

**Desenvolvimento de Redes Neurais para  
Previsão de Cargas Elétricas de Sistemas  
de Energia Elétrica**

**Mara Lúcia Martins Lopes**

**Carlos Roberto Minussi**

**Orientador**

Ilha Solteira – SP, Dezembro de 2005.

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

# **Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica**

**Mara Lúcia Martins Lopes**

Tese de Doutorado submetida ao Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP, como parte dos requisitos para a obtenção do título de *Doutor em Engenharia Elétrica*.

Ilha Solteira – SP, Dezembro de 2005.

A Deus.

Aos meus pais Manoel e Lourdes.

# Agradecimento

Ao Prof. Dr. Carlos Roberto Minussi, pelo empenho, dedicação e confiança na realização do meu trabalho. Pelo amigo e pai que se mostrou em cada tropeço e em cada vitória alcançada.

Aos meus pais, Manoel e Lourdes, que sempre me incentivaram e apoiaram na realização de um sonho. Aos meus irmãos, Márcio e Márcia, pelo carinho e apoio dedicado. Ao meu noivo, Valter, pelo amor, paciência e compreensão.

Aos meus colegas que estiveram ao meu lado em cada caminhada, em especial Elizete Amorim, Maria do Carmo Gomes da Silveira, Mariza Akiko, Rodrigo Daltin e Alessandra Altran pela força e apoio na realização do meu trabalho.

Aos técnicos do laboratório de computação Deoclécio Mitsuiti Kosaka e José Roberto Campos pelo apoio e assistência.

A Prof<sup>ª</sup>. Anna Diva Plasencia Lotufo, pelo seu apoio, dedicação e amizade.

A Fapesp por seu apoio financeiro, através de uma bolsa de estudos e reserva técnica, que permitiu que eu pudesse me dedicar integralmente ao desenvolvimento deste trabalho.

Agradeço acima de tudo a Deus, que me concedeu força e perseverança para continuar caminhando sempre em busca de meus sonhos.

# Resumo

Nos dias atuais, principalmente pelo fato de alguns sistemas serem desregulamentados, o estudo dos problemas de análise, planejamento e operação de sistemas de energia elétrica é de extrema importância para o funcionamento do sistema. Para isso é necessário que se obtenha, com antecedência, o comportamento da carga elétrica com o propósito de garantir o fornecimento de energia aos consumidores de forma econômica, segura e contínua. Este trabalho propõe o desenvolvimento de redes neurais artificiais utilizadas para resolver o problema de previsão de cargas elétricas. Para tanto, inicialmente, propôs-se a introdução de melhorias na rede neural *feedforward* com treinamento realizado utilizando o algoritmo retropropagação. Neste caso, foi desenvolvida/implementada a adaptação dos parâmetros de inclinação e translação da função sigmóide (função de ativação da rede neural). A inclusão desta nova estrutura de redes neurais produziu melhores resultados, se comparado à rede neural retropropagação convencional. Essas arquiteturas proporcionam bons resultados, porém, são estruturas de redes neurais que possuem o problema de convergência. O problema de previsão de cargas elétricas a curto-prazo necessita de uma rede neural que forneça uma saída de forma rápida e eficaz. No intuito de solucionar os problemas encontrados com o algoritmo retropropagação foi desenvolvida/implementada uma rede neural baseada na arquitetura ART (*Adaptive Resonance Theory*), denominada rede neural ART&ARTMAP nebulosa, aplicada ao problema de previsão de carga elétrica. Trata-se, por conseguinte, da principal contribuição desta tese. As redes neurais,

baseadas na arquitetura ART, possuem duas características fundamentais que são de extrema importância para o desempenho da rede (estabilidade e plasticidade), que permite a implementação do treinamento de modo contínuo. A rede neural ART&ARTMAP nebulosa visa reduzir as imprecisões dos resultados de previsão, através de um mecanismo que separa dados analógicos e binários, processando-os separadamente. Isto representa uma melhoria na obtenção da qualidade dos resultados (redução do tempo de processamento e maior precisão), se comparada à rede neural treinada via algoritmo retropropagação (freqüentemente considerada pela literatura especializada como um algoritmo de referência). Para ilustrar a metodologia proposta, são apresentados os resultados da previsão de carga, considerando-se os dados históricos de uma companhia do setor elétrico brasileiro para as três arquiteturas de redes neurais desenvolvidas.

# Abstract

Nowadays due to the deregulation it is very important to study the problems of analyzing, planning and operation of electric power systems. For a reliable operation it is necessary to know previously the behavior of the load to guarantee the energy providing to the users with security and continuity and in an economic way. This work proposes to develop artificial neural networks to solve the problem of electric load forecasting. First, it is introduced some improvements on the feedforward neural network, with the training effectuated with the backpropagation algorithm. The improvement was the adaptation of the inclination and translation parameters of the sigmoid function (activation function of the neural network). The inclusion of this new structure provides better results if compared to the conventional backpropagation algorithm. These architectures provide good results, although they are structures that have some convergence problems. The short term electric load forecasting problem needs a neural network that provide a fast and efficient output. To solve this problem a neural network based on the ART (*Adaptive Resonance Theory*), called fuzzy ART&ARTMAP applied to the load-forecasting problem, was developed and implemented. This is one of the contributions of this work. Neural networks based on the ART architecture have two important characteristics for the network performance, which are stability and plasticity, allowing the continuous training. The fuzzy ART&ARTMAP neural network reduces the imprecision of the results by a mechanism that separates the binary and analogical data and processing them separately. This represents a quality and an improvement on the results (reduction

of the processing time and better precision), if compared to the neural network with backpropagation training (often considered as a benchmark in precision by the specialized literature). To illustrate the proposed methodology results are presented considering the data of a Brazilian power company for the three neural network architecture developed.

# Lista de Figuras

2.1 – Série temporal estacionária .....	11
2.2 – Série temporal não-estacionária .....	11
3.1 – Componentes de um neurônio biológico .....	27
3.2 – Componentes de um neurônio artificial .....	28
3.3 – Modelo de um neurônio artificial .....	29
3.4 – Funções de ativação .....	31
3.5 – Disposição das redes neurais artificiais .....	32
4.1 – Treinamento de um neurônio situado na última camada .....	47
4.2 – Treinamento de um neurônio situado nas demais camadas .....	48
4.3 – O algoritmo gradiente descendente no espaço de pesos .....	48
4.4 – Representação de mínimos locais .....	50
4.5 – Funções de pertinência para as variáveis $\varepsilon g$ , $\Delta \varepsilon g$ e $\Delta \psi$ .....	54
4.6 – Arquitetura da rede neural adaptativa .....	56
5.1 – Arquitetura da rede neural ART .....	66
5.2 – Representação geométrica das categorias .....	68
5.3 – Rede neural ART nebulosa .....	69
5.4 – Fluxograma da rede neural ART nebulosa .....	74
5.5 – Rede neural ARTMAP nebulosa .....	77
5.6 – Fluxograma da rede neural ARTMAP nebulosa .....	81
6.1 – Rede neural ART&ARTMAP nebulosa .....	85
6.2 – Processador do módulo ART nebuloso .....	86

6.3 – Processador dos dados de saída da rede neural ART&ARTMAP nebulosa	.....	90
6.4 – Ilustração da rede neural ART&ARTMAP nebulosa na fase de análise	.....	92
7.1 – Resultados da previsão de carga para aplicação 1 (CN)	.....	101
7.2 – Resultados da previsão de carga para aplicação 2 (CN)	.....	101
7.3 – Resultados da previsão de carga para aplicação 3 (CN)	.....	102
7.4 – Resultados da previsão de carga para aplicação 1 (RACN)	.....	105
7.5 – Resultados da previsão de carga para aplicação 2 (RACN)	.....	105
7.6 – Resultados da previsão de carga para aplicação 3 (RACN)	.....	106
7.7 – Modelo da previsão de carga por redes neurais artificiais	.....	107
7.8 – Resultados da previsão de carga para aplicação 1 (ART&ARTMAP nebulosa)	.....	109
7.9 – Resultados da previsão de carga para aplicação 2 (ART&ARTMAP nebulosa)	.....	110
7.10 – Resultados da previsão de carga para aplicação 3 (ART&ARTMAP nebulosa)	.....	111
A.1 – Funções de pertinência	.....	133
A.2 – Conjuntos nebulosos	.....	134
A.3 – Operador AND	.....	134
A.4 – Operador OR	.....	135
A.5 – Operador NOT	.....	135
A.6 – Diagrama de bloco de um sistema nebuloso	.....	136

# Lista de Tabelas

4.1 – Regras do controlador nebuloso .....	55
7.1 – Especificação da rede neural – controlador nebuloso .....	100
7.2 – Resultados comparativos para aplicação 1 (CN) .....	102
7.3 – Resultados comparativos para aplicação 2 (CN) .....	103
7.4 – Resultados comparativos para aplicação 3 (CN) .....	103
7.5 – Especificação da rede neural adaptativa .....	104
7.6 – Resultados comparativos para aplicação 1 (RACN) .....	106
7.7 – Resultados comparativos para aplicação 2 (RACN) .....	107
7.8 – Resultados comparativos para aplicação 3 (RACN) .....	107
7.9 – Especificação da rede neural ART&ARTMAP nebulosa .....	109
7.10 - Resultados comparativos para aplicação 1 (ART&ARTMAP) .....	111
7.11 - Resultados comparativos para aplicação 2 (ART&ARTMAP) .....	111
7.12 – Resultados comparativos para aplicação 3 (ART&ARTMAP) .....	112
7.13 - Comparação entre os resultados obtidos das diferentes arquiteturas de redes neurais artificiais utilizadas no problema de previsão de cargas elétricas .....	113

## Lista de Abreviaturas

AR	=	modelo <i>Auto Regressive</i>
MA	=	modelo <i>Moving Average</i>
ARMA	=	modelo <i>Auto Regressive Moving Average</i>
ARIMA	=	modelo <i>Auto Regressive Integrated Moving Average</i>
NL	=	não-linearidade
CNM	=	<i>combinatorial neural model</i>
CPN	=	<i>counterpropagation network</i>
BAM	=	<i>bidirectional associative memory</i>
STM	=	memória a curto-prazo
LTM	=	memória a longo-prazo
GC	=	ganho em termos de número de ciclos
NBP	=	número de ciclos do algoritmo retropropagação
NBPM	=	número de ciclos do algoritmo retropropagação modificado
GT	=	ganho de tempo
TRP	=	tempo de processamento algoritmo retropropagação
TRI	=	tempo de execução das redes neurais implementadas
MAPE	=	erro percentual absoluto médio
<i>Erro Maximo</i>	=	erro máximo da previsão diária
RP	=	algoritmo retropropagação
CN	=	controlador nebuloso
RP Convencional (M)	=	algoritmo retropropagação convencional com momento

RP Convencional (SM)	=	algoritmo retropropagação convencional sem momento
RP Nebuloso	=	algoritmo retropropagação com controlador nebuloso
RACN	=	algoritmo retropropagação com processo adaptativo e controlador nebuloso
RNA	=	rede neural artificial
A/B	=	conversor de dados analógicos para binários
B/A	=	conversor de dados binários para analógicos

# Lista de Símbolos

Letras em negrito, maiúsculas e minúsculas representam matrizes e vetores, respectivamente.

$\mathbf{y}(t)$	=	carga elétrica
$a_0, a_1, \dots, a_n$	=	coeficientes de regressão
$q_1, \dots, q_n$	=	variáveis explanatórias
$\mathbf{a}(t)$	=	variável aleatória com média zero e variância constante
$\boldsymbol{\varphi}(t)$	=	vetor de coeficiente
$\mathbf{f}(t)$	=	vetor da função de ajuste para a modelagem da carga
$\boldsymbol{\varepsilon}(t)$	=	ruído branco
$\mathbf{L}$	=	matriz de transição
$\mathbf{T}$	=	operador transposto
$\mathbf{A}(t)$	=	matriz de transição
$\mathbf{w}(t)$	=	ruído branco com matriz de covariância $\mathbf{Q}(t)$
$\mathbf{z}(t)$	=	vetor de medição no tempo $t$
$\mathbf{B}(t)$	=	matriz que correlata $\mathbf{y}(t)$ e $\mathbf{z}(t)$
$\mathbf{v}(t)$	=	erro medido (ruído com matriz de covariância $\mathbf{S}(t)$ )
$\mathbf{k}(t)$	=	fator de combinação
$\theta_0$	=	termo constante
$\phi_1, \dots, \phi_p$	=	coeficientes auto-regressivos
$p$	=	ordem do modelo <i>Auto Regressive</i>
$\theta_1, \dots, \theta_r$	=	coeficientes de média móvel

$r$	=	ordem do modelo <i>Moving Average</i>
$s_i$	=	saída intermediária do neurônio
$X$	=	vetor contendo as entradas do neurônio
$V$	=	vetor contendo os pesos do neurônio
$x_1, x_2, \dots, x_n$	=	entradas do neurônio
$w_1, w_2, \dots, w_n$	=	pesos do neurônio
$F_R$	=	função relé
$F_L$	=	função linear
$F_S$	=	função sigmóide
$\varepsilon_i$	=	erro instantâneo de cada neurônio alocado na última camada
$d_i$	=	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
$\gamma$	=	taxa de treinamento da rede neural
$h$	=	índice de iteração
$\nabla_i(h)$	=	gradiente do erro quadrático com relação aos pesos do neurônio avaliado em $h$
$\rho$	=	constante que determina a translação da curva $y_i$
$\lambda$	=	constante que determina a inclinação da curva $y_i$
$sgm'(s_i)$	=	derivada da função sigmóide com relação a $s_i$
$R(j)$	=	conjunto dos índices dos elementos que se encontram na fileira seguinte à fileira do elemento $i$ e que estão interligados ao elemento $i$
$v_{ij}$	=	peso correspondente à interligação entre o $i$ -ésimo e $j$ -ésimo neurônio
$\eta$	=	constante momento
$\sigma_j$	=	derivada da função sigmóide com relação a $s_i$

$\varepsilon g$	=	erro global da rede neural
$np$	=	número de vetores padrão da rede
$\Delta \varepsilon g$	=	variação do erro global
$\Delta \gamma$	=	ação de controle exercida sobre o sistema
$\alpha_p$	=	um número positivo arbitrário
$\Delta \psi^q$	=	acréscimo procedente do controlador nebuloso
$\nabla_i^\lambda (h)$	=	gradiente do erro quadrático com relação a inclinação do neurônio $i$
$\lambda_i$	=	vetor contendo as inclinações do neurônio $i$
$\sigma_i^\lambda$	=	derivada da função sigmóide com relação a $\lambda_i$
$\nabla_i^\rho (h)$	=	gradiente do erro quadrático com relação a translação do neurônio $i$
$\rho_i$	=	vetor contendo as translações do neurônio $i$
$\sigma_i^\rho$	=	derivada da função sigmóide com relação a $\rho_i$
$F_1$	=	camada de comparação
$F_2$	=	camada de reconhecimento
$F_0$	=	camada que representa o vetor de entradas
$F_1^a$	=	camada de comparação para o módulo $ART_a$
$F_2^a$	=	camada de reconhecimento para o módulo $ART_a$
$F_0^a$	=	camada que representa o vetor de entradas para o módulo $ART_a$
$F_1^b$	=	camada de comparação para o módulo $ART_b$
$F_2^b$	=	camada de reconhecimento para o módulo $ART_b$
$F_0^b$	=	camada que representa o vetor de entradas para o módulo $ART_b$
$F^{ab}$	=	módulo de memória associativa
$\alpha$	=	parâmetro de escolha
$\beta$	=	parâmetro taxa de treinamento

$\rho$	=	parâmetro de vigilância
$T_j$	=	função de escolha
$I$	=	atividade em $F_0$
$M$	=	número de vetores de entrada na camada $F_1$
$N$	=	dimensão dos vetores de entrada que na camada $F_2$ formam as categorias
$M_a$	=	número de vetores de entrada na camada $F_1^a$ para o módulo $ART_a$
$M_b$	=	número de vetores de entrada na camada $F_1^b$ para o módulo $ART_b$
$N_a$	=	dimensões dos vetores de entrada para o módulo $ART_a$
$N_b$	=	dimensões dos vetores de entrada para o módulo $ART_b$
$J$	=	categoria ativa (escolhida) para o módulo $ART_a$
$K$	=	categoria ativa (escolhida) para o módulo $ART_b$
$a$	=	vetor de entrada do módulo $ART_a$
$a^c$	=	complemento do vetor de entrada do módulo $ART_a$
$b$	=	vetor de entrada do módulo $ART_b$
$A$	=	entrada para $F_1^a$ em forma de codificação de complemento
$B$	=	entrada para $F_1^b$ em forma de codificação de complemento
$\rho_a$	=	parâmetro de vigilância do módulo $ART_a$
$\rho_b$	=	parâmetro de vigilância do módulo $ART_b$
$\rho_{ab}$	=	parâmetro de vigilância do módulo inter-ART
$\bar{\rho}_a$	=	parâmetro de vigilância base
$x$	=	vetor de atividade em $F_1$
$y$	=	vetor de atividade em $F_2$
$x^a$	=	vetor de atividade em $F_1^a$ no módulo $ART_a$

$\mathbf{y}^a$	=	vetor de atividade em $F_2^a$ no módulo $ART_a$
$\mathbf{w}_j^a$	=	vetor peso no módulo $ART_a$
$\mathbf{x}^b$	=	vetor de atividade em $F_1^b$ no módulo $ART_b$
$\mathbf{y}^b$	=	vetor de atividade em $F_2^b$ no módulo $ART_b$
$\mathbf{w}_k^b$	=	vetor peso no $ART_b$
$\mathbf{x}^{ab}$	=	vetor de atividade no módulo inter-ART
$\mathbf{w}_j^{ab}$	=	vetor peso no módulo inter-ART
$\varepsilon$	=	tolerância de erro
$\mathbf{P}^{an}(h)$	=	dados de entrada analógicos
$\mathbf{A}^{bin}(h)$	=	dados de entrada binários
$m$	=	dimensão do vetor $\mathbf{P}^{an}$
$n$	=	dimensão do vetor $\mathbf{A}^{bin}$
$q$	=	número de horas anteriores à hora corrente ( $h$ )
$\mathbf{t}$	=	vetor tempo referente aos dados históricos
$L(h - q)$	=	valor da carga, $q$ horas antes da hora atual $h$
$L(h + 1)$	=	valor da carga elétrica correspondente à hora subsequente a hora corrente $h$
$L_n(h+1)$	=	valor da carga elétrica normalizado referente à hora subsequente da hora atual $h$
$C_{MAX}$	=	valor máximo preestabelecido da carga
$\mathbf{C}^{bin}$	=	vetor correspondente à representação binária da classe de $L_n(h+1)$
$\mathbf{A}^{bin}$	=	vetor correspondente à representação binária da área de $L_n(h+1)$
$L_n^{bin}(h+1)$	=	representação binária de $L_n(h+1)$
$L(h)$	=	valor da carga real referente a hora $h$
$\underline{L}(h)$	=	valor da carga estimada pela rede neural referente à hora $h$

$NT$	=	número total de horas
$mb$	=	dimensão do vetor $P^{bin}$
$cb$	=	dimensão do vetor $C^{bin}$
$ab$	=	dimensão do vetor $A^{bin}$
$X(h)$	=	vetores de entrada da rede neural
$Y(h)$	=	vetores de saída da rede neural
$\mu_A(x)$	=	valor da função de pertinência do conjunto nebuloso A correspondente ao elemento x
$\mu_C(x)$	=	valor da função de pertinência da interseção destes dois conjuntos nebulosos
$\mu_D(x)$	=	valor da função de pertinência da união destes conjuntos nebulosos
$\mu_{A^c}(x)$	=	valor da função de pertinência do complemento de A
$\delta_i$	=	valor do conjunto que tem um valor de pertinência $\mu_i$
$n_r$	=	número de regras nebulosas
$u$	=	projeção do centro de inércia

# Capítulo 1

## Introdução

### 1.1. Introdução

O planejamento da expansão, fluxo de potência, operação econômica, análise de segurança e controle de sistemas de energia elétrica são alguns exemplos de rotinas que dependem efetivamente do conhecimento do perfil da carga [O'Donovan, 1983], *i.e.*, da estimativa das informações futuras de uma série temporal concebida baseada em valores passados. Na literatura, encontram-se várias técnicas para realizar a previsão de carga [O'Donovan, 1983]: regressão linear múltipla ou simples, alisamento exponencial, estimação de estado, filtro de Kalman, modelos ARIMA de Box & Jenkins [Box & Jenkins, 1976] entre outros. Todos estes métodos necessitam da modelagem prévia da carga para posteriormente serem aplicados. Para modelar a carga, é imperativo que se conheça algumas informações, tais como: efeitos atmosféricos (dias nublados, velocidade do vento, variações repentinas de temperatura) e efeitos de dias não-convencionais (feriados, greves, etc.). Quanto mais informações forem disponibilizadas, maiores serão as chances de obter soluções de qualidade. Após ter sido realizado a modelagem da carga, usando estas informações, inicia-se a execução do algoritmo, a fim de obter os resultados (previsão de carga).

O uso das Redes Neurais Artificiais (RNA) [Haykin, 1994] é,

atualmente, um método alternativo para a resolução do problema de previsão de cargas elétricas [Chen et al., 1996; Cristofaro et al., 2003; Djukanovic et al., 1995; Kermanshahi & Iwamiya, 2002; Swarup & Satish, 2002; Metaxiotis et al., 2003; Baczynski & Parol, 2003; Sfetsos, 2003; Hippert et al., 2001; Liu et al., 1996].

As Redes Neurais Artificiais (RNA) são concepções em *hardware* e/ou *software* baseadas no mecanismo de funcionamento do cérebro.

A neurocomputação surgiu, basicamente, em 1943 através da proposição de um neurônio artificial por McCulloch e Pitts. A partir deste modelo, foram desenvolvidas várias concepções de RNA, porém, os resultados eram pouco significativos. Somente após os anos 70 é que houve considerável avanço, principalmente, com o advento do algoritmo retropropagação (*backpropagation*) [Wasserman, 1989] e da rede de Hopfield [Werbos, 1974] e, sobretudo, pelo avanço da microeletrônica a partir dos anos 80, tornou-se possível a idealização de estruturas em *hardware* de modo eficiente.

O algoritmo retropropagação tem por finalidade o aprendizado supervisionado (regra baseada no binômio estímulo de entrada – saída) de RNA compostas por várias fileiras de neurônios dispostos em paralelo e funções de ativação contínuas. Com esta estrutura pode-se executar tarefas como reconhecimento de padrões, diagnósticos complexos, previsão, etc. Ele é considerado, dentro da literatura especializada, um *benchmark* em termos de precisão. Contudo, a convergência é geralmente lenta, sendo que em alguns casos é não-convergente.

Uma proposta para tentar contornar este problema consiste em efetuar o ajuste da taxa de treinamento,  $\gamma$ , durante o processo de convergência [Lopes, 2000]. O ajuste da taxa de treinamento é feito usando um controlador nebuloso (processo adaptativo baseado na lógica nebulosa, via observação do erro global da rede durante o treinamento). Também, usa-se uma função exponencial decrescente para estabilizar a atuação do regulador no tempo de treinamento inicial e evitar a instabilidade no processo de convergência. Foi proposto,

portanto, um treinamento mais rápido, se comparado com a formulação convencional do algoritmo retropropagação, conseqüentemente, tornando o sistema previsor, a princípio, mais competitivo em comparação aos principais métodos encontrados na literatura especializada.

Outra proposta consiste, baseado no artigo de Stamatis et al. (1999), na implementação de um método de adaptação dos parâmetros de translação e inclinação da função não-linear da rede neural (função sigmóide), através do método do gradiente descendente. Isso faz com que a rede neural, a cada iteração, tenha a capacidade de encontrar uma melhor solução possivelmente fugindo do mínimo local, acelerando desta forma sua convergência.

A estrutura do algoritmo retropropagação não é “manipulável”, ou seja, o treinamento da rede em si não possui um algoritmo flexível. Logo, apesar deste algoritmo fornecer bons resultados, não existe a possibilidade de melhorar em demasia seu funcionamento, mesmo que as melhorias sejam implementadas, o algoritmo retropropagação ainda possui convergência lenta e o problema dos mínimos locais.

Há outras disponibilidades de redes neurais que oferecem resultados mais interessantes do ponto de vista de precisão e rapidez na obtenção das soluções, principalmente quando se combinam redes neurais com outras técnicas de inteligência artificial, como por exemplo, lógica nebulosa, algoritmos evolutivos, etc. [Liao & Tsao, 2004; Villalba & Bel, 2000; Kermanshahi & Iwamiya, 2002; Chandrashekar et al., 1999; Chui et al., 1997; Srinivasan et al., 1998].

Com o propósito de contornar o problema de convergência encontrado pelo algoritmo retropropagação, busca-se estruturas de redes neurais ou até mesmo os algoritmos híbridos capazes de desempenhar um funcionamento adequado. Dentre as arquiteturas existentes, destacam-se as redes neurais baseadas na teoria da ressonância adaptativa (*Adaptive Resonance Theory* – ART).

As redes neurais ART preservam duas características fundamentais para o processamento da rede: a estabilidade (capacidade de aprender através do

ajuste dos pesos) e a plasticidade (capacidade de continuar a aprender com a inclusão de novos padrões, sem perder a memória com relação aos padrões anteriores). Estas duas características proporcionam à rede uma aprendizagem estável e uma convergência rápida.

Logo, a idéia básica consiste na composição de uma rede neural que possa utilizar uma estrutura híbrida composta por arquiteturas de redes neurais baseadas na teoria da ressonância adaptativa aplicada ao problema de previsão de cargas elétricas. Essas duas arquiteturas utilizadas são: a rede neural ART nebulosa e a rede neural ARTMAP nebulosa, que juntas vão originar uma nova arquitetura de rede denominada rede neural ART&ARTMAP nebulosa [Ferreira, 2003]. Pretende-se com esta rede neural solucionar, ou pelo menos reduzir as imprecisões dos resultados da previsão de carga.

Esta pesquisa visa, por conseguinte, o desenvolvimento de um sistema neural para a previsão de carga elétrica multinodal que é um problema que exige, conseqüentemente, a precisão e a rapidez de resposta. Neste sentido, o sistema neural proposto, que compreende a rede neural ART&ARTMAP, disponibiliza tais requisitos, principalmente com relação à velocidade de resolução. Ressalta-se que, embora os exemplos de aplicação apresentados referem-se à previsão global, ou seja, trata-se da construção de uma única série temporal, a metodologia proposta é perfeitamente compatível com a previsão que envolve vários pontos (subestações, barramentos, etc.). É, portanto, suficientemente precisa, rápida e confiável. A confiabilidade é uma característica inerente das redes neurais da família ART, havendo, sempre, a garantia de geração de uma solução. Também, a rapidez é conferida, isto porque a adaptação de pesos (processo de treinamento) é realizada considerando apenas um único neurônio por padrão, ao contrário ao que acontece com a grande maioria do treinamento com outros algoritmos e redes neurais, onde a adaptação de pesos é realizada considerando-se todos ou um grupo de neurônios. Deve-se observar, por exemplo, nas redes neurais com treinamento via o algoritmo retropropagação, que o treinamento é sabidamente lento, podendo, em muitos casos, não existir convergência do processo adaptativo, principalmente,

quando o banco de dados for extenso e/ou a tolerância de erro durante o processo de treinamento for muito baixa.

## **1.2. Objetivo do Trabalho**

O objetivo deste trabalho é utilizar uma rede neural baseada na arquitetura ART [Carpenter & Grossberg, 1987; Carpenter & Grossberg, 1991a; Carpenter & Grossberg, 1991b; Carpenter & Grossberg, 1987; Ferreira, 2003], denominada rede neural ART&ARTMAP nebulosa [O'Donovan, 1983], e aplicá-la à resolução do problema de previsão de carga global de curto-prazo (24 horas à frente) de cargas elétricas.

A vantagem do emprego desta rede neural se deve ao fato dela apresentar a característica de estabilidade e plasticidade, tal como são as demais redes neurais da família ART.

Além disto, a maior parte das informações processadas por esta rede neural (como consequência da formulação do problema da previsão de carga proposta neste trabalho), é de natureza binária que, a princípio, tende a gerar soluções mais rápidas e mais precisas, se comparadas à abordagem analógica.

## **1.3. Contribuição do Trabalho**

A contribuição deste trabalho consiste no desenvolvimento de uma arquitetura de rede neural (rede neural ART&ARTMAP nebulosa) que possui a capacidade de realizar a previsão de carga a curto-prazo.

A estrutura desta rede neural é uma inovação dentre as arquiteturas das redes neurais baseadas na teoria da ressonância adaptativa e apresenta as seguintes qualidades:

1. tempo de treinamento reduzido;

2. precisão comparável às metodologias clássicas disponíveis na literatura;
3. quando forem disponibilizados novos dados, não há necessidade de reiniciar o treinamento. É suficiente apenas incorporar os novos padrões na “memória” da rede neural (treinamento continuado);
4. o tamanho do banco de dados não acarreta problemas de convergência do treinamento.

#### **1.4. Organização do Trabalho**

O trabalho está dividido em sete capítulos, sendo organizado da seguinte forma: previsão de cargas elétricas, redes neurais artificiais, algoritmo retropropagação, teoria da ressonância adaptativa, rede neural ART&ARTMAP nebulosa, aplicação das redes neurais – previsão de cargas elétricas e finalizando com as observações finais e sugestões para trabalhos futuros.

O capítulo 2 trata da teoria da previsão de carga elétrica descrevendo as características das cargas elétricas, os fatores que influenciam a modelagem da carga elétrica, classificação dos tipos de previsão de carga elétrica e finalmente as técnicas de previsão de carga elétrica existentes nos dias de hoje.

No capítulo 3 é feita uma abordagem geral sobre redes neurais na qual é apresentada uma síntese histórica sobre redes neurais, até os tipos de redes encontradas na literatura e as inúmeras vantagens em utilizá-las. Neste capítulo é descrito, também, o funcionamento de um neurônio artificial, das estruturas e dos tipos de treinamentos existentes.

No capítulo 4 é elaborado um minucioso estudo com relação ao algoritmo retropropagação. Este capítulo retrata duas formulações de algoritmo retropropagação: algoritmo retropropagação com controlador nebuloso [Lopes, 2000; Lopes et al., 2000; Lopes et al., 2003] e o algoritmo retropropagação com controlador nebuloso e com adaptação dos parâmetros de inclinação e translação da função sigmóide [Lopes et al., 2003].

No capítulo 5 são descritos os principais conceitos da teoria da ressonância adaptativa. Este capítulo enfoca a arquitetura e o algoritmo das redes neurais ART e ARTMAP que são as principais ferramentas para o desenvolvimento da rede neural proposta.

O desenvolvimento de uma arquitetura de rede neural, designada ART&ARTMAP nebulosa, para o problema de previsão de cargas elétricas, é discutido no capítulo 6. Esta rede é uma inovação dentre as redes existentes e é introduzida a partir do hibridismo entre duas redes da família ART: rede neural ART nebulosa e rede neural ARTMAP nebulosa.

No capítulo 7 é apresentada uma aplicação das três estruturas de redes neurais desenvolvidas (rede neural *feedforward* via algoritmo retropropagação com controlador nebuloso, rede neural *feedforward* via algoritmo retropropagação com controlador nebuloso e com adaptação dos parâmetros de inclinação e translação da função sigmóide e finalmente rede neural ART&ARTMAP nebulosa) no campo de previsão de cargas elétricas.

No capítulo 8 são apresentadas as conclusões e as contribuições deste trabalho, retratando também, as sugestões para trabalhos futuros.

Este texto, também, contém três apêndices. No apêndice A é descrito os principais conceitos sobre a teoria da lógica nebulosa introduzidas por Zadeh. O apêndice B é composto por dados de cargas horárias que foram utilizados na formação do banco de entradas usados no treinamento das redes neurais desenvolvidas. Os artigos científicos decorrentes deste trabalho encontram-se relacionados no apêndice C.

# Capítulo 2

## Previsão de Cargas Elétricas

*A previsão de carga vem se tornando, ao longo do tempo, um dos principais campos de pesquisa da Engenharia Elétrica. A previsão de cargas é um dos problemas-chave para o planejamento e operação dos sistemas elétricos de potência. Dentre as inúmeras aplicações na área destacam-se: fluxo de potência, fluxo de potência ótimo, análise de estabilidade, geração econômica, planejamento da produção, planejamento e operação de redes de distribuição, planejamento da tarifa e preços de eletricidade, serviço ao consumidor, etc. Assim sendo, este capítulo enfoca os conceitos sobre o problema de previsão de cargas elétricas. Será feito o detalhamento de como funciona a previsão de carga elétrica nos sistemas de potência, bem como, os métodos e as técnicas utilizadas para solucionar tal problema.*

### **2.1. Importância da Previsão de Cargas Elétricas**

Com a ascensão do mercado de energia competitivo, em consequência da desregulamentação dos sistemas de potência, a eletricidade tem se tornado uma mercadoria a ser vendida e comprada levando a grande competição no mercado, no qual o risco de perda tem de ser mínimo. Logo, a previsão de cargas

exerce um papel importante para os sistemas de potência e afeta de forma significativa os preços das tarifas elétricas [Hippert et al., 2001; Vehviläinen & Keppo, 2003; Sfetsos, 2003].

De forma geral, se o mercado de eletricidade possui um sistema de previsão de demanda de carga que execute esta tarefa com um erro mínimo, ou seja, o método desenvolvido seja bastante preciso, este mercado terá uma maximização em seus lucros e com isso reduzirá suas possíveis perdas, pois o sistema estará apto a desenvolver estratégias apropriadas de forma a operá-lo.

Existem diversas aplicações na área de sistemas de potência onde a previsão de carga também possui um alto grau de importância. São elas: geração econômica de potência, controle de distribuição e operação, planejamento de manutenção, segurança do sistema, entre outras.

## 2.2. Cargas Elétricas

As cargas elétricas são compostas por milhares de aparelhos e dispositivos que, quando consideradas em conjunto, apresentam tendências que podem ser estatisticamente previstas. Tais tendências são influenciadas por fatores que interferem na forma de modelar a carga. Esses fatores podem ser divididos em: condições meteorológicas, fatores diversos e fatores sazonais. Para efetuar a previsão, primeiramente, é necessário que seja feita uma análise desses fatores e verificar como eles influenciam o comportamento da carga. Na literatura tem sido proposto uma variedade de métodos previsionais, de modo a estabelecer previsões com certo grau de precisão. Esses métodos serão apresentados mais adiante. Os métodos de previsão de carga necessitam, basicamente, de duas condições fundamentais [Almeida et al., 1991]:

1. informações sobre o passado quantificadas em forma de dados e
2. assumir que o comportamento ocorrido no passado, de certa forma, irá se repetir no futuro.

Os métodos utilizados para previsão de carga podem ser classificados em três classes [O'Donovan, 1983]:

1. **Métodos Intuitivos:** Encontram-se nesta categoria os métodos de previsão que não utilizam um modelo matemático formal para descrever o comportamento da carga.
2. **Métodos Autônomos:** Compreendem os métodos de previsão que utilizam modelos baseados somente na extrapolação de observações passadas da carga. A técnica usada consiste na análise da evolução da carga no tempo, podendo, de acordo com determinados padrões de comportamento, ser classificada em horizontal, sazonal e tendenciosa. No padrão horizontal os dados da carga flutuam em torno de um determinado valor médio constante no tempo. Para o padrão tendencioso, os dados flutuam em torno de uma curva de tendência (média variável no tempo). No padrão sazonal, a carga é influenciada por fatores temporais, tais como: estações do ano, dias da semana. Já para o padrão cíclico as flutuações ocorrem variando em amplitude e duração.
3. **Métodos Causais:** Estes métodos assumem que a carga exibe uma relação de causa e efeito com uma ou mais variáveis independentes, que irão descrever seu comportamento. As variáveis utilizadas para justificar a tendência de crescimento da carga são: índices sócio-econômicos, crescimento populacional, etc.

A determinação do padrão de comportamento da carga é utilizada na escolha do modelo adequado, visando descrever a evolução da carga no tempo e através dele pode-se dividir a série temporal (evolução da carga no tempo) em duas classes [O'Donovan, 1983]:

1. **Estacionária:** Uma série temporal é dita ser estacionária se os dados da carga tiverem flutuações em torno de uma média constante no tempo. Na Figura 2.1, tanto o item (a) como o item (b), possuem dados que mantêm uma média constante no tempo, o que indica que a série temporal é estacionária.

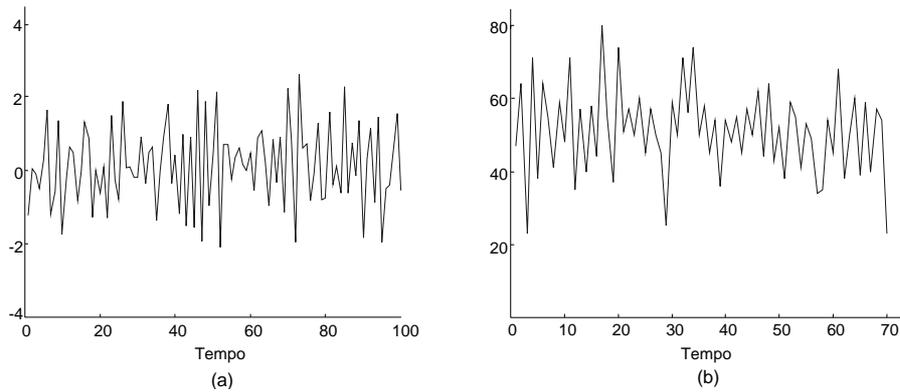


Figura 2.1. Série temporal estacionária.

2. **Não-estacionária:** A série temporal é não-estacionária se os dados da carga variam com o tempo, ou seja, se o padrão básico da série histórica dos dados apresentam padrões tendenciosos, cíclicos, sazonais ou aleatórios. Na Figura 2.2 nota-se que o item (a) apresenta um padrão sazonal sobreposto semelhante a um padrão horizontal e o item (b) exibe um padrão sazonal com aparente tendência para cima caracterizando assim uma série temporal não-estacionária. Trata-se, portanto, de um comportamento que não se observa uma tendência estatística.

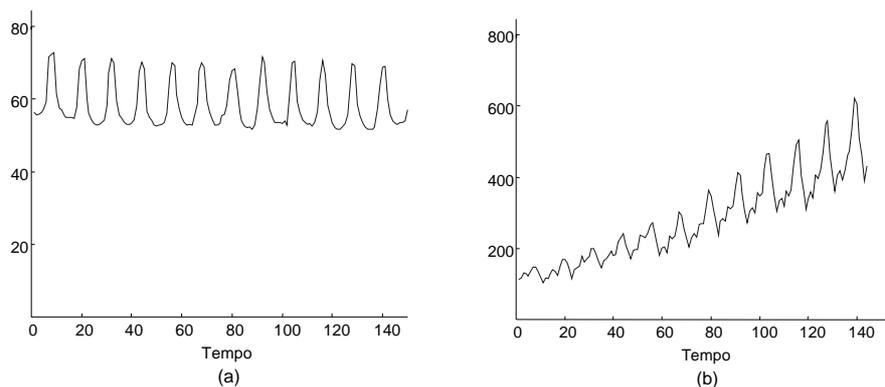


Figura 2.2. Série temporal não-estacionária.

Após selecionar a classe de modelos que melhor descreve os padrões de comportamento, é preciso escolher um modelo adequado desta classe que

melhor descreve a série temporal com o propósito de realizar previsões para valores futuros desta.

### 2.3. Fatores que Influenciam a Carga Elétrica

Os sistemas elétricos de potência fornecem energia elétrica para diferentes tipos de consumidores que podem ser divididos em:

1. Residencial;
2. Comercial;
3. Industrial.

Os fatores que influenciam a carga residencial dependem, basicamente, do consumo particular e são os mais difíceis de determinar já que cada pessoa possui um comportamento de consumo próprio. O consumo das indústrias apesar de serem previsíveis, já que a carga depende do grau de produção, enfrenta o problema de ocorrência de eventos inesperados (acidentes com as máquinas de produção ou até mesmo as greves) que venham a ocasionar distúrbios inesperados. Isto afeta bastante a previsão de carga, pois a grande parte da eletricidade é consumida pelas indústrias. Assim, dentre vários fatores que dificultam o trabalho de previsão tem-se:

- Fatores climáticos: são os fatores que ocorrem a curto prazo. Tem-se como exemplos: temperatura, velocidade do vento, neblina, umidade relativa do ar, temporal com relâmpago e trovão, chuva, neve, etc. Basicamente, tem-se que a temperatura é, em parte afetada, pela nebulosidade, chuva, neve, etc. Logo, dentre todos os fatores mencionados a temperatura influencia diretamente no consumo de energia elétrica delimitando o uso de condicionador de ar, aquecedor, refrigerador, etc. [Swarup & Satish, 2002; Hippert et al., 2001, Murto, 1998];

- Fatores econômicos e demográficos: são os fatores que ocorrem a longo prazo e que possuem importância fundamental na evolução da previsão de carga. Tem-se como exemplo: área demográfica (rural, residencial, industrial), crescimento industrial, aparecimento de novas indústrias, variação na agricultura, tendências econômicas, variação nos preços de eletricidade, administração da carga (demanda), etc. [Murto, 1998];
- Fatores de tempo: são desempenhados pelos comportamentos cíclicos e efeitos sazonais. No comportamento sazonal se observa a variação da carga nos acontecimentos a cerca de determinados períodos do ano, tais como: férias, feriados, início do ano escolar, natal, ano novo, semana típica onde corresponde ao ciclo de trabalho e descanso, etc. No comportamento cíclico se observa o comportamento da carga em dias especiais, tais como: redução significativa da carga nos dias de sábado e domingo, pequena redução da carga na sexta-feira e na segunda-feira, etc. [Murto, 1998];
- Fatores esporádicos: são fatores que causam perturbações na carga tais como: eventos esportivos, programas de televisão, paralisação das indústrias, início ou parada de eventos onde a carga elétrica é grande (usina siderúrgica, fornalha, fábrica, etc.) [Murto, 1998].

#### **2.4. Classificação da Previsão de Cargas Elétricas**

A previsão de carga temporal consiste na determinação de procedimentos efetuados para o fornecimento e consumo da carga realizados em horas, dias, meses ou anos. Desta forma, pode-se classificar a previsão de carga de acordo com o período em que a carga é prevista. Existem quatro tipos de previsão de cargas, são elas [Al-Kandari et al., 2004; Metaxiotis et al., 2003; Murto, 1998; Swarup & Satish, 2002; Yalcinoz & Eminoglu, 2004]:

1. **Previsão de Carga a Longo Prazo:** este tipo de previsão é realizada principalmente na operação de planejamento de sistemas de potência. Essa

previsão envolve um período de 10 a 20 anos. É realizada com o propósito de efetuar um planejamento a longo prazo. Esses tipos de previsões não consideram os dados de carga elétrica diária ou semanal, somente a tendência do consumo de demanda de carga a longo prazo. Podem ser aplicados também na provisão de equipamentos elétricos, preços de eletricidade, preços de fontes alternativas de energia, etc.

2. **Previsão de Carga a Médio Prazo:** esta previsão é feita para o planejamento de suprimento de combustível, programas de manutenção e planejamento de produção a médio prazo. Ela abrange o período de poucas semanas ou até mesmo alguns anos.
3. **Previsão de Carga a Curto Prazo:** ela ocorre no planejamento e operações econômica e de segurança diária dos sistemas de potência. A previsão é feita no intervalo de tempo de meia hora a poucas horas, ou até mesmo de 1 dia a 1 semana. A previsão de carga a curto prazo estima a carga para cada hora do dia, pico de carga diária ou geração de energia diária ou semanal.
4. **Previsão de Carga a Curtíssimo Prazo:** são essencialmente usadas para o planejamento de produção *on-line* e controle. A previsão ocorre entre poucos segundos e pouco menos de 15 minutos.

No trabalho desenvolvido somente será focado o problema de previsão a curto prazo e a previsão realizada é efetuada apenas para 24 horas à frente.

## 2.5. Técnicas de Previsão de Cargas Elétricas

Existem inúmeras técnicas ou métodos para efetuar a previsão de cargas elétricas. Estas podem ser categorizadas em duas classes fundamentais, que são [Gross & Galiana, 1987; Bunn & Farmer, 1985]:

- **Modelos Não-dinâmicos:** a carga é expressa como uma série temporal discreta consistindo de valores previstos para cada hora durante um período;

- **Modelos dinâmicos:** a carga é identificada não apenas como uma função de tempo do dia, mas também de seus comportamentos mais recentes. Por essa razão, a previsão para uma certa hora precisa de previsões feitas em horas anteriores.

Com respeito aos métodos existentes, conforme a literatura consultada, estes estão divididos, basicamente, em duas classes:

- 1) métodos estatísticos e
- 2) sistemas especialistas.

### 2.5.1. Métodos Estatísticos

Os métodos estatísticos são aqueles baseados em técnicas estatísticas onde a formulação da modelagem matemática da carga é de extrema importância. Dentre os métodos existentes tem-se: regressão linear ou múltipla, alisamento exponencial, filtro de Kalman, espaço de estado e série temporal de Box-Jenkins.

#### 2.5.1.1. Método de Regressão Linear ou Múltipla

Este modelo descreve o comportamento estocástico de padrões de carga horária em um sistema de potência. Ele assume que a carga, em uma determinada hora, pode ser estimada a partir da relação da carga padrão e algumas variáveis explanatórias, que, por exemplo, podem ser variáveis climáticas, o tipo do dia, classes de clientes, etc. O método pode ser descrito da seguinte forma conforme relatam [Moghram & Rahman, 1989; Swarup & Satish, 2002; Sfetsos, 2003; Murto, 1998]:

$$y(t) = a_0 + \sum_{i=1}^n a_i q_i(t) + a(t)$$

em que:

$y(t)$  = carga elétrica;

$a_0, a_1, \dots, a_n$  = coeficientes de regressão;

$q_1, \dots, q_n$  = variáveis explanatórias;

$a(t)$  = variável aleatória com média zero e variância constante.

Os coeficientes de regressão são encontrados através do método dos mínimos quadrados. São realizados testes estatísticos para determinar a significância desses coeficientes de regressão. É um método de fácil implementação.

### 2.5.1.2. Alisamento Exponencial

A modelagem da carga  $y(t)$ , para o tempo  $t$ , utilizando a função de ajuste [Moghram & Rahman, 1989]:

$$f(t) = L f(t-1)$$

é dada pela Equação (2.5.1.2.1)

$$y(t) = \varphi(t)^T f(t) + \varepsilon(t) \quad (2.5.1.2.1)$$

sendo:

$y(t)$  = carga elétrica;

$\varphi(t)$  = vetor de coeficiente;

$f(t)$  = vetor da função de ajuste para o processo;

$\varepsilon(t)$  = ruído branco;

$L$  = matriz de transição;

$T$  = operador transposto.

### 2.5.1.3. Espaço de Estado e Filtro de Kalman

Neste método a carga é modelada como uma variável de estado usando a formulação de espaço de estado. O modelo de espaço de estado para carga no tempo  $t$  é descrito da seguinte forma [Moghram & Rahman, 1989, Villalba & Bel,2000; Murto,1998]:

$$\text{Equação do espaço de estado:} \quad \mathbf{y}(t+1) = \mathbf{A}(t) \mathbf{y}(t) + \mathbf{w}(t)$$

$$\text{Equação de medida:} \quad z(t) = \mathbf{B}(t) \mathbf{y}(t) + v(t)$$

em que:

$\mathbf{y}(t)$  = carga elétrica;

$\mathbf{A}(t)$  = matriz de transição;

$\mathbf{w}(t)$  = ruído branco com matriz de covariância  $\mathbf{Q}(t)$ ;

$z(t)$  = vetor de medição no tempo  $t$ ;

$\mathbf{B}(t)$  = matriz que correlata  $\mathbf{y}(t)$  e  $z(t)$ ;

$v(t)$  = erro medido (ruído com matriz de covariância  $\mathbf{S}(t)$ ).

Para implementar o filtro de Kalman deve-se seguir os seguintes procedimentos:

1. encontrar a estimativa  $\mathbf{y}(t/t-1)$  e o erro da matriz de covariância  $\mathbf{p}(t/t-1)$ ;
2. calcular o ganho de Kalman:

$$\mathbf{k}(t) = \mathbf{p}(t/t-1) \mathbf{B}(t)^T [\mathbf{B}(t) \mathbf{p}(t/t-1) \mathbf{B}(t)^T + \mathbf{S}(t)]^{-1};$$

3. calcular a estimativa atualizada do erro da matriz de covariância:

$$\mathbf{p}(t/t) = [\mathbf{1} - \mathbf{k}(t) \mathbf{B}(t)] \mathbf{p}(t/t-1)$$

sendo:

$\mathbf{k}(t)$  = fator de combinação;

4. projetar, à frente, a estimativa  $y(t+1/t)$  e o erro da matriz de covariância  $p(t+1/t)$  associada com

$$y(t+1/t) = A(t) y(t/t)$$

$$p(t+1/t) = A(t) p(t/t) A(t)^T + Q(t);$$

5. Retornar ao passo 2 mudando para o próximo passo de tempo.

A previsão de espaço de estado é baseada no modelo de Kalman e a sua maior dificuldade está no processo de identificação.

#### 2.5.1.4. Série Temporal de Box&Jenkins

É a classe mais popular de modelos de previsão dinâmica. O princípio básico é que a série temporal da carga pode ser transformada em uma série temporal estacionária (invariante no tempo). A carga  $y(t)$  é modelado como sendo a saída de um filtro linear que tem como entrada, séries aleatórias  $a(t)$ , denominadas ruído branco, com média zero e variância  $\sigma_a^2(t)$ .

A classe de modelos que melhor apresenta as características da série temporal estacionária é a classe de modelos ARMA [O'Donovan, 1983; Moghram & Rahman, 1989; Murto, 1998]. Dentre os mesmos, podem-se citar os seguintes modelos: o modelo Ruído Branco, o modelo *Auto Regressive* (AR), o modelo *Moving Average* (MA) e finalmente o modelo *Auto Regressive Moving Average* (ARMA).

##### 2.5.1.4.1. Modelo Ruído Branco

O modelo é definido por [O'Donovan, 1983]:

$$y(t) = \theta_0 + a(t)$$

em que:

$y(t)$  = carga elétrica;  
 $a(t)$  = séries aleatórias;  
 $\theta_0$  = termo constante.

#### 2.5.1.4.2. Modelo *Auto Regressive* (AR(p))

O modelo é definido pela equação [O'Donovan, 1983; Moghram & Rahman, 1989]:

$$y(t) = \theta_0 + \phi_1 y(t-1) + \phi_2 y(t-2) + \dots + \phi_p y(t-p) + a(t)$$

sendo que:

$\phi_1, \dots, \phi_p$  = coeficientes auto-regressivos;  
 $p$  = ordem do modelo.

#### 2.5.1.4.3. Modelo *Moving Average* (MA(q))

O modelo é definido da seguinte forma [O'Donovan, 1983; Moghram & Rahman, 1989]:

$$y(t) = \theta_0 + a(t) - \theta_1 a(t-1) - \theta_2 a(t-2) - \dots - \theta_q a(t-r)$$

no qual:

$\theta_1, \dots, \theta_p$  = são coeficientes de média móvel;  
 $r$  = ordem do modelo.

#### 2.5.1.4.4. Modelo *Auto Regressive Moving Average* (ARMA(p,q))

Este modelo utiliza ambos os termos *autoregressive* e de *moving average*. O modelo é definido da seguinte maneira [O'Donovan, 1983; Moghram & Rahman, 1989; Murto, 1998]:

$$y(t) = \theta_0 + \phi_1 y(t-1) + \phi_2 y(t-2) + \dots + \phi_p y(t-p) + a(t) - \theta_1 a(t-1) - \theta_2 a(t-2) - \dots - \theta_q a(t-r)$$

Os modelos ARIMA( $p,d,r$ ) são as classes mais comuns de modelos que melhor representam uma série temporal não-estacionária.

As séries temporais não-estacionárias passam por uma transformação denominada *differencing*, a qual possui a finalidade de estacionarizá-las para então depois serem utilizadas [O'Donovan, 1983, Moghram & Rahman, 1989; Murto, 1998]. Dentre os modelos de série temporal não-estacionária tem-se: o modelo *Walk Aleatório* e os modelos *Auto Regressive Integrated Moving Average* (ARIMA).

#### 2.5.1.4.5. Modelo Walk Aleatório

O modelo é definido por [O'Donovan, 1983]:

$$y(t) = y(t-1) + \theta_0 + a(t)$$

Este modelo é caracterizado pelo fato de que as primeiras diferenças regulares desse modelo forma um modelo de Ruído Branco. Neste modelo, a previsão para todos os períodos de tempo futuro é exatamente o último valor observado da série temporal.

#### 2.5.1.4.6. Modelos *Auto Regressive Integrated Moving Average* (ARIMA)

São caracterizados pelas primeiras diferenças regulares formarem modelos ARMA, tais como AR(1), AR(2), MA(1) e MA(2) [O'Donovan, 1983].

O primeiro destes é conhecido como modelo *Autoregressive Integrated* ARI(1,1) sendo definido como [O'Donovan, 1983]:

$$y(t) = \theta_0 + (1 + \phi_1) y(t-1) - \phi_1 y(t-2) + a(t)$$

em que as primeiras diferenças regulares forma um modelo AR(1). O modelo ARI(2,1) é encontrado de forma similar e as primeiras diferenças regulares forma um modelo AR(2).

O modelo IMA(1,1) é definido como [O'Donovan, 1983]:

$$y(t) = \theta_0 + y(t-1) - \theta_1 a(t-1) + a(t)$$

no qual as primeiras diferenças regulares formam um modelo MA(1). O modelo IMA(1,2) é encontrado, de forma similar, sendo que as primeiras diferenças regulares formam um modelo MA(2).

O último modelo a ser considerado é o modelo ARIMA(1,1,1) sendo que as primeiras diferenças regulares deste modelo formam um modelo ARMA(1,1). Este modelo é descrito como [O'Donovan, 1983]:

$$y(t) = \theta_0 + (1 + \phi_1) y(t-1) - \phi_1 y(t-2) + a(t) - \theta_1 a(t-1)$$

De uma forma geral, os modelos considerados são todos casos particulares dos modelos ARIMA  $(p,1,r)$ , cujas primeiras diferenças regulares formam modelos ARMA $(p,r)$ .

Os modelos ARIMA $(p,d,r)$  são aqueles cujas  $d$ -ésimas diferenças regulares formam modelos ARMA $(p,r)$ . É importante lembrar que na prática modelos ARIMA $(p,d,r)$  com  $d \geq 2$  não ocorrem.

### 2.5.2. Sistemas Especialistas

Os sistemas especialistas são modelos heurísticos baseados na inteligência artificial e que tentam imitar o raciocínio humano. Em resumo, um sistema especialista é um programa que possui uma base de conhecimento em um domínio restrito e usa um raciocínio conclusivo e complexo na execução de tarefas [Moghram & Rahman, 1989; Metaxiotis et al., 2003; Murto, 1998].

A previsão de carga realizada por um técnico é feita em cima de um banco de dados histórico que contém informações que auxiliem na previsão, tais como: tipo do dia, fatores sociais e fatores do tempo. Desta forma, os valores de carga desses dias são tomados como uma base para a previsão. Um sistema especialista é uma versão automatizada deste processo de busca.

Pode-se também construir um sistema de previsão utilizando como base o conhecimento. Este conhecimento é representado por fatos e regras que possuem a capacidade de denotar as regras e fatos do tipo *if-then*. Essas regras definem as relações entre os fatores externos e as cargas diárias e são desenvolvidas com base na lógica nebulosa [Zadeh, 1965]. As técnicas baseadas em redes neurais artificiais, algoritmo genético, programação evolutiva, etc., também fazem parte dos sistemas especialistas e vêm sendo utilizadas na previsão de carga.

Existem outros métodos heurísticos que são utilizados na previsão de carga e, com certeza, estes vêm se tornando uma opção alternativa para a área, pelo fato de obterem resultados que são compatíveis com os obtidos pelos métodos tradicionais e por serem de fácil implementação. Normalmente, os sistemas especialistas não levam em consideração as correlações de fatores externos com a carga elétrica, o que é uma tarefa muito difícil, e tem de ser levada em consideração para utilizar os métodos tradicionais.

#### **2.5.2.1. Lógica Nebulosa**

A lógica nebulosa é uma generalização da lógica booleana. A diferença é que na lógica nebulosa, as entradas são avaliadas como variáveis lingüísticas. Por exemplo, a carga no transformador pode ser “baixa”, “média” ou “alta”. A lógica nebulosa possui a capacidade de deduzir saídas a partir das entradas nebulosas (mapeamento de entradas e saídas). Desta forma, a lógica nebulosa não necessita de uma modelagem matemática para relacionar as entradas e saídas e suas entradas podem conter algumas imprecisões. Isto garante que o método seja

robusto quando for utilizado. Dadas as entradas nebulosas, ocorre o processamento lógico (base de regras do tipo *if-then*) e em seguida a desnebulização a qual produzirá saídas com uma ótima precisão.

Existem inúmeros artigos que utilizam a lógica nebulosa para realizar a previsão de carga. Dentre eles destacam-se as referências: [Al-Kandari et al., 2004; Liao & Tsao, 2004; Liu et al., 1996; Wang et al., 2002].

### 2.5.2.2. Redes Neurais Artificiais

Desde 1990 as redes neurais artificiais vêm sendo utilizadas como ferramenta na resolução do problema de previsão de cargas elétricas [Swarup & Satish, 2002; Metaxiotis et al., 2003; Baczynski & Parol, 2003; Sfetsos, 2003; Hippert et al., 2001; Liu et al., 1996; Chen et al., 1996;].

As redes neurais são estruturas de processamento de informação, composta por unidades de processamento (neurônios) interconectadas. Estas possuem a capacidade de fornecer saídas relacionadas a entradas lineares ou não-lineares (generalização).

A rede neural artificial baseada no algoritmo retropropagação (*backpropagation*) [Rumelhart et al., 1986]. Uma das técnicas mais utilizadas para realizar a previsão de cargas elétricas. O treinamento é baseado no banco de dados de entrada com a conseqüente saída desejada. Os dados de entrada contêm dados históricos da carga, dados do tempo, etc. Já os dados de saída são formados por dados históricos da carga.

Para se efetuar a previsão de carga utilizando redes neurais artificiais é necessário:

- escolher qual a estrutura de rede neural será usada;
- escolher o tipo de treinamento mais adequado à estrutura da rede neural e ao problema em questão e

- escolher os dados que serão utilizados como entrada da rede neural artificial, ou seja, os dados representativos que caracterizam o problema.

A vantagem do uso das redes neurais é a capacidade da rede em se instruir somente através das relações existentes entre os padrões de entrada e de saída. Normalmente, os padrões de entrada são dados das cargas atuais e passadas. A saída é composta por valores da carga futura (um passo à frente). Além disso, as redes neurais possuem a capacidade de efetuar aproximações de funções contínuas com uma precisão desejada. Assim, podem ser vistas como métodos multivariados.

Os métodos baseados na inteligência artificial vêm demonstrando grande eficiência, quando aplicados a problemas da vida real, como, por exemplo, a previsão de cargas elétricas. Atualmente, na literatura encontram-se inúmeras técnicas que vem mostrando resultados bastante promissores. Tais técnicas são baseadas no hibridismo entre a lógica nebulosa, redes neurais artificiais, métodos estatísticos e estocásticos, e que quando unidas tendem a obter melhores resultados [Wang et al., 2002; Liao & Tsao, 2004; Villalba & Bel, 2000; Kermanshahi & Iwamiya, 2002; Chandrashekara et al., 1999; Chui et al., 1997; Skarman et al., 1998].

## **2.6. Comentários**

Neste capítulo foi apresentado um estudo sobre a previsão de cargas elétricas. Este enfocou na importância em se efetuar a previsão de carga elétrica nos dias de hoje e nas relações existentes entre os fatores (climático, econômico, tempo e aleatório) que interferem na previsão de carga elétrica. Também foram abordados os diferentes tipos de previsões de cargas elétricas que podem ser realizadas (longo-prazo, médio-prazo, curto prazo e curtíssimo prazo) e as inúmeras técnicas existentes na literatura que são utilizadas para resolver este problema.

# Capítulo 3

## Redes Neurais Artificiais

*Neste capítulo será apresentada uma revisão sobre redes neurais artificiais onde serão abordados os principais conceitos envolvendo os modelos de neurônios biológicos e artificiais, suas estruturas, seus componentes e o seu funcionamento. Também serão abordados os principais tipos de redes neurais artificiais e as formas de treinamento.*

### 3.1. Reflexão Histórica

Desde os últimos 100 anos, o ser humano vem sendo impulsionado em desvendar o conhecimento sobre o funcionamento do cérebro. A partir daí, pesquisadores já se sentiram estimulados em adentrar em um novo ramo da ciência.

Os primeiros conceitos da era moderna das redes neurais artificiais (RNAs) surgiram na década de 40, mais especificamente em 1943 com o trabalho precursor de McCulloch e Pitts [McCulloch & Pitts, 1943] que descrevia um cálculo lógico sobre as redes neurais unindo estudos neuro-biológicos com a lógica matemática. A década de 40 terminou com a publicação do livro “*The Organization of Behavior*” escrito por Donald Hebb, em 1949 [Hebb, 1949], que introduziu o conceito básico da aprendizagem Hebbiana.

A década de 50 presenciou o surgimento de redes baseadas em reforço, com formas simples de aprendizado desenvolvidas por Minsky em 1951. Em 1958 Von Neumann com o livro “*The Computer and the Brain*” [Von Neumann, 1958], descreveu a modelagem do desempenho do cérebro através de *hardware*.

Na década de 60, o interesse nesta área ressurgiu em 1962 com Rosenblatt, que publicou o livro “*Principles of Neurodynamics*” [Rosenblatt, 1962]. Este livro introduziu as redes denominadas *perceptrons*, que mais tarde, em 1969, se tornariam alvo de pesquisas efetuadas por Minsky e Papert [Minsky & Papert, 1969]. Eles descobriram que os *perceptrons*, descritos por Rosenblatt, eram incapazes de resolver problemas elementares como o problema do ou-exclusivo. Com isso, o interesse de pesquisa nesta área diminuiu.

Somente no final da década de 70 e início da década de 80, foi quando houve a renovação do interesse nas redes neurais artificiais. Grossberg, Kohonen, Anderson, Hopfield, etc. contribuíram nesta nova fase. Pode-se dizer que o marco mais importante foi o desenvolvimento do algoritmo *Backpropagation* (retropropagação), primeiramente proposto por Werbos em 1974 [Werbos, 1974], e em 1986 redescoberto por Rumelhart, Hinton e Williams [Rumelhart et al., 1986]. Este algoritmo tornou-se o mais popular entre as redes neurais artificiais e renovou o interesse de pesquisadores nesta área do conhecimento humano. Atualmente, o ramo de pesquisa nesta área tem expandido. Desta forma, espera-se redes mais eficientes que possam ser aplicadas a inúmeros problemas importantes da vida real.

### **3.2. Modelo Neural Biológico**

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 [Mendes Filho & Carvalho, 1997].

O cérebro humano é composto por cerca de 100 bilhões de neurônios que executam papel essencial na determinação do funcionamento e comportamento do corpo humano e do raciocínio. Na Figura 3.1 são mostrados os vários componentes de um neurônio biológico mais comum [Mendes Filho & Carvalho, 1997].

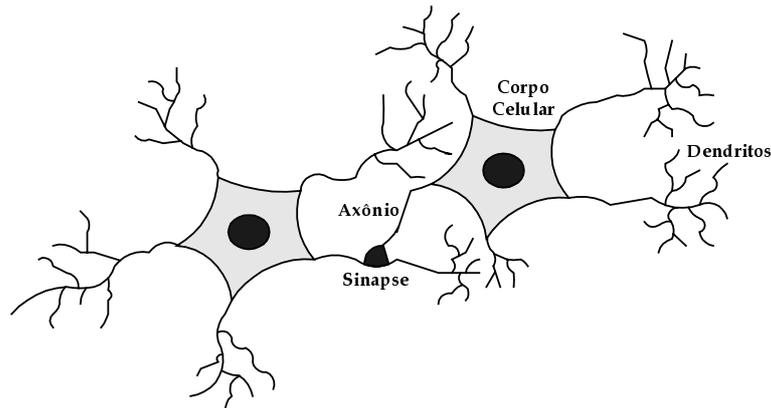


Figura 3.1. Componentes de um neurônio biológico.

No cérebro humano, os neurônios captam os sinais entre si, através de inúmeras estruturas finas chamadas *dendritos* (terminais de entrada), e enviam atividades elétricas por meio de um longo e fino suporte conhecido como *axônio* (terminal de saída) [Mendes Filho & Carvalho, 1997; Stergiou, 1996].

Os neurônios são interligados por meio das *sinapses*, região na qual o *axônio* de um neurônio conecta o *dendrito* de outro neurônio. Se um neurônio é ativado, um sinal eletroquímico é disparado ao longo do *axônio* que, através das *sinapses*, é enviado para outro neurônio.

O sinal eletroquímico do neurônio é disparado somente se o sinal total recebido dos *dendritos* exceder a um certo nível (*threshold*) e, pode-se dizer que, o comprimento deste sinal depende da eficácia das *sinapses*. Cada *sinapse* contém uma abertura com um neurotransmissor químico para transmitir um sinal (impulso nervoso). Assim, pode-se concluir que, através desta conectividade, é atribuída a inteligência.

### 3.3. 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 tentativa de emular a rede neural do cérebro deu origem à chamada Rede Neural Artificial.

A rede neural artificial é um processador paralelo composto por unidades de processamentos (neurônios ou nodos) que possui a capacidade de armazenar conhecimento. Semelhante ao cérebro humano, a rede neural possui um neurônio artificial que foi designado a imitar as características do neurônio biológico. Dentre essas características citam-se [Wasserman, 1989]:

- **Processamento paralelo maciço:** Armazenamento do conhecimento através do treinamento [Storb & Wazlawick, 1999].
- **Interligações entre neurônios feitas por conexões sinápticas:** Utilizadas para o armazenamento de informações [Storb & Wazlawick, 1999].
- **Capacidade de generalização:** Permite que a rede neural artificial forneça, em tempo real saídas com uma razoável precisão para entradas que não participaram da fase de treinamento [Storb & Wazlawick, 1999].

A Figura 3.2 mostra os componentes de um neurônio artificial proposto por McCulloch e Pitts [McCulloch & Pitts, 1943; Stergiou, 1996].

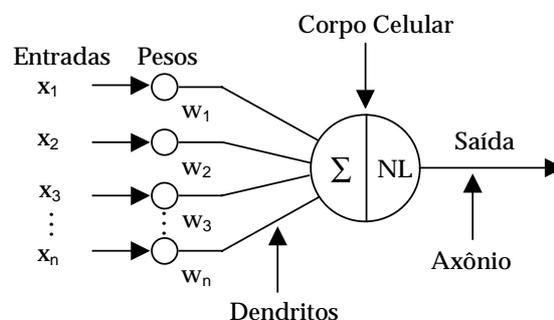


Figura 3.2. Componentes de um neurônio artificial.

O modelo básico de um neurônio artificial com  $n$  entradas é apresentado na Figura 3.3, sendo  $f(s)$  uma função não-linear denominada função de ativação.

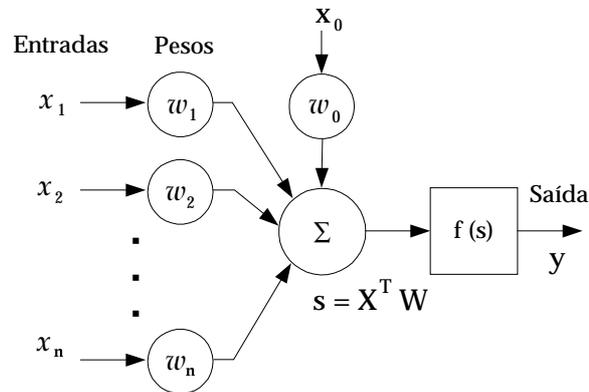


Figura 3.3. Modelo de um neurônio artificial.

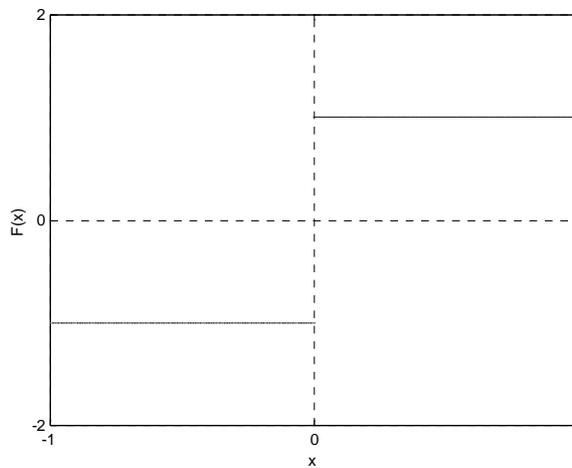
O processo de treinamento do neurônio artificial é muito simples e se desenvolve da seguinte forma [Wasserman, 1989]:

1. Um conjunto de entradas  $X, x_1, x_2, \dots, x_n$ , é aplicado ao neurônio artificial. As entradas correspondem aos sinais dentro das sinapses de um neurônio biológico.
2. Cada sinal é multiplicado por um peso associado  $V, w_1, w_2, \dots, w_n$ , que está relacionado com a “resistência” de uma única ligação sináptica biológica.
3. Em seguida estes são aplicados a um bloco somatório,  $\Sigma$ , denominado soma (*sôma* do grego que significa corpo celular), que corresponde ao corpo celular biológico.
4. Se a soma ponderada das entradas for maior que o valor de  $w_0$  (*bias*) o neurônio é ativado provocando um pulso na saída, como mostra a Equação (3.3.1). Caso contrário, o neurônio não é ativado. O peso *bias* pondera uma entrada (arbitrária)  $x_0 = +1$ , que atua como controle do nível de saída do neurônio [Storb & Wazlawich, 1999; Widrow & Lehr, 1990].

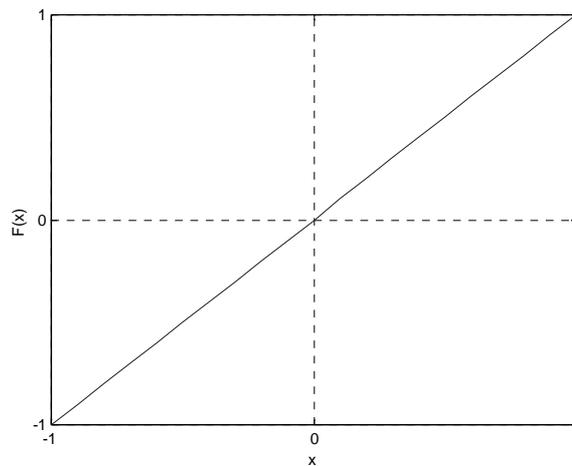
A saída intermediária do neurônio é, então, dada por:

$$s_i = \sum_j^n w_{ij} x_j \quad (3.3.1)$$

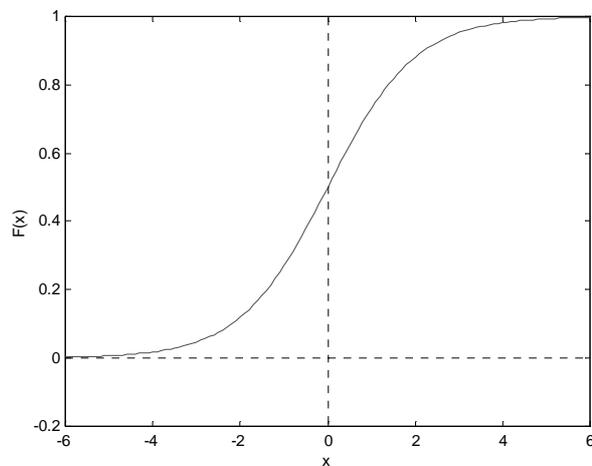
A ativação do neurônio artificial é feita por uma função denominada função de ativação. A Figura 3.4 mostra alguns exemplos de funções de ativação.



(a) Função Relé: 
$$F_R(s_i) = \begin{cases} 1 & s_i \geq 0 \\ -1 & s_i < 0 \end{cases}$$



(b) Função Linear: 
$$F_L(s_i) = s_i \text{ para todo } s_i$$



(c) Função Sigmoideal: 
$$F_S(s_i) = \frac{1}{1 + e^{-\lambda s_i}}$$

Figura 3.4. Funções de ativação: (a) função relé, (b) função linear e (c) função sigmoideal.

As funções do tipo relé são apropriadas para sistemas binários, enquanto que as funções sigmoideais podem ser empregadas tanto para sistemas contínuos como binários. A função sigmoide é a mais utilizada, por ser contínua e apresentar uma derivada simples [Aggarwal & Song, 1997; Fine, 1999; Simpson, 1989; Storb & Wazlawick, 1999; Widrow & Lehr, 1990].

### 3.4. Estrutura da Rede Neural

As redes neurais artificiais podem ser definidas como conjuntos bem estruturados de unidades de processamento, interligadas por canais de comunicação, cada qual tendo um determinado peso correspondente a um valor numérico.

Elas consistem de unidades de processamento, neurônios, conectados entre si formando uma disposição estrutural de camadas e conexões entre as

camadas. Basicamente, as redes neurais são compostas por três camadas: camada de entrada, camada intermediária e camada de saída como ilustra a Figura 3.5.

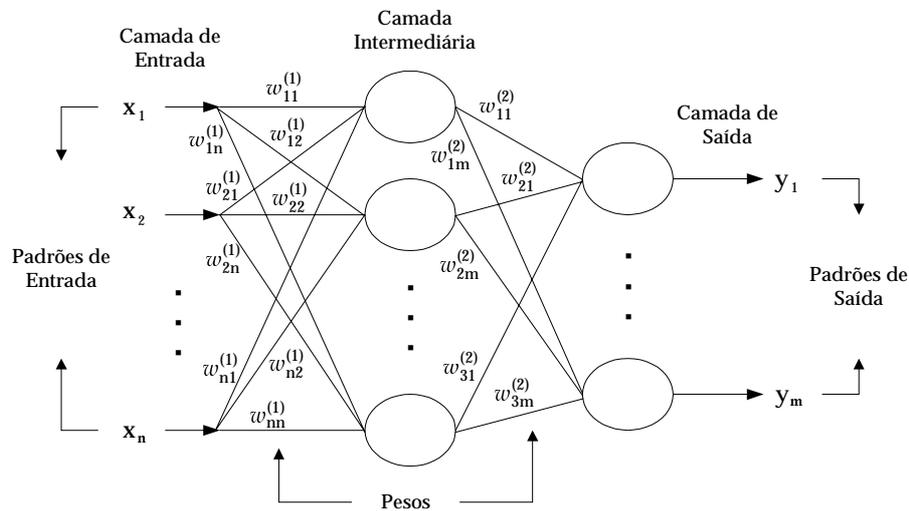


Figura 3.5. Disposição das redes neurais artificiais.

Com relação a propagação dos dados, as redes neurais podem ser divididas em duas classes [Krose & Smagt, 1996]:

1. *Redes Feedforward*: Os dados fluem das unidades de entrada para as unidades de saída. São estritamente *feedforward*. O processamento dos dados pode se estender sobre múltiplas unidades (camadas), porém, as conexões *feedback* não estão presentes [Krose & Smagt, 1996].
2. *Redes Recorrentes*: Contém conexões *feedback*. Em alguns casos, os valores de ativação das unidades submetem-se a um processo de adaptação tal que a rede evoluirá para um estado estável no qual estas ativações não variarão mais [Krose & Smagt, 1996].

A rede recorrente desenvolve uma memória a longo prazo nos neurônios internos, enquanto que na rede *feedforward* a saída é exclusivamente

determinada em função das entradas e dos valores dos pesos [Ward Systems Group, 2000; Wasserman, 1989].

### 3.5. Treinamento da Rede Neural

Dentre todas as características das redes neurais, uma das mais importantes é a habilidade de aprender e com isso melhorar seu desempenho. A rede é treinada de maneira que um conjunto de entrada produza o conjunto de saída desejada, ou pelo menos consistente [Mendes Filho & Carvalho, 1997; Wasserman, 1989].

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 [Wasserman, 1989]. Quanto ao tipo de treinamento, pode-se classificá-lo em dois grupos distintos:

1. **Treinamento Supervisionado ou Treinamento Associativo:** A rede é treinada através da combinação dos padrões de entrada e saída. Este treinamento exige a presença de um agente externo (tutor ou professor) na fase de aprendizado, que avalia e informa à rede sobre seu desempenho. O agente externo adquire conhecimento da rede, na forma de mapeamentos (padrões) de entrada-saída. Dentre algumas redes que possuem este tipo de treinamento pode-se citar: a rede Madaline, que utiliza o algoritmo de aprendizagem *Backpropagation*, a rede Grossberg, a rede ARTMAP, a rede ARTMAP *Fuzzy*, entre outras [Krose & Smagt, 1996; Wasserman, 1989].
2. **Treinamento Não-supervisionado (*Self-Organization*):** O conjunto de treinamento consiste exclusivamente de vetores de entrada. O treinamento não-supervisionado não possui tutor, ou seja, a rede é autônoma. Neste paradigma, o sistema é suposto como sendo capaz de descobrir,

estatisticamente, características relevantes dos dados de entrada. As redes de Hopfield, Kohonen e ART (convencional e nebulosa) são exemplos de redes que possuem treinamento não-supervisionado [Krose & Smagt, 1996; Wasserman, 1989].

3. **Treinamento Competitivo:** Semelhante ao treinamento supervisionado, neste treinamento existe uma saída desejada. As redes que utilizam este tipo de treinamento possuem vários neurônios de saída. Quando um padrão de entrada é aplicado à rede, os neurônios de saída “competem” entre si para que prevaleça apenas um neurônio, o qual fornecerá a saída desejada. Como exemplo de redes neurais que possuem este tipo de treinamento destaca-se a rede *Counterpropagation* [Storb & Wazlawick, 1999].
4. **Treinamento Híbrido:** É o treinamento onde ocorre uma alternância entre o treinamento não-supervisionado e o treinamento supervisionado.

Existem diversos algoritmos para efetuar a aprendizagem de redes neurais artificiais. Dentre eles destacam-se [Krose & Smagt, 1996; Wasserman, 1989]:

- regra de *Hebb*;
- regra delta de *Widrow e Hoff*;
- regra delta generalizada;
- algoritmo de aprendizagem *Back-propagation*.

### 3.6. Tipos de Redes Neurais Artificiais

Existem diversos modelos de redes neurais artificiais sendo utilizados nas mais variadas aplicações. Dentre os modelos de redes neurais mais conhecidos, destacam-se [Storb & Wazlawick, 1999]:

- **Rede neural de McCulloch-Pitts:** 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 dos pesos [McCulloch & Pitts, 1943].
- **Perceptron de camada simples:** Proposta por *Rosenblatt* em 1958 é utilizada para o reconhecimento e classificação de padrões e também é usada para resolução de problemas lógicos que envolvem os operadores AND e OR. Já, a rede neural perceptron múltiplas camadas pode realizar operações lógicas complexas [Rosenblatt, 1958].
- **Rede neural ADALINE:** Desenvolvida em 1959 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 neural multicamada, torna-se uma rede neural MADALINE e apresenta um alto grau de tolerância a falhas [Widrow & Hoff, 1960].
- **Rede neural *feedforward*:** Proposta em 1969 por *Minsky* e *Papert*. Uma rede neural multicamada que é utilizada, por exemplo, para classificação e controle de robôs [Minsky & Papert, 1969].
- **SOM de Kohonen:** Foi elaborada por *Kohonen* em 1972. A rede SOM (Self Organizing Map) de *Kohonen* é uma rede competitiva com a habilidade de fazer mapeamentos entre dados de entrada e saída [Kohonen, 1972].
- **Rede neural *Backpropagation*:** Em 1974, *Werbos* apresentou a primeira concepção do algoritmo *Backpropagation* [Werbos, 1974]. Porém, foi a partir de 1986 que *Rumelhart*, *Hinton* e *Williams*, informados do trabalho de *Werbos*, tiveram idéia de como ajustar os pesos de uma rede neural das unidades de entrada para a unidade de saída e propagar o erro na direção inversa das unidades da camada de saída. Esta rede neural é utilizada em operações lógicas complexas e classificação de padrões [Rumelhart et al., 1986].

- **Rede ART:** A rede ART (*Adaptive Resonance Theory*) foi desenvolvida em 1975 por Grossberg e tem por base características da teoria da ressonância adaptativa. Ela é adaptada para reconhecimento de sinais e processamento de imagens [Grossberg, 1976].
- **Rede de Hopfield:** Desenvolvida em 1982 por Hopfield sendo uma rede utilizada para reconhecimento de imagens [Hopfield, 1982].
- **Rede CNM:** A rede neural CNM (*Combinatorial Neural Model*) é uma rede apropriada para o processamento de reconhecimento, análise e classificação de dados [Machado & Rocha, 1989].
- **Rede CPN:** A rede neural CPN (*Counterpropagation Network* – composta por duas redes neurais em série: a rede de Kohonen com o treinamento não-supervisionado e a rede de Grossberg com o treinamento supervisionado) é uma rede competitiva projetada para funcionar como uma tabela de consulta autoprogramável com a habilidade de interpolar dados de entrada [Hecht-Nielsen, 1987].
- **Rede BAM:** Uma rede BAM (*Bidirectional Associative Memory*) possui uma memória associativa bidirecional. Ela permite um certo grau de tolerância a erros, quando os dados fornecidos possuem um padrão corrompido [Kosko, 1987].
- **Rede Neocognitron:** Uma rede multicamadas com conexões parciais entre as unidades das várias camadas. Foi desenvolvida para reconhecer caracteres alfabéticos escritos a mão. O treinamento desta rede é difícil, porém possui uma boa tolerância a erros, pois reconhece os caracteres mesmo com certa inclinação na escrita ou pequena distorção na imagem [Fukushima et al., 1983].

### 3.7. Vantagens das Redes Neurais Artificiais

As redes neurais artificiais estão baseadas numa arquitetura de implementação paralela que possui a capacidade de generalização, isto é, a rede neural consegue responder de maneira adequada a novas situações (diagnóstico) baseada no aprendizado realizado através de experiências passadas (treinamento). Estas duas características são de extrema importância, pois, tornam possível a resolução de problemas que na vida real são **difíceis** de serem resolvidos.

As redes neurais apresentam características singulares que só podem ser encontradas em suas estruturas. São elas [Haykin, 1994; Storb & Wazlawick, 1999]:

- **Aprendizado e generalização:** tem a capacidade de obter resultados sensíveis através da aprendizagem e do armazenamento de conhecimento;
- **Processamento paralelo:** permite que as tarefas complexas sejam executadas com maior rapidez;
- **Não linearidade:** elas suprem uma alternativa analítica que as técnicas convencionais limitam-se, muitas vezes, por suposições estritas de normalidade, linearidade, independência de variável, etc.;
- **Robustez:** a rede é apta a processar dados com ruídos ou dados incompletos de forma eficaz;
- **Flexibilidade:** as redes neurais possuem uma ampla aplicabilidade em qualquer que seja sua área de atuação.

### **3.8. Aplicações das Redes Neurais Artificiais**

A capacidade de aprendizado e generalização das redes neurais artificiais propicia sua aplicação em diversos problemas da vida real. Atualmente, um grande número de pesquisadores vem inovando diversas

arquiteturas de redes neurais e técnicas de aprendizado adaptando-as a aplicações específicas, como por exemplo, previsão de carga, avaliação de segurança, controle, diagnóstico de falhas, intensificação de sistemas, planejamento, operação e proteção de sistemas de potência, etc. [Aggarwal & Song, 1997].

Com isso, vem crescendo o interesse de aplicação das redes neurais a diversos tipos de problemas e em diversas áreas como Medicina, Engenharia, Biologia, etc. Dentre os principais tipos de aplicação tem-se:

- Diagnóstico;
- Reconhecimento de padrões;
- Processamento de Imagens;
- Regressão e previsão;
- Controle;
- Otimização;
- Filtragem de dados.

### **3.9. Comentários**

Neste capítulo foi apresentada uma abordagem geral sobre as redes neurais artificiais. Primeiramente foi feita uma reflexão histórica na qual mostra o crescimento no campo de pesquisa envolvendo as redes neurais artificiais, enfatizando desde o primeiro conceito até o avanço das redes neurais artificiais nos dias atuais. Com isso, efetuou-se o estudo do neurônio biológico e também do neurônio artificial que foi criado a partir das características do neurônio artificial. Este capítulo também mostra os diferentes tipos de treinamento que existem na literatura. Assim, é feita uma síntese sobre toda a estrutura e

funcionamento das redes neurais, relatando as vantagens em utilizá-las e as aplicações em que elas vêm se destacando.

# Capítulo 4

## Algoritmo Retropropagação

*Este capítulo fornece os conceitos e todo desenvolvimento do algoritmo retropropagação (backpropagation). Este algoritmo é uma das ferramentas mais utilizadas na previsão de carga, por esta razão, a importância de entender o seu funcionamento. É considerado um benchmark em termos de precisão, porém, possui uma convergência lenta. Na intenção de melhorar este problema, introduzem-se, neste capítulo, algumas modificações no algoritmo retropropagação, tais como: adaptação da taxa de treinamento da rede neural feedforward, através de um controlador nebuloso e adaptações dos parâmetros de inclinação e translação da função sigmóide (função de ativação da rede neural feedforward) pelo método do gradiente descendente.*

### 4.1. O Algoritmo Retropropagação

Em 1974, Werbos apresentou a primeira concepção do algoritmo Retropropagação (RP) [Werbos, 1974]. Porém, foi a partir de 1986 que Rumelhart, Hinton e Williams, informados do trabalho de Werbos, tiveram a idéia de como ajustar os pesos de uma rede neural das unidades de entrada para a unidade de saída. Os erros observados na camada escondida são determinados

pelo erro propagado na direção inversa da camada de saída. Por esta razão, o método é chamado algoritmo de aprendizagem retropropagação (RP) [Krose & Smagt, 1996]. O RP é um procedimento sistemático de adaptação de pesos de redes neurais baseado no método do gradiente descendente [Simpson, 1989; Wasserman, 1989].

O algoritmo retropropagação consiste na adaptação de pesos, tal que, o erro quadrático da rede é minimizado. A soma do erro quadrático instantâneo de cada neurônio alocado na última camada (saída da rede) é dada por [Villalba & Bel, 2000]:

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (4.1.1)$$

sendo:

$$\varepsilon_i = d_i - y_i; \quad (4.1.2)$$

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

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

$ns$  = número de neurônios da última camada da rede.

Considerando-se o neurônio de índice  $i$  da rede, e utilizando-se o método do gradiente descendente [Simpson, 1989, Villalba & Bel, 2000], o ajuste de pesos pode ser formulado como [Fine, 1999; Villalba & Bel, 2000]:

$$V_i(h+1) = V_i(h) - \theta_i(h) \quad (4.1.3)$$

sendo:

$$\theta_i(h) = \gamma [V_i(h)];$$

$\gamma$  = parâmetro de controle da estabilidade ou taxa de treinamento;

$h$  = representa o índice de iteração;

$V_i(h)$  = gradiente do erro quadrático com relação aos pesos do neurônio avaliado em  $h$ ;

$V_i$  = vetor contendo os pesos do neurônio  $i$ ;

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

Na Equação (4.1.3), a direção adotada para minimizar a função objetivo do erro quadrático corresponde à direção contrária ao gradiente. O gradiente  $\nabla_i(h)$  pode ser expresso por [Krose & Smagt, 1996]:

$$\nabla_i(h) = \frac{\partial \varepsilon_i^2}{\partial V_i(h)} = 2 \varepsilon_i \frac{\partial \varepsilon_i}{\partial V_i(h)} \quad (4.1.4)$$

A função de ativação adotada é a função sigmóide definida por [Fine, 1999; Simpson, 1989; Villalba & Bel, 2000]:

$$y_i = \frac{1 - e^{(-\lambda s_i + \rho)}}{1 + e^{(-\lambda s_i + \rho)}} \quad (4.1.5)$$

ou

$$y_i = \frac{1}{1 + e^{(-\lambda s_i + \rho)}} \quad (4.1.6)$$

sendo:

$\rho$  = constante que determina a translação da curva  $y_i$ ;

$\lambda$  = constante que determina a inclinação da curva  $y_i$ .

Observa-se que a saída  $y_i$  varia entre  $-1$  e  $+1$  e entre  $0$  e  $+1$ , respectivamente, quando se empregam as equações (4.1.5) e (4.1.6). Ou seja, as equações (4.1.5) e (4.1.6) são usadas quando se trabalha com dados positivos/negativos normalizados e somente positivos normalizados, respectivamente.

Diferenciando a Equação (4.1.2) com relação ao vetor  $V_i$ , obtém-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = - \frac{\partial y_i}{\partial V_i} = - \left( \frac{\partial y_i}{\partial s_i} \frac{\partial s_i}{\partial V_i} \right) \quad (4.1.7)$$

Da Equação (4.1.7), resulta:

$$\frac{\partial \varepsilon_i}{\partial V_i} = - \operatorname{sgm}'(s_i) \frac{\partial s_i}{\partial V_i} \quad (4.1.8)$$

em que:

$$\operatorname{sgm}'(s_i) = \frac{\partial y_i}{\partial s_i}.$$

Derivando a Equação (3.3.1), tem-se:

$$\frac{\partial s_i}{\partial V_i} = X_i \quad (4.1.9)$$

sendo:

$X_i$   $\triangleq$  vetor padrão;

$$= [x_{0i} \ x_{1i} \ x_{2i} \ \dots \ x_{ni}]^T.$$

Substituindo a Equação (4.1.9) na Equação (4.1.8), obtém-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = - \operatorname{sgm}'(s_i) X_i \quad (4.1.10)$$

Inserindo-se a Equação (4.1.10) na Equação (4.1.4), resulta em:

$$\nabla_i(h) = - 2 \varepsilon_i \operatorname{sgm}'(s_i) X_i \quad (4.1.11)$$

Utilizando o gradiente estimado através da Equação (4.1.11) no método do gradiente descendente, Equação (4.1.3), obtém-se o seguinte algoritmo [Villalba & Bel, 2000]:

$$V_i(h+1) = V_i(h) + 2 \gamma \beta_i X_i \quad (4.1.12)$$

Se o elemento  $i$  encontrar-se na última camada, então:

$$\beta_i = \text{sgm}'(s_i) \varepsilon_i \quad (4.1.13)$$

Se o elemento  $i$  encontrar-se nas demais camadas, tem-se:

$$\beta_i = \text{sgm}'(s_i) \sum_{k \in R(j)} w_{ik} \beta_k \quad (4.1.14)$$

sendo:

$\text{sgm}'(s_i)$  = derivada da função sigmóide dada pelas Equações (4.1.15) ou (4.1.16), respectivamente, com relação a  $s_i$ .

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

A derivada parcial da função sigmóide dada pela Equação (4.1.5) pode ser expressa por:

$$\begin{aligned} \frac{\partial y_i}{\partial s_i} &= \frac{\partial}{\partial s_i} \left\{ \frac{1 - e^{-\lambda s_i + \rho}}{1 + e^{-\lambda s_i + \rho}} \right\} \\ &= \frac{2 \lambda e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} \\ &= \frac{1}{2} \lambda \left\{ \frac{(1 + e^{-\lambda s_i + \rho})^2}{(1 + e^{-\lambda s_i + \rho})^2} - \frac{(1 - e^{-\lambda s_i + \rho})^2}{(1 + e^{-\lambda s_i + \rho})^2} \right\} \\ &= 0.5 \lambda (1 - y_i^2) \end{aligned} \quad (4.1.15)$$

A derivada parcial da função sigmóide dada pela Equação (4.1.6) pode ser descrita por:

$$\frac{\partial y_i}{\partial s_i} = \frac{\partial}{\partial s_i} \left\{ \frac{1}{1 + e^{-\lambda s_i + \rho}} \right\}$$

$$\begin{aligned}
&= \frac{-(-\lambda e^{-\lambda s_i + \rho})}{(1 + e^{-\lambda s_i + \rho})^2} \\
&= \frac{\lambda + \lambda e^{-\lambda s_i + \rho} - \lambda}{(1 + e^{-\lambda s_i + \rho})^2} = \lambda \left( \frac{1 + e^{-\lambda s_i + \rho} - 1}{(1 + e^{-\lambda s_i + \rho})^2} \right) \\
&= \lambda \left( \frac{1 + e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} - \frac{1}{(1 + e^{-\lambda s_i + \rho})^2} \right) \\
&= \lambda \left( \frac{1}{(1 + e^{-\lambda s_i + \rho})} - \frac{1}{(1 + e^{-\lambda s_i + \rho})^2} \right) \\
&= \lambda y_i (1 - y_i) \tag{4.1.16}
\end{aligned}$$

Resumindo, o algoritmo retropropagação segue os seguintes passos:

1. apresentação de um padrão  $X$  a rede, o qual fornece uma saída  $Y$ ;
2. cálculo do erro (diferença entre o valor desejado e a saída) para cada saída;
3. determinação do erro retropropagado pela rede associado à derivada parcial do erro quadrático de cada elemento relacionado aos pesos;
4. ajuste dos pesos de cada elemento;
5. apresenta-se um novo padrão a rede e repete-se o processo até que haja a convergência da rede, ou seja, a rede neural só irá convergir se o erro obtido através do treinamento da rede neural for menor que uma tolerância preestabelecida.

Os pesos iniciais são normalmente adotados como números randômicos (considerando-se o intervalo  $\{0,1\}$ ), visto que a iniciação nula quase sempre proporciona baixa convergência [Villalba & Bel, 2000].

O treinamento via RP pode ser efetuado, basicamente, de duas formas [Minussi & Silveira, 1995]:

- **Convergência por Padrão:** Consiste em ajustar os pesos da rede (considerando-se todas as camadas), fazendo-se 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 [Minussi & Silveira, 1995].
- **Uma Iteração por Padrão:** Este procedimento é idêntico ao primeiro, porém, fazendo-se somente uma iteração (ajuste de pesos) por padrão [Minussi & Silveira, 1995].

#### 4.2. 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 RP com momento [Widrow & Lehr, 1990].

O processo de aprendizagem exige que a mudança nos pesos seja proporcional a  $\partial \varepsilon_i / \partial V_i$ . 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  $\gamma$  grande, é tomar uma variação nos pesos que dependa da variação dos pesos anteriores acrescentando o termo momento. O termo momento leva em consideração o efeito de mudanças anteriores de pesos na direção do movimento atual no espaço de pesos. Este procedimento se constitui no algoritmo RP com momento [Krose & Smagt, 1996].

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

$$v_{ij}(h+1) = v_{ij}(h) + \Delta v_{ij}(h) \quad (4.2.1)$$

sendo:

$$\Delta v_{ij}(h) = 2 \gamma(1 - \eta) \beta_j x_i + \eta \Delta v_{ij}(h-1); \quad (4.2.2)$$

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

$\gamma$  = taxa de treinamento;

$\eta$  = constante momento ( $0 \leq \eta < 1$ ) [Widrow & Lehr, 1990].

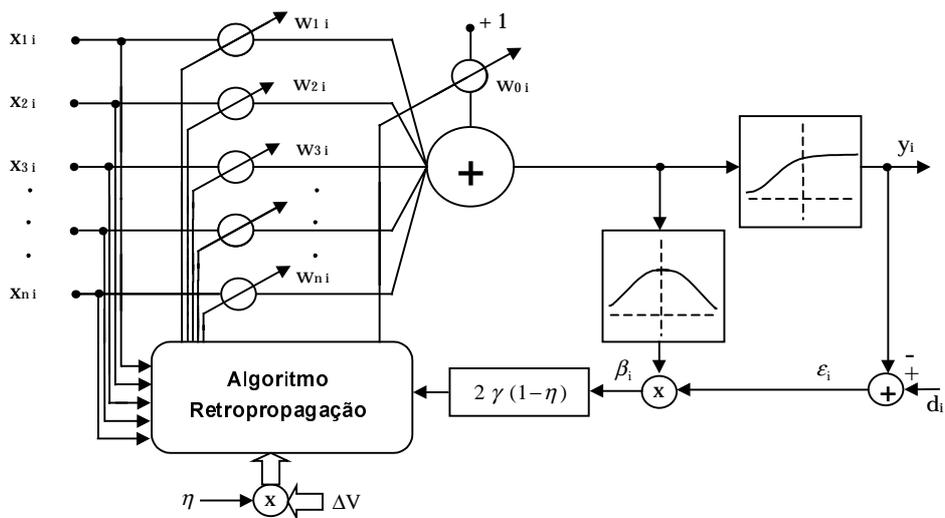


Figura 4.1. Treinamento de um neurônio situado na última camada.

Se o elemento  $j$  encontrar-se na última camada, como mostra a Figura 4.1, então [Widrow & Lehr, 1990]:

$$\beta_j = \sigma_j \varepsilon_j \quad (4.2.3)$$

em que:

$\sigma_j$  = derivada da função sigmoide dada pelas Equações (4.1.15) ou (4.1.16), respectivamente, com relação a  $s_j$ . No caso das Figuras 4.1 e 4.2, a derivada da função sigmoide é dada pela Equação (4.1.16).

Se o elemento  $j$  encontrar-se nas demais camadas, como mostra a Figura 4.2, tem-se [Widrow & Lehr, 1990]:

$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (4.2.4)$$

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  $j$ .

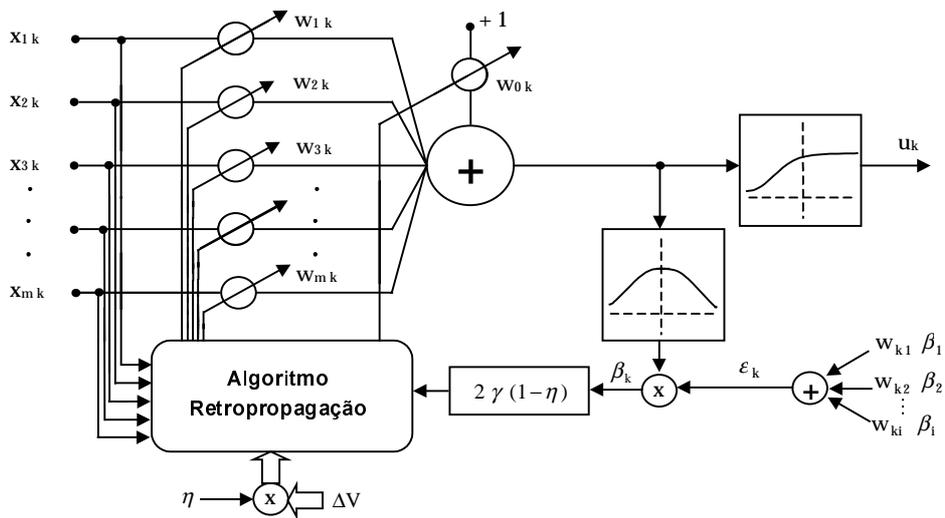


Figura 4.2. Treinamento de um neurônio situado nas demais camadas.

O parâmetro  $\gamma$ , que serve como controle de estabilidade do processo iterativo, é dependente de  $\lambda$ . A Figura 4.3 mostra o significado do termo momento.

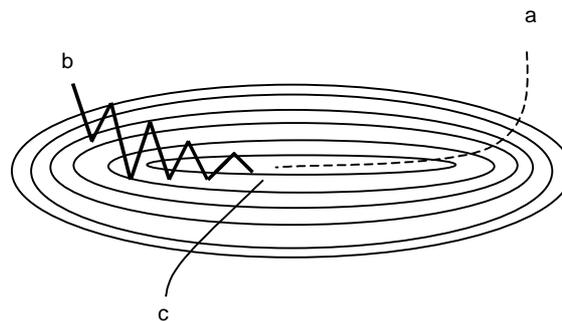


Figura 4.3. O algoritmo gradiente descendente no espaço de pesos, sendo: (a) taxa de treinamento pequena, (b) taxa de treinamento grande (notar as oscilações) e (c) taxa de treinamento grande, porém com o termo momento já adicionado.

Quando no treinamento da rede neural é utilizada uma taxa de treinamento baixa sem o acréscimo do termo momento, o algoritmo toma um longo tempo até o mínimo ser alcançado. Já para uma taxa de treinamento alta, o mínimo nunca é alcançado em consequência das oscilações. Com o momento, a princípio, o mínimo será obtido rapidamente [Krose & Smagt, 1996].

A Figura 4.3 é apresentada apenas para ilustrar o processo de convergência e não para demonstrá-lo. É, portanto, um procedimento de busca de um ponto mínimo na direção oposta ao gradiente da função erro global com descida controlada pelo parâmetro  $\gamma$ . Não são destacados os transtornos decorrentes dos pontos de mínimos locais, da ocorrência de paralisia, etc.

O termo momento promove movimentos em uma direção determinada pelo método gradiente, corrigindo esta direção, levando em conta as direções adotadas anteriormente. Ou seja, considerando o histórico das direções usadas no processo de convergência. Com isto o algoritmo “ganha velocidade”, dando a ele capacidade (algumas vezes) de escapar dos mínimos locais, já que a superfície de espaço de erro contém longas gargantas com curvas acentuadas ou até mesmo depressões com descidas suaves.

### **4.3. Problemas Gerados pelo Algoritmo Retropropagação**

Apesar do sucesso aparente do algoritmo de aprendizado retropropagação, existem alguns problemas que afetam seu desempenho. A maior parte dos problemas refere-se ao processo de treinamento que é longo, e pode causar um resultado de momento e uma taxa de treinamento não-ótimo. Os fracassos do treinamento geralmente surgem a partir de três problemas: (1) paralisia da rede, (2) mínimo local e (3) convergência lenta.

1. **Paralisia da Rede:** Com o treinamento da rede, os pesos podem ser ajustados assumindo valores muito grandes. A entrada total de uma unidade (camada) escondida ou unidade de saída pode, portanto, alcançar valores muito altos

(ou positivo ou negativo) e, em consequência da função de ativação sigmoidal, a unidade terá uma ativação muito próxima de zero ou muito próxima de um. Portanto, os pesos ajustados estarão próximos de zero, e o processo de treinamento pode chegar a uma saturação (ou efeito de paralisia) [Krose & Smagt, 1996].

2. **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, como ilustra a Figura 4.4. Os métodos probabilísticos podem ajudar a evitar esta armadilha, mas eles tendem a ser lentos. Uma outra possibilidade sugerida é aumentar o número de unidades escondidas, que funcionará por causa da dimensionalidade maior do espaço de erro [Krose & Smagt, 1996].
3. **Convergência Lenta:** Em consequência do fato dos pesos iniciais da rede serem gerados aleatoriamente e principalmente por causa do problema de mínimos locais, o vetor gradiente fica oscilando um grande número de vezes sobre a superfície do erro, o que faz com que diminua a velocidade de convergência da rede.

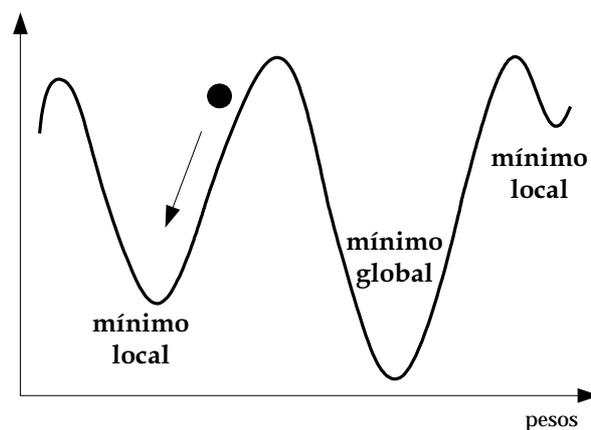


Figura 4.4. Representação de mínimos locais.

#### **4.4. Melhorias no Algoritmo Retropropagação**

Muitos pesquisadores buscam contornar os problemas gerados pelo algoritmo retropropagação. Uma alternativa para tentar melhorar o desempenho e a velocidade de convergência da rede neural foi desenvolvida por Lopes em 2000, no qual a proposta foi criar um controlador nebuloso capaz de adaptar a taxa de treinamento da rede neural e, assim, tornar a rede mais rápida e precisa [Lopes et al, 2000; Lopes & Minussi, 2000; Lopes et al., 2003].

Outra proposta desenvolvida baseou-se na idéia de adaptar os parâmetros de inclinação e translação da função de ativação da rede neural, neste caso, a função sigmóide, através do método do gradiente descendente [Lopes et al., 2003].

Logo, as melhorias desenvolvidas no algoritmo retropropagação até o presente momento são precisamente [Lopes et al, 2000; Lopes et al., 2003]:

1. adaptação da taxa de treinamento através do controlador nebuloso e
2. adaptação dos parâmetros de inclinação e translação da função sigmóide através do gradiente descendente.

##### **4.4.1. Adaptação da Taxa de Treinamento com Controlador Nebuloso**

A idéia básica da metodologia consiste na determinação do estado do sistema definido como sendo o erro global ( $\varepsilon_g$ ) e a variação do erro global ( $\Delta\varepsilon_g$ ). O objetivo é obter uma estrutura de controle que consiga com que o erro tenda a zero em um número mínimo de iterações, quando comparado ao procedimento convencional, neste caso o algoritmo retropropagação.

O controle é formulado utilizando os conceitos de lógica nebulosa [Terano et al., 1991]. O erro global ( $\varepsilon_g$ ) e sua variação ( $\Delta\varepsilon_g$ ) são os componentes

do estado do sistema, e  $\Delta\gamma$  é a ação de controle que deve ser exercida sobre o sistema.

O erro global é definido como sendo:

$$\varepsilon_g = \sum_{j=1}^{np} \sum_{i=1}^{ns} \varepsilon_i^2 \quad (4.4.1.1)$$

em que:

$\varepsilon_g$  = erro global da rede neural;

$np$  = número de vetores padrão da rede;

$ns$  = número de neurônios da última camada da rede.

O erro global corresponde ao cálculo de erros de todas as saídas (neurônios de saída), considerando-se todos os vetores padrões da rede. O treinamento deve ser executado utilizando uma iteração por padrão e, então, o erro global é calculado em cada iteração e ajustado o parâmetro  $\gamma$ , através de um acréscimo  $\Delta\gamma$  determinado via lógica nebulosa.

O estado do sistema e a ação de controle são definidos como [Lopes & Minussi, 2000]:

$$E^q = [\varepsilon_g^q \quad \Delta\varepsilon_g^q]^T \quad (4.4.1.2)$$

$$u^q = \Delta\gamma^q \quad (4.4.1.3)$$

sendo:

$q$  = o índice que indica a iteração corrente.

Para um padrão  $X$  de entrada da rede muito grande, o  $\varepsilon_g$  e a  $\Delta\varepsilon_g$  podem entrar em saturação. Então, o controle adaptativo é feito através do uso de uma função exponencial decrescente aplicada à resposta do controlador nebuloso. Desta forma, o controle adaptativo é dado por [Lopes et al., 2000]:

$$\Delta\gamma^q = \exp(-\alpha_p q) \Delta\psi^q \quad (4.4.1.4)$$

em que:

$\alpha_p$  = um número positivo arbitrário;

$\Delta\psi^q$  = acréscimo procedente do controlador nebuloso no instante  $q$ .

Tem-se que  $\alpha$  exerce a função de um decaimento exponencial imposto pelo controlador nebuloso com o objetivo de evitar a saturação da rede neural.

Este parâmetro será utilizado para ajustar o conjunto de pesos da rede referente à iteração subsequente. O processo deverá ser repetido até que o treinamento seja concluído. Trata-se de um procedimento muito simples, cujo sistema de controle requer um esforço adicional bastante reduzido, tendo em vista que o controlador possui duas variáveis de entrada e uma única de saída [Arabishahi et al., 1996]. Cada variável de estado pode ser representada entre 3 e 7 conjuntos nebulosos. A variável de controle também deverá ser representada com o mesmo número de conjuntos nebulosos.

A variável  $\varepsilon_g$  deverá ser normalizada considerando-se como fator de escala, o primeiro erro global gerado pela rede, ou seja, de índice  $q = 0$ . Com esta representação, o intervalo de variação de  $\varepsilon_g$  deverá estar compreendido entre 0 e +1. Se a heurística de adaptação estiver devidamente sintonizada, a convergência do processo deverá ser exponencial decrescente [Lopes et al., 2000].

A variável  $\Delta\varepsilon_g$  deverá variar entre -1 e +1. Se o processo de convergência for exponencial decrescente os valores de  $\Delta\varepsilon_g$  deverão ser sempre negativos. Neste caso, embora a escala de  $\Delta\varepsilon_g$  esteja entre -1 e +1, deve-se empregar, no conjunto de regras, um ajuste fino entre -1 e 0. No outro intervalo (0,+1], o ajuste poderá ser mais relaxado.

As funções de pertinência dos conjuntos nebulosos para várias variáveis envolvidas no treinamento da rede neural com o algoritmo

retropropagação, via controlador nebuloso, são ilustradas na Figura 4.5, sendo que:

- a Figura 4.5 (a) representa as funções de pertinência para o erro global  $\varepsilon_g$  ;
- a Figura 4.5 (b) as funções de pertinência para a variação do erro global  $\Delta\varepsilon_g$  ;
- a Figura 4.5 (c) as funções de pertinência para a ação de controle  $\Delta\psi$  .

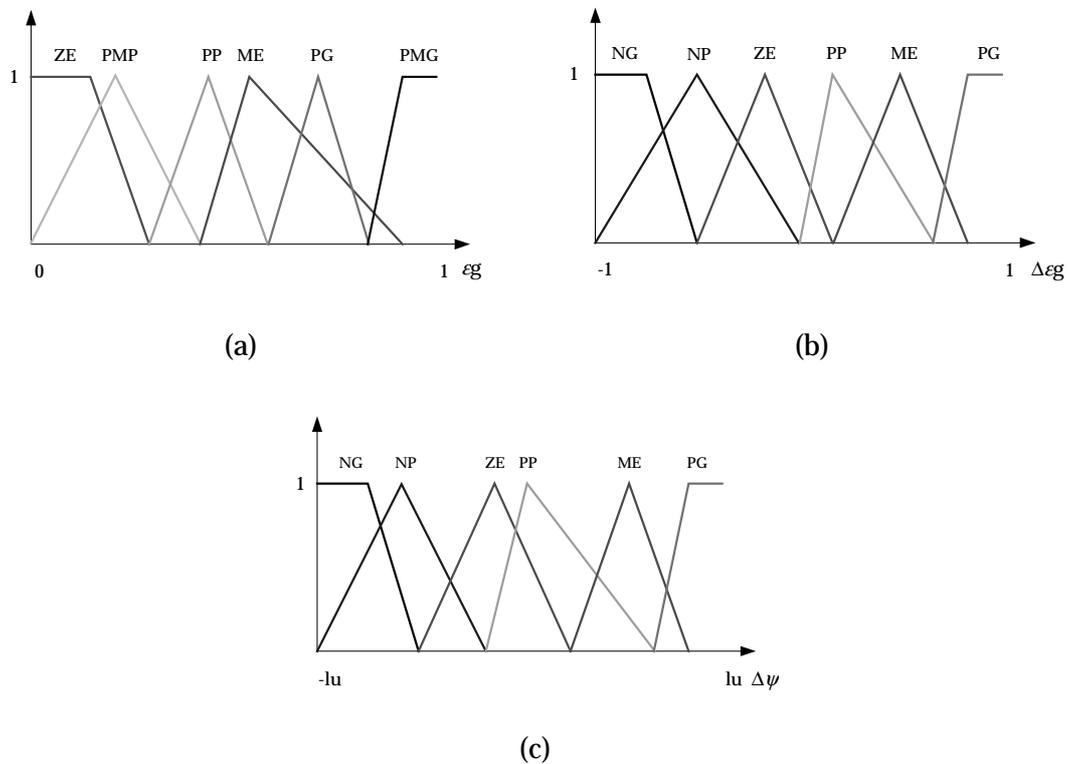


Figura 4.5. Funções de pertinência para as variáveis  $\varepsilon_g$  ,  $\Delta\varepsilon_g$  e  $\Delta\psi$  .

sendo:

NG = Negativo Grande;

NP = Negativo Pequeno;

ZE = Próximo de Zero;

PMP = Positivo Muito Pequeno;

- PP = Positivo Pequeno;  
 ME = Médio;  
 PG = Positivo Grande;  
 PMG = Positivo Muito Grande;  
 Lu = limite de variação de  $\Delta\psi$ .

No controlador nebuloso, as regras são codificadas na forma de uma tabela de decisões. Cada entrada representa o valor da variável nebulosa  $\Delta\psi$  dados os valores do erro global  $\varepsilon_g$  e a variação do erro global  $\Delta\varepsilon_g$ . O parâmetro  $\gamma$  (taxa de treinamento) deve ser arbitrado em função de  $\lambda$  (inclinação da curva). Da mesma forma, as variações de  $\gamma$  também devem seguir o mesmo procedimento. Deste modo, o parâmetro ( $lu$ ) deve ser ajustado para atender as especificações de cada problema em função de  $\lambda$ . Na Tabela 4.1 é apresentado o conjunto de regras nebulosas, totalizando 30 regras. O número de regras poderá ser aumentado visando melhorar o desempenho da rede no treinamento.

Tabela 4.1. Regras do controlador nebuloso.

$\Delta\varepsilon_g$	$\varepsilon_g$					
	ZE	PMP	PP	ME	PG	PMG
NG	ZE	ZE	NP	PG		PG
NP	NG	ZE	ME	NG	ME	
ZE	PP	NG	NG		PP	NP
PP	PG	ME		PG	NP	ZE
ME	ZE		ZE	PP	ZE	NG
PG		ZE	NG	ME	ME	ZE

#### 4.4.2. Adaptação dos Parâmetros da Rede Neural

Nesta seção será abordada a formulação para o processo de adaptação de dois parâmetros da rede neural *feedforward*, sendo estes, os parâmetros de inclinação e de translação da função não-linear (neste caso, a função sigmóide) ajustados iterativamente, para cada neurônio, através do método do gradiente descendente [Stamatis et al., 1999]. Para validar a metodologia, ela será aplicada ao problema de previsão de cargas elétricas.

A forma geral da função de ativação utilizada para ajustar a rede neural é dada pela Equação (4.4.2.1) [Stamatis et al., 1999]:

$$f(\lambda, \rho, s) \quad (4.4.2.1)$$

Os parâmetros de inclinação e translação possuem taxas de treinamento que são denotadas por  $\gamma_\lambda$  e  $\gamma_\rho$ , respectivamente. Os ajustes da inclinação e translação da função de ativação são desenvolvidos pelo método do gradiente descendente baseado no algoritmo retropropagação sem a inclusão do termo momento. Através da Figura 4.6 pode-se observar uma arquitetura de rede neural generalizada para um neurônio com  $\lambda$  and  $\rho$  efetuando a regra de inclinação e translação em um espaço multidimensional [Stamatis et al., 1999].

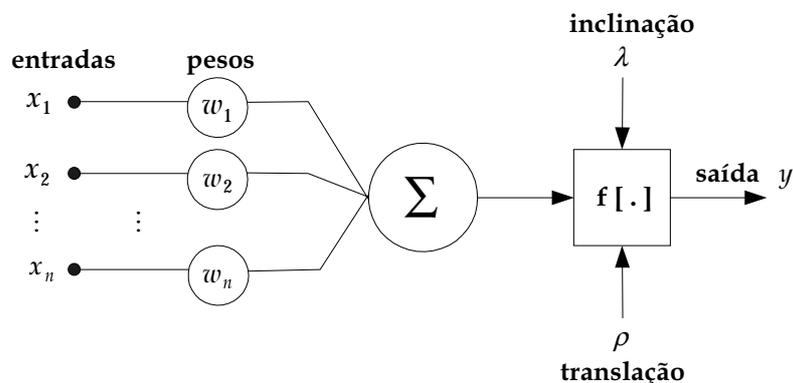


Figura 4.6. Arquitetura da rede neural adaptativa.

Semelhante ao cálculo de ajuste de pesos, o ajuste dos parâmetros de inclinação e translação da função sigmóide é realizado considerando o  $i$ -ésimo neurônio através do método do gradiente descendente.

#### a) Adaptação do Parâmetro de Inclinação da Função Sigmóide

O ajuste do parâmetro de inclinação da função sigmóide pode ser dado pela Equação (4.4.2.2) [Stamatis et al., 1999]:

$$\lambda_i(h+1) = \lambda_i(h) + \theta_i^\lambda(h) \quad (4.4.2.2)$$

em que:

$$\theta_i^\lambda(h) = -\gamma_\lambda [\nabla_i^\lambda(h)];$$

$\nabla_i^\lambda(h)$  = gradiente do erro quadrático com relação a inclinação do neurônio  $i$ ;

$\lambda_i$   $\triangleq$  vetor contendo as inclinações do neurônio  $i$ ;

$$= [\lambda_{0i} \ \lambda_{1i} \ \lambda_{2i} \ \dots \ \lambda_{ni}]^T.$$

O gradiente  $\nabla_i^\lambda$  é representado por:

$$\nabla_i^\lambda(h) = \frac{\partial \varepsilon_i^2}{\partial \lambda_i(h)} = 2 \varepsilon_i \frac{\partial \varepsilon_i}{\partial \lambda_i(h)}$$

Novamente, diferenciando a Equação (4.1.2), porém com relação ao vetor  $\lambda_i$ , obtém-se a seguinte equação:

$$\frac{\partial \varepsilon_i}{\partial \lambda_i} = -\frac{\partial y_i}{\partial \lambda_i} = -\sigma_i^\lambda$$

em que:

$\sigma_i^\lambda$   $\triangleq$  derivada da função sigmóide com relação a  $\lambda_i$ .

Logo, a regra que define a adaptação do parâmetro de inclinação da função sigmóide é dada pela equação abaixo:

$$\lambda_i(h+1) = \lambda_i(h) + 2\gamma_\lambda \beta_i^\lambda$$

Se o elemento  $i$  encontrar-se na última camada, então:

$$\beta_i^\lambda = \sigma_i^\lambda \varepsilon_i$$

Se o elemento  $i$  encontrar-se nas demais camadas, tem-se:

$$\beta_i^\lambda = \sigma_i^\lambda \sum_{k \in R(j)} w_{ik} \beta_k^\lambda$$

A derivada da função sigmóide dada pela Equação (4.1.5) com relação a  $\lambda_i$ ,  $\sigma_i^\lambda$ , pode ser descrita pela Equação (4.4.2.3):

$$\begin{aligned} \frac{\partial y_i}{\partial \lambda_i} &= \frac{\partial}{\partial \lambda_i} \left\{ \frac{1 - e^{-\lambda s_i + \rho}}{1 + e^{-\lambda s_i + \rho}} \right\} \\ &= \frac{2 s_i e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} \\ &= \frac{1}{2} s_i \left\{ \frac{(1 + e^{-\lambda s_i + \rho})^2}{(1 + e^{-\lambda s_i + \rho})^2} - \frac{(1 - e^{-\lambda s_i + \rho})^2}{(1 + e^{-\lambda s_i + \rho})^2} \right\} \\ &= 0.5 s_i (1 - y_i^2) \end{aligned} \quad (4.4.2.3)$$

A derivada da função sigmóide dada pela Equação (4.1.6) com relação a  $\lambda_i$ ,  $\sigma_i^\lambda$ , pode ser descrita pela Equação (4.4.2.4):

$$\begin{aligned} \frac{\partial y_i}{\partial \lambda_i} &= \frac{\partial}{\partial \lambda_i} \left\{ \frac{1}{1 + e^{-\lambda s_i + \rho}} \right\} \\ &= \frac{s_i e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} \\ &= \frac{s_i + s_i e^{-\lambda s_i + \rho} - s_i}{(1 + e^{-\lambda s_i + \rho})^2} = s_i \left( \frac{1 + e^{-\lambda s_i + \rho} - 1}{(1 + e^{-\lambda s_i + \rho})^2} \right) \\ &= s_i (y_i - y_i^2) = s_i y_i (1 - y_i) \end{aligned} \quad (4.4.2.4)$$

## b) Adaptação do Parâmetro de Translação da Função Sigmóide

Utilizando o mesmo esquema de adaptação do parâmetro de inclinação, pode-se formular o ajuste do parâmetro de translação da função sigmóide através da Equação (4.4.2.5) [Stamatis et al., 1999]:

$$\rho_i(h+1) = \rho_i(h) + \theta_i^\rho(h) \quad (4.4.2.5)$$

sendo:

$$\theta_i^\rho(h) = -\gamma_\rho [\nabla_i^\rho(h)];$$

$\nabla_i^\rho(h)$  = gradiente do erro quadrático com relação a translação do neurônio  $i$ ;

$\rho_i$   $\triangleq$  vetor contendo as translações do neurônio  $i$ ;

$$= [\rho_{0i} \ \rho_{1i} \ \rho_{2i} \ \dots \ \rho_{ni}]^T.$$

O gradiente  $\nabla_i^\rho$  é representado por:

$$\nabla_i^\rho(h) = \frac{\partial \varepsilon_i^2}{\partial \rho_i(h)} = 2 \varepsilon_i \frac{\partial \varepsilon_i}{\partial \rho_i(h)}$$

Novamente diferenciando a Equação (4.1.2) com relação ao vetor  $\rho_i$ , obtém-se a equação descrita abaixo:

$$\frac{\partial \varepsilon_i}{\partial \rho_i} = -\frac{\partial y_i}{\partial \rho_i} = -\sigma_i^\rho$$

em que:

$\sigma_i^\rho$   $\triangleq$  derivada da função sigmóide com relação a  $\rho_i$ .

A equação seguinte define a regra de adaptação do parâmetro de translação da função não linear [Stamatis et al., 1999]:

$$\rho_i(h+1) = \rho_i(h) + 2\gamma_\rho \beta_i^\rho$$

Se o elemento  $i$  encontrar-se na última camada, então:

$$\beta_i^\rho = \sigma_i^\rho \varepsilon_i$$

Se o elemento  $i$  encontrar-se nas demais camadas, tem-se:

$$\beta_i^\rho = \sigma_i^\rho \sum_{k \in R(j)} w_{ik} \beta_k^\rho$$

A derivada da função sigmóide dada pela Equação (4.1.5) com relação a  $\rho$ ,  $\sigma_i^\lambda$ , pode ser descrita pela Equação (4.4.2.6):

$$\begin{aligned} \frac{\partial y_i}{\partial \rho_i} &= \frac{\partial}{\partial \rho_i} \left\{ \frac{1 - e^{-\lambda s_i + \rho}}{1 + e^{-\lambda s_i + \rho}} \right\} \\ &= \frac{-2 e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} \\ &= -\frac{1}{2} \left\{ \frac{(1 + e^{-\lambda s_i + \rho})^2}{(1 + e^{-\lambda s_i + \rho})^2} - \frac{(1 - e^{-\lambda s_i + \rho})^2}{(1 + e^{-\lambda s_i + \rho})^2} \right\} \\ &= -0.5 (1 - y_i^2) \end{aligned} \quad (4.4.2.6)$$

A derivada da função sigmóide dada pela Equação (4.1.6) com relação a  $\rho$ ,  $\sigma_i^\rho$ , pode ser descrita pela Equação (4.4.2.7):

$$\begin{aligned} \frac{\partial y_i}{\partial \rho_i} &= \frac{\partial}{\partial \rho_i} \left\{ \frac{1}{1 + e^{-\lambda s_i + \rho}} \right\} \\ &= \frac{e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} = \frac{1 + e^{-\lambda s_i + \rho} - 1}{(1 + e^{-\lambda s_i + \rho})^2} \\ &= \frac{1 + e^{-\lambda s_i + \rho}}{(1 + e^{-\lambda s_i + \rho})^2} - \frac{1}{(1 + e^{-\lambda s_i + \rho})^2} \\ &= y_i - y_i^2 \\ &= y_i (1 - y_i) \end{aligned} \quad (4.4.2.7)$$

A regra de adaptação para os parâmetros de inclinação e translação da rede é calculada iterativamente para todo  $i$ -ésimo neurônio da rede. Ela faz com que a rede neural adaptativa forneça sempre uma saída, tornando a rede mais rápida que a rede convencional. Nesta arquitetura de rede neural também foi introduzido o controlador nebuloso a fim de obter melhores resultados.

#### 4.4.3. Perspectivas Futuras

O algoritmo retropropagação fornece bons resultados, todavia, o tempo de processamento é um dos problemas encontrados. Um grande número de trabalhos tem sido propostos na intenção de melhorar o desempenho do algoritmo retropropagação [Lopes et al, 2000; Lopes et al., 2003, entre outros], porém, ainda se observa que o algoritmo não proporciona uma flexibilidade de forma a modificar de modo significativo sua estrutura. Afinal, se fosse possível tal mudança, o algoritmo não seria mais o algoritmo retropropagação, pois o fundamento dele está baseado no método do gradiente descendente, logo não pode ser alterado.

As reais possibilidades de melhoria do desempenho do algoritmo retropropagação restringem-se efetivamente às mudanças na taxa de aprendizado, inclinação e translação da função de ativação e, também, à substituição da função sigmóide por uma outra função mais eficiente (*e.g.*, funções de base radial). Esgotados estes recursos, poucas são as chances de aprimoramento deste tipo de rede neural. Deve-se ressaltar, ainda, que o algoritmo retropropagação é um tanto ineficiente no trato de atividades que requerem o treinamento continuado, ou seja, uma vez concluído o treinamento, havendo necessidade de incluir novos padrões, o treinamento deverá ser reinicializado o que o torna pouco prático em aplicações complexas, como, por exemplo, previsão de carga, etc.

Destes fatos buscaram-se novas arquiteturas para tentar suprir o problema de tempo de processamento, já que para a aplicação de previsão de carga elétrica é necessário que os cálculos sejam feitos quase em tempo *on-line*.

Estas devem, ser suficientemente precisas, estáveis (garantia de obtenção de uma solução) e dotadas de recursos eficientes para a inclusão do treinamento continuado.

Uma abordagem encontrada foi a utilização das redes baseadas na teoria da ressonância adaptativa. Esta rede supre a dificuldade encontrada no algoritmo retropropagação, já que sua estrutura possibilita alterações de forma a criar novas arquiteturas baseadas nas arquiteturas já existentes (família ART).

Estas arquiteturas possibilitam uma estrutura de tal forma que a previsão de carga elétrica seja feita de forma multinodal, ou seja, elas possuem a capacidade de separar as cargas por suas características (residencial, comercial, industrial) e a partir delas efetuar a previsão. Em consequência do fato dos sistemas atualmente serem desregulamentados, obter uma rede que realize uma previsão multinodal de forma *on-line*, será um passo muito importante dentro das pesquisas até hoje realizadas.

#### 4.5. Comentários

Este capítulo enfocou o desenvolvimento do algoritmo retropropagação. Também, abordou a estrutura deste algoritmo com a adição do termo momento. Nota-se que o algoritmo retropropagação gera alguns problemas, dentre eles: mínimos locais, paralisia e baixa convergência. Porém, o algoritmo fornece resultados que a princípio são bons. Logo, tentou-se melhorar este algoritmo implementando algumas modificações, tais como: adaptação da taxa de treinamento da rede neural *feedforward*, através de um controlador nebuloso e adaptações dos parâmetros de inclinação e translação da função sigmóide através do método do gradiente descendente.

## Capítulo 5

# Teoria da Ressonância Adaptativa

*Nos últimos anos, as redes neurais vêm se destacando em vários tipos de aplicações, tais como: diagnóstico, reconhecimento de padrões, processamento de imagens, controle, otimização, previsão, etc. Assim, cada arquitetura de rede neural se identifica com um determinado tipo de problema. Dentre as diversas arquiteturas de redes neurais existentes, destacam-se as redes neurais baseadas na teoria da ressonância adaptativa (Adaptive Resonance Theory - ART). Esta rede neural proporciona certa flexibilidade, a qual favorece a criação de novas arquiteturas de redes que formam a família ART. Este capítulo introduz os conceitos da teoria da ressonância adaptativa, bem como toda a descrição e detalhamento do algoritmo das redes neurais ART. Aqui também, tratar-se-á da rede neural ARTMAP que é uma arquitetura de rede neural que faz parte da família ART.*

### 5.1. Rede Neural ART

Na tentativa de compreender como os sistemas biológicos são capazes de conservar a plasticidade (capacidade de aprender continuamente novos padrões incluídos, sem perder a memória relacionada a padrões anteriores)

durante toda a vida e sem comprometer a estabilidade dos padrões instruídos anteriormente.

Grossberg introduziu, em 1976, a rede ART (*Adaptive Resonance Theory*) [Grossberg, 1976; Grossberg, 1976], um sistema de aprendizagem não-supervisionado, como uma teoria do processo de informação cognitiva humana. Esta rede possui uma topologia cuja dinâmica é baseada na teoria da ressonância adaptativa [Weenink, 1997]. A importância desta rede está baseada na resolução do dilema da plasticidade e da estabilidade (características fundamentais da família das redes ART), feita através do teste de vigilância, o qual originará uma rede mais rápida e precisa. A estabilidade está relacionada com a garantia de agrupamento de todos os elementos nas classes criadas pelo sistema, tendo em vista que os pesos da rede possuem a característica somente de decréscimo, ou seja, à medida que as adaptações dos pesos são realizadas, os novos valores tendem sempre a diminuir até a estabilização.

As redes ART são, então, redes neurais desenvolvidas para codificar reconhecimentos estáveis, em tempo real, através da auto-organização, em resposta a seqüências arbitrárias de padrões de entrada [Carpenter & Grossberg, 1992; Gopal et al., 1999; Keyvan et al., 1999; Kim et al., 2001].

Dentre alguns modelos que fazem parte da família ART, destacam-se:

1. Rede neural ART1: rede que possui treinamento não-supervisionado. Possui a capacidade de reconhecer padrões de entrada binários de forma arbitrária [Carpenter & Grossberg, 1987];
2. Rede neural ART2: rede que também possui treinamento não-supervisionado e emprega tanto padrões de entrada binários como padrões de entrada analógicos [Carpenter & Grossberg, 1987];
3. Rede neural Fuzzy ART: rede baseada no treinamento não-supervisionado e que engloba em sua arquitetura cálculos baseados na lógica nebulosa [Carpenter et al., 1991b].

4. Rede neural ARTMAP: rede que possui treinamento supervisionado. É composta por dois módulos ART interconectados, através do campo inter-ART. Esta rede também pode identificar padrões de entradas binários ou analógicos [Carpenter et al., 1991a].
5. Rede neural Fuzzy ARTMAP: esta rede possui treinamento supervisionado como a rede neural ARTMAP, porém, todos os cálculos são fundamentados na lógica nebulosa [Carpenter et al., 1992]

Com a perspectiva de solucionar problemas baseados na vida real vários autores procuraram criar variações desses modelos adaptando-os às suas aplicações. As redes a seguir, também possuem a arquitetura da família ART. São elas:

- **LAPART** (*Laterally Primed Adaptive Resonance Theory*) [Healy et al., 1993];
- **ART-EMAP** (*Evidence Integration for Dynamic Predictive Mapping*) [Carpenter & Ross, 1995];
- **Gaussian ARTMAP** [Williamson, 1996];
- **ART-MMAP** (*ART Mixture MAP*) [Liu et al., 2004];
- **ART-CPN** (*ART Counterpropagation Neural Network*) [Liu & Li, 2004];
- **IPSFAM** (*Integrated Probabilistic Simplified Fuzzy ARTMAP*) [Jervis et al., 2004], etc.

Um processo importante efetuado na rede neural ART é a combinação de padrões, o qual compara o padrão de entrada atual com uma representação de categoria selecionada. A arquitetura da rede neural ART consiste de dois subsistemas: o subsistema de atenção e o subsistema de orientação mostrados na Figura 5.1.

O subsistema de atenção possui duas camadas de neurônios interconectados: uma camada serve como nível de comparação (campo  $F_1$ ) e a

outra de reconhecimento (campo  $F_2$ ), sendo o campo  $F_0$  a camada de nós que representa o vetor de entrada atual  $A$ . Os padrões de atividade desenvolvidos sobre os nós nas duas camadas,  $F_1$  e  $F_2$ , no estado de ressonância são chamados de memória a curto prazo (*short-term memory* – STM). A aprendizagem ocorre durante o período de ressonância [Djukanovic et al., 1995; Georgiopoulos et al., 1996; Gopal et al., 1999; Simpson, 1989].

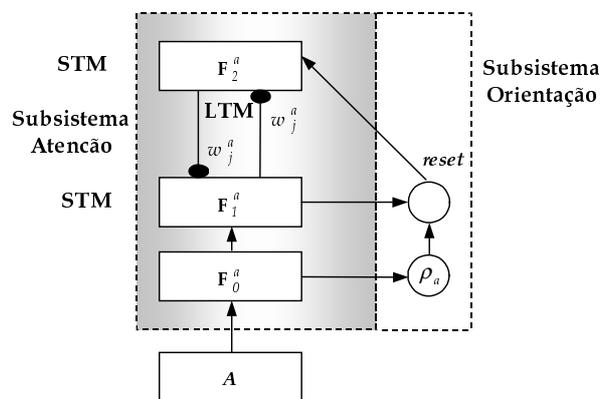


Figura 5.1. Arquitetura da rede neural ART.

As camadas  $F_1$  e  $F_2$  são conectadas através de conexões não-recorrentes ou diretas (*feedforward*) ( $F_1$  a  $F_2$ ) e recorrentes (*feedback*) ( $F_2$  a  $F_1$ ). Os pesos associados com as conexões de baixo para cima (*bottom-up*) (conexões de pesos de  $F_1$  para  $F_2$ ) e de cima para baixo (*top-down*) (conexões de pesos de  $F_2$  para  $F_1$ ) entre as camadas  $F_1$  e  $F_2$  são chamados de memória a longo prazo (*long-term memory* – LTM) [Gopal et al., 1999; Keyvan et al., 1999].

O subsistema de orientação é necessário para estabilizar o processo de STM e a aprendizagem em LTM. Logo, permite que a rede aprenda em torno de novas entradas sem esquecer seu conhecimento prévio. Ele é responsável pelo controle do padrão a ser reconhecido e possui dois sinais de entrada e um de saída. Os dois sinais de entrada são representados pelos padrões de dados de entrada e pela atividade total em  $F_1$  e o sinal de saída pelo *reset* [Gopal et al., 1999; Keyvan et al., 1999; Weenink, 1997].

A ressonância e o *reset* são realizados no subsistema de orientação através de um parâmetro denominado parâmetro de vigilância,  $\rho$  ( $\rho$  possui valor decimal compreendido entre 0 e 1), que determina a decisão do processo de classificação de categorias [Gopal et al., 1999; Keyvan et al., 1999].

Resumindo, tem-se que o subsistema de atenção é responsável na indicação de uma categoria vencedora, ao passo que, o subsistema de orientação possui a incumbência de aceitar a categoria proposta ou reorientar a busca para a escolha de uma nova categoria [Granger et al., 1997].

**Consideração :** Os vetores, para fins de uso nas redes neurais da família ART, serão representados como linhas e não como colunas como habitualmente adotados na literatura.

Esta representação é empregada na grande maioria das redes neurais ART descendentes por ser um modo mais simples de formulação das equações envolvidas no modelo neural.

### 5.1.1. Representação Geométrica

As categorias formadas pela rede neural ART são ilustradas através de hiper-retângulos. Desta forma, os hiper-retângulos são definidos entre valores Min e Max, como ilustra a Figura 5.2 [Carpenter & Grossberg, 1992; Carpenter et al., 1992].

Na Figura 5.2,  $\mathbf{u} = [u_1 \ u_2]$  e  $\mathbf{v} = [v_1 \ v_2]$ , os operadores  $\wedge$  e  $\vee$  correspondem respectivamente, aos operadores lógicos AND e OR, em que [Carpenter & Grossberg, 1992]:

$$(\mathbf{u} \wedge \mathbf{v})_1 = \min (u_1, v_1)$$

$$(\mathbf{u} \wedge \mathbf{v})_2 = \min (u_2, v_2)$$

$$(\mathbf{u} \vee \mathbf{v})_1 = \max (u_1, v_1)$$

$$(\mathbf{u} \vee \mathbf{v})_2 = \max(u_2, v_2)$$

sendo que, as posições  $\mathbf{u}$  e  $\mathbf{v}$  são originadas do vetor peso,  $\mathbf{w}_j = [u_j \ v_j^c]$  na forma de codificação de complemento.

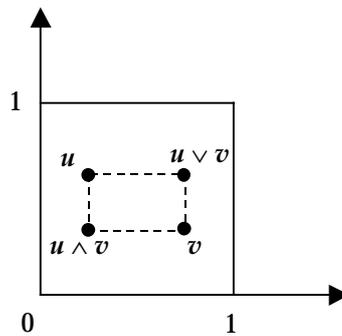


Figura 5.2. Representação geométrica das categorias.

### 5.1.2. Parâmetros Importantes

Existem parâmetros que envolvem a rede neural ART e são de extrema importância para o desenvolvimento da aprendizagem. Dentre alguns parâmetros destacam-se:

- **Parâmetro de escolha  $\alpha$  ( $\alpha > 0$ ):** O parâmetro de escolha controla a seqüência de busca entre os nós da camada  $F_2$ . Ou seja, quando um ponto (entrada de dados) pertence a mais de um hiper-retângulo o parâmetro de escolha assegura que o menor dos hiper-retângulos seja o escolhido dentre os demais [Gopal et al., 1999; Weenink, 1997].
- **Parâmetro de vigilância  $\rho$  ( $\rho \in [0,1]$ ):** O parâmetro de vigilância verifica a combinação dos padrões de entrada e dos pesos para que ocorra a ressonância. Em outras palavras, ele controla o tamanho máximo dos hiper-retângulos. Assim, temos que para um valor de  $\rho$  pequeno, tem-se uma capacidade de generalização maior, porém, uma decisão de classificação pequena que produzirá poucos tipos de classes. Por outro lado, se o valor de

$\rho$  é grande a rede efetua boas distinções e conseqüentemente produz uma boa decisão de classificação. Ou seja, pequenas variações nos padrões de entrada resultarão na criação de novas classes (categorias) e conduzirá o sistema a uma generalização pequena [Gopal et al., 1999; Keyvan et al., 1999; Carpenter & Grossberg., 2003].

### 5.1.3. Algoritmo ART Nebuloso

A rede neural ART nebulosa incorpora cálculos da teoria dos conjuntos nebulosos [Zadeh, 1965] em sistemas ART. A diferença fundamental entre as redes neurais ART e ART nebulosa se baseia no operador de interseção, que na rede neural ART é definido como sendo  $\cap$ , e na rede neural ART nebulosa será definido pelo operador  $\wedge$  (operador AND utilizado na teoria dos conjuntos nebulosos). Isto possibilita tanto o processamento de dados analógicos como binários.

A rede neural ART nebulosa pode aprender categorias estáveis (capacidade de reconhecimento estável através de auto-organização) em resposta a padrões de entradas analógicos ou binários [Granger et al., 1997; Georgiopoulos et al., 1996; Lubkin & Cauwenberghs, 2002].

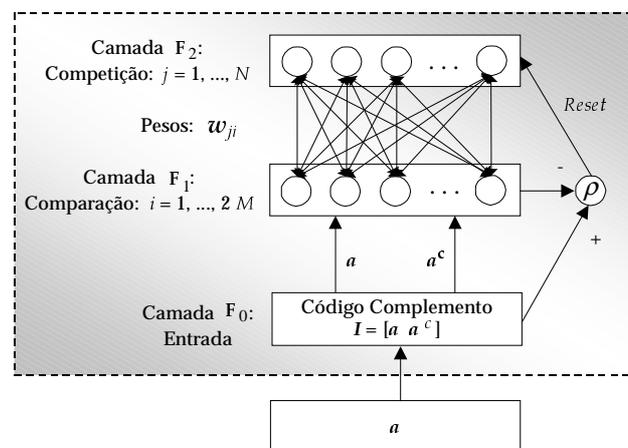


Figura 5.3. Rede neural ART nebulosa.

Através da Figura 5.3, pode-se compreender o algoritmo ART nebuloso que será descrito nas subseções seguintes.

#### a) Vetores de Atividade do Campo ART

Cada sistema ART inclui um campo  $F_0$  que representa o vetor de entrada atual, um campo  $F_1$  que recebe ambas as entradas de baixo para cima de  $F_0$  e de cima para baixo de  $F_2$ , que representa a categoria ativa. O vetor  $I$  denota a atividade em  $F_0$  e os vetores  $x$  e  $y$  as atividades nos campos  $F_1$  e  $F_2$ , respectivamente [Carpenter et al., 1992; Georgiopoulos et al., 1996].

Assim  $I = [I_1 \dots I_M]$ , com cada componente  $I_i \in [0, 1]$  para  $i = 1, \dots, M$ ,  $x = [x_1 \dots x_M]$  e  $y = [y_1 \dots y_N]$  para  $j = 1, \dots, N$ , sendo  $M$  o número de vetores de entrada na camada  $F_1$  e  $N$ , a dimensão dos vetores de entrada que na camada  $F_2$  formam as categorias.

#### b) Vetor Peso

Associado com cada categoria de  $F_2$  o nó  $j$  é um vetor  $w_j = [w_{j1} \dots w_{jM}]$  de pesos adaptativos ou memória a longo prazo. Inicialmente adota-se:

$$w_{j1}(0) = \dots = w_{jM}(0) = 1 \quad (5.1.3.1)$$

e cada categoria é dita ser não-ativa. Após a categoria ser selecionada por codificação, ela torna-se ativa [Carpenter et al., 1992].

#### c) Parâmetros

Os seguintes parâmetros são de extrema importância e devem ser definidos antes de iniciar o treinamento da rede neural ART nebulosa. São eles [Carpenter et al., 1992; Georgiopoulos et al., 1996]:

- O parâmetro de escolha:  $\alpha > 0$ ;
- O parâmetro taxa de treinamento:  $\beta \in [0,1]$ ;

- O parâmetro de vigilância:  $\rho \in [0,1]$ .

#### d) Escolha de categoria

Para cada entrada  $I$  e nó  $j$  em  $F_2$ , a função de escolha  $T_j$  é definida por [Carpenter et al., 1992; Georgiopoulos et al., 1996]

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (5.1.3.2)$$

sendo a interseção do operador nebuloso e a norma  $|\cdot|$  definidas, respectivamente, por:

$$(p \wedge q)_i \equiv \min(p_i, q_i) \quad (5.1.3.3)$$

$$|p| \equiv \sum_{i=1}^M |p_i| \quad (5.1.3.4)$$

para qualquer vetor  $M$ -dimensional  $p$  e  $q$ . O sistema realiza uma escolha de categoria quando um nó de  $F_2$  torna-se ativo em um dado tempo. O índice  $J$  indica a categoria escolhida, sendo:

$$T_J = \max \{T_j : j = 1, \dots, N\} \quad (5.1.3.5)$$

Desta forma, quando a categoria  $J$ -ésima é escolhida tem-se [Carpenter et al., 1992; Georgiopoulos et al., 1996]:

- $y_j = 1$
- $y_j = 0$  para  $j \neq J$

#### e) Ressonância

A ressonância ocorre se a função de combinação  $|I \wedge w_j| / |I|$  da categoria escolhida satisfaz o critério de vigilância descrito pela Equação (5.1.3.6) [Carpenter et al., 1992; Georgiopoulos et al., 1996]:

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (5.1.3.6)$$

se a Equação (5.1.3.6) for satisfeita ocorre a ressonância, caso contrário o valor da função de escolha  $T_j$  é fixo em 0 (zero) para evitar que uma seleção persista na mesma categoria durante o processo de busca. A busca continua até que a categoria  $J$  escolhida satisfaça a Equação (5.1.3.6).

#### f) Aprendizagem

Uma vez concluída a busca, o vetor peso,  $w_j$ , é adaptado de acordo com a Equação (5.1.3.7) [Carpenter et al., 1992; Georgiopoulos et al., 1996]:

$$w_j^{novo} = \beta (I \wedge w_j^{velho}) + (1 - \beta) w_j^{velho} \quad (5.1.3.7)$$

quando  $\beta = 1$ , tem-se o treinamento rápido. O treinamento rápido permite ao sistema se adaptar com maior rapidez. Já o treinamento lento,  $\beta < 1$ , força os pesos a se adaptarem lentamente sobre muitos ciclos de aprendizagem [Gopal et al., 1999].

Para compreender, geometricamente, como o parâmetro de treinamento influencia a rede, pode-se notar que os pesos não crescem com o tempo, desta forma, o hiper-retângulo somente se expandirá. Quando ocorre o treinamento rápido,  $\beta = 1$ , o hiper-retângulo se expandirá apenas o suficiente para incluir o ponto representado pelo vetor de entrada. Entretanto, quando o treinamento da rede neural ART for lento,  $\beta < 1$ , o hiper-retângulo irá se estender em direção ao ponto na proporção do tamanho de  $\beta$ .

#### g) Normalização da Entrada

As entradas são normalizadas para que se evite a proliferação de categorias na rede neural ART nebulosa. A normalização pode ser realizada pelo pré-processamento de cada vetor de entrada  $a$ , por exemplo, fixando [Carpenter et al., 1992; Georgiopoulos et al., 1996]:

$$I = \frac{a}{|a|}$$

#### h) Codificação do Complemento

É uma regra de normalização que preserva a amplitude da informação. Ela representa as respostas *on-off* para um vetor de entrada  $a$ . De forma simples,  $a$  representa a resposta *on*. O complemento de  $(a, a^c)$ , representa a resposta *off*, assim [Carpenter et al., 1992; Georgiopoulos et al., 1996]

$$a_i^c \equiv 1 - a_i$$

O complemento da entrada codificada  $I$  para o campo  $F_1$  é um vetor  $2M$ -dimensional:

$$\begin{aligned} I &\triangleq [a \ a^c] \\ &= [a_1 \dots a_M \ a_1^c \dots a_M^c] \end{aligned}$$

Observa-se que:

$$\begin{aligned} |I| &= |[a \ a^c]| \\ &= \sum_{i=1}^M a_i + \left( M - \sum_{i=1}^M a_i \right) = M \end{aligned}$$

Assim, as entradas pré-processadas em forma de codificação de complemento são automaticamente normalizadas.

Uma observação importante é que quando a codificação de complemento é usada na Equação (5.1.3.1), esta é substituída por:

$$w_{j1}(0) = \dots = w_{j,2M}(0) = 1$$

Todos os procedimentos anteriormente citados podem ser vistos de forma mais simples através do fluxograma mostrado na Figura 5.4.

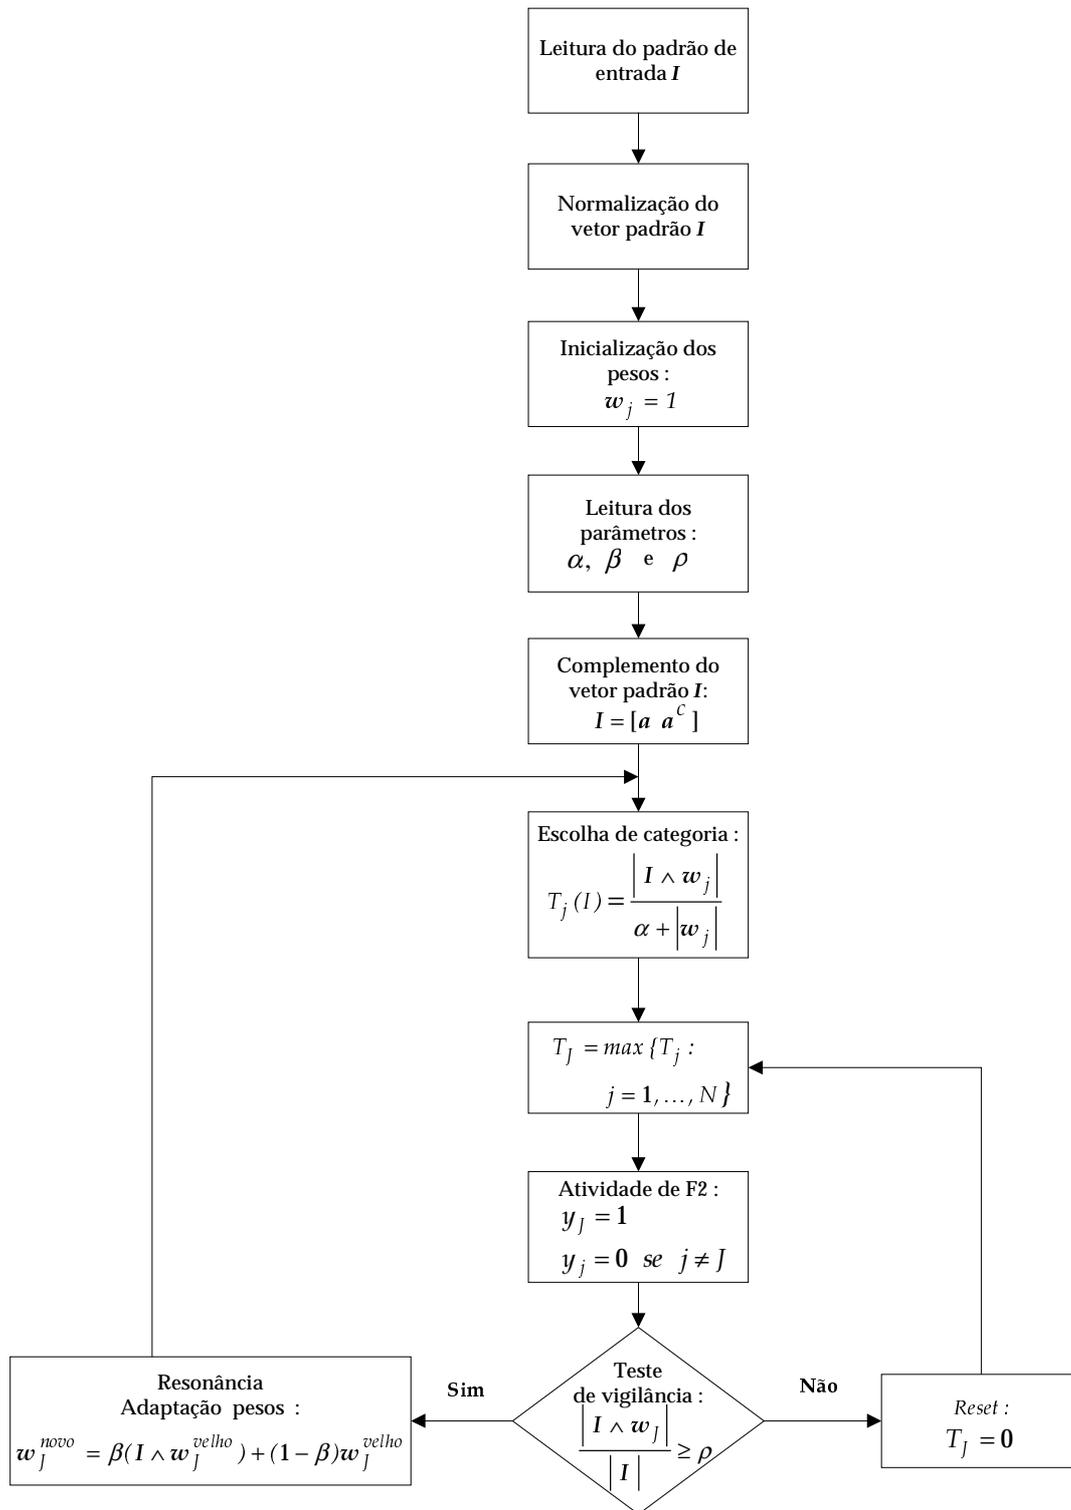


Figura 5.4. Fluxograma da rede neural ART nebulosa.

## 5.2. Rede Neural ARTMAP

A rede neural ARTMAP é um sistema de aprendizagem supervisionado capaz de auto-organizar o reconhecimento estável de categorias em resposta a seqüências arbitrárias de padrões de entradas. A rede é composta de um par de módulos da teoria da ressonância adaptativa,  $ART_a$  e  $ART_b$ , que são conectados através de um módulo de memória associativa inter-ART,  $F^{ab}$  [Lim & Harrison, 1997].

A rede possui um mecanismo interno, que ao mesmo tempo, maximiza a generalização e minimiza o erro através de um processo auto-regulador chamado *match tracking*. Sempre que a rede faz um prognóstico errado, através de uma conexão associativa instruída, o parâmetro de vigilância  $\rho_a$  do módulo  $ART_a$  será elevado em uma quantidade mínima necessária a corrigir o erro no módulo  $ART_b$ .

O módulo  $ART_a$  inicializará, então, a busca de uma nova categoria para a entrada atual até que se encontre um prognóstico correto ou crie uma nova categoria no módulo  $ART_a$  e a sua conexão associativa correspondente à categoria no módulo  $ART_b$  [Lim & Harrison, 1997].

O módulo  $ART_a$  aprende a classificar os padrões de entrada apresentados na camada  $F_0^a$ , enquanto o módulo  $ART_b$ , com parâmetro de vigilância  $\rho_b$ , desenvolve categorias referentes aos padrões de saída desejado expostos na camada  $F_0^b$ . Os módulos  $F_2^a$  e  $F^{ab}$  são conectados por um vínculo associativo cujos pesos são ajustados através do treinamento. Nos módulos  $F_2^b$  e  $F^{ab}$ , cada nó de  $F_2^b$  é conectado com seu nó correspondente em  $F^{ab}$  e vice-versa [Lim & Harrison, 1997].

A adaptação dos pesos, efetuada no módulo inter-ART entre uma categoria ativa  $J$  do  $ART_a$  e uma categoria ativa  $K$  do  $ART_b$ , é realizada de forma que, a conexão correspondente as categorias ativas dos módulos  $ART_a$  e  $ART_b$ , ou seja, a conexão entre  $F_2^a \rightarrow F^{ab}$ , terá valor 1 (um) e todas as demais conexões

referentes ao mesmo nó do  $ART_a$  terá valor igual a 0 (zero) [Kartalopoulos, 1996; Lim & Harrison, 1997].

Quando um padrão é apresentado à rede, a camada  $F^{ab}$  recebe entradas de ambos os módulos  $ART_a$  e  $ART_b$ . A entrada do módulo  $ART_a$  refere-se à conexão associativa  $J \rightarrow K$  e a entrada do  $ART_b$  a categoria ativa de  $F_2^b$ .

Se as duas entradas em  $F^{ab}$  combinam, ou seja, se o prognóstico da rede é confirmado pela categoria selecionada, a rede aprenderá modificando os protótipos das categorias escolhidas em  $ART_a$  e  $ART_b$ , segundo um critério de treinamento.

Se as duas entradas não combinam, um sinal de *reset* é gerado e um processo denominado *match tracking* se inicializará, de forma que, o grau do parâmetro de vigilância no  $ART_a$  será elevado em uma quantidade mínima necessária para que não ocorra a combinação para aquela entrada atual do  $ART_a$  na camada  $F_1^a$ .

Isto ativará uma nova busca na qual escolherá uma nova categoria no  $ART_a$ , cujo prognóstico será combinado novamente com a categoria atual do  $ART_b$ . Este processo continua até a rede encontrar uma categoria no  $ART_a$  que prediz a categoria correta da entrada atual ou crie uma nova categoria em  $F_2^a$  e a sua conexão correspondente com o módulo  $F^{ab}$ . Após poucas apresentações do conjunto de treinamento, a rede auto-estabilizará e obterá a saída esperada para cada entrada sem necessariamente efetuar todo o processo de busca [Lim & Harrison, 1997].

### 5.2.1. Algoritmo ARTMAP Nebuloso

A rede neural ARTMAP nebulosa incorpora a teoria de conjuntos nebulosos em seus cálculos e, como tal, é capaz de aprender categorias estáveis em resposta a padrões de entradas analógicos ou binários. Ela consiste de dois módulos ART nebulosos,  $ART_a$  e  $ART_b$  nebulosos. A diferença entre a rede neural

ARTMAP e a rede neural ARTMAP nebulosa consiste basicamente nos operadores nebulosos. A Figura 5.5 mostra a arquitetura da rede ARTMAP nebulosa [Carpenter et al., 1992; Raveendran et al., 2000].

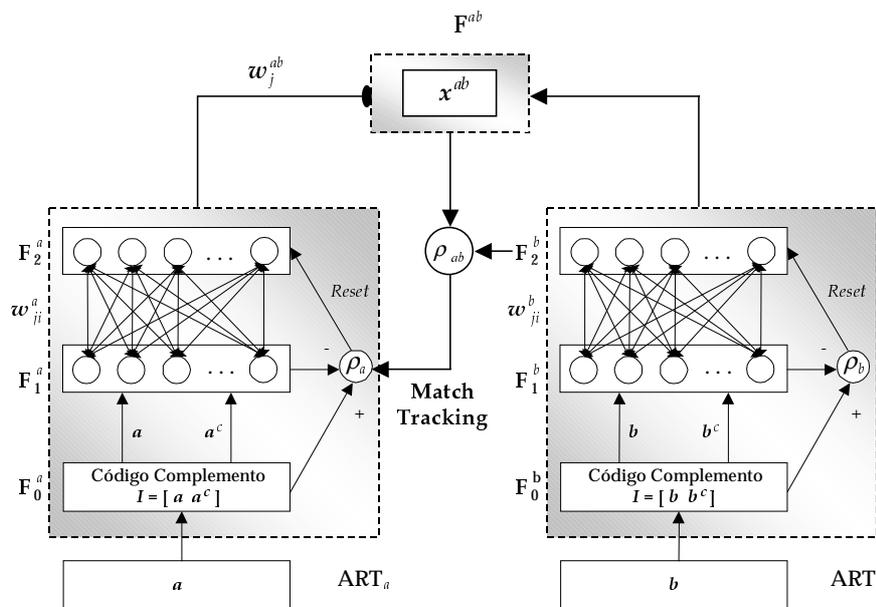


Figura 5.5. Rede neural ARTMAP nebulosa.

Os procedimentos do algoritmo ARTMAP nebuloso será descrito nas próximas subseções [Carpenter et al., 1992; Raveendran et al., 2000].

#### a) Redes Neurais $ART_a$ e $ART_b$

O vetor  $ART_a$  representa um padrão de entrada e o vetor  $ART_b$  a saída desejada correspondente ao vetor de entrada  $ART_a$ .

As entradas para o  $ART_a$  e o  $ART_b$  estão na forma de codificação de complemento. Para o módulo  $ART_a$  tem-se  $I = A = [a a^c]$  e para o  $ART_b$   $I = B = [b b^c]$ . A seguir, descrevem-se os vetores de atividade dos módulos envolvidos na rede neural ARTMAP nebulosa.

- ART<sub>a</sub>:  $\mathbf{x}^a = [x_1^a \dots x_{2M_a}^a]$ ,  $\mathbf{y}^a = [y_1^a \dots y_{2N_a}^a]$  e  $\mathbf{w}_j^a = [w_{j1}^a \dots w_{j,2M_a}^a]$ ;
- ART<sub>b</sub>:  $\mathbf{x}^b = [x_1^b \dots x_{2M_b}^b]$ ,  $\mathbf{y}^b = [y_1^b \dots y_{2N_b}^b]$  e  $\mathbf{w}_k^b = [w_{k1}^b \dots w_{k,2M_b}^b]$ ;
- inter-ART:  $\mathbf{x}^{ab} = [x_1^{ab} \dots x_{N_b}^{ab}]$  e  $\mathbf{w}_j^{ab} = [w_{j1}^{ab} \dots w_{jN_b}^{ab}]$ .

Sendo  $M_a$  e  $M_b$ , adotados como números de vetores de entrada na camada  $F_1^a$  e  $F_1^b$  e  $N_a$  e  $N_b$  as dimensões dos vetores de entrada que formam as categorias nas camadas  $F_2^a$  e  $F_2^b$  dos módulos ART<sub>a</sub> e ART<sub>b</sub>, respectivamente.

## b) Vetores Pesos

Todos os pesos relacionados ao ART<sub>a</sub>, ART<sub>b</sub> e ao inter-ART inicialmente possuem:

$$w_{j1}^a(0) = \dots = w_{j,2M_a}^a(0) = 1$$

$$w_{k1}^b(0) = \dots = w_{k,2M_b}^b(0) = 1$$

$$w_j^{ab}(0) = \dots = w_{jN_b}^{ab}(0) = 1$$

representando as categorias não-ativas. Após a seleção das categorias elas tornam-se ativas.

## c) Parâmetros

Os parâmetros, relacionados a seguir, são essenciais no desenvolvimento da rede neural ARTMAP nebulosa. São eles [Carpenter et al., 1992; Georgiopoulos et al., 1996]:

- O parâmetro de escolha -  $\alpha > 0$ ;
- O parâmetro taxa de treinamento -  $\beta \in [0,1]$ ;
- Os parâmetros de vigilância dos módulos ART<sub>a</sub>, ART<sub>b</sub> e inter-ART  $\rho_a$ ,  $\rho_b$  e  $\rho_{ab} \in [0,1]$ .

*Match Tracking*: Inicialmente o parâmetro de vigilância,  $\rho_a$ , do  $ART_a$  equivale a um parâmetro de vigilância base,  $\bar{\rho}_a$ . O parâmetro de vigilância de  $F^{ab}$  é dado por  $\rho_{ab}$ . Se [Carpenter et al., 1992]:

$$|\mathbf{x}^{ab}| < \rho_{ab} |\mathbf{y}^b| \quad (5.2.1.1)$$

$\rho_a$  é incrementada até que seja ligeiramente maior que:

$$\frac{|A \wedge w_J^a|}{|A|} \quad (5.2.1.2)$$

sendo

$A$  = entrada para  $F_1^a$  em forma de codificação de complemento. Então:

$$\frac{|A \wedge w_J^a|}{|A|} < \rho_a \quad (5.2.1.3)$$

sendo:

$J$  = índice do nó ativo em  $F_2^a$ .

Quando isso ocorre a busca no  $ART_a$  conduz cada ativação de outro nó  $J$  em  $F_2^a$  com:

$$\frac{|A \wedge w_J^a|}{|A|} \geq \rho_a \quad \text{e} \quad \frac{|\mathbf{y}^b \wedge w_J^{ab}|}{|\mathbf{y}^b|} \geq \rho_{ab}$$

ou se tal nó não existe, é necessário que se faça um acréscimo em  $\rho_a$ , de maneira que, seja obtido um novo valor de  $\rho_a$ , ligeiramente maior que o valor obtido na Equação (5.2.1.2). Desta forma:

$$\rho_a = \frac{|A \wedge w_J^a|}{|A|} + \varepsilon$$

Então, se um nó escolhido no  $ART_a$  falhar no critério de combinação, inicia-se uma nova busca de forma a encontrar o nó em  $F_2^a$  que satisfaça o critério de combinação [Carpenter et al., 1992; Georgiopoulos et al., 1996].

#### d) Aprendizagem

Os pesos  $w_{jk}^{ab}$  em caminhos  $F_2^a \rightarrow F^{ab}$  inicialmente satisfaz [Carpenter et al., 1992; Georgiopoulos et al., 1996]

$$w_{jk}^{ab} = 1$$

e durante o processo de ressonância se a categoria  $J$  do  $ART_a$  ativa e a categoria  $K$  do  $ART_b$  ativa combinarem, a adaptação dos pesos inter-ART será efetuada da seguinte maneira:

- $w_{JK}^{ab} = 1$
- $w_{jk}^{ab} = 0$  para  $j \neq J$  e  $k \neq K$

O fluxograma apresentado na Figura 5.6 estabelece todos os procedimentos do algoritmo ARTMAP nebuloso de uma forma mais simples.

A rede neural ARTMAP é uma rede que possui dois módulos ART acoplados através de um módulo inter-ART. A desenvoltura e o treinamento da rede é idêntica a rede ART, com uma única diferença, que a rede ARTMAP possui um sistema de conexão entre os dois módulos ART existentes na rede que combinam os parâmetros de entrada com a parâmetros de saída através do *match tracking*, fazendo com que a rede tenha um treinamento supervisionado.

O seu treinamento ocorre da mesma forma da rede ART, sendo que agora existirá mais uma matriz de pesos relacionado ao campo  $F^{ab}$ . Outro fato que difere as redes ART e ARTMAP é o acréscimo que ocorre no parâmetro de vigilância do módulo  $ART_a$  com a finalidade de excluir de vez a categoria do  $ART_a$  que não combinou com a categoria do  $ART_b$ .

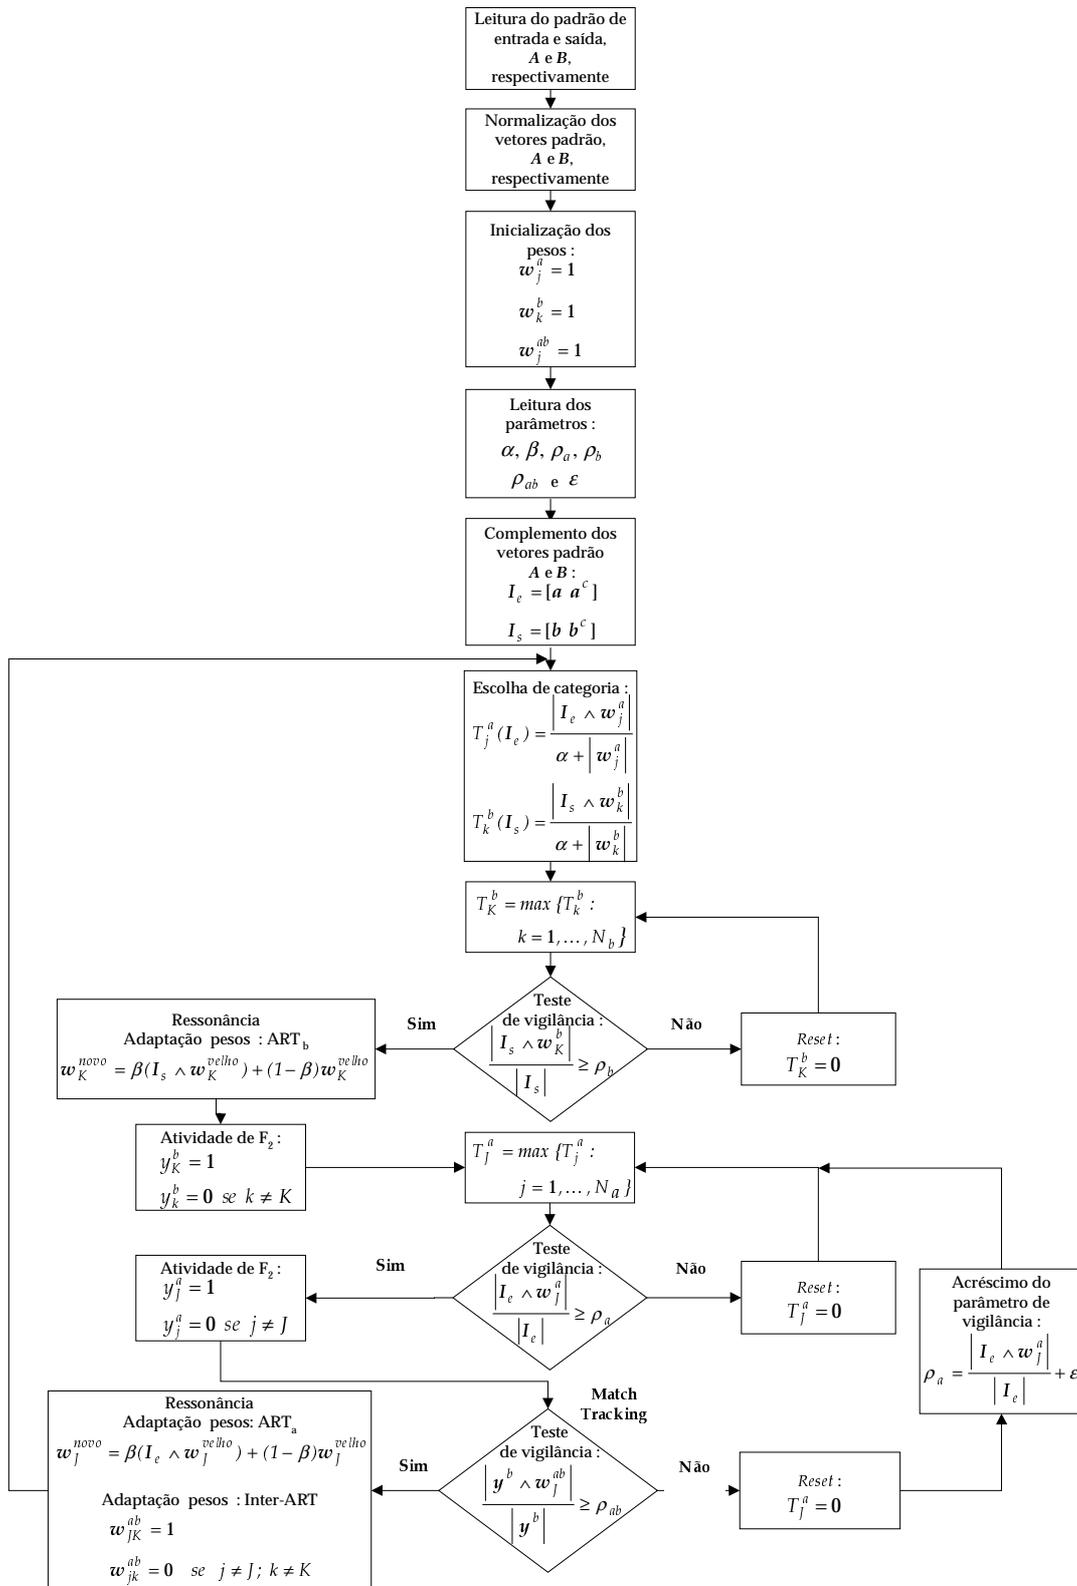


Figura 5.6. Fluxograma da rede neural ARTMAP nebulosa.

### **5.3. Comentários**

Neste capítulo foi efetuado um estudo teórico sobre a teoria da ressonância adaptativa. Como a nova arquitetura de rede neural a ser desenvolvida (rede neural ART&ARTMAP nebulosa) é composta por duas redes neurais baseadas na teoria da ressonância adaptativa. Este capítulo serviu como um instrumento conceitual no qual foram apresentados os algoritmos e as estruturas de ambas as redes (ART nebulosa e ARTMAP nebulosa) utilizadas na construção da rede neural ART&ARTMAP nebulosa.

# Capítulo 6

## Rede Neural ART&ARTMAP Nebulosa

*Este capítulo introduz o conceito de uma nova arquitetura de rede neural baseada na teoria da ressonância adaptativa, denominada rede neural ART&ARTMAP nebulosa, para fins do uso em previsão de carga. Esta arquitetura é uma inovação dentro das redes neurais artificiais. Ela é composta por duas redes neurais baseadas na teoria da ressonância adaptativa: rede neural ART nebulosa e rede neural ARTMAP nebulosa. Esta arquitetura possui a vantagem de trabalhar tanto com dados binários como analógicos. É uma rede neural que também faz parte da família ART, logo possui as características fundamentais desta família que é a plasticidade e a estabilidade.*

### 6.1. Arquitetura da Rede Neural ART&ARTMAP Nebulosa

A rede neural ART&ARTMAP nebulosa [Ferreira, 2003] é uma arquitetura que foi concebida para trabalhar, com maior eficiência, com dados binários e analógicos simultaneamente. Trata-se de uma rede neural composta por dois módulos:

1. rede neural ART nebulosa [Carpenter et al., 1991b];
2. rede neural ARTMAP nebulosa [Carpenter et al., 1992; Carpenter & Grossberg, 1992].

A importância do emprego deste sistema refere-se à característica de estabilidade e plasticidade, além de oferecer respostas bastante rápidas (treinamento rápido).

A rede neural ARTMAP é composta por dois módulos ART denominados ART<sub>a</sub> e ART<sub>b</sub>, os quais são treinados de modo não-supervisionado, baseados no estímulo de entradas. Estes dois módulos são interligados por um módulo inter-ART que é responsável pelo “casamento” entre as informações de entrada e de saída codificadas nas redes neurais ART<sub>a</sub> e ART<sub>b</sub>, ou seja, é realizado o mapeamento  $b = f(a)$ ,  $a$  (entrada)  $\in \mathfrak{R}^n$  e  $b$  (saída)  $\in \mathfrak{R}^m$ , sendo  $f$  uma função desconhecida (linear ou não-linear) multidimensional. Assim, ainda que os módulos ART<sub>a</sub> e ART<sub>b</sub> sejam treinados de modo não-supervisionado, na rede neural ARTMAP o treinamento é realizado de modo supervisionado (baseado em estímulos de entrada e de saída), cuja função é exercida pelo mecanismo inter-ART.

A previsão de carga é formulada como um problema que usa variáveis híbridas, *i.e.*, dados binários (para expressar os dias, meses, anos, etc.) e dados analógicos (valores da carga elétrica, temperatura, etc.). Daí a razão de se trabalhar com a rede neural ART&ARTMAP nebulosa.

A rede neural ARTMAP, na arquitetura ART&ARTMAP, tem por objetivo, o processamento apenas de dados binários, embora as entradas de dados da rede neurais (rede neural ART) sejam compostas tanto de dados binários quanto de dados analógicos. Dentro da arquitetura da rede neural ART&ARTMAP nebulosa está embutido um mecanismo o qual possibilita a transformação dos dados analógicos em dados binários.

Na Figura 6.1 [Lopes et al., 2005], apresenta-se a rede neural ART&ARTMAP nebulosa, organizada e ajustada para resolver o problema de previsão de carga. São identificadas as duas redes neurais ART e ARTMAP nebulosas. À esquerda e à direita encontram-se, respectivamente, as duas redes neurais ART nebulosa e ARTMAP nebulosa (composta pelos módulos  $ART_a$ ,  $ART_b$  e inter-ART).

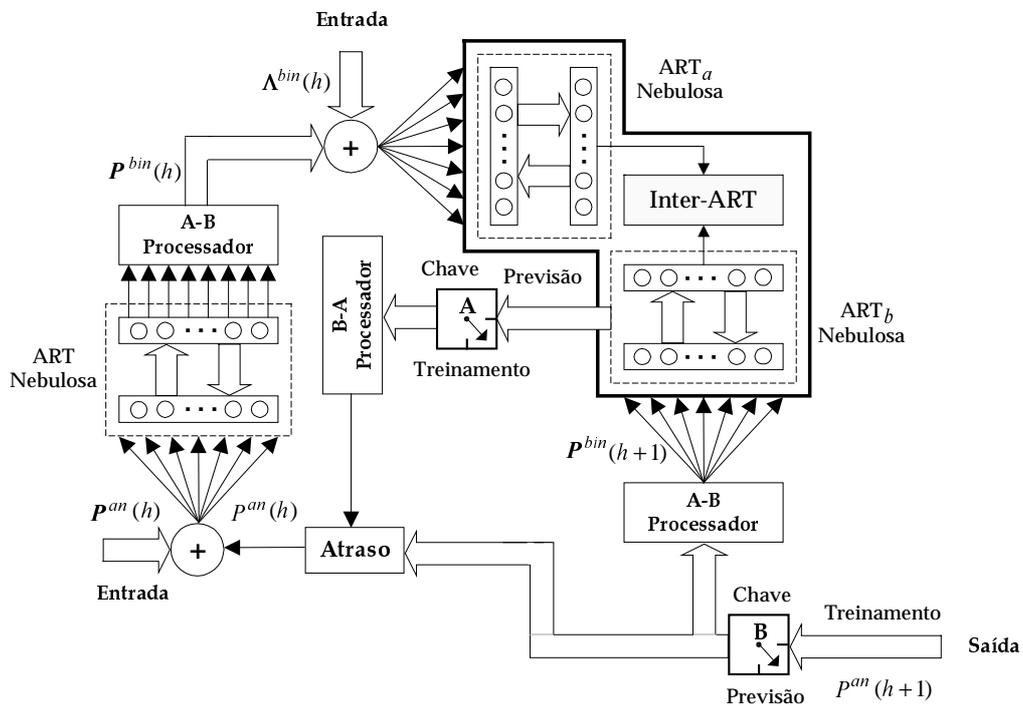


Figura 6.1. Rede neural ART&ARTMAP nebulosa.

O funcionamento desta rede neural constitui de duas fases:

- (1) treinamento;
- (2) previsão.

Na fase de treinamento, na rede neural, as chaves A e B deverão estar posicionadas na modalidade “treinamento”. A entrada é composta pelo vetor

$P^{an}(h)$  (grandezas analógicas), pelo escalar  $P^{an}(h)$ , correspondente ao dado de saída da rede neural sofrendo um atraso de uma hora, e pelo vetor  $A^{bin}(h)$  (dados binários). A saída é composta pela carga referente a 1 hora à frente. Na fase de previsão, as chaves A e B deverão ser colocadas na posição “previsão”. Neste caso, a entrada escalar  $P^{an}(h)$  é gerada pela rede neural correspondente a carga com um atraso de 1 hora em relação a carga prevista  $P^{an}(h + 1)$ . Observa-se que  $P^{an}(h + 1)$  é fornecida sob código ativo da rede neural ARTMAP, devendo, portanto, ser convertido em dados reais, via uso do processador B-A.

O conjunto de padrões de entrada que compõem a rede neural ART&ARTMAP nebulosa é formado por dois subconjuntos de entradas de dados.

O primeiro conjunto de entrada de dados é apresentado ao módulo ART nebuloso. Este conjunto contém apenas dados de entrada analógicos. Este módulo ART nebuloso tem por finalidade agrupar os dados de entrada analógicos, através de similaridades tratadas dentro da arquitetura da rede neural ART nebulosa ilustrada na Figura 6.2 (este procedimento é efetuado através do teste de vigilância).

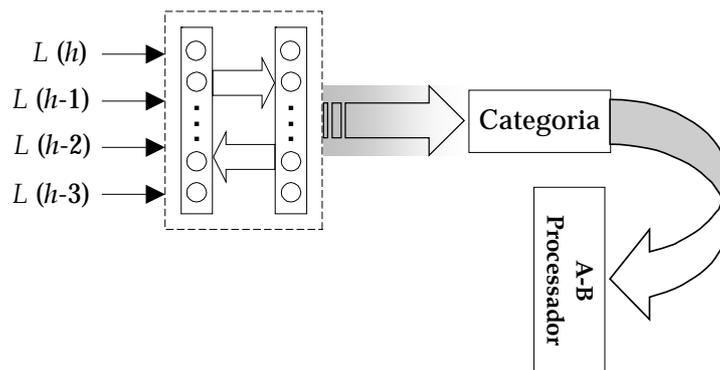


Figura 6.2. Processador do módulo ART nebuloso.

Os dados que formam o conjunto de entrada para o módulo ART nebuloso são constituídos de dados de carga elétrica horária (e.g., carga atual,

uma, duas e três cargas anteriores). A saída da rede neural ART nebulosa é transformada via processador código ativo/código binário em informação binária. Deve-se ressaltar que o código ativo refere-se às atividades estabelecidas na saída do módulo ART nebuloso.

O segundo conjunto de entrada é composto apenas de dados binários que correspondem a dados que se referem ao tempo, neste caso, a hora correspondente a cada carga elétrica, o dia da semana e o mês.

Resumindo, a rede neural ART&ARTMAP nebulosa são compostas pelos seguintes padrões de entrada de dados:

**padrão de entrada:** O padrão de entrada de dados da rede é dividido em duas partes [Lopes et al., 2004]:

1. a primeira parte constitui o padrão de entrada de dados analógicos. É composta por dados históricos (de hora em hora) predefinidos em um intervalo, por exemplo, mensal. Em uma determinada hora  $h$ , a entrada é definida como sendo os dados históricos da carga elétrica (correspondentes à hora atual, 1, 2, . . . e  $q$  horas anteriores).
2. a segunda parte constitui o padrão de entrada de dados binários. Estes dados são referentes ao tempo (mês, dia da semana, se é feriado ou não, hora, etc.).

Esta é a estratégia usada nesta pesquisa. Contudo, deve-se considerar que há uma grande variedade de estratégias propostas na literatura. O que distingue uma das demais, refere-se aos dados que são usados em cada janela. Por exemplo, na estratégia aqui empregada, são tomados  $q$  horas anteriores à hora corrente. Uma outra estratégia poderia ser adotada acrescentando outros valores de carga correspondentes à hora corrente de dias, de semanas ou meses anterior. Assim, via de regra, a aplicação de redes neurais para a previsão de carga é realizada considerando-se dois enfoques:

- (1) melhoria das arquiteturas e das técnicas de treinamento;
- (2) melhoria da estratégia para a constituição dos dados de entrada.

Neste trabalho, o desenvolvimento do sistema para previsão de carga refere-se ao enfoque (1), ou seja, está sendo proposto um novo modelo neural para a previsão de carga, baseado numa composição modular de redes neurais ART nebulosas.

Com o objetivo de refinar os resultados, pode-se incluir, também nessa base de dados, outras variáveis como: temperatura, umidade, velocidade do vento, dias nublados, etc., que correspondem às variáveis exógenas do problema.

Os padrões de entrada da rede são representados como:

$$P^{an}(h) = [L(h-q) \dots L(h-2) L(h-1) L(h)], \quad P^{an} \in R^m \quad (6.1.1)$$

$$A^{bin}(h) = [t], \quad A^{bin} \in R^n \quad (6.1.2)$$

em que:

$P^{an}(h)$  = dados de entrada analógicos;

$A^{bin}(h)$  = dados de entrada binários;

$m$  = dimensão do vetor  $P^{an}$ ;

$n$  = dimensão do vetor  $A^{bin}$ ;

$q$  = número de horas anteriores à hora corrente ( $h$ );

$L(h-q)$  = valor da carga,  $q$  horas antes da hora atual  $h$ ;

$t$  = vetor tempo referente aos dados históricos (mês, dia da semana, feriado, hora, etc.).

As cargas elétricas  $L(h - q) \dots L(h - 2) L(h - 1)$  representam o laço de realimentação da saída com um atraso, respectivamente, de  $q, \dots, 2$  e 1 hora da hora corrente  $h$ .

O vetor  $P^{an}(h)$  constitui a entrada da rede neural, tendo como função a classificação em categorias. Em seguida estas categorias são convertidas em dados binários, originando o vetor  $P^{bin}(h)$ .

Desta forma, a entrada da rede neural ARTMAP nebulosa é composta apenas por dados binários formadas pelo vetor binário da saída do processador A/B, acrescido do vetor binário que representa os dados do tempo.

O conjunto de padrões que representa a saída desejada da rede neural ART&ARTMAP nebulosa é formada por valores de cargas elétricas horárias relativas à hora subsequente aos valores de carga horária que compõem o dados de entrada. Este conjunto também é composto apenas por dados analógicos e é dado da seguinte maneira:

**Padrão de saída:** Corresponde ao valor da carga relativa à hora  $(h+1)$ , que é processada em classes e áreas e, posteriormente, codificada em dados binários [Lopes et al., 2004].

Como o objetivo da rede neural ART&ARTMAP nebulosa é fazer com que todo o processamento, treinamento e diagnóstico da rede neural, tenha um embasamento apenas em dados binários, o próximo passo consiste em tentar fazer com que os dados analógicos que compõem a saída da rede sejam transformados em dados binários.

Primeiramente, efetuou-se uma normalização dos dados de saída, em um intervalo  $[0, 1]$ , através da razão dos valores das cargas elétricas que compunham o banco de dados por um valor de carga máximo (valor de carga preestabelecido, maior que os valores do banco de dados). Então

$$L_n(h+1) = L(h+1) / CMAX \quad (6.1.3)$$

em que:

$L_n(h+1)$  = valor da carga elétrica normalizado referente à hora subsequente da hora atual  $h$ ;

$L(h+1)$  = valor da carga elétrica correspondente à hora subsequente da hora atual  $h$ ;

$CMAX$  = valor máximo preestabelecido da carga.

O intervalo  $[0, 1]$  é discretizado em classes e cada classe é subdividida em áreas como mostra a Figura 6.3. Para os resultados de previsão de carga elétrica obtidos foram utilizados 127 classes (representação por 7 bits) e 15 áreas (representação por 4 bits).

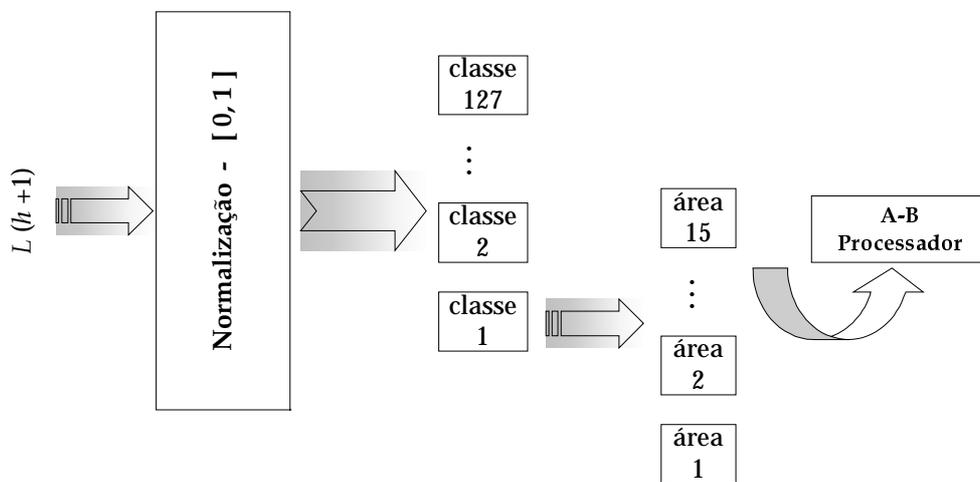


Figura 6.3. Processador dos dados de saída da rede neural ART&ARTMAP nebulosa.

Inicialmente a proposta era apenas de utilizar como classificação da carga elétrica apenas a classe, ou seja, cada valor que uma carga elétrica

assumesse, deveria pertencer a uma classe específica. Porém, com o decorrer dos testes efetuados, observou-se que valores de cargas diferentes poderiam estar pertencendo a mesmo tipo de classe, o que geraria um enorme erro na previsão.

A idéia foi, então, fazer com que dentro da classe houvesse uma subdivisão, de forma que os valores de cargas elétricas diferentes que assumissem a mesma classe tivessem, através desta nova subdivisão, um novo esquema de representação.

Dessa forma, cada valor de carga elétrica assume uma classe e uma área de forma única, de maneira que, se ocorrer o fato do banco de dados possuir valores de cargas elétricas próximos, é possível aumentar ou diminuir os intervalos de classes e áreas de forma a encontrar sempre uma configuração apta a representar uma carga elétrica específica. Isso é importante, pois cada configuração pode apenas ser relacionada a um único valor de carga elétrica.

Assim sendo, espera-se que a rede consiga identificar o valor da carga elétrica de forma mais precisa possível. Desta forma, cada valor de  $L_n(l+1)$  será representado por classe e área, na forma binária, do seguinte modo [Lopes et al., 2004]:

$$L_n^{bin}(l+1) = \underbrace{[101 \dots 0]}_{C^{bin}} \underbrace{[001 \dots 1]}_{A^{bin}} \quad (6.1.4)$$

em que:

$C^{bin}$  = vetor correspondente à representação binária da classe de  $L_n(l+1)$ ;

$A^{bin}$  = vetor correspondente à representação binária da área de  $L_n(l+1)$ ;

$L_n^{bin}(l+1)$  = representação binária de  $L_n(l+1)$ .

Após identificar a configuração em classes e áreas referentes a cada valor de carga elétrica, o próximo passo é binarizar as classes e as áreas através do processador código ativo/código binário.

Estes dados binarizados compõem o banco de saída do módulo ARTMAP nebuloso.

O módulo ARTMAP nebuloso se baseia apenas no processamento de dados binários o que favorece o treinamento e o diagnóstico, tornando-os a princípio, mais rápidos.

Este sistema neural contém chaves que indicam o estado da rede: fase de treinamento ou fase análise (no presente caso, corresponde à realização da previsão de carga elétrica). Um conversor A/B é empregado para realizar a conversão analógica/binária da saída da rede neural ARTMAP nebulosa durante a fase de treinamento. A rede neural ARTMAP nebulosa fornece uma saída binária (fase de análise) que deve ser convertida em informação analógica para ser agregada à entrada da rede neural ART nebulosa como ilustra a Figura 6.4.

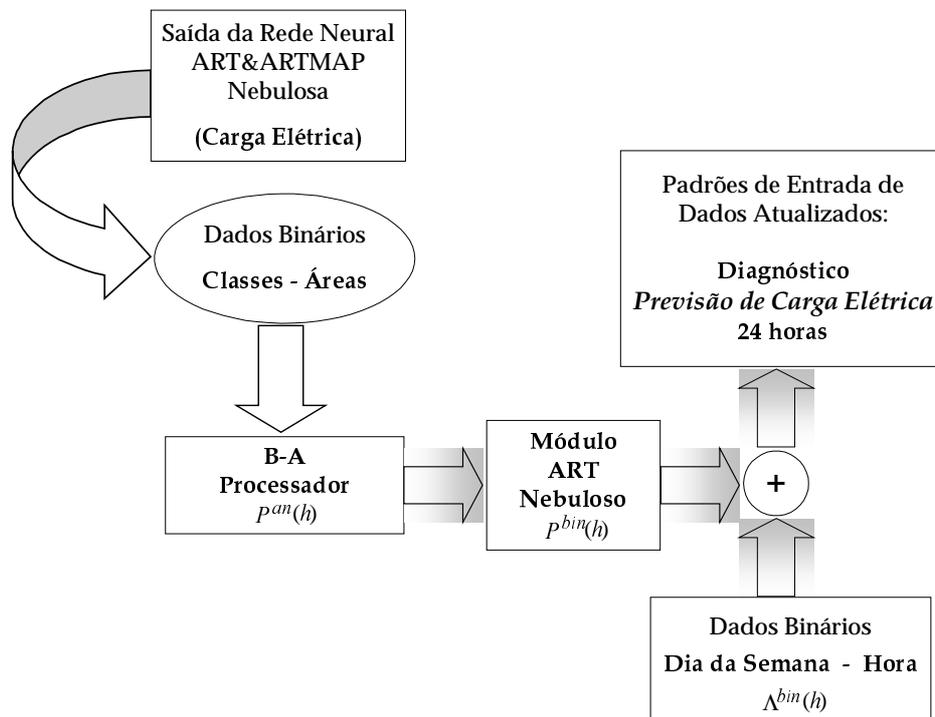


Figura 6.4. Ilustração da rede neural ART&ARTMAP nebulosa na fase de análise.

Deste modo, a previsão de carga elétrica corresponde aos valores da saída da rede neural ARTMAP nebulosa para o intervalo de tempo considerado (por exemplo, a previsão diária, 24 horas à frente).

Em resumo, os dados de entrada analógicos são incluídos na entrada da rede neural ART nebulosa, enquanto que, se forem binários, a inclusão far-se-á diretamente na entrada da rede neural ARTMAP nebulosa (que, neste trabalho, só manipula informações binárias). Os módulos conversores A/B são empregados, portanto, para compatibilizar os diferentes tipos de informações (analógicas/binárias) manipuladas nas diferentes partes da rede neural.

## **6.2. Comentários**

Neste capítulo o objetivo foi apresentar o desenvolvimento da rede neural ART&ARTMAP nebulosa aplicada ao problema de previsão de cargas elétricas. O processamento da rede neural ART&ARTMAP nebulosa está baseado no tratamento apenas de dados binários, com isso, todos os dados analógicos são convertidos em dados binários. É importante salientar que esta rede neural mantém as características fundamentais que as redes neurais baseadas na teoria da ressonância adaptativa possuem que é a plasticidade e a estabilidade. Estas características são de extrema importância para o funcionamento da rede neural, pois garante a convergência da rede neural de forma rápida e precisa.

## Capítulo 7

# Aplicação das Redes Neurais na Previsão de Cargas Elétricas

*Este capítulo apresenta alguns resultados obtidos através do algoritmo retropropagação neuro-nebuloso desenvolvido por [Lopes, 2000], do algoritmo retropropagação neuro-nebuloso com adaptação dos parâmetros de inclinação e translação da função sigmóide [Lopes et al., 2003] e finalmente alguns resultados obtidos do desenvolvimento da rede neural ART&ARTMAP nebulosa [Lopes et al., 2004]. Todas as arquiteturas visam a resolução do problema de previsão de carga a curto prazo (24 horas à frente). Para a fase de treinamento da rede neural, serão utilizados os dados históricos de uma companhia do setor elétrico brasileiro. Para testar a eficiência das metodologias propostas, os resultados obtidos serão comparados com os obtidos por uma rede neural treinada através do algoritmo retropropagação convencional. A precisão deverá ser verificada calculando-se o erro médio e erro máximo ocorrido, considerando-se o horizonte de previsão. O erro será calculado tomando-se a diferença entre a série prevista e os valores conhecidos das cargas (valores de referência).*

## 7.1. Critérios para Avaliação da Rede Neural

Para avaliar o desempenho das redes neurais baseadas no algoritmo retropropagação, define-se o ganho em termos do número de ciclos:

$$GC = \frac{NRP}{NRPM}$$

sendo:

$NRP$  = número de ciclos do algoritmo retropropagação;

$NRPM$  = número de ciclos do algoritmo retropropagação modificado.

O ganho de tempo necessário para a realização do treinamento é dado da seguinte forma [Lopes & Minussi, 2000]:

$$GT = \frac{TRP}{TRI}$$

em que:

$TRP$  = tempo de execução (processamento) do algoritmo retropropagação;

$TRI$  = tempo de execução das redes neurais implementadas.

Para uma análise da precisão, são definidos o erro percentual absoluto médio  $MAPE$  [Srinivasan et al., 1998] e o erro máximo da previsão diária, comparando-se os valores reais da carga com os valores estimados através da rede neural da seguinte forma:

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

$$Erro\ máximo\ (\%) = \max \{ |L(h) - \underline{L}(h)| / L(h) \} \times 100$$

sendo:

$L(h)$  = valor da carga real referente a hora  $h$ ;

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

$NT$  = número total de horas.

O programa foi elaborado em FORTRAN e processado em um microcomputador Pentium 4 (1,7 GHz e 256 MB de memória RAM). O tempo de processamento diz respeito apenas à execução do algoritmo, sendo excluídas as operações de leitura e saída dos dados.

## 7.2. Formulação do Problema de Previsão de Cargas Elétricas utilizando o Algoritmo Retropropagação

No desenvolvimento do trabalho existem características importantes que devem ser comentadas e analisadas com a finalidade de compreender o desempenho do algoritmo proposto com relação a previsão de cargas elétricas. Uma delas consiste em verificar qual deve ser a função sigmóide utilizada durante o processo de treinamento da rede neural.

Como o problema a ser abordado corresponde à previsão de cargas elétricas, a função não-linear adotada é a função sigmóide definida pela Equação (4.1.6) [Fine, 1999; Simpson, 1989; Widrow & Lehr, 1990].

Para trabalhar com modelos binários deve-se adotar valores grandes para o parâmetro  $\lambda$  [Widrow & Lehr, 1990], enquanto que para modelos contínuos é recomendável adotar valores de menor magnitude [Minussi & Silveira, 1995]. A derivada  $\sigma$  tem forte semelhança com a curva de distribuição normal (de Gauss). Constitui-se de um *corpo central* e suas laterais designadas, como forma de simplificação, *caudas esquerda* e *direita* [Minussi & Silveira, 1995]. Nota-se que a diminuição de  $\lambda$  produz uma suavização na função sigmóide  $y$ , enquanto que sua derivada  $\sigma$  tende a diminuir a amplitude da curva e alongar as caudas.

No algoritmo retropropagação, a adaptação de pesos, que concorrem a cada neurônio, é efetuada utilizando-se, basicamente, o erro propagado no sentido inverso, multiplicado por  $\sigma$  e pela entrada no referido neurônio. Deste modo, os pesos têm efetivo ajuste somente para valores de “s” situados no corpo central da

função  $\sigma$ . À medida que os pesos se tornarem significativos, há desaceleração dos ajustes dos mesmos, tendendo para a completa paralisia, justamente onde se encontram os terminais das caudas (tanto direita como esquerda) [Minussi & Silveira, 1995]. A escolha de  $\lambda$  deve ser feita levando-se em conta a experiência com treinamento.

Nos resultados apresentados, por conveniência, o parâmetro  $\gamma$  (taxa de treinamento) é redefinido do seguinte modo [Lopes & Minussi, 2000]:

$$\gamma = (2 \gamma^* / \lambda) \quad (\text{para sigmóide definida pela Equação (4.1.5)}) \quad (7.2.1)$$

$$\gamma = (\gamma^* / \lambda) \quad (\text{para sigmóide definida pela Equação (4.1.6)}) \quad (7.2.2)$$

Substituindo-se as expressões de  $\gamma$  (Equações (7.2.1) e (7.2.2)) na Equação (4.2.2), será “anulada” a dependência da amplitude de  $\sigma$  com relação a  $\lambda$ . A amplitude de  $\sigma$  será mantida constante para qualquer valor de  $\lambda$ . Esta alternativa torna-se mais conveniente tendo em vista que  $\lambda$  atuará somente nas caudas esquerda e direita de  $\sigma$ . Assim, arbitrando-se um valor inicial para  $\gamma^*$ , este parâmetro será ajustado via controlador nebuloso, substituindo-se  $\Delta\gamma$  por  $\Delta\gamma^*$  [Lopes & Minussi, 2000].

A previsão de carga a curto-prazo (previsão diária) é realizada de acordo com o seguinte esquema: 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, *e.g.*, mensal. A entrada da rede, para uma determinada hora  $h$ , é definida como sendo os valores da carga extraídos dos dados históricos em quatro instantes (*e.g.*, valor corrente, uma, duas e três horas anteriores), a temperatura, etc., e os dados referentes ao tempo (mês, dia da semana, feriado e hora, etc.). 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, etc). Assim, o vetor de entrada e a saída, respectivamente, são definidos da seguinte forma [Lopes et al., 2000]:

$$X(h) = [ t L(h-3) L(h-2) L(h-1) L(h) ], \quad X \in R^m \quad (7.2.3)$$

$$Y(h) = [ L(h+1) ], \quad Y \in R^1 \quad (7.2.4)$$

sendo:

$m$  = dimensão do vetor  $X$ ;

$L(h-q)$  = valor da carga  $q$  horas anterior à hora corrente  $h$ ;

$L(h+1)$  = valor da carga elétrica 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  $(-1,+1)$ .

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  $L(h-3)$ , ... ,  $L(h-1)$  representam o laço de realimentação, com atraso, da saída. Deste modo, esta rede é do tipo recorrente.

Os dados históricos que compõem os arquivos de entrada e saída das redes neurais 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.

### 7.2.1. Controlador Nebuloso

Para esta arquitetura de rede neural, rede neural *feedforward* com controlador nebuloso (CN), são consideradas três aplicações, sendo que o banco de dados possui, respectivamente, dados históricos de 21 (Apêndice B.1), 42 (Apêndice B.2) e 84 dias (Apêndice B.3).

De um modo geral, utiliza-se um vetor de entrada de dimensão 12, composto pelos seguintes dados: 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.

A primeira aplicação (Aplicação 1) composta por dados históricos de 21 dias está compreendida entre o dia 8 de julho de 1998 e o dia 28 de julho de 1998, num total de 504 vetores de entrada. Para a segunda aplicação (Aplicação 2), composta por 42 dias, os dados históricos estão compreendidos entre o dia 17 de junho de 1998 e o dia 28 de julho de 1998 resultando num banco de entradas formado por 1008 vetores. E, finalmente, a terceira aplicação (Aplicação 3) que 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. É importante ressaltar que o dia 11 de junho de 1998 foi excluído do banco de dados, pelo fato de ser um dia atípico (feriado), cujos dados contêm imprecisões grosseiras que se utilizados interferem consideravelmente nos resultados da previsão.

Os valores das cargas são, inicialmente, normalizados uma vez que a saída somente pode variar entre 0 e +1. A série prevista será, então, finalmente, convertida aos valores reais, ou seja, multiplicados pelo valor da base preestabelecida.

A Tabela 7.1 apresenta os principais parâmetros referentes às redes neurais utilizadas e ao treinamento. Os parâmetros referentes ao algoritmo retropropagação convencional é semelhante aos parâmetros das redes neurais, sendo que o parâmetro  $\alpha$  assume valor igual a 0.

Tabela 7.1. Especificação da rede neural – controlador nebuloso.

Parâmetros	Aplicação 1	Aplicação 2	Aplicação 3
Número de vetores padrão	504	1008	2016
Número de camadas	3	3	3
Número de neurônios por camada	12-30-1	12-30-1	12-30-1
Tolerância (%)	2,0	2,5	3,0
Taxa de treinamento $\gamma^*$	4,5	5,5	6,0
Termo momento $\eta$	0,9	0,9	0,9
Inclinação da função sigmóide $\lambda$	0,3	0,3	0,3
Parâmetro $\alpha$	0,002	0,81	0,06

Os números de neurônios que compõem cada camada são escolhidos conforme as características do sistema, assim como os valores dos padrões envolvidos no treinamento da rede neural.

Na Figura 7.1 são mostrados, para a Aplicação 1, os resultados da previsão de carga (via algoritmo retropropagação convencional e retropropagação via controlador nebuloso) referentes ao dia 29 de julho de 1998. A Figura 7.2 ilustra os resultados da previsão de carga (via algoritmo retropropagação convencional e retropropagação via controlador nebuloso) referentes ao dia 29 de julho de 1998 obtidos para Aplicação 2. Os resultados da previsão de carga encontrados para Aplicação 3 (via algoritmo retropropagação convencional (RP) e retropropagação via controlador nebuloso (RP Nebuloso)) referentes ao dia 28 de julho de 1998 são apresentados na Figura 7.3.

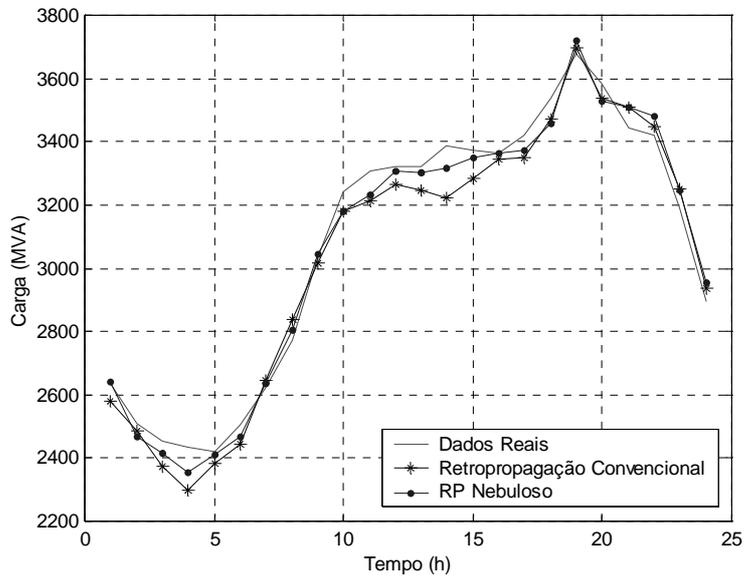


Figura 7.1. Resultados da previsão de carga para Aplicação 1 (CN).

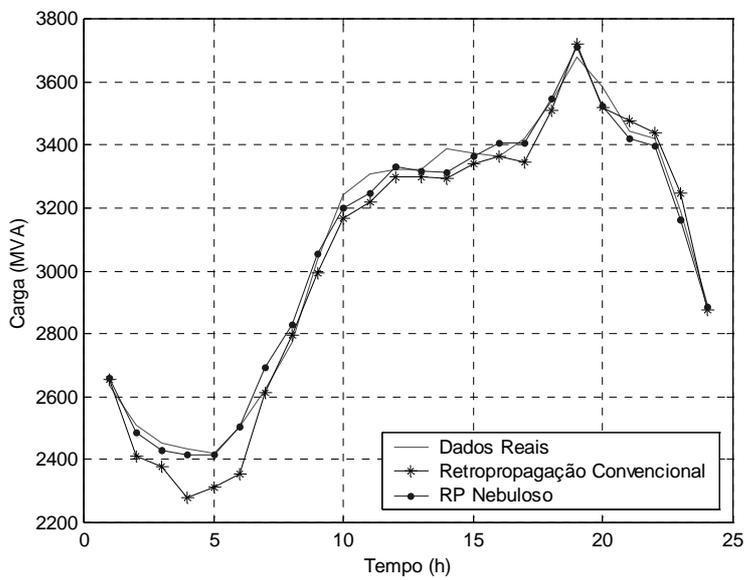


Figura 7.2. Resultados da previsão de carga Aplicação 2 (CN).

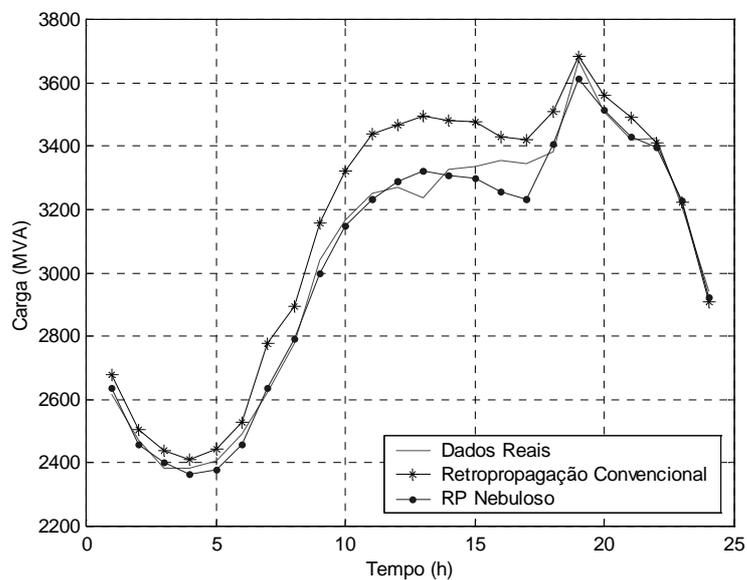


Figura 7.3. Resultados da previsão de carga para Aplicação 3 (CN).

As Tabelas 7.2, 7.3 e 7.4 apresentam os resultados comparativos em termos de ganhos de ciclo e tempo e também fornece, em porcentagem, o erro com relação ao valor real da carga.

Tabela 7.2. Resultados comparativos para Aplicação1 (CN).

Item	RP	RP Nebuloso
Número Ciclos	24801	16973
Tempo Processamento(s)	443,56	322,35
Ganho GC	-	1,46
Ganho GT	-	1,38
MAPE (%)	2,03	1,35
Erro Máximo (%)	5,62	3,31

Tabela 7.3. Resultados comparativos para Aplicação2 (CN).

Item	RP	RP Nebuloso
Número Ciclos	2452	1932
Tempo Processamento(s)	86,72	69,26
Ganho <i>GC</i>	-	1,27
Ganho <i>GT</i>	-	1,25
<i>MAPE</i> (%)	1,97	0,91
<i>Erro Máximo</i> (%)	6,36	2,71

Tabela 7.4. Resultados comparativos para Aplicação3 (CN).

Item	RP	RP Nebuloso
Número Ciclos	1735	1662
Tempo Processamento(s)	120,16	118,30
Ganho <i>GC</i>	-	1,04
Ganho <i>GT</i>	-	1,02
<i>MAPE</i> (%)	3,01	1,03
<i>Erro Máximo</i> (%)	8,01	3,45

Deve-se observar que o número de ciclos de treinamento nas três aplicações foi consideravelmente diferente, tendo em vista que foram utilizadas tolerâncias distintas. Procurou-se usar tolerâncias mais brandas à medida que aumentava o número de padrões. Isto se fez necessário visando evitar problemas na convergência da rede.

### 7.2.2. Controlador Nebuloso e Adaptação dos Parâmetros de Inclinação e Translação da Função Sigmóide

Os dados para compor o treinamento, empregados para esta rede neural, são (para cada vetor): os dados do tempo (dia do mês e a hora do dia), as 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 consequência da não disponibilidade dos mesmos. Considerando-se a representação binária, o vetor  $t$  terá dimensão 8 que, juntamente com os dados da carga, serão 12 componentes ( $m = 12$ ).

Os bancos de dados utilizados para validar esta metodologia (previsão de cargas elétricas, utilizando a rede neural *feedforward* treinada pelo algoritmo retropropagação com controlador nebuloso e um processo adaptativo dos parâmetros de inclinação e translação da função sigmóide, que é a função de ativação utilizada pela rede neural) são constituídos pelos mesmos dados que compõem as aplicações 1, 2 e 3 mencionadas anteriormente. A Tabela 7.5 mostra os principais parâmetros, referentes a rede neural adaptativa, utilizada nas aplicações 1, 2 e 3, simultaneamente.

Tabela 7.5. Especificação da rede neural adaptativa.

Parâmetros	Aplicação		
	1	2	3
Número de vetores padrão	504	1008	2016
Número de camadas	3	3	3
Número de neurônios por camada	12-30-1	12-33-1	12-33-1
Tolerância (%)	4,0	3,8	4,0
Taxa de treinamento $\gamma^*$	5,5	6,5	6,5
Termo momento $\eta$	0,0	0,0	0,0
Inclinação inicial da função sigmóide $\lambda$	0,30	0,20	0,25
Translação inicial da função sigmóide $\rho$	0,0	0,0	0,0
Taxa de treinamento - inclinação da função sigmóide $\gamma_\lambda$	0,10	0,35	0,65
Taxa de treinamento - translação da função sigmóide $\gamma_\rho$	0,50	0,33	0,80
Parâmetro $\alpha$	0,4821	0,4281	0,4843

A Figura 7.4 mostra os resultados da previsão de carga elétrica, Aplicação 1, (via retropropagação convencional - RP convencional e RACN - retropropagação adaptativa com controlador nebuloso) referente ao dia 29 de julho de 1998.

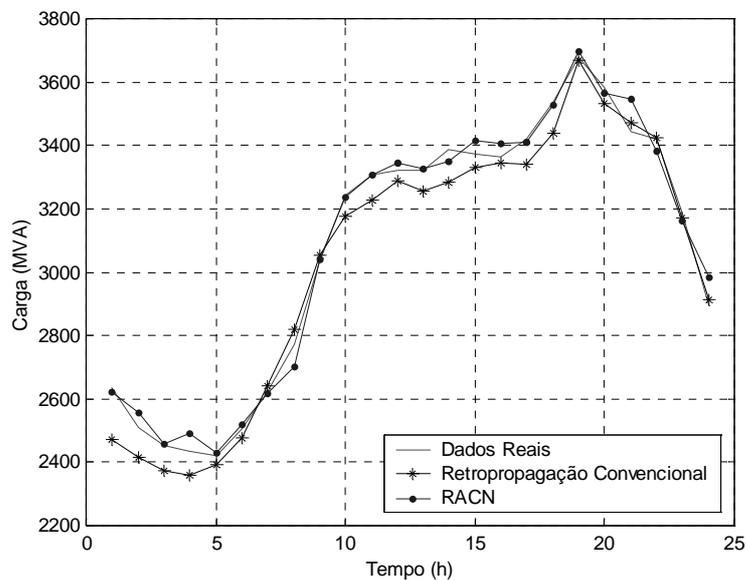


Figura 7.4. Resultados da previsão de carga para Aplicação 1 (RACN).

Os resultados obtidos para a Aplicação 2, referentes ao dia 29 de julho de 1998, estão ilustrados na Figura 7.5.

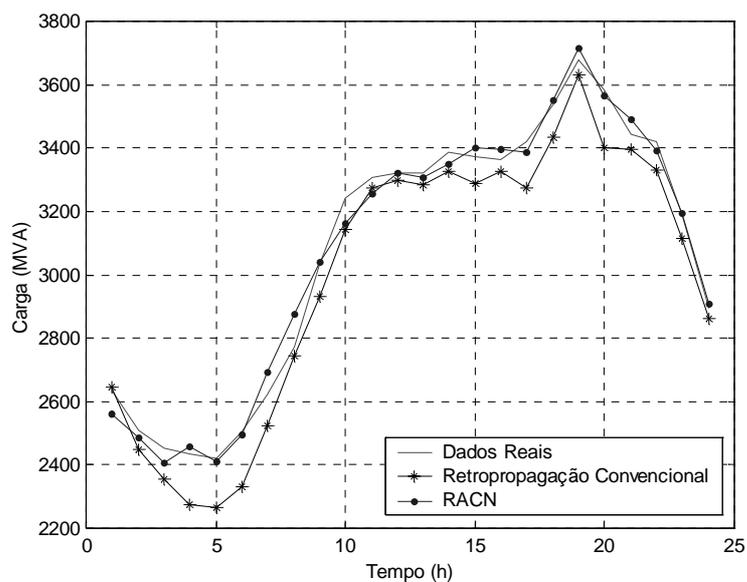


Figura 7.5. Resultados da previsão de carga para Aplicação 2 (RACN).

Para a aplicação 3, previsão de carga elétrica referente ao dia 28 de julho de 1998, os resultados são apresentados na Figura 7.6.

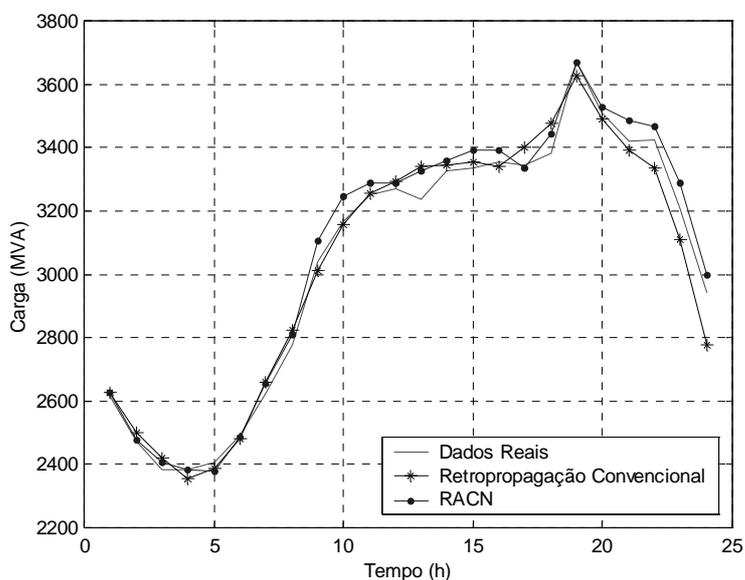


Figura 7.6. Resultados da previsão de carga para Aplicação 3 (RACN).

As Tabelas 7.6, 7.7 e 7.8 mostram os resultados comparativos em termos de ganhos de ciclo e tempo e os erros obtidos com relação ao valor real da carga elétrica.

Tabela 7.6. Resultados comparativos para Aplicação1 (RACN).

Item	RP Convencional	RACN
Número Ciclos	66986	1878
Tempo Processamento(s)	1358,60	33,17
Ganho $GC$	–	35,67
Ganho $GT$	–	40,96
$MAPE$ (%)	1,80	0,97
$Erro$ Máximo (%)	6,20	2,98

Tabela 7.7. Resultados comparativos para Aplicação2 (RACN).

Item	RP Convencional	RACN
Número Ciclos	2866	1094
Tempo Processamento(s)	120,89	46,28
Ganho $GC$	–	2,62
Ganho $GT$	–	2,61
MAPE (%)	2,79	1,12
Erro Máximo (%)	6,92	3,63

Tabela 7.8. Resultados comparativos para Aplicação3 (RACN).

Item	RP Convencional	RACN
Número Ciclos	916502	2107
Tempo Processamento(s)	3548,35	165,23
Ganho $GC$	–	434,98
Ganho $GT$	–	21,48
MAPE (%)	1,42	1,20
Erro Máximo (%)	5,61	2,69

### 7.3. Formulação do Problema de Previsão de Cargas Elétricas usando a Rede Neural ART&ARTMAP Nebulosa

A previsão de carga elétrica, via redes neurais (neste caso, a rede ART&ARTMAP nebulosa), pode ser formulada do seguinte modo, como ilustrada na Figura 7.7, sendo que os padrões de entrada de dados dependem efetivamente dos valores da carga elétrica e das variáveis exógenas (Equações (6.1.1) e (6.1.2)). Após a geração do banco de entrada e saída de dados (dados binários), o processamento da rede neural ART&ARTMAP nebulosa fica restrita ao módulo ARTMAP nebuloso. Os vetores de entrada e de saída do módulo ARTMAP nebuloso são ilustrados da seguinte forma [Lopes et al., 2004]:

$$X(h) = [P^{bin}(h) \ A^{bin}(h)] \quad X \in R^{mb+n} \quad (7.3.1)$$

$$Y(h) = L_n^{bin}(h+1), \quad Y \in R^{cb+ab} \quad (7.3.2)$$

sendo:

$mb$  = dimensão do vetor  $P^{bin}$ ;

$cb$  = dimensão do vetor  $C^{bin}$ ;

$ab$  = dimensão do vetor  $A^{bin}$ .

### 7.3.1. Rede Neural ART&ARTMAP Nebulosa

Nesta seção, serão apresentados os resultados da previsão de carga usando a rede neural ART&ARTMAP nebulosa. Deve-se destacar que o objetivo desta bordagem com redes neurais refere-se à apresentação de uma nova estrutura de rede neural (ART&ARTMAP nebulosa), em que é evidenciado o funcionamento e o seu desempenho, para a resolução do problema de previsão de carga. Os dados referentes ao tempo usados no treinamento neste trabalho são (para cada vetor): dia da semana e hora do dia. Considerando a representação do vetor de entrada que compõe a rede ART&ARTMAP nebulosa tem-se:

- **Vetor de entrada**

$$X(h) \in \mathfrak{R}^{20} \rightarrow P^{bin}(h) \in \mathfrak{R}^{12} \text{ e } A^{bin}(h) \in \mathfrak{R}^8$$

- **Vetor de saída**

$$Y(h) \in \mathfrak{R}^{11}$$

Para testar a eficiência da rede proposta (rede ART&ARTMAP nebulosa), é efetuado um esquema de previsão de cargas elétricas utilizando os mesmos dados que compunham as aplicações 1, 2 e 3 utilizadas anteriormente.

É importante enfatizar que todas as aplicações 1, 2 e 3 foram utilizadas no treinamento e diagnóstico de todas as arquiteturas de redes neurais propostas (rede neural *feedforward* – algoritmo retropropagação com controlador nebuloso, rede neural *feedforward* – algoritmo retropropagação com controlador

nebuloso e adaptação dos parâmetros de inclinação e translação da função de ativação da rede neural e rede neural ART&ARTMAP nebulosa). A Tabela 7.9 apresenta os principais parâmetros utilizados no treinamento e diagnóstico da rede neural desenvolvida.

Tabela 7.9. Especificação da rede neural ART&ARTMAP nebulosa.

Parâmetros	Aplicação		
	1	2	3
Número de vetores padrão	504	1008	2016
Taxa de Treinamento - $\beta$	1,0000	1,0000	1,0000
Parâmetro de escolha - $\alpha$	1,3500	0,0003	0,0170
Parâmetro de Vigilância (ART <sub>a</sub> ) - $\rho_a$	0,9400	0,9300	0,9200
Parâmetro de Vigilância (ART <sub>b</sub> ) - $\rho_b$	0,9900	0,9800	0,9900
Parâmetro de Vigilância (inter-ART) - $\rho_{ab}$	1,0000	1,0000	1,0000

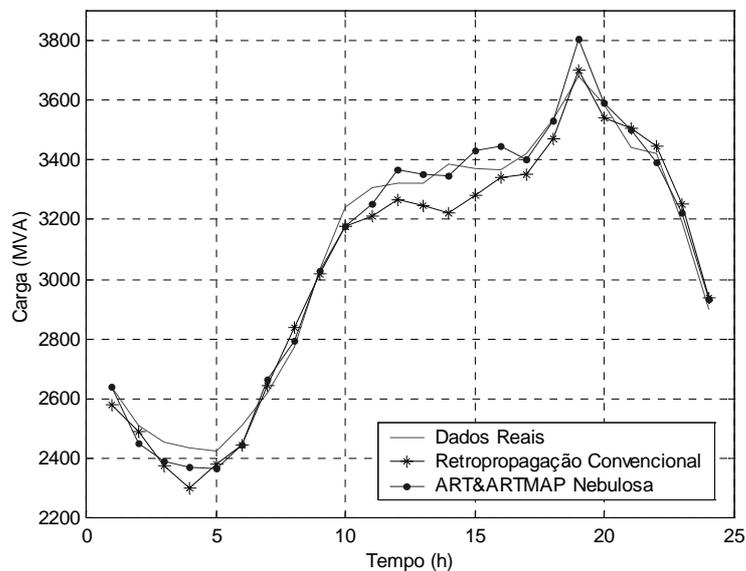


Figura 7.8. Resultados da previsão de carga para Aplicação 1 (ART&ARTMAP Nebulosa).

A Figura 7.8 mostra os resultados da previsão de carga para Aplicação 1 (dados reais, resultados obtidos através do algoritmo retropropagação [Lopes et al, 2003] e os resultados gerados pela rede ART&ARTMAP nebulosa), referentes ao dia 29 de julho de 1998.

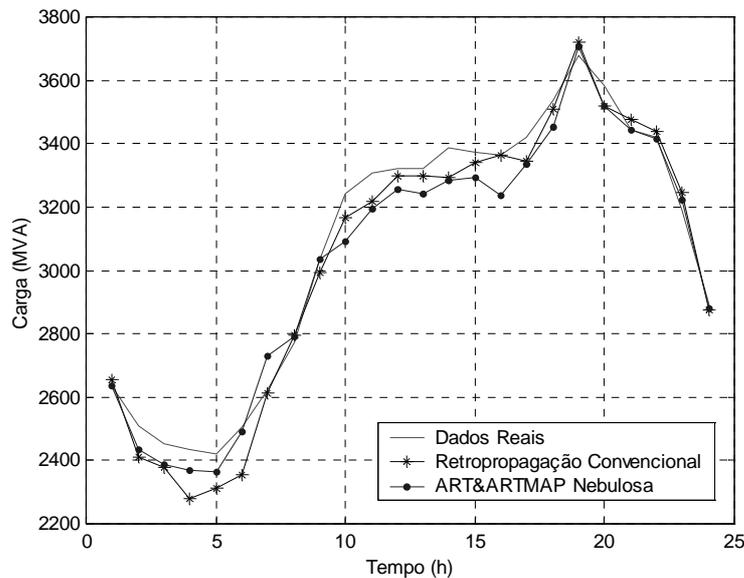


Figura 7.9. Resultados da previsão de carga para Aplicação 2 (ART&ARTMAP Nebulosa).

Na Figura 7.9 são apresentados os resultados da previsão de carga para Aplicação 2 (dados reais, resultados obtidos através do algoritmo retropropagação [Lopes et al, 2003] e os resultados gerados pela rede ART&ARTMAP nebulosa) referentes ao dia 29 de julho de 1998.

Já a Figura 7.10 exprime os resultados obtidos para Aplicação 3 referentes ao dia 28 de julho de 1998.

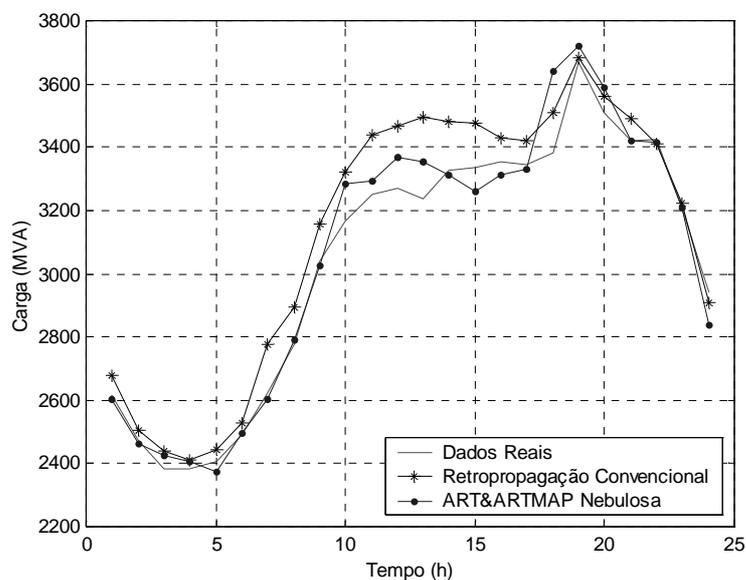


Figura 7.10. Resultados da previsão de carga para Aplicação 3 (ART&ARTMAP Nebulosa).

Tabela 7.10. Resultados comparativos para Aplicação 1 (ART&ARTMAP).

Item	RP Convencional	ART&ARTMAP Nebulosa
Tempo Processamento (s)	443,56	1,71
GT	–	259,39
MAPE (%)	2,03	1,49
Erro Máximo (%)	5,62	3,38

Tabela 7.11. Resultados comparativos para Aplicação 2 (ART&ARTMAP).

Item	RP Convencional	ART&ARTMAP Nebulosa
Tempo Processamento (s)	86,72	8,55
GT	–	10,14
MAPE (%)	1,97	1,80
Erro Máximo (%)	6,36	5,54

Os resultados comparativos de ambos os métodos estão relacionados nas Tabelas 7.10, 7.11 e 7.12.

Tabela 7.12. Resultados comparativos para Aplicação 3 (ART&ARTMAP).

Item	RP Convencional	ART&ARTMAP Nebulosa
Tempo Processamento (s)	120,16	62,68
GT	–	1,92
MAPE (%)	3,01	1,59
Erro Máximo (%)	8,01	7,58

A grande vantagem da rede neural ART&ARTMAP nebulosa se deve ao fato de que independente da tolerância de erro pré-estabelecida ela sempre irá fornecer uma resposta, que neste caso, será o valor de carga estimado.

O mesmo não ocorre com a rede neural que utiliza o algoritmo retropropagação. À medida que diminuimos a tolerância de erro, o processo de convergência da rede se torna lento ou pode ocorrer até o fato de não haver convergência, ou seja, a rede neural não irá fornecer nenhum resultado de previsão de carga.

Através da Tabela 7.13 podemos fazer uma análise criteriosa do desempenho da rede neural ART&ARTMAP nebulosa comparada às demais arquiteturas aqui apresentadas. Foram implementadas as seguintes arquiteturas:

1. Algoritmo RP convencional com momento (M);
2. Algoritmo RP convencional sem momento (SM);
3. Algoritmo RP com momento e controlador nebuloso;
4. Algoritmo RP sem momento adaptativo com controlador nebuloso;
5. ART&ARTMAP nebuloso.

Analisando os resultados, observa-se que para as Aplicações 1 e 2 e 3, a rede neural ART&ARTMAP nebulosa forneceu um resultado de previsão de carga que se manteve dentro de uma tolerância de erro, que pela literatura, é concebível. Porém, observa-se que o tempo de processamento (TP) gerado pela rede neural ART&ARTMAP nebulosa é menor que as das demais arquiteturas.

Com isso conclui-se, que a arquitetura proposta (rede neural ART&ARTMAP nebulosa) oferece resultados satisfatórios com um tempo de processamento menor que o tempo de processamento gerado pelas demais arquiteturas.

Tabela 7.13. Comparação entre os resultados obtidos das diferentes arquiteturas de redes neurais artificiais utilizadas no problema de previsão de cargas elétricas.

Aplicações	Rede Neural	Mape	Máximo	TP (s)
1	RP Convencional (M)	2,03	5,62	443,56
	RP Convencional (SM)	1,80	6,20	1358,60
	RP Nebuloso	1,35	3,31	322,35
	RACN	0,97	2,98	33,17
	ART&ARTMAP Nebulosa	1,49	3,38	1,71
2	RP Convencional (M)	1,97	6,36	86,72
	RP Convencional (SM)	2,79	6,92	120,89
	RP Nebuloso	0,91	2,71	69,26
	RACN	1,12	3,63	46,28
	ART&ARTMAP Nebulosa	1,80	5,54	8,55
3	RP Convencional M)	3,01	8,01	120,16
	RP Convencional (SM)	1,42	5,61	3548,35
	RP Nebuloso	1,03	3,45	118,30
	RACN	1,20	2,69	165,26
	ART&ARTMAP Nebulosa	1,59	7,58	62,68

#### 7.4. Comentários

Neste capítulo foi apresentada a aplicação das três arquiteturas de redes neurais no problema de previsão de cargas elétricas (rede neural *feedforward* com algoritmo retropropagação com controlador nebuloso, rede neural *feedforward* com algoritmo retropropagação com controlador nebuloso e adaptação dos parâmetros de inclinação e translação da função sigmóide através do método do gradiente descendente e a rede neural ART&ARTMAP nebulosa). Todos os resultados obtidos pelas três redes neurais são mostrados neste capítulo e através deles observa-se a eficiência da rede neural ART&ARTMAP nebulosa. Conclui-se, através destes experimentos, que a rede neural proposta apresenta um desempenho superior em relação às principais arquiteturas disponíveis na literatura especializada, em especial ao algoritmo retropropagação o qual é considerado um *benchmark* universal. O desempenho superior refere-se à obtenção de soluções (previsão de carga) com um ganho de tempo total cerca de 16 unidades (16 vezes mais rápido) ou superior (chegando a 322 vezes mais rápido) com uma melhor precisão. Outra vantagem que deve ser destacada corresponde a possibilidade de realizar o treinamento de forma continuada.

# Capítulo 8

## Conclusões e Sugestões para Trabalhos Futuros

### 8.1. Conclusões

Este trabalho teve por objetivo o desenvolvimento de uma metodologia para previsão de cargas elétricas, através de uma nova arquitetura de rede neural baseada na teoria da ressonância adaptativa (rede neural ART&ARTMAP nebulosa). Foram realizados vários testes para previsão de cargas elétricas considerando-se uma base de dados históricos de uma companhia do setor elétrico brasileiro.

Também foi implementada a rede *feedforward* com algoritmo retropropagação com controlador nebuloso [Lopes, 2000] e a rede neural *feedforward* com algoritmo retropropagação com controlador nebuloso e adaptação dos parâmetros de inclinação e translação da função sigmóide [Lopes et al., 2003] para a resolução do problema de previsão de cargas elétricas. Todas as arquiteturas de redes neurais foram implementadas na tentativa de aperfeiçoar o algoritmo retropropagação convencional no sentido da precisão e agilidade no processo de convergência.

Quando se usou o algoritmo retropropagação com controlador nebuloso pôde-se verificar que a formulação abordada reduz o número de ciclos

de treinamento, bem como o tempo de processamento, se comparado com o algoritmo retropropagação convencional. Pode-se observar que com o aumento do número de vetores de entrada, a rede neural nebulosa tende a apresentar ganhos maiores. Deve-se ressaltar que a metodologia abordada proporcionou, em todas as simulações realizadas, previsões mais precisas quando comparada ao algoritmo retropropagação convencional. Isto, certamente, constitui-se num importante recurso para a resolução de problemas de previsão de carga mais complexos, como por exemplo, para a previsão de cargas elétricas multinodais, em que são considerados um número maior de variáveis e de informações.

Contudo, notou-se que o controlador nebuloso melhorava os resultados, porém, não apresenta uma melhoria expressiva em termos de processamento. A idéia foi então implementar um processo adaptativo nos parâmetros que compõem a função de ativação da rede neural, que neste caso é a função sigmóide [Stamatis et al., 1999]. Logo, a cada iteração os parâmetros de inclinação e translação da função sigmóide são adaptados através do método do gradiente descendente.

Através de testes realizados utilizando os dados de entrada para a aplicação 1, pode-se verificar que a implementação do processo adaptativo na função de ativação, fez com que a rede neural se tornasse mais rápida e precisa, quando comparada ao algoritmo retropropagação convencional e ao algoritmo retropropagação com controlador nebuloso. É importante enfatizar que o algoritmo retropropagação convencional, usado como agente de comparação para análise da rede neural adaptativa, foi processado sem o termo de momento. A rede neural adaptativa conseguiu obter um ganho de tempo de processamento de 35,16% com relação ao método convencional, ou seja, ela conseguiu reduzir o tempo de processamento. Todavia, ainda observou-se que para resultados de aplicações que precisam de respostas *on-line*, ainda havia a necessidade de melhorar o tempo de processamento da rede.

Logo, surgiu a idéia de utilizar as redes neurais baseadas na teoria da ressonância adaptativa. Estas redes possuem a característica da estabilidade e da

plasticidade. Para tanto, foi desenvolvida uma arquitetura neural híbrida (ART&ARTMAP) com capacidade de realizar a previsão de carga de forma rápida e precisa (equiparável às outras redes neurais artificiais disponíveis na literatura especializada).

Trata-se de uma nova abordagem, que visa proporcionar resultados com precisão similar às demais redes neurais e métodos disponíveis na literatura especializada, com menor tempo de processamento e menor restrição quanto ao número de variáveis associadas ao problema sob análise e quanto ao tamanho da base de dados a ser usada.

Foi desenvolvido, por conseguinte, um procedimento de previsão de cargas elétricas, a curto-prazo, executado considerando 24 horas à frente, através de uma rede neural ART&ARTMAP nebulosa. Esta é uma rede em que grande parte do processamento se baseia em dados binários.

Pode-se observar que, em termos de tempo de processamento, a rede ART&ARTMAP nebulosa se sobressai à rede retropropagação em ambas aplicações 1 e 2, destacando a característica abordada nesta arquitetura de rede que é a velocidade, obtendo, assim, respostas em tempo real, que é o caso da previsão de cargas elétricas. Também, nota-se que, observando o erro percentual médio absoluto (*MAPE*) e o erro máximo, a rede ART&ARTMAP nebulosa efetuou previsões mais precisas que a rede retropropagação convencional.

Este trabalho trouxe como contribuições o estudo de duas arquiteturas de redes neurais (algoritmo RP com controlador nebuloso e algoritmo RP com controlador nebuloso e adaptação dos parâmetros da função sigmóide) utilizadas na previsão de cargas elétricas e também trouxe o desenvolvimento de uma nova arquitetura de rede neural (ART&ARTMAP nebulosa), desenvolvida especialmente para a aplicação na previsão de carga, que é uma inovação dentre as arquiteturas ART existentes na literatura. Concluindo, a formulação da rede neural ART&ARTMAP nebulosa apresentada nesta pesquisa fornece as seguintes vantagens:

- Redução no tempo de processamento;
- Preserva as características de plasticidade e de estabilidade;
- Aplicação em sistemas de grande porte;
- Implementação em sistemas contínuos;
- Qualidade dos resultados.

## 8.2. Sugestões para Trabalhos Futuros

Os resultados desta pesquisa podem ser considerados satisfatórios (do ponto de vista da precisão e rapidez na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar esta metodologia ainda mais eficiente:

1. estudo e implementação de novas melhorias no algoritmo, podendo aglutinar outras metodologias visando uma melhor representação e manipulação das informações no módulo do código ativo da rede neural ART e cálculo das funções de escolha (para melhor inferir a semelhança dos padrões);
2. desenvolvimento de técnica de treinamento de redes, baseada em redes neurais modulares (compostas por várias sub-redes neurais que desempenham funções específicas / mais especializadas) para a previsão de cargas elétricas realizada por barramento que é um problema relevante em abordagens em sistemas de distribuição de energia elétrica, especialmente em ambientes desregulamentados. Estes ambientes competitivos têm estimulado grandes investimentos em pesquisa e aplicação de novas tecnologias em controle e automação;
3. aplicação da rede neural ART&ARTMAP modular para a previsão de carga multinodal, ou seja, por exemplo, na área de distribuição de energia elétrica,

buscando a distinção da previsão por barra, conjuntos de barras, subestações, etc. e de consumidores (residencial, comercial e industrial). Trata-se, portanto, de uma abordagem que deixa de prever apenas a demanda de forma global, que é um procedimento comumente adotado na literatura, para a previsão em vários pontos da rede elétrica;

4. desenvolver estratégias de implementação do treinamento continuado. Este é um assunto que vem sendo, cada vez mais objeto de investigação, visto que a maioria das redes neurais tem apresentado dificuldades no tratamento desta questão. A solução mais elementar consiste em retreinar a rede neural quando devem ser considerados novos padrões, ou seja, inicia-se novamente o processo de treinamento. Esta é uma das vantagens do uso das redes neurais ART descendentes;
5. investigar a aplicação da arquitetura ART&ARTMAP nebulosa para a resolução de outras modalidades de previsão, por exemplo, a previsão a longo prazo e a previsão de carga espacial que se constitui na inferência sobre a demanda de energia dos consumidores distribuída por área territorial.

# Capítulo 9

## Referências Bibliográficas

- AGGARWAL, R. and SONG, Y. "Artificial neural networks in power systems," Power Engineering Journal, Vol. 11, No. 3, pp. 129-134, 1997.
- AL-KANDARI, A. M.; SOLIMAN, S. A. and EL-HAWARY, M. E. "Fuzzy short-term electric load forecasting," Electric Power & Energy Systems, Vol. 26, No. 2, pp. 111-122, 2004.
- ALMEIDA, C.; FISHWICH, P. A. and TANG, Z. "Time series forecasting using neural network vs. Box-Jenkins methodology," Simulation Councils, Inc., pp. 303-310, 1991.
- ARABSHAHI, P.; CHOI, J. J.; MARKS II, R. J. and CAUDELL, T. P. "Fuzzy parameter adaptation in optimization: Some neural net training examples," IEEE Computational Science & Engineering, Vol. 3, No. 1, pp. 57-65, 1996.
- AZIZ, S. A. and PARTHIBAN, J. "Fuzzy logic introduction," Fuzzy Logic and Its Uses, 1996.
- BACZYNSKI, D. and PAROL, M. "Influence of artificial neural network structure on quality of short-term electric energy consumption forecast," IEE Proceedings Generation Transmission Distribution, Vol. 151, No. 2, pp. 241-245, 2004.
- BAUER, P.; NOUAK, S. and WINKLER, R. "A brief course in fuzzy logic and fuzzy control," 1996.

- BEZDEK, J. C. "Fuzzy Models – What are they, and why?," IEEE Transactions on Fuzzy Systems, Vol. 1, pp. 1-6, 1993.
- BOX, G. E. and JENKINS, G. M. "Time series analysis: Forecasting and control," Holden-Day, San Francisco, 1976.
- BUNN, D. W. and FARMER, E. D. "Comparative models for electrical load forecasting," Wiley, Belfast, 1985.
- CARPENTER, G. A. and GROSSBERG, S. "A massively parallel architecture for a self-organizing neural pattern recognition machine," Computer Vision, Graphics, and Image Processing, Vol. 37, pp. 54-115, 1987.
- CARPENTER, G. A. and GROSSBERG, S. "ART2: Stable self-organization of pattern recognition codes for analog input patterns," Applied Optics, Vol. 26, pp. 4919-4930, 1987.
- CARPENTER, G. A.; GROSSBERG, S. and REYNOLDS, J. H. "ARTMAP: Supervised real-learning and classification of non-stationary data by a self-organizing neural network," Neural Network, Vol. 4, No. 5, pp. 565-588, 1991a.
- CARPENTER, G. A.; GROSSBERG, S. and ROSEN D. B. " Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system," Neural Network, Vol. 4, No. 1, pp. 759-771, 1991b.
- CARPENTER, G. A. and GROSSBERG, S. "A self-organizing neural network for supervised learning, recognition and prediction," IEEE Communications Magazine, Vol. 30, No. 9, pp. 38-49, 1992.
- CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H. and ROSEN, D. B. "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps," IEEE Transactions on Neural Networks, Vol. 3, No. 5, pp. 698-713, 1992.
- CARPENTER, G. A. and ROSS, W. D. "ART-EMAP: A neural network architecture for object recognition by evidence accumulation," IEEE Transactions on Neural Networks, Vol. 6, No. 4, pp. 805-818, 1995.

- CARPENTER, G. A. and GROSSBERG, S. "Adaptive resonance theory," M. A. Arbib (Ed.), *The Handbook of Brain Theory and Neural Networks*, Second Edition (MA: MIT Press, Cambridge), pp. 87-90, 2003.
- CHANDRASHEKARA, A. S.; ANANTHAPADMANABHA, T. and KULKARNI, A. D. "A neuro-expert system for planning and load forecasting of distribution system," *International Journal of Electrical Power & Energy Systems*, Vol. 21, No. 5, pp. 309-314, 1999.
- CHEN, C. S.; TZENG, Y. M. and HWANG, J. C. "The application of artificial neural networks to substation load forecasting," *Electric Power Systems Research*, Vol. 38, No. 2, pp. 153-160, 1996.
- CHUI, C.-C.; COOK, D. F.; KAO, J.-L. and CHOU, Y.-C. "Combining a neural network and a rule-based expert system for short-term load forecasting," *Computers & Industrial Engineering*, Vol. 32, No. 4, pp. 787-797, 1997.
- CRISTOFARO, M.; FROSINI, L. and ANGLANI, N. "Free electricity market: How industrial customers and ESCOs can make the most from load forecasting techniques," *Proceedings of the 2003 IEEE International Workshop on Soft Computing in Industrial Applications*, New York, pp. 13-18, 2003.
- DJUKANOVIC, M.; RUZIC, S.; BABIC, B.; SOBAJIC, D. J. and PAO, Y.-H. "A neural-net based short term load forecasting using moving window procedure," *Electrical Power & Energy Systems*, Vol. 17, No. 6, pp. 391-397, 1995.
- FERREIRA, W. P. "Análise dinâmica de contingências de sistemas de energia elétrica por redes neurais baseadas na teoria da ressonância adaptativa," Tese de Doutorado, Programa de Pós-graduação em Engenharia Elétrica, UNESP - Ilha Solteira - SP, 2003.
- FINE, T. L. "Feedforward neural network methodology," Springer-Verlag, USA, 1999.

- FUKUSHIMA, K.; MIYAKE, S. and ITO, T. "Neocognitron: Self-organizing network capable of position-invariant recognition of patterns," in Proceedings of 5<sup>th</sup> International Conference Pattern Recognition, Vol. 1, pp. 459-461, 1980.
- GEORGIOPOULOS, M.; FERNLUND, H.; BEBIS, G. and HEILEMAN, G. L. "Order of search in fuzzy ART and fuzzy ARTMAP: Effect of the choice parameter," Neural Networks, Vol. 9, No. 9, pp. 1541-1559, 1996.
- GOPAL, S.; WOODCOCK, C. E. and STRAHLER, A. H. "Fuzzy neural network classification of global land cover from a 1-degree AVHRR data set," Remote Sensing of Environment, Vol. 67, No. 2, pp. 230-243, 1999.
- GRANGER, E.; BLAQUIÈRE, Y.; SAVARIA, Y.; CANTIN, M.-A. and LAVOIE, P. "A VLSI architecture for fast clustering with fuzzy ART neural networks," International Journal of Microelectronics System Integration, Vol. 5, No. 1, pp. 3-18, 1997.
- GROSS, G. and GALIANA, F. D. "Short term load forecasting," Proceedings of the IEEE, Vol. 75, No. 12, pp. 1558-1573, 1987.
- 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.
- HEALY, M. J.; CAUDELL, T. P. and SMITH, S. D. G. "A neural-network architecture for pattern sequence verification through interferencing," IEEE Transactions on Neural Networks, Vol. 4, No. 1, pp. 9-20, 1993.
- HEBB, D. O. "The organization of behaviour," Wiley, New York, 1949.

- HECHT-NIELSEN, R. "Counterpropagation networks," Proceedings of IEEE International Conference on Neural Networks, IEEE Press, New York, pp. 19-32, 1987.
- HIPPERT, H. S.; PEDREIRA, C. E. and SOUZA, R. C. "Neural networks for short-term load forecasting: Are view and evaluation," IEEE Transactions on Power Systems, Vol. 16, No. 1, pp. 44-55, 2001.
- HOPFIELD, J. J. "Neural networks and physical systems with emergent collective computational abilities," Proceedings of the National Academy of Sciences, Vol. 79, pp. 2554-2558, 1982.
- JERVIS, B. W.; DJEBALI, S. and SMAGLO, L. "Integrated probabilistic simplified fuzzy ARTMAP," IEE Proceedings Science, Measurement and Technology, Vol. 151, No. 3, pp. 218-228, 2004.
- KANDEL, A. "Fuzzy control systems," CRC Press, 1993.
- KARTALOPOULOS, S. V. "Understanding neural networks and fuzzy logic: Basic concepts and applications," IEEE Press, Piscataway, NJ, USA, 1996.
- KERMANSHAHI, B. and IWAMIYA, H. "Up to year 2020 load forecasting using neural nets," International Journal of Electrical Power & Energy Systems, Vol. 24, No. 9, pp. 789-797, 2002.
- KEYVAN, S.; SONG, X. and KELLY, M. "Nuclear fuel pellet inspection using artificial neural networks," Journal of Nuclear Materials, Vol. 264, No. 1-2, pp. 141-154, 1999.
- KIM, M.; JANG, D. and YANG, Y. "A robust-invariant pattern recognition model using fuzz ART," Pattern Recognition, Vol. 34, No. 8, pp. 1685-1696, 2001.
- KOHONEN, T. "Correlation matrix memories," IEEE Transactions on Computers, Vol. 21, pp. 353-359, 1972.
- KOSKO, B. "Adaptive Bidirectional associative memory," Applied Optics, Vol. 26, No. 23, pp. 4947-4960, 1987.

- KROSE, B. and SMAGT, P. V. "An introduction to neural networks," Online Book, University of Amsterdam, Eighth Edition, 1996.
- LIAO, G.-C. and TSAO, T.-P. "Application of fuzzy neural networks and artificial intelligence for load forecasting," *Electric Power Systems Research*, Vol. 70, No. 3, pp. 237-244, 2004.
- LIM, C. P. and HARRISON, R. F. "Modified fuzzy ARTMAP approaches bayes optimal classification rates: An empirical demonstration," *Neural Networks*, Vol. 10, No. 4, pp. 755-774, 1997.
- LIU, T.-C. and LI, R.-K. "A new ART-counterpropagation neural network for solving a forecasting problem," *Expert Systems with Applications*, Article in Press (Available Online), pp. 1-7, 2004.
- LIU, W.; SETO, K. C.; WU, E. Y.; GOPAL, S. and WOODCOCK, C. E. "ART-MMAP: A neural network approach to subpixel classification," *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 42, No. 9, pp. 1976-1983, 2004.
- LIU, k.; SUBBARAYAN, S.; SHOULTS, R. R.; MANRY, M. T.; KWAN, C.; LEWIS, F. L. and NACCARINO, J. "Comparison of very short-term load forecasting techniques," *IEEE Transactions on Power Systems*, Vol. 11, No. 2, pp. 877-882, 1996.
- LOPES, M. L. M. "Desenvolvimento de um sistema previsor de cargas elétricas via redes neurais," *Dissertação de Mestrado, Programa de Pós-graduação em Engenharia Elétrica - Faculdade de Engenharia de Ilha Solteira - UNESP*, 2000.
- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "A fast electric load forecasting using adaptive neural networks," *Proceedings of the 2003 IEEE Bologna Power-Tech, Italy*, Vol. 1, pp. 23-26, 2003.

- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "A fast electric load forecasting using neural networks," 43<sup>rd</sup> MIDWEST Symposium on Circuits and Systems, Lansing - Michigan, USA, Vol. 2, pp. 646-649, 2000.
- LOPES, M. L. M. and MINUSSI, C. R. "Treinamento de redes neurais via back-propagation com controlador nebuloso," XIII Congresso Brasileiro de Automática, Florianópolis - SC, pp. 1616-1621, 2000.
- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "Electrical load forecasting formulation by a fast neural network," Engineering Intelligent Systems for Electrical Engineering and Communications, Vol. 11, No. 1, pp. 51-57, 2003.
- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "Electric load forecasting using a fuzzy ART&ARTMAP neural network," Journal of Applied Soft Computing, Vol. 5, No. 2, pp. 235-244, 2005.
- LUBKIN, J. and CAUWENBERGHS, G. "VLSI implementation of fuzzy adaptive resonance and learning vector quantization," Analog Integrated Circuits na Signal Processing, Vol. 30, No. 2, pp. 149-157, 2002.
- MACHADO, R. J. and ROCHA, A. F. "Handling knowledge in high order neural networks: The combinatorial neural network," Rio Scientific Center, IBM Technical Report CCR076, Rio de Janeiro, 1989.
- MCCULLOCH, W. and PITTS, W. A. "A logical calculus of the ideas imminent in nervous activity," Bull Math Biophys, Vol. 5, pp. 115-133, 1943.
- MCDONALD, J. D. "Electric power substations engineering," Boca Raton, CRC Press, 2003.
- MENDES FILHO, E. F. and CARVALHO, A. C. P. L. "Evolutionary design of MLP neural network architectures," IV SBRN - Simpósio Brasileiro de Redes Neurais, Campos do Jordão - São Paulo, pp. 58-65, 1997.
- METAXIOTIS, K.; KAGIANNAS, A.; ASKOUNIS, D. and PSARRAS, J. "Artificial intelligence in short term electric load forecasting: A state-of-the-art survey

- for the researcher,” *Energy Conversion and Management*, Vol. 44, No. 9, pp. 1525-1534, 2003.
- MINSKY, M. and PAPER, S. “Perceptrons: An introduction to Computational Geometry,” Cambridge, MIT Press, 1969.
- MINUSSI, C. R. and SILVEIRA, M. C. G. “Electric power systems transient stability by neural networks,” 38<sup>th</sup> Midwest Symposium On Circuits And Systems, Rio de Janeiro - RJ, Vol. 2, pp. 1305-1308, 1995.
- MOGHRAM, I. and RAHMAN, S. “Analysis and evaluation of five short-term load forecasting techniques,” *IEEE Transactions on Power Systems*, Vol. 4, No. 4, pp. 1484-1491, 1989.
- MURTO, P. “Neural network models for short-term load forecasting,” Masters Thesis, Department of Engineering Physics and Mathematics, Helsinki University of Technology, 1998.
- O’DONOVAN, T. M. “Short Term Forecasting: An introduction to the Box-Jenkins approach,” John Wiley & Sons, New York, 1983.
- PARK, D. C.; EL-SHARKAWI, M. A. and MARK II, R. J. “Electric load forecasting an artificial neural network,” *IEEE Transactions on Power Systems*, Vol. 6, No. 2, pp. 442-449, 1991.
- PENG, T. M.; HUBELE, N. F. and KARADY, G. G. “Conceptual approach to the application of neural network for short-term load forecasting,” *IEEE International Symposium on Circuits and Systems*, Vol. 4, pp. 2942-2945, 1990.
- RAVEENDRAN, P.; PALANIAPPAN, R. and OMATU, S. “Fuzzy ARTMAP classification of invariant features derived using angle of rotation from a neural network,” *Information Sciences*, Vol. 130, No. 1-4, pp. 67-84, 2000.
- ROSENBLATT, F. “Principles of neurodynamics,” 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.; HINTON, G. E. and WILLIAMS, R. J. "Learning representations by Back-propagation errors," *Nature*, No. 323, pp. 533-536, 1986.
- SENJYU, T.; TAKARA, H.; UEZATO, K. and FUNABASHI, T. "One-hour-ahead load forecasting using neural network," *IEEE Transactions on Power Systems*, Vol. 17, No. 1, pp. 113-118, 2002.
- SENJYU, T.; MANDAL, P.; UEZATO, K. and FUNABASHI, T. "Next day load curve forecasting using recurrent neural network structure," *IEE Proceedings Generation, Transmission, and Distribution*, Vol. 151, No. 3, pp. 388-394, 2004.
- SENJYU, T.; MANDAL, P.; UEZATO, K. and FUNABASHI, T. "Next day load curve forecasting using hybrid correction method," *IEEE Transactions on Power Systems (Accepted for future publication)*, Vol. PP, No. 99, pp. 1-8, 2004.
- SFETSOS, A. "Short-term load forecasting with a hybrid clustering algorithm," *IEE Proceedings Generation, Transmission, and Distribution*, Vol. 150, No. 3, pp. 257-262, 2003.
- SIMPSON, P. K. "Artificial neural systems: Foundations, paradigms, applications, and implementations," New York, Pergamon Press, 1989.
- SKARMAN, S. E.; GEORGIPOULOS, M. and GONZALEZ, A. J. "Short-term electrical load forecasting using a fuzzy ARTMAP neural network," *Proceedings of the International Society for Optical Engineering (SPIE)*, Vol. 3390, pp. 181-191, 1998.
- SRINIVASAN, D.; TAN, S. S.; CHANG, C. S. and 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, 1998.
- STAMATIS, N.; PARTHIMOS, D. and GRIFFITH, T. M. “Forecasting chaotic cardiovascular times series with an adaptive slope multilayer perceptron neural network,” IEEE Transactions on Biomedical Engineering, Vol. 46, No. 12, pp. 1441-1453, 1999.
- STERGIOU, C. “Neural networks, the human brain and learning,” SURPRISE 96 Reporters – Neural Networks and Their Uses, Vol. 2, 1996.
- STORB, B. H. and WAZLAWICK, R. S. “Algumas ‘pinceladas’ sobre redes neurais artificiais,” Departamento de Informática e Estatística - Universidade Federal de Santa Catarina - UFSC, 1999.
- SWARUP, K. S. and SATISH, B. “Integrated ANN approach to forecast load,” IEEE Computer Applications in Power, Vol. 15, No. 1, pp. 46-51, 2002.
- TERANO, T.; ASAI, K. and SUGENO, M. “Fuzzy systems theory and its applications,” Academic Press, 1991.
- VEHVILÄINEN, I. and KEPPO, J. “Managing electricity market price risk,” European Journal of Operational Research, Vol. 145, No. 1, pp. 136-147, 2003.
- VILLALBA, S. A. and BEL, C. A. “Hybrid demand model for load estimation and short term load forecasting in distribution electric systems,” IEEE Transactions on Power Delivery, Vol. 15, No. 2, pp. 764-769, 2000.
- VON NEUMANN, J. “The computer and the brain,” Yale University Press, New Haven, 1958.
- WANG, X.; HATZIARGYRIOU, N. and TSOUKALAS, L. H. “A new methodology for nodal load forecasting in deregulated power systems,” IEEE Power Engineering Review, Vol. 22, No. 5, pp. 48-51, 2002.
- WARD SYSTEMS GROUP, Inc. “Neural network architectures (Neuro Shell 2),” 2000.

- WASSERMAN, P. D. "Neural computing - theory and practice," Van Nostrand Reinhold, 1989.
- WEENINK, D. "Category ART: A variation on adaptive resonance theory neural networks," Institute of Phonetic Sciences – University of Amsterdam, IFA Proceedings 21, pp. 117-129, 1997.
- WERBOS, P. J. "Beyond regression: New tools for prediction and analysis in the behavioral sciences," Master Thesis, Harvard University, 1974.
- WIDROW, B. and HOFF, M. E. "Adaptive switching circuits," In Western Electronic Show and Convention – Convention Record, Vol. 4, pp. 96-104, Institute of Radio Engineers, New York, 1960.
- WIDROW, B. and LEHR, M. A. "30 years of adaptive neural networks: perceptron, madaline, and backpropagation," Proceedings of the IEEE, Vol. 78, No. 9, pp. 1415-1442, 1990.
- WILLIAMSON, J. R. "Gaussian ARTMAP: A neural network for fast incremental learning of noisy multidimensional maps," Neural Networks, Vol. 9, No. 5, pp. 881-897, 1996.
- YALCINOZ, T. and EMINOGLU, U. "Short term and medium term power distribution load forecasting by neural networks," Energy Conversion and Management, Article in Press (Available Online), pp. 1-13, 2004.
- ZADEH, L. "Fuzzy sets," Information and Control, Vol. 8, pp. 338-353, 1965.

# Apêndice A - Lógica Nebulosa

*Este apêndice apresenta os principais conceitos sobre lógica nebulosa, com o intuito de um melhor entendimento do mecanismo de adaptação de pesos realizado pelo algoritmo de retropropagação na previsão de cargas elétricas. Serão apresentadas algumas definições, dentre elas: conjuntos nebulosos, funções de pertinência, conceito fundamental da lógica nebulosa e controle nebuloso, no qual engloba basicamente três fases: nebulização, inferência e desnebulização, completando assim a chamada ação de controle.*

## A.1. Lógica Nebulosa

A lógica nebulosa foi estruturada, em 1965, por Lofti A. Zadeh da Universidade da Califórnia para tratar e representar incertezas. Ela torna-se importante pelo fato de que o mundo não é constituído por fatos absolutamente verdadeiros ou falsos e permite representar valores de pertinência (grau de verdade) intermediários entre os valores verdadeiros e falsos da lógica clássica. A lógica clássica é aplicada às informações consideradas completamente verdadeiras, cujo valor de verdade é igual a 1, ou informações completamente falsas, cujo valor de verdade é igual a 0. Já a lógica nebulosa tem a vantagem de poder ser aplicada às informações que não são completamente verdadeiras ou

falsas, podendo variar entre 0 e 1. A lógica nebulosa é, basicamente, uma lógica de multivalores que permite que valores intermediários sejam definidos entre avaliações convencionais como *sim/não*, *verdadeiro/falso*, são as chamadas variáveis lingüísticas, objetos ou palavras lingüísticas, que possuem uma representação melhor que os números. As variáveis nebulosas são adjetivos que modificam a variável, de tal forma que noções como *bastante morno* ou *bastante frio* sejam formuladas matematicamente e processadas por computador [Bauer, 1996].

### A.1.1. Conjuntos Nebulosos

Um conjunto nebuloso  $A$  em  $X$ , coleção de objetos, é definido como sendo o conjunto de pares ordenados:

$$A = \{(x, \mu_A(x)) \mid x \in X\} \quad (\text{A.1.1.1})$$

sendo:

$\mu_A(x)$  = valor função de pertinência do conjunto nebuloso  $A$  correspondente ao elemento  $x$ .

### A.1.2. Funções de Pertinência

A função de pertinência é uma representação gráfica da magnitude de participação de cada entrada. Ela associa um peso a cada entrada processada, definindo uma superposição funcional entre as entradas e, finalmente, determinando uma resposta de saída. As regras utilizam os valores de pertinência da entrada como fator peso para determinar sua influência na conclusão final de saída. Uma vez as funções concluídas, pesadas e combinadas, elas são desnebulizadas em uma saída real (*crisp*) que conduz o sistema.

As funções de pertinência nebulosas podem ter diferentes formas associadas com cada entrada e resposta de saída. A função de pertinência triangular é a mais comum, mas as demais funções de pertinência (trapezoidal,

gaussiana e exponencial) podem ser usadas de acordo com a preferência ou experiência do projetista.

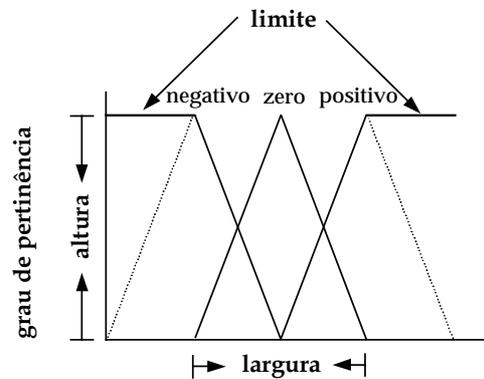


Figura A.1. Funções de pertinência.

A Figura A.1 mostra as características da função de pertinência, na qual a altura ou magnitude é normalizada entre os valores 0 e 1.

O grau de pertinência é determinado pela projeção vertical do parâmetro de entrada do eixo horizontal no limite mais alto da função de pertinência, o qual tem valores compreendidos entre 0 e 1 [Bezdek, 1993].

### A.1.3. Operadores Lógicos

Supondo-se que A e B são dois conjuntos nebulosos com funções de pertinência designadas, respectivamente, por  $\mu_A(x)$  e  $\mu_B(x)$  (definidas pela Figura A.2), pode-se introduzir os operadores básicos mais importantes dos conjuntos nebulosos definidos por Zadeh da seguinte maneira [Arabshahi, 1996; Aziz & Parthiban, 1996; Bauer, 1996; Kartalopoulos, 1996; Terano et al., 1991; Zadeh, 1965]:

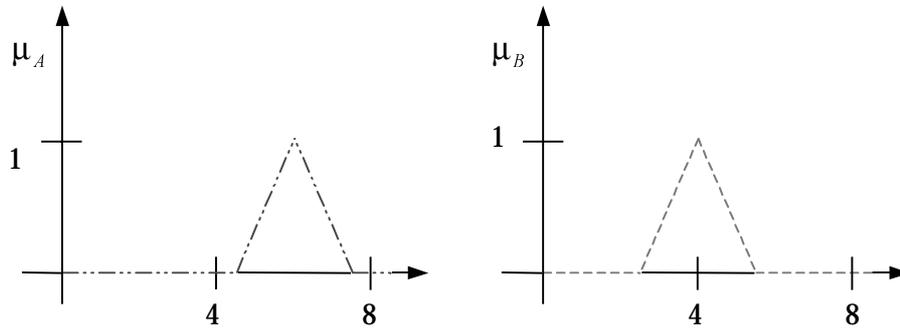


Figura A.2. Conjuntos nebulosos.

**Operador AND ou interseção de dois conjuntos:** A função de pertinência da interseção destes dois conjuntos nebulosos ( $C = A \cap B$ ) é definida por:

$$\mu_C(x) = \min\{\mu_A(x), \mu_B(x)\}, x \in X \quad (\text{A.1.3.1})$$

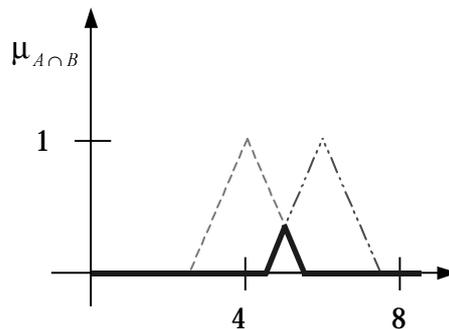


Figura A.3. Operador AND.

Na Figura A.3, a linha cheia define a interseção dos dois conjuntos nebulosos A e B [Bauer, 1996].

**Operador OR ou união entre dois conjuntos:** A função de pertinência da união destes conjuntos nebulosos ( $D = A \cup B$ ) é definida por:

$$\mu_D(x) = \max\{\mu_A(x), \mu_B(x)\}, x \in X \quad (\text{A.1.3.2})$$

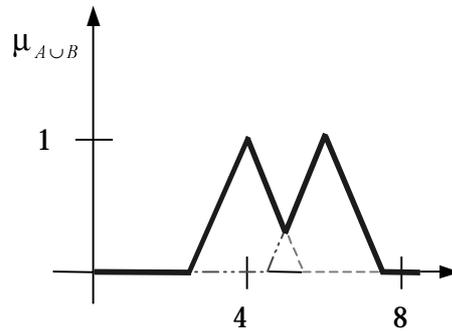


Figura A.4. Operador OR.

Neste caso, a linha cheia mostrada na Figura A.4 define a união dos dois conjuntos nebulosos A e B [Bauer, 1996].

**Operador NOT ou o complemento de um conjunto nebuloso:** A função de pertinência do complemento de A, A' é definida por:

$$\mu_{A'}(x) = 1 - \mu_A(x), x \in X \quad (\text{A.1.3.3})$$

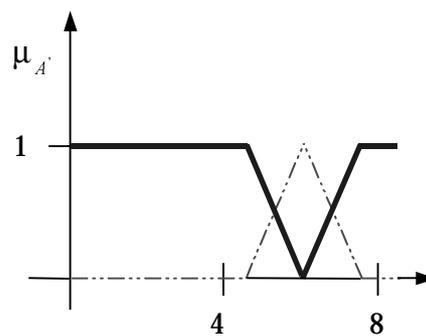


Figura A.5. Operador NOT.

Na Figura A.5 o complemento do conjunto A é dado pela linha cheia [Bauer, 1996].

## A.2. Controle Nebuloso

Os problemas complexos, normalmente, exigem soluções complexas, que por sua vez, necessitam de tempo e esforço proporcional ao nível de complexidade. Os sistemas nebulosos utilizam soluções simples para resolver estes tipos de problemas, baseadas em regras *if-then*, pois em vez de controlar e/ou modelar um processo através do uso de relações complicadas entre as variáveis, o sistema nebuloso leva em conta o controle e/ou modelagem do processo através do uso de um conjunto simples de vários tipos de regras de senso comum. O controle nebuloso utiliza estas regras baseada em um procedimento proposto nos anos 70 por Ebrahim Mamdani [Aziz & Parthiban, 1996].

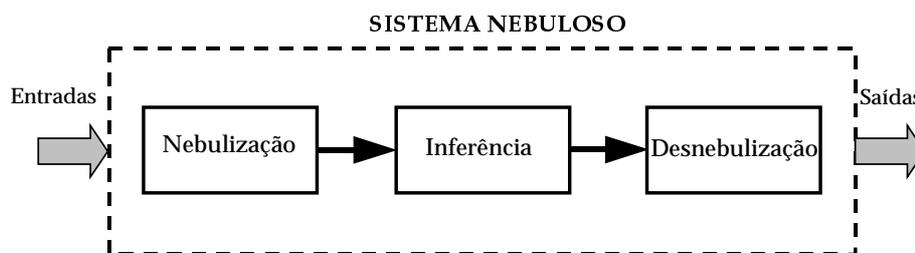


Figura A.6. Diagrama de bloco de um sistema nebuloso.

Esse mecanismo é constituído, basicamente, por três partes como mostra a Figura A.6: nebulização que converte variáveis reais (*crisp*) em variáveis lingüísticas; inferência que consiste na manipulação de base de regras utilizando declarações *if-then* e, ainda, operações nebulosas, como definidas anteriormente (Equações (A.1.3.1) - (A.1.3.3)) e desnebulização que converte o resultado obtido (variáveis lingüísticas) em variáveis reais (*crisp*), as quais constituem a ação de controle [Arabshahi, 1996].

### A.2.1. Nebulização

A nebulização é um processo que decompõe um sistema de entrada e/ou saída em um ou mais conjuntos nebulosos. Cada conjunto nebuloso cobre

uma região particular de um sistema de entradas ou valores de saída e, através da função de pertinência, produz um grau de pertinência com valores compreendidos entre 0 e 1. O resultado dos conjuntos nebulosos representa o grau para o qual um sistema de entrada ou um valor de saída é um membro daquele conjunto nebuloso particular [Kandel, 1993].

Para entender o processo de nebulização, toma-se como exemplo a temperatura. Ela pode ser nebulizada em vários conjuntos nebulosos chamados “fria”, “normal” ou “quente” e assim por diante.

Observa-se na fase de nebulização uma superposição entre os limites dos conjuntos nebulosos que é necessária para prover uma operação suave do sistema. O processo de nebulização permite que as entradas e saídas do sistema sejam expressas em termos lingüísticos de maneira que as regras possam ser aplicadas de uma maneira simples para expressar um sistema complexo.

### A.2.2. Inferência

Após as entradas e saídas do sistema terem sido decompostas em seus respectivos grupos de conjuntos nebulosos, um conjunto de regras associadas a estes conjuntos nebulosos devem ser definidas para reger o comportamento do sistema [Kandel, 1993].

As regras nebulosas são uma série de declarações *if-then* que consistem de uma condição e uma ação definidas como sendo uma função da entrada dos conjuntos nebulosos e uma função da saída dos conjuntos nebulosos, respectivamente [Aziz & Parthiban, 1996]:

IF CONDIÇÃO THEN AÇÃO

sendo:

CONDIÇÃO =  $f$  (entrada de conjuntos nebulosos)

AÇÃO =  $f$  (saída de conjuntos nebulosos)

$f$  = função

Normalmente, um sistema nebuloso exige mais de uma regra para descrever completamente toda a ação necessária e cada regra é avaliada para surtir uma ação baseada na firmeza da condição.

### A.2.3. Desnebulização

Desnebulização é um processo que converte um conjunto nebuloso ou um número nebuloso em um valor ou número real (*crisp*). Este processo é utilizado na modelagem e no controle da lógica nebulosa para converter as saídas nebulosas dos sistemas em valores reais [Kandel, 1993].

Existem numerosas técnicas para desnebulizar um conjunto nebuloso, dentre elas as três principais encontradas na literatura são [Arabshahi, 1996]:

1. **critério *max*:** Encontra o ponto no qual a função de pertinência é um máximo;
2. **média do máximo:** Toma a média dos pontos em que a função de pertinência está para um valor máximo;
3. **centro de área:** Encontra o centro de gravidade da solução dos conjuntos nebulosos.

Dentre eles, o método mais comum é o método de centro de área também conhecido como centróide. O valor de saída é calculado pelo somatório do produto da pertinência do conjunto de entrada, para cada entrada, pelo valor de saída determinado através de um conjunto de regras. Este resultado é dividido pelo somatório da pertinência do conjunto de entrada para cada entrada, resultando assim o valor da ação de controle.

Desta forma, para um conjunto nebuloso tem-se [Arabshahi, 1996; Kartalopoulos et al., 1996; Terano, 1991]:

$$u = \frac{\sum_{i=1}^{n_r} \mu_i \delta_i}{\sum_{i=1}^n \mu_i} \quad (\text{A.2.3.1})$$

sendo:

$\delta_i$  = valor do conjunto que tem um valor de pertinência  $\mu_i$ ;

$n_r$  = número de regras nebulosas.

O valor  $u$  calculado pela Equação (A.2.3.1) corresponde a projeção do centro de inércia da figura definida pelo conjunto de regras sobre o eixo da variável de controle.

## Apêndice B - Dados de Cargas Elétricas

*Neste apêndice são apresentados os bancos de dados históricos de cargas elétricas fornecidos por uma companhia do setor elétrico brasileiro utilizado para realizar o treinamento das arquiteturas das redes neurais propostas. Estes dados contêm valores das cargas horárias do ano de 1998. No apêndice B.1 está a composição de um banco 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 B.2 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 banco de entradas formado por 1008 vetores. E, finalmente, o apêndice B.3 que 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.*

# Apêndice B.1 – Aplicação 1

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	28/7		
01	2388,5	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	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	2941,4		

# Apêndice B.2 – Aplicação 2

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	3358,3	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	2350,0	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			

# Apêndice B.3 – Aplicação 3

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			

## Apêndice C - Publicações

*Este apêndice apresenta a publicação de artigos resultantes de trabalhos desenvolvidos em veículos científicos até o momento. Os artigos ilustram o desenvolvimento das redes neurais apresentadas nos capítulos 4 e 6, e as soluções obtidas dessas arquiteturas na aplicação de previsão de cargas elétricas e análise de sensibilidade e controle preventivo dos Sistemas Elétricos de Potência.*

### C.1. Publicações

ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R. e VILLARREAL, F. “Um estudo das funções de base radial aplicadas à previsão de cargas elétricas via redes neurais artificiais,” XXVIII CNMAC - Congresso Nacional de Matemática Aplicada e Computacional, São Paulo – SP, ST9, pp. 1-6, 2005.

ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R. e VILLARREAL, F. “Um estudo de previsão de cargas elétricas por redes neurais artificiais,” Dincon 2005 - 4º Congresso Temático de Dinâmica e Controle da SBMAC, Bauru – SP, pp. 878-885, 2005.

- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "Electric load forecasting using a fuzzy ART&ARTMAP neural network," *Applied Soft Computing*, Vol. 5, No. 2, pp. 235-244, 2005.
- LOTUFO, A. D. P.; LOPES, M. L. M. e MINUSSI, C. R. "Análise de sensibilidade por redes neurais para aplicação em estabilidade transitória de sistemas elétricos de potência," *Dincon 2004 - 3º Congresso Temático de Dinâmica e Controle da SBMAC, Ilha Solteira - SP*, pp. 1347-1355, 2004.
- LOPES, M. L. M.; LOTUFO, A. D. P. e MINUSSI, C. R. "Previsão de curto-prazo de cargas elétricas por redes neurais," *CBA 2004 - XV Congresso da Sociedade Brasileira de Automática, Gramado - RS*, 2004.
- LOPES, M. L. M.; LOTUFO, A. D. P. e MINUSSI, C. R. "Rede neural ART&ARTMAP aplicada ao problema de previsão de cargas elétricas," *XXVI CNMAC - Congresso Nacional de Matemática Aplicada e Computacional, São José do Rio Preto - SP*, pp. 167, 2003. (resumo).
- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "Electrical load forecasting formulation by a fast neural network," *Engineering Intelligent Systems*, Vol. 11, No. 1, pp. 51-57, 2003.
- LOTUFO, A. D. P.; LOPES, M. L. M. e MINUSSI, C. R. "A neural network for transient stability analysis and preventive control of electric energy systems," *VI CBRN - Congresso Brasileiro de Redes Neurais, São Paulo - SP*, pp. 91-96, 2003.
- LOPES, M. L. M.; MINUSSI, C. R. and LOTUFO, A. P. "A fast electric load forecasting using adaptive neural networks," *Proceedings of the 2003 IEEE Bologna Power-Tech, Italy*, Vol. 1, pp. 23-26, 2003.
- LOTUFO, A. D. P.; LOPES, M. L. M. and MINUSSI, C. R. "Dynamic preventive control of electric power systems by neural networks," *V Induscon - IEEE Industry Applications Society, Salvador - BA*, Vol. 1, pp. 1-6, 2002.