

unesp

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

DISSERTAÇÃO DE MESTRADO
EM
ENGENHARIA ELÉTRICA



1210001124

Nº 30

"IMPLEMENTAÇÃO ELETRÔNICA DE UMA REDE
NEURAL ARTIFICIAL COM FUNÇÃO DE BASE
RADIAL E SUAS APLICAÇÕES"

ALUNO: MÁRCIO BARBOSA LUCKS
ORIENTADOR: NOBUO OKI

Te. 1124

UNIVERSIDADE ESTADUAL PAULISTA


"JÚLIO DE MESQUITA FILHO"

FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Dissertação de Mestrado:

**"Implementação Eletrônica de uma Rede Neural
Artificial com Função de Base Radial e Suas
Aplicações"**



1210001124

Proc. 54199 CISA-NR 163

UNESP - "CAMPUS DE ILHA SOLTEIRA"	
SERVIÇO TÉCN. DE BIBLIOTECA E DOCUMENTAÇÃO	
DATA DE CHEGADA	DATA DE TOMBO
12/11/99	30/11/99
REGISTRADO POR	TOMBO
Tangit	12 1124
AQUISIÇÃO	CLASSIFICAÇÃO
Dooz - autor R\$ 10,00	269412

MARCIO BARBOSA LUCKS

Dissertação submetida à Faculdade de Engenharia de Ilha Solteira - Unesp como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Sys 3040204

ORIENTADOR: PROF. DR. NOBUO OKI

ILHA SOLTEIRA - S.P.

DEZEMBRO - 1998



“IMPLEMENTAÇÃO ELETRÔNICA DE UMA REDE NEURAL ARTIFICIAL COM FUNÇÃO DE BASE RADIAL E SUAS APLICAÇÕES”

MARCIO BARBOSA LUCKS

DISSERTAÇÃO SUBMETIDA À FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA – UNESP – COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO TÍTULO DE MESTRE EM ENGENHARIA ELÉTRICA (ME).



Prof. Dr. Carlos Roberto Minussi - Coordenador

COMISSÃO EXAMINADORA:



Prof. Dr. Nobuo Oki - orientador



Prof. Dr. Alberto Martins Jorge



Prof. Dr. Carlos Roberto Minussi

Ilha Solteira – SP, dezembro de 1998

Agradecimentos

Em primeiro lugar, gostaria de agradecer a Deus e a todos aqueles que, em seu nome, nos transmitiram forças espirituais nos momentos difíceis.

Ao meu orientador, Prof. Dr. Nobuo Oki, pela oportunidade de aprimoramento que me concedeu e pela paciência e atenção com que sempre me orientou durante o transcorrer do trabalho.

A toda minha família pelo carinho e pelo apoio.

Aos amigos e colegas do Departamento de Engenharia Elétrica.

Aos professores Carlos Roberto Minussi, Aparecido Augusto de Carvalho, Marcelo C. M. Teixeira e Edvaldo Assunção pelo apoio que me deram em todo o curso.

À CAPES (Coordenadoria de Aperfeiçoamento de Pessoal de Nível Superior) pelo suporte financeiro.



Resumo

Este trabalho apresenta uma proposta de implementação de uma Rede Neural com Função de Base Radial (RNFBR), de forma eletrônica analógica. É feita uma introdução às Redes Neurais Artificiais e, mais especificamente, às RNFBR's. Um aspecto importante nesse tipo de rede é que são utilizadas funções com uma característica de resposta local e simétrica em torno de um centro, como por exemplo, a função gaussiana e a função secante hiperbólica quadrática. Estas funções se caracterizam pelos parâmetros de forma que são centro, largura e amplitude.

O circuito proposto e implementado nesta pesquisa permite o ajuste de todos os parâmetros de forma das funções. Além disso, é mostrada a possibilidade de expandir a utilização do circuito para casos de múltiplas variáveis de entrada.

A rede implementada foi utilizada para resolver alguns problemas práticos de aproximação de funções como senóide e sinc, e em tarefas de linearização de uma ponte de Wheatstone com termistor e a linearização de um oscilador controlado por tensão (VCO).

A rede utilizada nos experimentos práticos demonstrou excelente capacidade de ajuste e o seu funcionamento foi coerente com o que era esperado teoricamente. A aproximação das funções não ficou perfeita, ressentindo-se da falta de mais funções de base, porém a linearização do termistor foi considerada boa e a do VCO razoável. Em suma, as aplicações demonstraram o funcionamento e a capacidade da rede, porém uma proposta de trabalho futuro é a integração do circuito, o que permitiria construir muitas funções e, conseqüentemente aumentar a capacidade da rede.

Abstract

This work presents a proposal of Radial Basis Function Neural Network (RBFNN) implementation, in electronic analog way. An introduction to Artificial Neural Networks is presented, and more specifically, to RBFNN's. An important feature of this kind of network is the use of functions with a local and symmetric response around a center. As an example of such functions one can quote gaussian function and squared hyperbolic secant. These functions may be characterized by center, width and magnitude parameters.

The circuit, proposed and implemented in this work, allows the adjustment of all shape parameters. Furthermore, it is shown the possibility of expansion in using the circuit in the multivariable case.

Implemented network was used to solve a few practical problems of function approximation, like sinusoidal and sinc functions, linearization of a Wheatstone bridge with termistor and linearization of a voltage controlled oscillator (VCO).

The network has shown excellent possibilities of adjustment and its functionality was consistent with what was expected. Function approximations were not perfect, because of the few basis functions available (four, at most), but the linearization of transducer has worked well and that of the VCO was considered acceptable. In summary, applications proved the ability and working of the proposed circuit; however, a future work will consist of integration of the circuit, allowing the composition of more functions and, consequently, increasing the capability of the network.

Sumário

CAPÍTULO 1	1
<i>Introdução Geral</i>	1
1.1. Motivações desta Tese	1
 CAPÍTULO 2	3
<i>Redes Neurais Artificiais</i>	3
2.1. Introdução	3
2.2. Breve Histórico	5
2.3. Características Básicas das RNA's	8
2.4. Conclusões	9
 CAPÍTULO 3	10
<i>Redes Neurais com Função de Base Radial (RNFBR)</i>	10
3.1. Introdução	10
3.2. Fundamentos Teóricos das RNFBR	10
3.3. Funções Radiais	11
3.3.1. Função Gaussiana	12
3.3.2. Função Secante Hiperbólica Quadrática (SHQ)	13
3.4. Processo de Aprendizado	14
3.4.1. Método Clássico	15
3.4.2. Método de Moody-Darken	16
3.4.3. Método do Gradiente Descendente	16
3.5. Conclusões	17

CAPÍTULO 4..... 18

Implementação Eletrônica de RNFBR's..... 18

4.1. Introdução..... 18

4.2. Implementação Eletrônica de Redes Neurais..... 18

4.3. Revisão da Literatura..... 20

4.4. Circuito Proposto 22

4.4.1. O Par Diferencial Bipolar..... 22

4.4.2. A Diferença como Aproximação da Derivada..... 24

4.5. Simulações com o Circuito Proposto 26

4.6. Conclusões 29

CAPÍTULO 5..... 30

Proposta de Implementação do Circuito FBR

utilizando Amplificadores Operacionais de Transcondutância (OTA's)30

5.1. Introdução..... 30

5.2. Princípio de Funcionamento do OTA..... 30

5.3. O OTA Linearizado 34

5.4. O Circuito FBR com OTA's 36

5.5. Circuito FBR Multivariável..... 38

5.6. Resultados Experimentais 39

5.7. Discussão e Conclusões 42

CAPÍTULO 6..... 43

Aplicações do Circuito43

6.1. Introdução..... 43

6.2. Aproximação da Função Senoidal 44

6.3. Aproximação da Função Sinc 48

6.4. Linearização de Termistor 51

6.5. Linearização de VCO..... 56

6.6. Conclusões 59

CAPÍTULO 7	60
<i>Conclusões Finais</i>	<i>60</i>
Referências Bibliográficas	62
Apêndice	67
A.1. Método do Gradiente Descendente	68
A.1.1. FBR Gaussiana.....	69
A.1.2. Função SHQ	70
A.2. Método de Moody-Darken	71
A.2.1. O Algoritmo "K-means"	71
A.2.2. O Algoritmo "P-nearest"	72
A.3. Implementação Computacional.....	73
A.3.1. FBR Gaussiana.....	73
A.3.2. FBR SHQ	75
A.4. Considerações Sobre o Ajuste dos Pesos no Circuito Prático	77

Índice de Tabelas

Tabela 6.1 - Parâmetros da RNFBR que aproxima uma senóide.	45
Tabela 6.2 - Parâmetros da RNFBR que aproxima uma função Sinc.	49
Tabela 6.3 - Parâmetros da RNFBR usadas na linearização de termistor.	54
Tabela 6.4 - Parâmetros da RNFBR usadas na linearização do VCO.	58

Índice de Figuras

Figura 2.1- Esquema de parte de uma rede neural biológica.	4
Figura 2.2 - Modelo do neurônio de McCulloch - Pitts.	5
Figura 2.3 - Função de ativação tipo relé.	5
Figura 2.4 - Esquema genérico de uma rede neural artificial.	6
Figura 2.5 - Esquema de um PMC com três camadas.	7
Figura 3.1 - Gráfico da função gaussiana com parâmetros $c = 0$, $b = 1$ e $w = 1$	12
Figura 3.2 - Gráfico da função SHQ com parâmetros $c = 0$, $b = 1$ e $w = 1$	13
Figura 3.3 - Diagrama esquemático de uma RNFBR.	14
Figura 4.1 - Esquema simplificado do par diferencial bipolar.	22
Figura 4.2a. - Curva característica do par diferencial bipolar.	23
Figura 4.2b. - Curva de transcondutância do par diferencial bipolar.	24
Figura 4.3 - Circuito básico proposto para implementação de FBR.	25
Figura 4.4 - Curva característica do circuito FBR básico obtida por simulação.	26
Figura 4.5 - Variação de centro do circuito FBR básico simulado.	27
Figura 4.6 - Variação na Amplitude da FBR simulada.	28
Figura 4.7 - Variação da largura da função com relação mudança em R_4	28
Figura 5.1 - Simbologia usada para o OTA.	31
Figura 5.2 - Esquema simplificado do OTA.	32
Figura 5.3 - Diagrama esquemático do OTA LM13600N.	32
Figura 5.4 - Curva característica do OTA LM13600N obtida por simulação.	33

Figura 5.5 - Ampliação da curva anterior mostrando a região quase linear.	34
Figura 5.6 - OTA linearizado.	35
Figura 5.7 - Curva característica simulada do OTA LM13600N linearizado.	35
Figura 5.8 - Diagrama completo do circuito FBR.	36
Figura 5.9 - Curva típica da resposta do circuito FBR.	37
Figura 5.10 - Resposta do circuito FBR para correntes de polarização i_{b3} variando entre 20 μA e 100 μA	38
Figura 5.11 - Diagrama do circuito FBR multivariável.	39
Figura 5.12 - Saída da FBR para uma entrada triangular.	40
Figura 5.13 - Curva experimental obtida para o circuito FBR.	40
Figura 5.14 - Comparação entre a FBR experimental e uma gaussiana teórica com $c=0$, $b=0.4669$ e $w=1.3$	41
Figura 5.15 - Comparação entre a FBR experimental e uma SHQ teórica com $c=0$, $b=0.77$ e $w=1.3369$	41
Figura 6.1 - Diagrama esquemático básico da RNFBF utilizada.	43
Figura 6.2 - FBR's encontradas na aproximação de senóide.	45
Figura 6.3 - Função senoidal versus a aproximação da rede teórica	46
Figura 6.4 - Função senoidal (curva lisa) e a aproximação experimental (curva com ruído).	46
Figura 6.5 - Curva experimental na tela do osciloscópio digital.	47
Figura 6.6 - Resultado da aproximação de senóide (experimental versus teórico).	47
Figura 6.7 - Gráfico do Erro (diferença ponto-a-ponto entre a curva experimental e a ideal).	48
Figura 6.8 - Gráfico da função sinc.	49
Figura 6.9 - FBR's obtidas no aprendizado da função sinc.	50
Figura 6.10 - Função sinc teórica e a aproximação da rede.	50
Figura 6.11 - Curvas experimentais na tela do osciloscópio digital. Onda triangular na entrada (acima) e saída da rede (abaixo).	51
Figura 6.12 - Diagrama da ponte com termistor.	52
Figura 6.13 - Resposta da ponte com termistor.	52
Figura 6.14 - Inversa da resposta do termistor.	53

Figura 6.15 - Gráfico da rede simulada e os pontos (o) usados na fase de aprendizado da função inversa.....	53
Figura 6.16 - FBR's teóricas encontradas na simulação.....	54
Figura 6.17 - Curva experimental do conjunto Ponte-RNFBR.	55
Figura 6.18 - Gráfico do erro percentual entre a resposta experimental e a ideal.	55
Figura 6.19 - Circuito VCO com temporizador 555.....	56
Figura 6.20 - Gráfico da resposta do VCO em função de Vcon.....	57
Figura 6.21 - Gráfico mostrando a curva característica do VCO e a sua inversa.....	57
Figura 6.22 - Gráfico mostrando a curva desejada (pontilhada) e a aproximação teórica da rede após o processo de aprendizado.	58
Figura 6.23 - Gráfico das FBR's obtidas no treinamento.....	58
Figura 6.24 - Resultado experimental e simulado.	59
Figura A.1 - Esquema para aprendizado da rede.	68
Figura A.2 - Demonstração gráfica do algoritmo "k-means".....	72

Simbologia

RNA :	Rede Neural Artificial;
RNFBR :	Rede Neural com Função de Base Radial;
PMC :	Perceptron Multi-Camadas;
FBR :	Função de Base Radial;
SHQ :	Secante Hiperbólica Quadrática;
x :	Variável de entrada da RNA;
y :	Variável de saída da RNA;
M :	Número de FBR's;
N :	Número de pares-exemplos usados na fase de aprendizado da rede;
w_i :	Peso ou Amplitude da i-ésima FBR;
b_i :	Largura da i-ésima FBR;
c_i :	Centro da i-ésima FBR;

p_i :	vetor de parâmetros de forma da i-ésima FBR;
$f(.)$:	Função não-linear;
d :	Máxima distância euclidiana entre os centros das FBR's;
LMS :	Algoritmo mínimos quadrados;
p :	Parâmetro qualquer da rede;
Δp :	Alteração de um parâmetro p ;
μ :	Taxa de aprendizado;
E :	Erro quadrático;
MOS :	Tecnologia metal-óxido-semicondutor usada em circuitos integrados;
FGMOS :	Transistor MOS de porta flutuante;
β :	Ganho de corrente do transistor bipolar;
V_t :	Equivalente térmico de tensão (V);
V_{dif} :	Tensão diferencial na entrada do par diferencial;
I_{dif} :	Corrente diferencial na saída do par diferencial;
I_p :	Corrente de polarização do par diferencial ou do OTA;
OTA :	Amplificador operacional de transcondutância;
V_{cc} :	Tensão positiva da fonte de alimentação;
VCO :	Oscilador controlado por tensão;
V_{con} :	Tensão de controle de frequência do VCO;
C :	Capacitância usada no VCO;
R_a, R_b :	Resistores usados no VCO;
F_o :	Frequência de saída do VCO;
x_p :	Padrão de entrada usado no treinamento da RNA;
y_p :	Saída da RNA para um padrão x_p aplicado na entrada;
d_p :	Saída desejada para um padrão x_p aplicado à entrada da RNA;
P :	Fator de sobreposição usado no algoritmo "P-nearest";
x_{+prox} :	Padrão de entrada mais próximo do centro da i-ésima FBR (utilizado no algoritmo "K-means");
g :	Trancondutância;
EC :	Espelho de Corrente.

CAPÍTULO 1

Introdução Geral

O objetivo maior quando se fala em Redes Neurais Artificiais é, sem dúvida, a construção física de um neurocomputador que iguale ou supere a inteligência humana, bem como a utilização de suas propriedades na resolução de problemas específicos. Assim sendo, este campo tem grandes implicações em desenvolvimento tanto de Hardware quanto de Software. Muitas pesquisas e esforços têm sido feitos nesse sentido, e vários resultados práticos foram relatados na literatura. No entanto, ainda há muitos desafios técnicos a vencer até que esta tecnologia possa estar tão presente em nosso cotidiano quanto os computadores digitais da atualidade.

Em geral, a maioria das pesquisas com redes neurais artificiais são feitas com simulações empregando o computador. Contudo, a implementação analógica mostra-se extremamente promissora pois permite aproveitar o paralelismo inerente às redes neurais. Isto significa uma maior rapidez de resposta em comparação com as simulações.

1.1. Motivações desta Tese

No início desta pesquisa, percebeu-se que as limitações dos circuitos práticos impunham grandes entraves nas pesquisas com redes neurais. Um exemplo é o caso da saturação. Em uma rede neural teórica ou simulada em computador, é permitida uma variação nos pesos (sinapses, multiplicadores) praticamente infinita. Mas, quando se vai implementar o circuito sináptico na prática, nota-se que ele só apresenta uma faixa de trabalho limitada.



Para tratar esse problema, iniciou-se um estudo sobre as limitações e não-idealidades presentes nas implementações eletrônicas de redes neurais. A partir da proposta de Lont em [1], na qual é utilizada uma sinapse não-linear, com uma correspondente mudança no algoritmo de aprendizado, de forma a incluir esta não-linearidade, passou-se ao estudo de uma sinapse gaussiana, proposta por Choi [2], e que segundo ele apresentava melhores características de convergência e rapidez.

Decidiu-se aprofundar o estudo a respeito das assim chamadas “sinapses gaussianas”. Durante a pesquisa chegou-se à conclusão de que se tratava na verdade de uma topologia de rede totalmente diferente da mais conhecida (Perceptron Multi-Camadas (PMC)) [3]. Este novo tipo de rede é conhecido pelo nome de Rede Neural com Função de Base Radial (RNFBR) [4]. Os aspectos teóricos deste tipo de rede serão detalhados mais adiante no Capítulo 3.

Há vários circuitos propostos na literatura para implementação de RNFBR's conforme será mostrado no Capítulo 4, no entanto, em nenhum dos artigos pesquisados havia aplicações práticas desses circuitos. Muitos se limitavam a propor novas formas de realizar a função gaussiana ou algo próximo dela.

Daí surgiu o interesse em implementar e aplicar uma RNFBR em algumas tarefas. O objetivo deste trabalho, portanto, é apresentar o projeto de um circuito analógico para implementação de uma Rede Neural com Função de Base Radial, introduzida no Capítulo 3 e detalhada nos capítulos posteriores, bem como mostrar aplicações práticas desta rede em alguns problemas de linearização e aproximação de funções.

Esta tese é dividida em sete capítulos e um apêndice. Os Capítulos 2 e 3 constituem uma introdução às redes neurais e mais especificamente às redes com função de base radial. Os Capítulos 4 e 5 tratam da proposta de implementação propriamente dita. O Capítulo 6 mostra os resultados obtidos em algumas aplicações práticas e o Capítulo 7 apresenta as conclusões finais da tese. No apêndice são apresentados os algoritmos que foram elaborados para efetuar o aprendizado.



CAPÍTULO 2

Redes Neurais Artificiais

2.1. Introdução

Um dos mais impressionantes fenômenos da Natureza é o princípio da inteligência. Apesar de toda a tecnologia atual, ainda não se conseguiu produzir uma máquina verdadeiramente inteligente. Sem dúvida, houve um progresso considerável no campo do processamento de informação, principalmente depois do advento da moderna eletrônica digital com o conseqüente aumento na capacidade computacional.

Entretanto, ainda que o computador digital tenha atingido um grau elevado de confiabilidade, rapidez e precisão, o fato é que o cérebro humano executa operações para as quais os mais modernos computadores se mostram frágeis. Alguns exemplos que se pode citar são: reconhecimento de padrões, reconhecimento de voz, memória associativa, e muitos outros. Todas estas tarefas envolvem questões como solução de ambigüidades e processamento paralelo de grande quantidade de informação.

Assim sendo, os cientistas têm-se voltado para a Natureza e a forma como ela trata com essas questões há milhões de anos. Partindo da estrutura cerebral, a questão que se impõe é: por qual processo de funcionamento as células do cérebro colocam em funcionamento as faculdades de imaginação, reflexão, memória, aprendizado, controle do organismo e tantas outras capacidades fundamentais para a existência do ser humano.

Esta questão permaneceu em aberto por muito tempo, porém, com o avanço da ciência, sobretudo da biologia e da eletrônica, começaram a ser estabelecidas



as bases para o que hoje é conhecido como neurobiologia, isto é, o estudo dos neurônios biológicos. Aos poucos está sendo desvendado o funcionamento elétrico e químico dos neurônios e de suas partes constituintes. Um estudo mais profundo sobre o funcionamento do cérebro pode ser encontrado em [5].




Fig. 2.1: Esquema de parte de uma rede neural biológica.

Na Fig. 2.1 é apresentado o esquema simplificado de uma rede neural biológica. O neurônio é basicamente um processador de informação com múltiplas entradas (dendritos) e uma única saída (axônio), a qual pode se interligar a milhares de outros neurônios por meio de conexões denominadas sinapses. A partir dos estudos com as redes biológicas foi que surgiu o campo das redes neurais artificiais, que nada mais são do que tentativas de emular a capacidade de processamento do cérebro. Entretanto, este desenvolvimento foi relativamente lento e será mais detalhado no item seguinte. Para um maior aprofundamento recomenda-se a leitura de [3], [6] e [7].

2.2. Breve Histórico

Um grande marco no campo das redes neurais foi o trabalho pioneiro de McCulloch e Pitts, em 1943, no qual eles apresentaram o primeiro modelo computacional do neurônio (Fig.2.2). Este modelo consiste de um combinador linear seguido por uma função de ativação não-linear do tipo relé.




Fig. 2.2: Modelo do neurônio de McCulloch - Pitts.




Fig. 2.3: Função de ativação tipo relé.

Baseados neste primeiro modelo, surgiram os estudos iniciais com redes conexionistas, fundamentadas na utilização de unidades de processamento pequenas e simples conectadas em paralelo e em camadas sucessivas, estrutura essa que por analogia se denominou Rede Neural Artificial.




Fig. 2.4 - Esquema genérico de uma rede neural artificial.

A partir do modelo de McCulloch-Pitts descrito anteriormente, os avanços se sucederam uns aos outros. Graças ao esforço de inúmeros pesquisadores foram surgindo novas configurações de rede e novos processos de aprendizado. Como destaques principais podemos citar as redes de Hopfield, Kohonen, Hebb, o perceptron de Rosenblatt, e principalmente, na atualidade, a criação do algoritmo “back-propagation” para redes de múltiplas camadas, em geral denominada de Perceptron Multi-Camadas (PMC), e utilizando função de ativação diferenciável.




Fig. 2.5: Esquema de um PMC com três camadas.

O algoritmo “back-propagation” foi apresentado em 1986 por Rumelhart et al., mas verificou-se mais tarde que o algoritmo já havia sido descrito por Werbos em sua tese de mestrado, em 1974, porém permaneceu desconhecido pela comunidade científica. A ênfase dada a este algoritmo deve-se ao fato de sua criação ser responsável pelo ressurgimento das redes neurais artificiais. Estas haviam sofrido um descrédito quando ficou demonstrada a impossibilidade das primeiras topologias em aproximar funções simples como a função OU-Exclusivo e devido à falta de um algoritmo eficiente para o aprendizado. O “back-propagation” substitui as funções relé por sigmóides, que são diferenciáveis, o que permite a utilização do método do gradiente descendente (método de otimização) no aprendizado das redes de múltiplas camadas.

Ultimamente, vem sendo pesquisada uma nova forma de rede que é baseada em funções de base radial (por ex.: gaussiana). Esta rede apresenta alguns aspectos bastante diferentes da rede multi-camadas com sigmóide, devido principalmente à característica de resposta local das funções.

É nesta topologia de rede que se está interessado neste trabalho; deste modo, ela será objeto de estudo do próximo capítulo.

2.3. Características Básicas das RNA's

As RNA's são estruturas computacionais que apresentam como principais características as seguintes:

- paralelismo;
- capacidade de aprendizado;
- generalização;
- robustez.

Em síntese, o funcionamento da RNA é o seguinte:

1. Apresentação de pontos da função a ser aprendida, geralmente denominados pares exemplo (entrada-saída desejada);
2. Fase de Aprendizado (ajuste);
3. A rede simula a função aprendida (execução).

Esta capacidade das redes em simular a função aprendida pode ser encontrada na literatura com várias denominações: identificação de sistemas, aproximação de função, interpolação, filtros adaptativos, síntese de funções, etc.

Em outras palavras, a rede “aprende” os pares exemplo e generaliza para valores de entrada não utilizados na fase de aprendizado, fornecendo saídas coerentes mesmo para valores de entrada que não tenham sido apresentados anteriormente.



2.4. Conclusões

Neste capítulo foi apresentada uma visão geral do campo das redes neurais artificiais e de como ela se relaciona às redes neurais biológicas. Foi feita uma descrição das principais propriedades e características das RNA's, e também um breve relato de algumas realizações fundamentais nesse campo.



CAPÍTULO 3

Redes Neurais com Função de Base Radial (RNFBR)

3.1. Introdução

As redes neurais com função de base radial representam um paradigma novo no campo das redes neurais artificiais. Embora já houvesse a aplicação desse tipo de estrutura na resolução de problemas de interpolação com múltiplas variáveis e em estatística, só recentemente elas vêm sendo incluídas no campo de estudos das RNA [4].

Este capítulo tem por finalidade apresentar os principais aspectos teóricos referentes às RNFBR's, tais como: seus fundamentos matemáticos e o processo de aprendizado.

3.2. Fundamentos Teóricos das RNFBR

De forma geral, uma função qualquer $y(\mathbf{x})$ pode ser representada pela soma ponderada de um número finito de *funções de base* $f(\cdot)$, conforme apresentado abaixo:

$$y(\mathbf{x}) \equiv \sum_{i=1}^M w_i f(\mathbf{x}, \mathbf{p}_i) + w_0 B \quad (3.1)$$

sendo que :



- M - número de funções de base;
- w_i - peso referente à i -ésima função de base;
- w_0 - peso referente ao "bias";
- B - "bias" (em geral, $B = +1$);
- p_i - vetor de parâmetros, incluindo os fatores de forma e de deslocamento da i -ésima função de base.

Os parâmetros M , w_i , w_0 e p_i são sujeitos a ajuste através de aprendizado.

A equação (3.1) pode aproximar qualquer função arbitrária com um grau desejável de precisão desde que se disponha de um número suficientemente grande de unidades intermediárias ("hidden units"), e que a função de base $f(x, p_i)$ seja absolutamente integrável ou uma função monotônica limitada [8].

Algumas funções bastante conhecidas enquadram-se nos requisitos acima citados.

3.3. Funções Radiais

As funções radiais formam uma classe especial de funções. Sua característica básica é apresentarem uma resposta monotonicamente crescente ou decrescente a partir de um centro [4].

A seguir apresentar-se-ão as duas funções de base radial que serão utilizadas nesta tese: a função gaussiana e a função secante hiperbólica quadrática.



3.3.1. Função Gaussiana

A função gaussiana é dada pela equação:

$$f(x, b, c, w) = w \cdot \exp(-b(x-c)^2) \quad (3.2)$$

sendo: c - centro

b - largura

w - amplitude.

Na Figura 3.1 é mostrada uma função gaussiana típica.




Fig.3.1: Gráfico da função gaussiana com parâmetros
 $c = 0$, $b = 1$ e $w = 1$.

3.3.2. Função Secante Hiperbólica Quadrática (SHQ)

A função SHQ é dada por:

$$f(x, b, c, w) = w \cdot (\operatorname{sech}(b(x-c)))^2 \quad (3.3)$$

sendo: c - centro

b - largura

w - amplitude.

Na Figura 3.2 pode ser visualizada a função SHQ típica.




Fig.3.2: Gráfico da função SHQ com parâmetros

$c = 0$, $b = 1$ e $w = 1$.

3.4. Processo de Aprendizado

Neste trabalho utilizou-se como função de base a função gaussiana e a função secante hiperbólica ao quadrado. A partir da equação (3.1), pode-se obter uma visualização esquemática da rede conforme apresentado na Fig. 3.3.




Fig.3.3: Diagrama esquemático de uma RNFBR.

A RNFBR é geralmente dividida em três camadas. A primeira é constituída por funções lineares e serve apenas para distribuir os sinais de entrada para a segunda camada. A segunda camada compõe-se das funções de base radiais e executa uma transformação não-linear no espaço de entrada. A última camada fecha o processo e constitui-se de um simples combinador linear.

O aprendizado da RNFBR apresenta, em geral, quatro fases:

- 1)** Determinação do número de unidades da camada intermediária;
- 2)** Localização dos centros;
- 3)** Determinação da largura das funções;
- 4)** Ajuste dos pesos de ligação entre as camadas intermediária e de saída.

A literatura apresenta vários métodos para implementar cada uma das fases descritas acima [4], [6], [8]-[11].

3.4.1. Método Clássico

É o mais simples. Inicialmente, arbitra-se o número M de unidades na camada intermediária. Em seguida os centros são determinados aleatoriamente a partir dos padrões de entrada. A largura é calculada por:

$$b = \frac{M}{d^2} \quad (3.4)$$

sendo d a máxima distância euclidiana entre os centros. Por fim, a camada de saída é otimizada com o uso da pseudo-inversa.



3.4.2. Método de Moody-Darken

É um método híbrido em que a camada intermediária se auto-organiza e a camada de saída é ajustada de modo supervisionado. No ajuste dos centros utiliza-se um algoritmo de agrupamento como, por exemplo, o “k-means” [35]. Para determinação da largura das funções utiliza-se um algoritmo que gere uma hiper-superfície contígua e suave, como o “p-nearest”. A determinação dos pesos lineares da camada de saída é feita com o algoritmo dos mínimos quadrados (LMS) [36].

3.4.3. Método do Gradiente Descendente

Este método foi bastante difundido pelo algoritmo “back-propagation”. Ele se baseia na busca em uma direção de decréscimo do erro quadrático na saída em função dos parâmetros ajustáveis da rede. A alteração dos parâmetros (Δp) no método do gradiente descendente padrão é calculada por [06]-[09]:

$$\Delta p = -\mu \frac{\partial E}{\partial p} \quad (3.5)$$

em que μ é a taxa de aprendizado, p é o parâmetro a ser ajustado e E representa a função Erro Quadrático decorrente da apresentação de todos os padrões de treinamento.

Desta forma, durante o processo de aprendizado, o conjunto de parâmetros na iteração $k+1$ é dado por:

$$p(k+1) = p(k) + \Delta p(k) \quad (3.6)$$



Com o intuito de diminuir a probabilidade do processo estacionar em um mínimo local, pode-se aplicar variantes do método padrão, como por exemplo a técnica do momento, taxa de aprendizado adaptativa, etc. Neste trabalho foi utilizada uma variante conhecida como “simulated annealing” [09] na qual é acrescentado um termo de ruído aleatório sendo que a amplitude máxima do ruído depende de uma temperatura virtual T cujo valor decresce a cada iteração.

3.5. Conclusões

Em geral, na literatura, tem-se enaltecido muito a rapidez e a facilidade de aprendizado das RNFBR's. Entretanto, o que se pôde constatar nesta pesquisa é que esta é uma afirmação prematura e muito relativa. Na verdade, vários fatores influem na velocidade e na facilidade do aprendizado, conforme relacionados a seguir:

- FBR utilizada;
- dimensão do vetor de entrada;
- grau de liberdade permitido no ajuste dos parâmetros da rede (centros, larguras e amplitudes das FBR's).

A FBR utilizada não influi muito, porém, o segundo fator é extremamente importante e indica a própria viabilidade ou não de utilizar uma RNFBR na solução de um determinado problema. Isto se deve ao fato de que o número de unidades necessárias na camada intermediária cresce geometricamente com a dimensão da entrada. O terceiro fator é muito importante na implementação eletrônica da rede pois está diretamente relacionado com as limitações dos circuitos utilizados. Acrescente-se a isso a possibilidade ou não de auto-ajustar o número de unidades da camada intermediária e se terá uma idéia das dificuldades envolvidas na solução do problema do aprendizado. Portanto, a rigor só se pode afirmar que o modelo clássico é verdadeiramente bem mais rápido que o PMC, porém, no geral, não é o mais otimizado e nem fornece a melhor aproximação.



CAPÍTULO 4

Implementação Eletrônica de RNFBR's

4.1. Introdução

Neste capítulo serão apresentados o circuito proposto para implementação das RNFBR's, bem como uma visão geral de algumas propostas encontradas na literatura. Serão comentadas também as principais características das implementações práticas das redes e, ainda, os desafios a serem enfrentados.

4.2. Implementação Eletrônica de Redes Neurais

Embora haja a possibilidade de construir discretamente a RNA, o objetivo maior é sempre visando a implementação na forma de circuito integrado [12]-[16]. Pode-se dividir as implementações da seguinte forma:

- ♦ digital;
- ♦ analógica;
- ♦ mista.



A grande vantagem da implementação analógica é o aproveitamento do paralelismo natural da rede, o que aumenta em muito a velocidade de trabalho do circuito. Entretanto, há vários problemas a enfrentar, sendo que o principal deles é a necessidade de uma memória analógica para armazenar os parâmetros ajustáveis da rede. Atualmente, há várias propostas para implementação dessas memórias. As mais usuais são resistores, capacitores e transistores MOS de porta flutuante (FGMOS). Um outro problema importante na implementação analógica é o descasamento entre componentes, gerando as diferenças indesejadas de tensão ou corrente ("offset", em inglês). No caso da rede mista, a implementação das funções é feita analogicamente e o armazenamento dos parâmetros e o controle da rede são feitos digitalmente.

Pode-se classificar as implementações de RNA's quanto a outros fatores, como por exemplo:

- ◇ Arquitetura;
- ◇ Programável ou fixa;
- ◇ Aprendizado ("off line", "on-chip" ou "chip-in-the-loop");
- ◇ Número de neurônios;
- ◇ Escalabilidade;
- ◇ Bits de precisão;
- ◇ Custo.

Vale a pena detalhar os diversos tipos de aprendizado que podem ser implementados:

- * "off-line": é feita uma simulação no computador e depois transfere-se os parâmetros encontrados para o circuito;
- * "on-chip": o algoritmo é implementado eletronicamente dentro do circuito;



- * “chip-in-the-loop”: em cada iteração o erro na saída é calculado apresentando os padrões exemplos ao circuito e medindo-se a sua saída. Os valores atualizados dos parâmetros são calculados no computador e transferidos para o circuito.

4.3. Revisão da Literatura

Neste item, será feita uma breve retrospectiva de algumas propostas encontradas na literatura sobre implementação de RNFBR's.

Em [17] é apresentado um circuito MOS para computar similaridade e dissimilaridade entre sinais, em outras palavras, o grau de proximidade entre eles. O circuito utiliza um bloco denominado “correlacionador de corrente”, o qual por sua vez tem um funcionamento próximo ao de uma porta AND. Nessa proposta podem ser ajustados os centros e as amplitudes da função. Uma das características do circuito é que ele usa transistores em inversão fraca. Isto implica níveis de corrente da ordem de nanoamperes tornando o circuito evidentemente mais sensível a ruídos. Além disso, o uso da inversão fraca limita bastante a velocidade de resposta do circuito.

Em [2] é proposto um circuito para implementar a função gaussiana usando aproximação por partes. Isto é feito por intermédio de um par diferencial e espelhos de corrente os quais realizam as operações aritméticas necessárias (soma ou diferença). Os parâmetros de amplitude e centro podem ser ajustados eletronicamente, mas a largura das funções depende das dimensões dos transistores do par diferencial, o que torna a programação mais difícil e limitada. O artigo não trata da escalabilidade.

Em [18] é proposto um circuito para implementação de função gaussiana. Ele utiliza um transistor MOS na saturação atuando como quadrador e um espelho de Widlar com MOS em inversão fraca para realizar a exponencial. O circuito implementa apenas metade da função. Para conseguir uma função completa é necessário utilizar um



circuito quadrático na entrada. A amplitude pode ser variada em uma ampla faixa, mas a largura é limitada a uma pequena faixa. Para tornar o circuito realmente viável é imprescindível o uso dos quadradores na entrada.

Em [19] é apresentado um circuito que implementa uma função de base radial aproximadamente gaussiana. O funcionamento do circuito é baseado na característica de corrente de um par complementar CMOS (inversor). Apesar da simplicidade e pequeno tamanho, o circuito apresenta certos inconvenientes tais como: assimetria da função e o fato da amplitude depender das dimensões dos transistores que formam o par complementar. É descrita, também, uma versão multivariável do circuito utilizando o correlacionador de correntes para multiplicar as funções entre si.

Em [20] é feita uma proposta para implementar funções não-lineares baseada em séries de Dirac as quais, nesse caso, são compostas por diferenças de tangentes hiperbólicas. O artigo não trata esse processo como RNFBF, mas o resultado é similar. Também não é feita uma análise do caso multivariável.

Em [21] são apresentados dois circuitos para implementação de funções gaussianas. É utilizado um multiplicador de Gilbert para realizar a função quadrática e um transistor MOS em inversão fraca conectado como diodo para a função exponencial. Um dos circuitos permite apenas a variação do centro e da largura com várias ordens de magnitudes. O outro permite a variação de todos os parâmetros incluindo a amplitude, mas a largura fica restrita a apenas uma ordem de magnitude.

Em [22] propõe-se um circuito para redes gaussianas utilizando quadradores na entrada, os quais implementam a norma euclidiana (distância entre o vetor de entrada e o centro da gaussiana). A função exponencial é realizada por meio de um integrador com capacitor e a saída da gaussiana é na forma de pulsos retangulares sendo que a amplitude da função é dada pela largura dos pulsos. A variância (largura da função) pode variar duas ordens de magnitude.



4.4. Circuito Proposto

O circuito proposto neste trabalho é baseado na curva característica de transcondutância do par diferencial com transistores bipolares. O par diferencial é um dos blocos mais utilizados na implementação de redes neurais. Portanto, é conveniente fazer uma breve revisão sobre esse circuito e suas curvas características.

4.4.1. O Par Diferencial Bipolar

O esquema do par diferencial é apresentado na Fig.4.1. Como o próprio nome sugere, a saída do circuito é função da diferença entre as tensões nas entradas [23]-[25].




Fig.4.1 : Esquema simplificado do par diferencial bipolar.

A equação que rege o par diferencial é dada por:

$$I_{dif} = \alpha_F \cdot I_p \cdot \tanh\left(\frac{V_{dif}}{2V_t}\right) \quad (4.1)$$

sendo : $\alpha_F \rightarrow$ Relação entre as correntes de coletor e emissor em um transistor bipolar;

$V_t \rightarrow$ equivalente térmico de tensão (V).

A Fig.4.2a mostra a curva característica de saída do par diferencial.




Fig. 4.2a. Curva característica do par diferencial bipolar.

A equação de transcondutância do par diferencial é dada por:

$$g = \frac{\partial I_{dif}}{\partial V_{dif}} = \frac{\alpha_F \cdot I_p}{2V_t} \cdot \text{sech}^2\left(\frac{V_{dif}}{2V_t}\right) \quad (4.2)$$

sendo : $g \rightarrow$ transcondutância do par diferencial.

A Fig.4.2b apresenta a curva característica de transcondutância típica de um par diferencial bipolar.




Fig.4.2b. Curva de transcondutância do par diferencial bipolar.

A resposta do par diferencial tem uma aparência bastante familiar aos pesquisadores de redes neurais pois nada mais é do que a tangente hiperbólica (sigmóide) frequentemente usada no perceptron multicamadas juntamente com o algoritmo “back-propagation”. Já a curva de transcondutância é a derivada da primeira e é também bastante familiar, pois trata-se da secante hiperbólica ao quadrado. A idéia original deste trabalho foi utilizar esta característica de transcondutância para implementar uma função de base radial. Um problema que surgiu foi o seguinte: Como implementar a derivada?

4.4.2. A Diferença como Aproximação da Derivada

Para responder à questão formulada partiu-se da fórmula da derivada de uma determinada função $f(x)$. Ela é dada por :

$$f'(x) = \lim_{\Delta \rightarrow 0} \frac{f(x + \Delta) - f(x)}{\Delta} \quad (4.3)$$

Da fórmula (4.3) depreende-se que para Δ suficientemente pequeno pode-se conseguir uma aproximação suficiente da derivada. Portanto, chegou-se à conclusão de que com dois pares diferenciais e uma pequena tensão de offset aplicada na entrada de um deles obtém-se a implementação eletrônica da função derivada suficientemente próxima da desejada. Desta forma, a equação fica:

$$f'(x) \cong \frac{f(x + \Delta) - f(x)}{\Delta} \quad (4.4)$$

O circuito completo fundamentado nas idéias apresentadas é mostrado na figura seguinte.




Fig. 4.3 : Circuito básico proposto para implementação de FBR.

4.5. Simulações com o Circuito Proposto

Foram realizadas várias simulações com o circuito proposto a fim de avaliar o seu comportamento com relação aos parâmetros ajustáveis. Os quatro gráficos seguintes mostram as principais características do circuito.

Primeiramente, é mostrada a curva principal do circuito, a qual permite a visualização clara de seu comportamento como função radial.




Fig.4.4: Curva característica do circuito FBR básico
obtida via simulação.

A segunda curva mostra o comportamento do circuito com relação à variação dos centros mantendo-se fixos os demais parâmetros.




Fig.4.5: Variação de centro do circuito FBR básico simulado.

A terceira curva apresenta a variação na amplitude da saída em função de variações na corrente de cauda dos pares diferenciais.




Fig.4.6: Variação na Amplitude da FBR simulada.

Por último, é mostrada a variação na largura em função de variações no resistor R4.




Fig.4.7: Variação da largura da FBR em função de variações de R4.

4.6. Conclusões

Neste capítulo foi apresentada a idéia básica para implementação de FRB's. As simulações demonstraram as capacidades do circuito com relação às variações de parâmetros de forma, tais como: amplitude, centro e largura das funções.

Um detalhe a ser ressaltado é que, devido às não-idealidades presentes no circuito, quando a amplitude da função é modificada o centro sofre um deslocamento. Entretanto, isto não constitui um problema grave pois pode ser contrabalançado por uma tensão de centro apropriada na entrada.

As variações da largura com a mudança no resistor R4 não podem ser consideradas satisfatórias, pois alteram o tipo de função, fazendo que ela deixe de se aproximar da gaussiana ou da secante hiperbólica quadrática. Portanto, para se variar a largura, de forma adequada, sem modificar o tipo de função, deve ser encontrada uma outra maneira de obter essa flexibilidade. No próximo capítulo será apresentada uma forma de fazer isso usando um OTA linearizado na entrada do circuito.



CAPÍTULO 5

Proposta de Implementação do Circuito FBR utilizando Amplificadores Operacionais de Transcondutância (OTA's)

5.1. Introdução

A idéia básica do circuito para implementar a FBR está mostrada no Capítulo 4. No entanto, decidiu-se utilizar amplificadores operacionais de transcondutância (OTA's) na implementação prática, o que permitiria a montagem discreta do circuito com um melhor casamento entre componentes e maior facilidade na montagem.

Neste capítulo será analisada com mais detalhes essa implementação, partindo-se dos principais aspectos do OTA até o circuito FBR completo.

5.2. Princípio de Funcionamento do OTA

A simbologia usada para representar o OTA é mostrada na Fig. 5.1. O amplificador operacional de transcondutância consiste basicamente em um par diferencial na entrada e alguns espelhos de corrente, os quais fazem a subtração das correntes de coletor dos transistores componentes do par diferencial, conforme mostrado nas Figs. 5.2 e 5.3 [26], [27].



O comportamento do OTA é descrito pela equação:

$$i_{saída} = g \cdot i_p \cdot v_{ent} \quad (5.1)$$

sendo: g - transcondutância do OTA;

i_p - corrente de polarização;

v_{ent} - tensão diferencial na entrada.




Fig. 5.1: Simbologia usada para o OTA.




Fig. 5.2: Esquema simplificado do OTA.




Fig. 5.3: Diagrama esquemático de um OTA encontrado no CI comercial dual OTA LM13600N.

O OTA efetua uma operação de multiplicação entre a corrente de polarização e a tensão diferencial na entrada. Contudo, esta multiplicação só apresenta comportamento linear para uma pequena faixa de tensão na entrada, conforme é mostrado nas Figuras 5.4 e 5.5. O circuito tem uma resposta característica praticamente idêntica à do par diferencial, ou seja, uma tangente hiperbólica.

Como o núcleo básico do OTA é o par diferencial bipolar, o seu comportamento é similar. Assim, a curva de transcondutância também tem a forma de uma SHQ.




Fig. 5.4: Curva característica do OTA LM13600N obtida por simulação.




Fig. 5.5: Ampliação da curva anterior mostrando a região quase linear.

5.3. O OTA Linearizado

Geralmente, utiliza-se o OTA em aplicações lineares tais como: amplificadores, filtros, impedâncias e osciladores (todos estes circuitos controlados por corrente), ou, então, como elementos de chaveamento em multiplexadores, temporizadores e “sample-hold”.

Em [26] é apresentado um circuito que lineariza o OTA em uma ampla faixa de trabalho.




Fig. 5.6: OTA linearizado.

Na Fig. 5.7 é apresentada a curva característica para o circuito com OTA linearizado. Nota-se que ele funciona como multiplicador linear em uma ampla faixa.




Fig. 5.7: Curva característica simulada do OTA LM13600N linearizado.

5.4. O Circuito FBR com OTA's

O circuito proposto neste trabalho usa a característica de tangente hiperbólica do OTA, exatamente como no circuito proposto no capítulo anterior, no intuito de obter a sua derivada, que é a secante hiperbólica quadrática. Na entrada, um OTA linearizado permite que se varie o centro e a largura da função.




Fig. 5.8: Diagrama completo do circuito FBR.

Os OTA's 1 e 2 realizam uma função secante hiperbólica quadrática fixa com relação ao centro e à largura. O terceiro OTA executa a função de multiplicador. Assim, o circuito FBR completo realiza a seguinte função:

$$f(x, b, c, w) = w \cdot (\text{sech}(b(x - c)))^2 \quad (5.2)$$

sendo: c - centro;

b - largura;

w - amplitude.

A realização da gaussiana é feita da mesma forma. Trata-se na verdade de uma aproximação. Conforme pode-se notar nas figuras 5.11 e 5.12, o circuito aproxima muito bem ambas as funções de base.




Fig. 5.9: Curva típica da resposta do circuito FBR.




Fig. 5.10: Resposta do circuito FBR para correntes de polarização i_{b3} variando entre 20 μA e 100 μA .

5.5. Circuito FBR Multivariável

O circuito FBR com OTA pode ser facilmente convertido para o caso com múltiplas variáveis de entrada. Para isso, basta se acrescentar tantos OTA's linearizados quanto seja a dimensão da entrada. A equação que descreve o circuito fica:

$$f(\mathbf{x}) = w \cdot \text{sech}^2(b_1(x_1 - c_1) + b_2(x_2 - c_2) + \dots + b_n(x_n - c_n)) \quad (5.3)$$

O esquema eletrônico do circuito está apresentado a seguir:




Fig. 5.11: Diagrama do circuito FBR multivariável.

5.6. Resultados Experimentais

Na implementação prática, as fontes de corrente foram substituídas por resistores e as fontes de tensão de centro por divisores resistivos. Na Figura 5.12 é apresentada a curva experimental da saída de uma FBR típica para uma entrada triangular, obtida no osciloscópio. Na Figura 5.13 é apresentado um gráfico do tipo XY, o qual mostra a característica da FBR.




Fig.5.12: Saída da FBR para uma entrada triangular.




Fig. 5.13: Curva experimental obtida para o circuito FBR.

Nas Figuras 5.14 e 5.15 mostra-se a comparação da FBR implementada com uma gaussiana e uma SHQ.




Fig. 5.14: Comparação entre a FBR experimental e uma gaussiana teórica com $c=0$, $b=0.4669$ e $w=1.3$.




Fig. 5.15: Comparação entre a FBR experimental e uma SHQ teórica com $c=0$, $b=0.77$ e $w=1.3369$.

5.7. Discussão e Conclusões

Neste capítulo foi apresentado o circuito FBR implementado na prática. Foram realizadas simulações para o caso unidimensional. Os resultados das simulações foram compatíveis com o esperado teoricamente. Os resultados experimentais demonstraram que o circuito pode ser usado tanto para implementação da função gaussiana quanto da função SHQ, com resultados satisfatórios em ambos os casos.

Entretanto, deve-se salientar que há certos desvios entre a simulação e a prática. A amplitude da função, para uma determinada corrente de polarização, é menor que na simulada. Isto provavelmente se deve a uma falha no modelo do OTA LM13600N no Spice, visto que o circuito é utilizado no seu limite e não da forma usual. Além disso, nota-se uma assimetria entre a parte plana da função (extremos), ou seja, de um lado ela sofre um desvio para cima do zero e do outro lado fica abaixo de zero. Este efeito varia de um circuito para outro e não compromete o seu funcionamento pois pode ser corrigido com variações adequadas nas correntes de polarização dos OTA's da saída. Estes problemas podem também ter a sua origem devido a efeitos de temperatura que restam ser estudados.



CAPÍTULO 6

Aplicações do Circuito

6.1. Introdução

Neste capítulo serão apresentadas as aplicações práticas usadas para demonstrar a capacidade da RNFBR proposta. O esquema básico da rede implementada é como está mostrado na Fig.6.1. Em cada aplicação foi utilizado um número específico de unidades FBR, variando de dois a quatro dependendo de cada necessidade.




Fig.6.1: Diagrama esquemático básico da RNFBR utilizada.

O processo de treinamento foi “off-line”, ou seja, a rede foi simulada no computador até que fosse considerado satisfatório seu desempenho. Os algoritmos utilizados para realizar o aprendizado são baseados no método do gradiente descendente e podem ser visualizados no apêndice. Após a fase de treinamento “off-line”, partindo dos dados simulados, foram ajustados os potenciômetros de cada função implementada, utilizando-se o osciloscópio.

6.2. Aproximação da Função Senoidal

A primeira aplicação da RNFBR foi a aproximação de uma função senoidal. Na literatura, há alguns circuitos que podem ser utilizados para conversão de onda triangular-senoidal [20], [24], [26]. A RNFBR proposta nesta tese pode ser considerada uma generalização desses circuitos, pois ela permite a aproximação ou síntese de praticamente qualquer função, desde que se disponha de um número suficientemente grande de funções de base. Desta forma, o circuito pode ser muito útil na implementação integrada ou discreta de qualquer função não-linear.

A função senoidal que se deseja aproximar é dada por:

$$f(x) = \text{sen}(1.6x) \quad (6.1)$$



Após o treinamento da rede, obteve-se os seguintes parâmetros para as funções SHQ:

Função SHQ	c	b	w
1	0.7	0.8	1.4
2	-0.7	-0.8	-1.4

Tabela 6.1: Parâmetros da RNFBR que aproxima uma senóide.




Figura 6.2: FBR's encontradas na aproximação de senóide.




Fig. 6.3: Função senoidal (o) versus a aproximação da rede teórica (*).




Fig. 6.4: Função senoidal (curva lisa) e a aproximação experimental (curva com ruído).




Fig.6.5: Curva experimental na tela do osciloscópio digital.




Fig.6.6: Resultado da aproximação de senóide
(experimental versus teórico).




Fig.6.7: Gráfico do Erro (diferença ponto-a-ponto entre a curva experimental e a ideal).

6.3. Aproximação da Função Sinc

Esta aplicação serve para demonstrar a capacidade do circuito em realizar outras funções. A função sinc que se deseja aproximar é dada por:

$$\text{sinc}(x) = \frac{\text{sen } o(x)}{x} \quad (6.2)$$

O gráfico desta função é apresentado na próxima figura. Utilizou-se um fator de escala na variável x , da ordem de 3.5, ou seja, a fim de adequar a função às tensões disponíveis na implementação, substituiu-se x por $3.5 x$.




Figura 6.8: Gráfico da função sinc.

Após o treinamento da rede, obtiveram-se os seguintes parâmetros para as funções SHQ:

Função SHQ	c	b	w
1	-0.0030	1.8332	1.2759
2	1.9467	2.6414	0.3488
3	3.5725	1.1721	0.2754
4	4.8753	3.7655	0.2216

Tabela 6.2: Parâmetros da RNFBR que aproxima uma função Sinc.




Figura 6.9: FBR's obtidas no aprendizado da função sinc.




Figura 6.10: Função sinc teórica e a aproximação da rede.




Figura 6.11: Curvas experimentais na tela do osciloscópio digital.

Onda triangular na entrada (acima) e saída da rede (abaixo).

6.4. Linearização de Termistor

Transdutores são dispositivos que convertem sinais de diversas formas de energia (mecânica, química, eletromagnética, etc.) em sinais elétricos (tensão ou corrente), tendo uma ampla utilização em instrumentação eletrônica. Idealmente, deseja-se que um transdutor seja linear em uma larga faixa de trabalho. No entanto, a maioria dos transdutores apresenta uma característica exponencial ou logarítmica. Assim sendo, muitas técnicas digitais e analógicas foram apresentadas na literatura para sua linearização [28], [29]. Em consequência da característica de aprendizado da RNFBR, ela pode ser empregada nessa tarefa, fazendo que a rede aprenda a função inversa da característica do transdutor e aplicando-a à saída do sensor.

Neste trabalho, foram utilizados a ponte de termistor e sensor integrado de referência encontrados no Sistema de Controle de Temperatura de Fluxo de Ar (Degem SystemsTM). O esquema da ponte e de sua resposta característica são apresentados nas Figuras 6.12 e 6.13, respectivamente.




Fig.6.12: Diagrama da ponte com termistor.




Fig.6.13: Resposta da ponte com termistor.

A função inversa, a ser aprendida, é apresentada na Fig.6.14 e a aproximação obtida pela rede com três gaussianas é mostrada na Fig.6.15.




Fig.6.14: Inversa da resposta do termistor.




Fig.6.15: Gráfico da rede simulada e os pontos (o) usados na fase de aprendizado da função inversa.

As funções gaussianas encontradas no aprendizado são mostradas na Tabela 6.3 e na Figura 6.16.

Função Gaussiana	c	b	w
1	1.3946	0.0000	1.4877
2	3.6274	0.0994	2.4330
3	4.9195	0.5258	3.1568

Tabela 6.3: Parâmetros da RNFBR usadas na linearização de termistor.




Fig.6.16: FBR’s teóricas encontradas na simulação.

Na Figura 6.17 é apresentado o resultado experimental obtido com a rede acoplada à ponte de termistor e na Fig.6.18 pode-se visualizar o erro percentual entre a curva prática e a curva linear ideal. Nota-se que o erro percentual ficou abaixo de $\pm 2\%$.




Fig.6.17: Curva experimental do conjunto Ponte-RNFBR.




Fig.6.18: Gráfico do erro percentual entre a resposta experimental e a ideal.

6.5. Linearização de VCO

A linearização de um VCO (oscilador controlado por tensão) tem o propósito de testar a performance da rede. Usualmente, o VCO é usado para geração de sinais. A configuração implementada neste trabalho, utilizando o CI 555, é apresentada na Fig.6.19. Por meio de uma tensão V_{con} , aplicada ao pino 5, a frequência do oscilador pode ser variada numa determinada faixa [30]. Essa configuração foi escolhida de tal modo a evidenciar a não-linearidade entre a tensão de controle e a frequência na saída. Os valores dos componentes utilizados são: $R_a = 100k\Omega$, $R_b = 10k\Omega$ e $C = 22nF$.




Fig.6.19: Circuito VCO com temporizador 555.

Na Fig.6.20 é apresentada a característica de variação na frequência de saída em função da tensão de controle V_{con} . Na Fig. 6.21, é feita uma comparação entre esta curva e sua inversa.




Fig.6.20: Gráfico da resposta do VCO em função de V_{con} .




Fig.6.21: Gráfico mostrando a curva característica do VCO e a sua inversa.

A aproximação obtida pela rede é apresentada na Figura 6.22 e as FBR's obtidas no aprendizado são mostradas na Tabela 6.4 e a sua representação gráfica na Figura 6.23.




Fig.6.22: Gráfico mostrando a curva desejada (pontilhada) e a aproximação teórica da rede após o processo de aprendizado.

Função SHQ	c	b	w
1	-0.1225	1.1399	10.7545
2	1.1334	0.5845	3.1189
3	3.6928	0.0000	0.7830

Tabela 6.4: Parâmetros da RNFBR usadas na linearização do VCO.




Fig.6.23: Gráfico das FBR's obtidas no treinamento.

O resultado final da linearização do VCO pode ser visto na Figura abaixo:




Fig.6.24: Resultado experimental e simulado.

6.6. Conclusões

Neste capítulo, foram apresentadas algumas aplicações práticas da RNFBR proposta. Foi realizada a aproximação de duas funções: senoidal e sinc. Foi obtida uma aproximação razoável, porém não ótima. Isto se deve ao fato de não se dispor de uma rede com maior número de FBR's. Além disso, foram feitas duas linearizações de circuitos não-lineares. A primeira, uma ponte de Wheatstone com termistor. Os resultados foram considerados excelentes, visto que o erro percentual da prática, em relação ao que seria ideal, foi de apenas $\pm 2\%$. A segunda linearização foi de um oscilador controlado por tensão (VCO). Os resultados experimentais também foram compatíveis com o que era esperado.

CAPÍTULO 7

Conclusões Finais

As Redes Neurais Artificiais têm-se mostrado promissoras na resolução de diversos problemas científicos e tecnológicos da atualidade, como por exemplo, a inteligência artificial. Nesse sentido, para aproveitar a característica de paralelismo das redes, a implementação eletrônica surge como a melhor opção, sendo que a implementação analógica apresenta muitas vantagens em relação às propostas digitais, visto que a sua abordagem é totalmente paralela.

Neste trabalho, o objetivo visado foi a proposição e a implementação prática de um circuito que realiza uma Rede Neural com Função de Base Radial. O circuito proposto e implementado apresentou um bom desempenho tanto na realização da função gaussiana quanto da secante hiperbólica quadrática. Ele permite o ajuste de todos os parâmetros de forma das funções, tais como: amplitude, centro e largura, assim como pode ser utilizado no caso de múltiplas variáveis de entrada.

Apesar de algumas não-idealidades presentes no circuito prático, elas não se constituem em uma limitação severa, pois podem ser contrabalançadas por ajustes adequados nas correntes de polarização dos OTA's e uma tensão de centro conveniente na entrada do circuito.

A rede implementada foi aplicada à resolução de variados problemas de aproximação de funções e linearização de circuitos não-lineares.

No tocante às aproximações, foi realizada a aproximação de duas funções: senoidal e sinc. Foi obtida uma aproximação razoável, porém não ótima. Isto se deve ao fato de não se dispor de uma rede com maior número de FBR's.



Além disso, foram feitas duas linearizações. A primeira, uma ponte de Wheatstone com termistor. Os resultados foram considerados excelentes, visto que o erro percentual da prática, em relação ao que seria ideal, foi de apenas $\pm 2\%$. A segunda linearização foi de um VCO. Os resultados experimentais também foram compatíveis com o que era esperado.

Propostas para trabalhos futuros:

- integrar o circuito FBR completo uni e multi-variável;
- estudar a utilização do transistor MOS porta flutuante (FGMOS) como memória analógica;
- estudar a utilização do par diferencial MOS para implementação de FBR;
- compensação de efeitos de temperatura;
- aprendizado “on-chip” e “chip-in-the-loop”;
- aplicação do circuito a problemas multi-dimensionais como, por exemplo: controle automático, reconhecimento de padrões, lógica nebulosa, etc...



Referências Bibliográficas

- [01] LONT J. B. and GUGGENBÜHL W., "Analog CMOS Implementation of a Multilayer Perceptron with Nonlinear Synapses". IEEE Trans. on Neural Networks, vol. 3, no. 3, May 1992, pp. 457-465.
- [02] CHOI J., SHEU B. J. and CHANG C. F., "A Gaussian Synapse Circuit for Analog VLSI Neural Networks". IEEE Trans. on VLSI Systems, vol. 2, no. 1, March 1994, pp. 129-133.
- [03] WIDROW B. and LEHR M. A., "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation". Proc. IEEE, vol. 78, no. 9, Sept. 1990, pp. 1415-1442.
- [04] ORR M. J. L., "Introduction to Radial Basis Function Networks". Manual, April, 1996.
- [05] ABELES M., "Corticonics - Neural Circuits of the Cerebral Cortex". Cambridge University Press, first edition, 1991.
- [06] HAYKINS S., "Neural Networks - A Comprehensive Foundation". Macmillan Publisher Company, 1994.
- [07] WASSERMAN P. D., "Neural Computing : Theory and Practice". Van Nostrand Reinhold, 1989.
- [08] LEE S. and KIL R. M., "A Gaussian Potential Function Network With Hierarchically Self-Organizing Learning". Neural Networks, vol. 4, 1991, pp. 207-224.



- [9] POGGIO T. and GIROSI F., "A Theory of Networks for Approximation and Learning". AI Memo No. 1140, 1989.
- [10] GABRIJEL I. and DOBNIKAR A., "Adaptive RBF Neural Network". Technical Report, University of Ljubljana, 1998.
- [11] GABRIJEL I. and DOBNIKAR A. and STEELE N., "RBF Neural Networks and Fuzzy Logic Based Control - a Case Study". Proc. 2nd IMACS, Hammamet, Tunisia, vol.2, April 1998, pp. 284- 289.
- [12] DUONG T. A., EBERHARDT S. P., DAUD T. and THAKOOR A., "Learning in Neural Networks: VLSI Implementation Strategies". JPL Technical Report, Pasadena, CA.
- [13] SIGVARTSEN R. L., "An Analog Neural Network with On-Chip Learning". M.Sc. Thesis, August, 1994.
- [14] SOELBERG K., SIGVARTSEN R. L., LANDE T. S. and BERG Y., "An Analog Continuous-Time Neural Network". Technical Report, November, 1993.
- [15] ANDREOU A. G., BOAHEN K. A., POULIQUEN P. O., PAVASOVIC A., JENKINS R. E. and STROHBEHN K., "Current-Mode Subthreshold MOS Circuits for Analog VLSI Neural Systems". IEEE Trans. on Neural Networks, vol.2, no.2, March, 1991, pp. 205-213.
- [16] ALMEIDA A. P. and FRANCA J. E., "Digitally Programmable Analog Building Blocks for the Implementation of Artificial Neural Networks". IEEE Trans. on Neural Networks, vol.7, no.2, March, 1996, pp. 506-514.
- [17] DELBRÜCK T., "Bump Circuits - for computing similarity and dissimilarity of analog voltages". CNS MEMO 26, May 24, 1993.



- [18] MADRENAS J., VERLEYSEN M., THISSEN P. and VOZ J. L., "A CMOS Analog Circuit for Gaussian Functions". IEEE Trans. on Circuits and Systems-II : Analog and Digital Signal Processing, vol. 43, no. 1, January 1996, pp. 70-74.
- [19] THEOGARAJAN L. and AKERS L. A., "A Scalable Low Voltage Analog Gaussian Radial Basis Circuit". IEEE Trans. on Circuits and Systems-II: Analog and Digital Signal Processing, vol.44, no.11,pp. 977-979, November 1997.
- [20] TURCHETTI C. and CONTI M., "A General Approach to Nonlinear Synthesis with MOS Analog Circuits". IEEE Trans. on Circuits and Systems-I: Fundamental Theory and Applications, vol.40, no.9, September, 1993.
- [21] WATKINS S. S. and CHAU P. M., "A Radial Basis Function Neurocomputer Implemented with Analog VLSI Circuits". Int. Joint Conf. on Neural Networks, 1992, vol.2, pp. 607-612.
- [22] CHURCHER S., MURRAY A. F. and REEKIE H. M., "Programmable Analogue VLSI for Radial Basis Function Networks". Electronic Letters, 2nd September 1993, vol.29, no.18, pp. 1603-1605.
- [23] GREBENE A. B., "Bipolar and MOS Analog Integrated Circuit Design," John Wiley and Sons, 1984.
- [24] TOUMAZOU C., LIDGEY F. J. and HAIGH D. G., "Analogue IC Design: The Current-Mode Approach". IEE Circuits and Systems Series, 1990.
- [25] KIMURA K., "Some Circuit Design Techniques for Low-Voltage Analog Functional Elements Using Squaring Circuits". IEEE Trans. on Circuits and Systems - I: Fundamental Theory and Applications, vol. 43, no. 7, July 1996, pp. 559-576.



- [26] FRANCO S., "Design with Operational Amplifiers and Analog Integrated Circuits". McGraw-Hill, 1988.
- [27] DATA SHEET, "LM13600N Dual Operational Transconductance Amplifiers with Linearizing Diodes and Buffers". National Semiconductor DataBook.
- [28] PATRANABIS D., GHOSH S. and BAKSHI C., "Linearizing Transducer Characteristics". IEEE Trans. on Instrumentation and Measurements, vol.37, pp. 66-69, March 1988.
- [29] PATRANABIS D. and GHOSH S., "A Novel Software-Based Transducer Linearizer". IEEE Trans. on Instrumentation and Measurements, vol.38, pp. 1122-1126, December 1989.
- [30] MALVINO A. P., "Eletrônica - Volume II". McGraw-Hill, 1986.
- [31] GOTO S., NAKAMURA M. and KYURA N., "Accurate Contour Control of Mechatronic Servo Systems Using Gaussian Networks". IEEE Trans. on Industrial Electronics, vol. 43, no. 4, August 1996, pp. 469-476.
- [32] CHEN S., COWAN C. F. N. and GRANT P. M., "Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks". IEEE Trans. on Neural Networks, vol. 2, no. 2, March 1991, pp. 302-309.
- [33] LUCKS M. B., CARVALHO A. A. e TEIXEIRA M. C. M., "Modelamento de um Sensor Táctil Piezo-Resistivo com Redes Neurónais Artificiais". Anais do III Fórum Nacional de Ciência e Tecnologia em Saúde, vol. 2, p. 629-630, Outubro, 1996.
- [34] LIN S-Y., HUANG R-J. and CHIUEH T-D., "A Tunable Gaussian/Square Function Computation Circuit for Analog Neural Networks". IEEE Trans. on



Circuits and Systems-II: Analog and Digital Signal Processing, vol.45, no.3., pp. 441-446, March 1988.

- [35] ROSENBLUM M. and DAVIS L. S., "An Improved Radial Basis Function Network for Visual Autonomous Road Following". IEEE Trans. on Neural Networks, vol.7, no.5, pp. 1111-1120, September 1996.
- [36] ROSENBLUM M., YACOOB Y. and DAVIS L. S., "Human Express Recognition from Motion Using Radial Basis Function Network for Visual Architecture". IEEE Trans. on Neural Networks, vol.7, no.5, pp. 1121-1137, September 1996.
- [37] SEDRA A. S. and ROBERTS G. W., "SPICE for Microelectronic Circuits". Oxford University Press, third edition, 1992.
- [38] RICHMOND A. E., "Calculus for Electronics". McGraw-Hill, third edition.
- [39] MULGREW B., "Applying Radial Basis Functions". IEEE Signal Processing Magazine, March, 1996.



APÊNDICE



APÊNDICE

Neste apêndice serão dadas algumas informações adicionais a respeito das equações e métodos utilizados no aprendizado da RNFBR.

A.1. Método do Gradiente Descendente

Este foi o método escolhido para efetuar o aprendizado das RNFBR's constantes deste trabalho, pois ele permite que se ajuste todos os parâmetros da rede. O esquema básico para implementação desse método parte da configuração mostrada na Figura A.1.




Figura A.1: Esquema para aprendizado da rede.

sendo: $x_p \Rightarrow$ p-ésimo padrão de entrada;

$y_p \Rightarrow$ saída da rede para entrada x_p ;

$d_p \Rightarrow$ saída desejada para entrada d_p (corresponde ao valor da função a ser aprendida).

Define-se uma função de erro quadrático a ser minimizada no aprendizado, dada por:

$$E = \sum_{p=1}^N \frac{1}{2} (d_p - y_p)^2 \quad (\text{A.1})$$

Desta forma, as equações para o aprendizado são apresentadas a seguir:

A.1.1. FBR Gaussiana

As equações para o aprendizado da rede com FBR gaussiana são dadas abaixo:

$$\frac{\partial E}{\partial w_i} = \sum_{p=1}^N g_{ip} \cdot (y_p - d_p) \quad (\text{A.2})$$

$$\frac{\partial E}{\partial c_i} = \sum_{p=1}^N 2 \cdot b_i \cdot w_i \cdot g_{ip} \cdot (y_p - d_p) \cdot (x_p - c_i) \quad (\text{A.3})$$

$$\frac{\partial E}{\partial b_i} = \sum_{p=1}^N -w_i \cdot g_{ip} \cdot (y_p - d_p) \cdot (x_p - c_i)^2 \quad (\text{A.4})$$

sendo: $g_{ip} = \exp(-b_i(x_p - c_i)^2)$;
 c_i = centro da i -ésima FBR;
 b_i = largura da i -ésima FBR;
 w_i = amplitude da i -ésima FBR.

A.1.2. Função SHQ

Para funções do tipo secante hiperbólica quadrática, as equações do aprendizado ficam:

$$\frac{\partial E}{\partial w_i} = \sum_{p=1}^N \text{sip} \cdot (y_p - d_p) \quad (\text{A.5})$$

$$\frac{\partial E}{\partial b_i} = \sum_{p=1}^N 2w_i \cdot \text{tip} \cdot \text{sip} \cdot (y_p - d_p)(x_p - c_i) \quad (\text{A.6})$$

$$\frac{\partial E}{\partial c_i} = \sum_{p=1}^N -2 \cdot b_i \cdot w_i \cdot \text{tip} \cdot \text{sip} \quad (\text{A.7})$$

sendo :

$$\text{tip} = \tanh(b_i(x_p - c_i)); \quad (\text{A.8})$$

$$\text{sip} = \text{sech}^2(b_i(x_p - c_i)). \quad (\text{A.9})$$

A.2. Método de Moody-Darken

Neste item serão apresentadas os métodos de agrupamento e ajuste da largura das FBR's no método de Moody-Darken.

A.2.1. O Algoritmo "K-means"

Trata-se de um algoritmo de agrupamento de centros e consiste em movimentar os centros das FBR's em direção aos pontos da função mais próximos deles.

A equação para esse procedimento é:

$$\Delta c_i(t+1) = c_i(t) + k.[c_i(t) - x_{+prox}(t)] \quad (\text{A.10})$$

sendo : $c_i \Rightarrow$ centro da i-ésima FBR;

$x_{+prox} \Rightarrow$ padrão de entrada mais próximo do i-ésimo centro

$k \Rightarrow$ taxa de ajuste do centro

$\Delta c_i \Rightarrow$ variação no centro.

Na figura seguinte pode-se melhor visualizar esse processo.






Figura A.2: Demonstração gráfica do algoritmo “k-means”.

A.2.2. O Algoritmo “P-nearest”

Este algoritmo adapta as larguras das FBR's com base na minimização da seguinte função:

$$E = \frac{1}{2} \sum_i \left[\sum_j f(c_j) \cdot (c_i - c_j)^2 \cdot b_i - P \right]^2 \quad (\text{A.11})$$

sendo: $P \Rightarrow$ fator de sobreposição.

A.3. Implementação Computacional

Os algoritmos de aprendizado foram implementados no software MatLab, versão 4.0. A seguir, apresentam-se as funções e programas desenvolvidos.

A.3.1. FBR Gaussiana

```
% Função aprend.m
% utilizada no aprendizado com FBR's gaussianas
erro=[ ];eqs=0;
for j=1:maxiter
    saida;
    erro=[erro eqs];
    if eqs>eqsmaxd
        cdeltaw;
        cdeltab;
        cdeltac;
        w=w+deltaw;
        c=c+deltac;
        b=abs(b+deltab);
    else
        break;
    end
end
saida
figure(1);plot(xd,yd,xd,yd);grid
figure(2);plot(xd,yd,xd,y);grid
figure(3);plot(erro);

% Função saida.m
% Cálculo da Saída da Rede
for i=1:m
    g(i,1:n)=vgauss(xd,a(i),b(i),c(i));
end;
y=w*g;
eqs=sumsq(y-yd);
```



```

% Função cdeltaw.m
% Atualização dos pesos w(i) da rede
dEpdw=zeros(size(yd));
for i=1:m
    dEpdw(i,1:n)=g(i,1:n).*(y-yd);
end
daux=dEpdw';
dEdw=sum(daux);
deltaw=-miw*dEdw;

% Função cdeltab
% Atualização dos parâmetros de abertura b(i) da rede
dEpdb=zeros(size(yd));
for i=1:m
    dEpdb(i,1:n)=-w(i)*dEpdw(i,1:n).*(xd-c(i)*ones(size(xd))).^2;
end
daux=dEpdb';
dEdb=sum(daux);
deltab=-mib*dEdb;

% Função cdeltac
% Atualização dos centros c(i) da rede
dEpdc=zeros(size(yd));
for i=1:m
    dEpdc(i,1:n)=2*b(i)*w(i)*dEpdw(i,1:n).*(xd-c(i)*ones(size(xd)));
end
daux=dEpdc';
dEdc=sum(daux);
deltac=-mic*dEdc;

```



A.3.2. FBR SHQ

```
% Função aprends.m
% Esta função efetua o aprendizado para redes
% com FBR do tipo SHQ
erro=[];eqs=0;
for j=1:maxiter
    saidasec;
    erro=[erro eqs];
    if eqs>eqsmaxd
        t=t*.9;
        % Atualização dos pesos w(i) da rede
        dEpdw=zeros(size(yd));
        for i=1:m
            dEpdw(i,1:n)=gs(i,1:n).*(y-yd);
        end
        daux=dEpdw';
        dEdw=sum(daux);
        deltaw=-miw*dEdw;
        % Atualização dos parâmetros de abertura b(i) da rede
        dEpdb=zeros(size(yd));
        for i=1:m
            dEpdb(i,1:n)=-2*w(i)*dEpdw(i,1:n).*(xd-
c(i)*ones(size(xd))).*(tanh(b(i)*(xd-c(i)*ones(size(xd)))));
        end
        daux=dEpdb';
        dEdb=sum(daux);
        deltab=-mib*dEdb;
        %cdeltac;
        % Atualização dos centros c(i) da rede
        dEpdc=zeros(size(yd));
        for i=1:m
            dEpdc(i,1:n)=2*b(i)*w(i)*dEpdw(i,1:n).*tanh(b(i)*(xd-
c(i)*ones(size(xd))));
        end
        daux=dEpdc';
        dEdc=sum(daux);
        deltac=-mic*dEdc;
        w=w+deltaw+t*randn(1,m);
        c=c+deltac+t*randn(1,m);
        b=b+deltab+t*randn(1,m);
    end;
```

```

end
end
saidasec
figure(1);plot(xd,yd,xd,yd);grid
figure(2);plot(xd,yd,xd,y);grid
figure(3);plot(erro);

% Função saidasec.m
% Cálculo da Saída da Rede usando sech^2
gs=[];y=[];
for i=1:m
    gs(i,1:n)=vsec2(xd,b(i),c(i));
end;
y=w*gs;
eqs=sumsqr(y-yd);

% função vsec2.m
% calcula uma FBR do tipo SHQ
function y = vsec2(x,b,c)
c=c*ones(size(x));
y=(sech(b*(x-c))).^2;

```

A.4. Considerações Sobre o Ajuste dos Pesos no Circuito Prático

Neste trabalho, foi utilizado o aprendizado “off-line”. Desta forma, os valores teóricos dos parâmetros de forma das FBR's foram obtidos via simulação no computador, restando a tarefa de transpor os valores encontrados para o circuito prático.

Os parâmetros ajustáveis foram implementados na prática por potenciômetros e o ajuste foi realizado com o auxílio do osciloscópio. Devido às características de interdependência entre os parâmetros foi necessário utilizar o osciloscópio, de forma que possibilitasse acompanhar visualmente todos os parâmetros simultaneamente. Se este problema de interdependência for resolvido, o ajuste será facilitado, bastando tomar alguns pontos da função usando o voltímetro.



UNIVERSIDADE ESTADUAL PAULISTA - UNESP
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
AV. BRASIL, 56 - CAIXA POSTAL 31
15385-000 - ILHA SOLTEIRA - SP

