,9	3429,7	3120,5	3397,7	3418,0	3497,1	3549,0	3526,5	3483,4	3316,0
22	3322,8	3294,7	3306,2	3325,4	3288,1	3126,0	3003,9	3362,6	3493,6	3467,1	3509,8	3727,6	3325,1	3039,8	3335,5	3372,5	3429,2	3443,2	3458,0	3356,2	3224,0
23	3151,1	3155,3	3138,5	3107,7	3103,6	2976,6	2884,1	3184,8	3312,6	3327,1	3429,7	3571,9	3237,1	2957,6	3164,9	3224,5	3312,8	3349,5	3378,4	3251,4	3140,4
24	2879,2	2858,7	2862,0	2853,2	2821,3	2769,2	2664,2	2897,9	3007,9	3038,5	3134,5	3365,3	3054,9	2740,8	2906,3	2907,8	2961,0	3023,9	3127,1	3025,5	2879,2

Hora	Dias																				
	25/5	26/5	27/5	28/5	29/5	30/5	31/5	01/6	02/6	03/6	04/6	05/6	06/6	07/6	08/6	09/6	10/6	12/6	13/6	14/6	15/6
01	2666,3	2837,3	2882,5	2725,2	2758,3	2635,2	2568,2	2401,6	2573,8	2613,3	2571,6	2568,8	2622,9	2521,5	2374,7	2512,6	2523,0	2597,1	2587,5	2506,5	2411,8
02	2538,6	2741,6	2777,1	2607,7	2593,7	2508,8	2404,1	2303,4	2459,5	2494,6	2468,1	2468,6	2467,7	2384,3	2288,1	2426,4	2411,0	2460,4	2463,6	2406,8	2331,4
03	2500,1	2669,3	2766,8	2552,9	2564,7	2436,0	2340,5	2281,9	2405,6	2424,8	2385,4	2399,0	2403,1	2305,7	2213,3	2372,4	2363,8	2383,8	2413,5	2299,7	2248,4
04	2468,2	2635,9	2722,7	2534,8	2507,7	2375,9	2285,6	2264,4	2383,7	2398,5	2395,7	2398,5	2366,4	2252,3	2218,5	2350,6	2362,4	2354,7	2370,0	2254,6	2233,4
05	2498,9	2611,7	2690,1	2546,9	2520,7	2384,5	2286,8	2278,6	2396,3	2427,0	2434,9	2398,8	2358,7	2234,7	2261,8	2389,1	2365,0	2312,4	2346,7	2242,1	2268,2
06	2599,0	2716,3	2786,9	2651,5	2641,7	2380,5	2267,2	2403,9	2501,1	2547,6	2511,4	2495,9	2388,5	2243,9	2354,6	2485,7	2450,6	2429,8	2364,9	2276,3	2348,3
07	2772,8	2877,3	2984,4	2873,8	2813,2	2474,3	2204,6	2606,3	2681,3	2769,2	2792,0	2703,4	2370,4	2159,3	2548,8	2675,4	2610,7	2591,1	2388,6	2237,2	2591,4
08	2921,0	2965,9	3101,7	2993,5	2956,4	2509,2	2174,9	2766,6	2762,3	2917,3	2941,6	2852,6	2421,0	2074,4	2694,5	2792,9	2698,9	2753,6	2439,6	2191,1	2757,8
09	3173,2	3212,9	3385,0	3288,6	3218,9	2662,0	2316,6	2957,1	2983,0	3130,2	3115,6	3044,2	2559,0	2189,8	2923,3	2953,7	2937,1	3007,8	2613,0	2315,1	2973,6
10	3414,3	3419,8	3503,2	3442,9	3364,6	2796,8	2357,0	3128,9	3096,1	3274,5	3242,3	3169,4	2677,6	2319,8	3058,5	3074,1	3015,7	3154,7	2702,2	2328,5	3077,1
11	3486,5	3502,6	3569,9	3489,0	3455,6	2844,5	2422,6	3256,6	3178,4	3324,3	3318,2	3254,4	2731,7	2370,9	3145,2	3171,3	3100,3	3217,4	2776,9	2412,1	3201,6
12	3540,3	3534,7	3563,9	3505,1	3437,5	2837,6	2448,2	3276,1	3202,4	3375,0	3339,2	3263,1	2742,4	2391,3	3213,2	3176,1	3051,0	3234,1	2739,7	2427,7	3210,6
13	3527,8	3510,9	3514,3	3467,1	3442,7	2814,5	2427,0	3250,4	3220,8	3354,1	3326,5	3255,9	2737,5	2410,8	3193,2	3150,2	2788,7	3146,0	2757,0	2446,9	3211,9
14	3550,9	3558,3	3513,5	3436,4	3507,7	2807,1	2394,8	3276,9	3226,2	3310,7	3320,1	3255,3	2747,7	2414,0	3217,5	3174,8	2635,2	3202,7	2703,8	2419,5	3218,8
15	3558,8	3638,9	3568,0	3437,2	3531,7	2742,7	2393,2	3262,9	3237,3	3321,2	3328,6	3270,2	2679,8	2368,0	3229,3	3168,3	2707,1	3209,6	2697,9	2386,7	3219,4
16	3523,6	3639,5	3628,7	3409,7	3466,0	2694,5	2418,8	3260,3	3182,4	3312,2	3333,6	3244,5	2663,4	2367,3	3201,3	3182,9	2922,1	3161,1	2667,2	2308,1	3214,1
17	3586,2	3652,9	3606,5	3426,1	3470,2	2791,0	2483,8	3264,2	3227,9	3398,9	3379,7	3259,9	2700,7	2463,4	3244,4	3240,1	3004,2	3201,1	2770,6	2389,9	3239,0
18	3808,3	3441,1	3833,5	3765,8	3689,3	3243,9	2958,5	3552,2	3499,1	3637,5	3589,4	3519,5	3130,5	2890,3	3580,8	3504,4	3290,3	3402,8	3211,1	2875,2	3576,8
19	3891,9	3628,8	3809,4	3805,0	3665,6	3519,0	3271,7	3640,2	3631,7	3692,5	3653,2	3618,7	3444,6	3249,5	3616,8	3669,4	3491,4	3519,2	3439,0	3275,7	3669,0
20	3711,0	3528,2	3619,8	3574,8	3474,4	3408,2	3223,9	3494,1	3447,2	3525,1	3487,7	3462,6	3349,3	3131,5	3470,8	3493,7	3368,6	3375,2	3380,7	3163,5	3508,6
21	3610,7	3514,9	3567,5	3540,4	3437,7	3333,6	3125,8	3420,8	3361,5	3401,5	3403,2	3373,0	3327,6	3051,6	3428,2	3432,6	3248,3	3297,3	3241,9	3096,9	3433,5
22	3600,7	3530,2	3443,1	3479,4	3327,1	3165,4	3029,1	3350,6	3361,5	3370,6	3322,1	3331,1	3161,0	2998,6	3310,6	3361,0	3206,2	3243,8	3106,1	3019,0	3343,1
23	3404,0	3446,1	3237,1	3320,8	3138,3	2987,5	2863,5	3101,5	3193,9	3167,9	3144,1	3168,2	2959,2	2864,5	3089,1	3117,9	3051,6	3056,0	2937,4	2894,6	3128,8
24	3111,3	3189,7	3005,0	3047,6	2899,8	2779,5	2659,9	2839,5	2859,9	2839,0	2863,0	2865,3	2756,6	2580,7	2792,4	2816,5	2815,9	2807,7	2718,5	2639,1	2832,3

Hora	Dias																				
	16/6	17/6	18/6	19/6	20/6	21/6	22/6	23/6	24/6	25/6	26/6	27/6	28/6	29/6	30/6	01/7	02/7	03/7	04/7	05/7	06/7
01	2583,2	2541,6	2605,6	2620,4	2630,9	2438,8	2264,9	2440,4	2513,4	2588,8	2499,3	2581,7	2478,0	2435,4	2574,6	2515,5	2575,1	2665,7	2613,8	2582,3	2480,3
02	2426,5	2399,8	2450,1	2462,3	2474,6	2317,7	2163,3	2305,7	2366,2	2387,1	2367,6	2405,1	2357,3	2302,6	2396,7	2345,4	2460,9	2511,6	2487,7	2418,9	2354,9
03	2370,9	2366,2	2388,2	2435,1	2383,2	2259,9	2110,3	2267,7	2312,1	2348,3	2315,8	2340,9	2274,0	2284,2	2287,3	2350,6	2364,7	2440,8	2406,7	2342,3	2293,1
04	2339,6	2329,3	2396,3	2371,6	2342,9	2187,3	2094,4	2231,9	2299,9	2370,6	2300,6	2324,8	2236,9	2254,8	2241,1	2318,9	2350,6	2423,3	2368,4	2302,8	2260,5
05	2351,0	2364,7	2388,5	2394,3	2359,2	2187,7	2137,5	2271,2	2301,7	2396,9	2347,5	2290,9	2189,7	2282,5	2286,7	2334,9	2360,7	2425,9	2335,7	2262,5	2282,8
06	2463,0	2492,1	2478,5	2508,8	2386,0	2183,2	2237,1	2356,4	2408,1	2488,5	2427,4	2317,4	2169,7	2390,2	2384,3	2429,0	2440,6	2501,6	2381,4	2241,5	2410,4
07	2654,0	2729,8	2731,3	2718,5	2439,4	2166,3	2489,3	2595,7	2605,6	2722,4	2668,1	2321,5	2158,8	2626,8	2580,4	2616,4	2684,7	2639,8	2446,1	2231,7	2628,4
08	2763,9	2831,8	2835,3	2832,5	2488,8	2133,3	2689,7	2728,0	2789,7	2889,2	2772,6	2393,1	2144,0	2797,7	2720,7	2778,1	2781,7	2805,6	2455,9	2181,8	2786,3
09	2947,2	3027,0	3024,5	3082,8	2656,7	2205,1	2896,1	2948,4	3034,8	3063,8	2956,4	2581,4	2283,0	2949,1	2912,5	2969,1	3000,7	3016,2	2598,0	2293,2	2976,2
10	3071,9	3141,9	3168,4	3251,1	2788,7	2339,3	3057,1	3099,4	3122,5	3225,2	3105,4	2697,9	2313,3	3124,0	3068,9	3090,0	3146,7	3163,4	2731,0	2337,7	3153,4
11	3152,9	3194,8	3238,7	3381,0	2837,9	2410,8	3154,5	3150,5	3206,2	3280,0	3199,6	2738,4	2377,6	3194,4	3147,3	3201,8	3212,6	3259,2	2763,4	2348,7	3279,4
12	3142,5	3258,8	3247,0	3381,6	2831,1	2439,7	3201,8	3153,1	3253,4	3304,3	3151,1	2734,6	2412,3	3258,4	3190,5	3261,9	3330,7	3239,3	2803,0	2402,7	3294,9
13	3106,5	3256,6	3178,5	3363,6	2790,8	2451,0	3149,5	3148,4	3255,7	3291,9	3173,2	2717,7	2441,8	3264,7	3161,8	3240,2	3333,4	3205,6	2822,3	2392,4	3289,0
14	3095,7	3236,5	3174,7	3374,1	2809,1	2455,9	3140,3	3092,7	3285,5	3283,4	3192,1	2660,9	2432,4	3264,4	3156,0	3241,3	3345,3	3163,2	2767,3	2388,4	3314,5
15	2970,2	3265,1	3207,4	3379,2	2796,3	2433,5	3132,3	2922,4	3296,2	3243,9	3205,3	2616,2	2409,1	3256,2	3205,8	3251,9	3330,7	3010,5	2745,7	2351,6	3331,5
16	2789,0	3263,4	3211,7	3376,1	2751,1	2420,0	3129,3	2791,6	3309,6	3225,5	3190,0	2536,7	2351,9	3249,0	3202,9	3237,9	3348,6	2830,4	2737,2	2339,7	3339,7
17	2490,1	3331,3	3287,9	3364,4	2792,7	2471,1	3176,7	2479,9	3332,5	3224,5	3163,1	2307,6	2401,3	3271,8	3228,6	3301,4	3387,1	2538,7	2738,0	2412,4	3333,2
18	2783,1	3606,7	3538,4	3602,9	3181,5	2914,5	3348,6	2698,6	3598,5	3389,4	3432,1	2658,7	2858,7	3476,3	3432,2	3450,8	3552,1	2718,5	3127,4	2884,9	3476,5
19	3320,5	3718,4	3695,9	3730,3	3328,9	3136,1	3513,0	3272,8	3741,8	3556,8	3558,3	3289,2	3232,5	3673,1	3610,7	3706,5	3712,3	3298,9	3487,4	3261,2	3699,0
20	3279,4	3517,3	3519,3	3536,5	3240,2	3038,5	3383,2	3223,3	3540,6	3463,2	3400,8	3255,3	3158,5	3528,9	3484,1	3518,5	3534,1	3262,8	3376,2	3174,8	3489,7
21	3261,0	3434,1	3472,8	3488,4	3165,1	2971,4	3345,0	3194,2	3446,0	3320,6	3364,0	3152,4	3100,9	3384,9	3450,6	3444,3	3503,0	3229,2	3286,3	3152,7	3415,0
22	3244,4	3414,3	3393,9	3360,0	3028,3	2889,9	3230,9	3246,8	3434,9	3252,7	3305,8	3075,3	3006,2	3335,7	3339,9	3413,9	3425,1	3261,7	3181,8	3045,2	3519,4
23	3079,1	3222,0	3193,6	3242,5	2873,0	2726,3	3024,5	3052,5	3207,6	3024,0	3097,5	2938,9	2903,1	3147,3	3160,4	3191,3	3212,3	3160,4	2964,1	2908,2	3180,2
24	2781,1	2880,7	2917,0	2941,9	2694,1	2516,7	2671,9	2793,5	2878,8	2756,6	2852,0	2723,6	2672,9	2841,6	2839,5	2899,1	2947,6	2884,8	2765,7	2699,8	2898,7

Hora	Dias																				
	07/7	08/7	09/7	10/7	11/7	12/7	13/7	14/7	15/7	16/7	17/7	18/7	19/7	20/7	21/7	22/7	23/7	24/7	25/7	26/7	27/7
01	2619,2	2588,5	2615,6	2580,1	2612,3	2442,1	2300,0	2459,6	2469,9	2554,7	2552,2	2666,6	2626,6	2371,0	2578,7	2572,2	2613,1	2603,5	2600,7	2537,5	2461,2
02	2488,9	2450,4	2477,3	2478,4	2467,2	2325,6	2194,3	2303,6	2377,2	2416,5	2419,8	2505,7	2504,2	2357,8	2421,4	2437,3	2468,9	2465,3	2466,2	2400,4	2355,1
03	2402,9	2396,6	2428,2	2423,2	2386,5	2277,4	2157,0	2273,3	2311,9	2348,4	2353,3	2434,4	2388,4	2256,4	2411,1	2388,4	2417,1	2420,4	2348,4	2329,4	2284,3
04	2335,2	2343,9	2402,0	2376,6	2325,7	2227,3	2114,7	2232,2	2279,2	2303,9	2347,0	2373,2	2337,7	2246,7	2368,5	2368,2	2380,1	2367,5	2361,1	2280,4	2237,1
05	2414,7	2364,3	2423,1	2384,1	2329,0	2195,4	2164,1	2257,4	2284,4	2336,2	2350,2	2391,2	2345,0	2254,1	2398,2	2403,1	2410,0	2398,0	2356,3	2240,8	2263,8
06	2490,1	2442,7	2508,9	2464,8	2344,4	2211,2	2227,5	2388,6	2406,0	2412,9	2446,1	2400,1	2323,3	2353,1	2468,3	2498,5	2502,2	2502,9	2379,3	2260,1	2359,8
07	2714,7	2663,8	2727,4	2746,5	2381,4	2189,7	2462,5	2550,0	2559,2	2592,6	2646,9	2395,7	2279,2	2530,4	2625,1	2639,7	2648,3	2674,3	2363,1	2177,9	2508,7
08	2841,6	2792,0	2892,1	2844,8	2413,2	2183,4	2682,2	2667,2	2702,2	2764,5	2777,2	2427,0	2255,9	2763,2	2812,2	2814,0	2831,5	3016,2	2442,3	2185,1	2705,8
09	3083,9	3027,1	3152,7	3009,1	2598,8	2265,7	2892,8	2854,6	2928,1	2950,7	3022,9	2693,0	2313,7	2990,9	3029,8	3086,8	3098,6	3145,1	2558,9	2286,8	2980,2
10	3171,5	3176,8	3250,1	3154,1	2708,8	2367,6	3047,1	2969,6	3038,5	3077,6	3143,3	2730,2	2336,1	3157,4	3211,7	3248,7	3146,3	3259,3	2677,9	2328,5	3151,7
11	3215,2	3250,9	3332,2	3216,9	2733,6	2400,8	3125,4	3034,7	3071,7	3159,6	3192,1	2758,2	2358,1	3232,1	3262,5	3264,9	3211,9	3303,6	2747,8	2367,9	3242,9
12	3206,1	3366,2	3347,4	3221,7	2716,7	2382,6	3072,7	3063,4	3170,4	3169,0	3224,8	2741,8	2415,9	3236,2	3280,3	3248,9	3289,8	3290,4	2748,7	2381,5	3269,0
13	3183,6	3351,0	3334,5	3192,6	2721,5	2394,8	3093,6	3031,3	3121,7	3143,6	3198,3	2759,3	2438,9	3165,7	3388,8	3232,8	3290,5	3259,9	2747,8	2421,9	3271,9
14	3133,8	3349,0	3359,5	3179,5	2710,2	2373,6	3110,2	3056,9	3123,0	3154,7	3246,8	2781,9	2392,0	3213,1	3412,8	3257,3	3324,9	3326,3	2726,7	2387,7	3340,5
15	2968,2	3429,4	3284,7	3210,8	2689,6	2336,6	3087,8	3085,0	3145,8	3211,6	3254,5	2745,7	2360,9	3262,1	3435,4	3262,6	3314,1	3336,1	2673,6	2367,9	3340,0
16	2805,8	3447,8	3295,4	3239,7	2719,7	2304,6	3113,4	3052,9	3178,8	3206,5	3237,8	2673,4	2339,1	3279,7	3464,0	3289,2	3311,7	3273,6	2675,9	2312,2	3292,7
17	2549,6	3400,9	3403,6	3161,7	2728,7	2111,4	3195,1	3099,0	3204,7	3270,3	3260,9	2699,0	2429,6	3365,7	3374,4	3334,2	3336,2	3301,3	2637,6	2396,5	3330,2
18	2671,6	3531,4	3569,2	3300,4	3014,4	2383,6	3345,3	3313,8	3349,5	3390,2	3380,8	3017,3	2871,9	3466,5	3489,9	3379,2	3447,2	3434,4	2979,3	2717,2	3390,5
19	3062,1	3803,1	3715,9	3594,8	3376,2	2932,4	3553,4	3567,3	3654,3	3682,3	3667,5	3451,0	3247,6	3643,4	3757,2	3626,6	3586,4	3567,5	3409,3	3218,9	3655,2
20	3192,9	3589,6	3512,6	3461,3	3316,3	3006,1	3401,8	3424,2	3457,8	3502,2	3498,2	3423,9	3182,6	3510,0	3613,3	3446,9	3448,9	3421,4	3310,8	3176,4	3490,9
21	3248,9	3503,7	3438,2	3349,8	3254,3	2964,0	3305,5	3322,1	3389,9	3415,7	3431,6	3339,0	3161,7	3472,1	3514,7	3420,4	3418,0	3338,2	3250,2	3134,5	3411,8
22	3296,7	3524,5	3449,0	3341,2	3157,4	2862,2	3304,7	3325,2	3392,1	3414,0	3374,8	3227,0	3110,8	3446,0	3427,0	3385,6	3352,8	3322,9	3216,9	3053,9	3395,3
23	3160,0	3223,4	3175,5	3149,8	2967,2	2705,5	3027,5	3045,1	3153,1	3149,3	3205,5	3095,2	2960,6	3182,9	3200,5	3181,7	3188,6	3113,6	2977,2	2939,6	3206,3
24	2854,0	2934,4	2822,2	2893,2	2713,0	2496,2	2728,5	2736,0	2830,2	2885,9	2961,9	2879,4	2754,4	2910,5	2856,1	2898,1	2910,8	2860,1	2766,9	2704,0	2882,2