

UNIVERSIDADE ESTADUAL PAULISTA

Instituto de Geociências e Ciências Exatas

Campus de Rio Claro

MODELO DO BULBO OLFATIVO BASEADO EM  
REDES NEURAIS RECORRENTES

Luciano Ferro

Orientador: Prof. Dr. José Roberto Campanha

Dissertação de Mestrado elaborada junto ao Programa de Pós-Graduação em Física – Área de Concentração em Física Aplicada, para obtenção do Título de Mestre em Física Aplicada

Rio Claro (SP)

2007

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

530.15 Ferro, Luciano

F395m Modelo do bulbo olfativo baseado em redes neurais recorrentes / Luciano Ferro. – Rio Claro : [s.d.], 2007  
97 f. : il., figs., gráfs., tabs.

Dissertação (mestrado) – Universidade Estadual Paulista,  
Instituto de Geociências e Ciências Exatas  
Orientador: José Roberto Campanha

1. Física matemática. 2. Caos. 3. Odorantes. 4. Simulação Computacional. 5. Sistemas dinâmicos. I. Título.

Comissão Examinadora

---

Prof. Dr. Márcio Luiz de Andrade Netto

---

Prof. Dr. Gerson Antonio Santarine

---

Prof. Dr. José Roberto Campanha

---

Aluno: Luciano Ferro

Rio Claro, 02 de julho de 2007.

Resultado: Aprovado.

## DEDICATÓRIA

À minha esposa Maria, à minha filha Claudia, à  
minha neta Giovanna e aos meus pais Gastone e  
Violetta (in memoriam).

## AGRADECIMENTOS

Ao Prof. Dr. José Roberto Campanha pela orientação deste trabalho, pela dedicada amizade, pelo apoio e estímulo e pelos conhecimentos transmitidos.

À COPEMA (Comissão Permanente do Magistério), da Academia da Força Aérea, pelo apoio e pelas facilidades concedidas para que pudéssemos concluir este trabalho.

Aos professores e funcionários do Departamento de Física da UNESP de Rio Claro (SP) pelo apoio, incentivo e ensinamentos transmitidos.

Aos colegas de curso Natale Chierice Júnior, Luiz Roberto Salomão e Sidney Jorge Schinaider pela amizade e pelo apoio.

A todos aqueles que, de alguma forma, colaboraram para a realização deste trabalho.

## SUMÁRIO

Índice.....	i
Índice de Figuras.....	iii
Índice de Tabelas.....	vii
Resumo.....	viii
Abstract.....	ix
1 – Introdução .....	1
2 – Redes Neurais Artificiais.....	3
3 – Os Expoentes Característicos de Lyapunov e a Transformada Rápida de Fourier.....	24
4 – O Olfato Humano e uma Tentativa de Simulação Computacional dos Neurônios	
Receptores Olfativos.....	30
5 – Conclusões e Sugestões.....	84
Anexo 1.....	86
Referências Bibliográficas.....	89

## ÍNDICE

1 – Introdução.....	1
2 – Redes Neurais Artificiais.....	3
2.1. – Redes Neurais Artificiais.....	3
2.2. – Um Breve Histórico sobre as Redes Neurais.....	13
2.3. – Os Tipos de Redes.....	19
2.4. – Redes Neurais e Caos.....	20
3 – Os Expoentes Característicos de Lyapunov e a Transformada Rápida de Fourier....	24
3.1. – Os Expoentes Característicos de Lyapunov.....	24
3.2. – A Transformada Rápida de Fourier.....	28
4 – O Olfato Humano e uma Tentativa de Simulação Computacional dos Neurônios	
Receptores Olfativos.....	30
4.1. – Um Breve Relato do Sistema Olfativo Humano.....	30
4.2. – A Estrutura Básica de uma Rede Neural com Dois Neurônios.....	33
4.3. – Rede Neural de Quatro Neurônios.....	45
4.4. – Rede Neural de Seis Neurônios.....	58
4.5. – Rede Neural de Oito Neurônios.....	65
5 – Conclusões e Sugestões.....	84

Anexo 1.....	86
Referências Bibliográficas.....	89

## ÍNDICE DE FIGURAS

FIGURA 2.1 – O neurônio humano.....	4
FIGURA 2.2 – O potencial de ação durante a aplicação de um estímulo.....	6
FIGURA 2.3 – Um modelo de rede direta.....	8
FIGURA 2.4 – Um modelo de rede recorrente.....	9
FIGURA 2.5 – Um neurônio artificial.....	11
FIGURA 2.6 – A função logística e a sua derivada.....	12
FIGURA 2.7 – A função tangente hiperbólica e a sua derivada.....	12
FIGURA 2.8 – O neurônio de McCulloch/Pitts.....	14
FIGURA 2.9 – O perceptron de Rosenblatt.....	16
FIGURA 3.1 – O LCE aplicado sobre o mapa logístico.....	27
FIGURA 3.2 – O LCE aplicado para $r$ em $[19,20]$ , sobre o mapa $z$ .....	28
FIGURA 4.1 – O sistema olfativo humano, conforme figura retirada do sítio <a href="http://www.nobelprize.org">http://www.nobelprize.org</a> .....	31
FIGURA 4.2(a) – Na ausência de odorantes, o comportamento da rede é caótico, conforme quadro, onde aparece o espectro de frequências de bandas largas, após a aplicação da FFT sobre o sinal emitido.....	34
FIGURA 4.2(b) – Quando a rede reconhece um odorante, o seu comportamento deixa de ser caótico, como é mostrado no quadro onde aparecem somente duas amplitudes (ou magnitudes) no espectro de	

frequências, após a aplicação da FFT sobre o sinal emitido.....	34
FIGURA 4.3(a) – Estrutura básica da rede neural recorrente de dois neurônios.....	35
FIGURA 4.3(b) – Estrutura básica da rede de dois neurônios e a sua forma simplificada equivalente.....	36
FIGURA 4.4 – Os expoentes de Lyapunov para o parâmetro de ganho $r \in [10,20]$ .....	38
FIGURA 4.5 – Gráfico do neurônio (1) da estrutura básica da rede, após 4,000 iterações..	40
FIGURA 4.6 – Gráfico do neurônio (2) da estrutura básica da rede, após 4,000 iterações..	41
FIGURA 4.7 – Gráfico do neurônio soma (S) da estrutura básica da rede, após 4,000 iteraões.....	41
FIGURA 4.8 – Gráfico do neurônio soma (S). Cem últimas iterações.....	42
FIGURA 4.9 - Gráfico das 2,100 últimas iterações do neurônio soma (pontos isolados de $S(i) \times S(i-1)$ ).....	43
FIGURA 4.10 – O atrator da estrutura básica da rede de dois neurônios.....	43
FIGURA 4.11 – A FFT aplicada ao neurônio soma (S).....	44
FIGURA 4.12 – A FFT aplicada ao neurônio soma (com o logaritmo decimal).....	45
FIGURA 4.13(a) – Arranjo da rede de quatro neurônios.....	46
FIGURA 4.13(b) – Arranjo simplificado da rede de quatro neurônios.....	46
FIGURA 4.14 – Gráfico do neurônio soma (S), após 4,000 iterações.....	49
FIGURA 4.15 – Gráfico do neurônio soma (S). Cem últimas iterações.....	49
FIGURA 4.16 – Gráfico das 2,100 últimas iterações do neurônio soma (pontos isolados de $S(i) \times S(i-1)$ ).....	50
FIGURA 4.17 – O atrator formado pelos neurônios (1) e (2).....	50

FIGURA 4.18 – O atrator formado pelos neurônios (2) e (3).....	51
FIGURA 4.19 – O atrator formado pelos neurônios (3) e (4).....	51
FIGURA 4.20 – A FFT aplicada ao neurônio soma (com o logaritmo decimal).....	52
FIGURA 4.21(a) – Na ausência de odorantes, o comportamento da rede é caótico.....	53
FIGURA 4.21(b) – Quando o odorante se fixa no receptor, o valor da sinapse $q_1$ muda de $\theta$ para $0.035$ e faz com que a rede mude para o comportamento não-caótico.....	54
FIGURA 4.21(c) – Estilização da FIGURA 4.21(b).....	55
FIGURA 4.22 – Gráfico do neurônio soma (S). Cem últimas iterações.....	56
FIGURA 4.23 – O atrator para o caso não-caótico.....	56
FIGURA 4.24 – O arranjo da rede de seis neurônios.....	58
FIGURA 4.25(a) – Na ausência de odorantes, o comportamento da rede é caótico.....	60
FIGURA 4.25(b) – Quando a molécula odorífera se liga ao receptor o comportamento da rede passa a ser não-caótico (padrão AB, neste caso).....	60
FIGURA 4.26 – O arranjo da rede neural de oito neurônios.....	65
FIGURA 4.27 – Gráfico do neurônio soma (S), após 4,000 iterações.....	67
FIGURA 4.28 – Gráfico das cem últimas iterações do neurônio soma (S).....	68
FIGURA 4.29 – Gráfico das 2,100 últimas iterações do neurônio soma (pontos isolados de $S(i)$ por $S(i-1)$ ).....	68
FIGURA 4.30 – O atrator formado pelos neurônios (1) e (2).....	69
FIGURA 4.31 – O atrator formado pelos neurônios (2) e (3).....	69
FIGURA 4.32 – O atrator formado pelos neurônios (3) e (4).....	70

FIGURA 4.33 – O atrator formado pelos neurônios (4) e (5).....	70
FIGURA 4.34 – O atrator formado pelos neurônios (5) e (6).....	71
FIGURA 4.35 – O atrator formado pelos neurônios (6) e (7).....	71
FIGURA 4.36 – O atrator formado pelos neurônios (7) e (8).....	72
FIGURA 4.37 – A FFT aplicada ao neurônio soma (com o logaritmo decimal).....	72
FIGURA 4.38 – Gráfico das cem últimas iterações do neurônio soma (S).....	74
FIGURA 4.39(a) – Na ausência de odorantes, o comportamento da rede é caótico.....	75
FIGURA 4.39(b) – Quando a molécula odorífera se liga ao receptor o comportamento da rede passa a ser não-caótico (padrão AAB, neste caso).....	76
FIGURA 4.39(c) – Estilização da FIGURA 4.39(b).....	76

## ÍNDICE DE TABELAS

TABELA 4.1 – Quadro resumo dos padrões CAÓTICO, A e B (as figuras representam o neurônio soma na forma normalizada).....	57
TABELA 4.2(a) – Quadro resumo dos padrões CAÓTICO, OA e OB (as figuras representam o neurônio soma na forma normalizada).....	63
TABELA 4.2(b) – Quadro resumo dos padrões AA, AB, BA e BB (as figuras representam o neurônio soma na forma normalizada).....	64
TABELA 4.3 – Os expoentes de Lyapunov.....	78
TABELA 4.4 – Quadro resumo dos padrões OOA e OOB (as figuras representam o neurônio soma na forma normalizada).....	79
TABELA 4.5 – Quadro resumo dos padrões OAA, OAB, OBA e OBB (as figuras representam o neurônio soma na forma normalizada).....	80
TABELA 4.6 – Quadro resumo dos padrões CAÓTICO, AOA, AOB, BOA e BOB (as figuras representam o neurônio soma na forma normalizada).....	81
TABELA 4.7(a) – Quadro resumo dos padrões AAA, AAB, ABA e BAA (as figuras representam o neurônio soma na forma normalizada).....	82
TABELA 4.7(b) – Quadro resumo dos padrões ABB, BAB, BBA e BBB (as figuras representam o neurônio soma na forma normalizada).....	83

## RESUMO

Neste trabalho construímos modelos de redes neurais artificiais recorrentes com dois, com quatro, com seis e com oito neurônios na tentativa de simular computacionalmente como os neurônios receptores olfativos dos vertebrados, em especial dos seres humanos, conseguem identificar e reconhecer as diferentes moléculas odoríferas (ou odorantes) transportadas pelo ar. Para isso, usamos uma rede que evolui de um sistema dinâmico caótico, na ausência de odorantes, para o não-caótico, quando do reconhecimento de um odor constituído, no máximo, de até três odorantes.

Palavras-chave: caos, odorantes, olfato, redes neurais artificiais, simulação computacional, sistemas dinâmicos.

## ABSTRACT

We built models of recurrent artificial neural networks with two, four, six and eight neurons in order to simulate, using computational simulation, the way vertebrate's olfactory neurons, in special the humans, identify and recognize different odoriferous molecules (or odorants) in the air. For that purpose, we used a network that evolves from a chaotic dynamic system, in the absence of odorants, to the non-chaotic, when it recognizes an odor that is made of, at most, three odorants.

Key-words: artificial neural networks, chaos, computational simulation, dynamic systems, odorants, olfaction.

# **CAPÍTULO 1**

## **Introdução**

O objetivo deste trabalho é o de desenvolver um modelo dos neurônios receptores olfativos dos vertebrados, em especial aqueles dos seres humanos, mas de uma forma bastante simplificada, usando as redes neurais artificiais recorrentes.

A forma simplificada é devida ao fato de que operamos, no máximo, com uma rede neural artificial de oito neurônios, pois todos aqueles que se utilizam dessas redes para os seus trabalhos de pesquisa sabem que à medida que o número de neurônios aumenta, a complexidade dos cálculos aumenta sobremaneira. Desta forma, iniciamos os trabalhos com uma rede neural básica de dois neurônios para, em seguida, progredirmos para uma de quatro, depois para uma de seis e, finalmente, para uma rede de oito neurônios, tendo em vista a intenção de estabelecer as regras que permitem a evolução para redes com dez ou mais neurônios. Começamos os trabalhos de simulação com uma rede neural de dois neurônios, devido ao fato de que, atualmente, os pesquisadores admitem incontestavelmente que uma rede desta forma pode exibir um comportamento caótico.

Para isso, no Capítulo 2, faremos um breve histórico da evolução do conceito e dos modelos das redes neurais artificiais desde o trabalho pioneiro de

McCulloch/Pitts, de 1943, até o presente momento. Discorreremos, em especial, sobre as redes neurais recorrentes tendo em vista que elas permitem a memorização com a consequente recuperação do que foi anteriormente memorizado.

No Capítulo 3, faremos uma exposição da Transformada Rápida de Fourier (FFT, do original em inglês) e de como ela é aplicada no caso discreto e dos Expoentes Característicos de Lyapunov (LCE, do original em inglês), ambos desenvolvidos dentro do software MATLAB® (MATrix LABoratory), os dois métodos matemáticos utilizados para a confirmação e validação dos resultados obtidos sobre a evolução de um sistema dinâmico complexo.

No Capítulo 4, faremos um pequeno relato do sistema olfativo humano e do seu funcionamento, como também de sua simulação computacional em pequena escala, começando com a nossa estrutura básica de trabalho de apenas dois neurônios. Posteriormente, acrescentando outras estruturas similares e ligando-as de duas em duas formaremos as redes de quatro, de seis e de oito neurônios, cujas fórmulas se constituem de mapas discretos. Com a inclusão de parâmetros de controle, para o acoplamento entre as estruturas, a dinâmica do sistema sai de um comportamento caótico, no seu estado fundamental, para um comportamento não-caótico, estabelecendo com isto que a rede é capaz de identificar e reconhecer os odorantes (ou moléculas odoríferas) de um odor (ou cheiro).

No Capítulo 5, abordaremos as conclusões advindas deste trabalho, as quais refletem que os parâmetros de controle foram encontrados, analisados e confirmados para as aplicações no reconhecimento de odorantes, bem como encaminharemos as discussões que a partir dele possam ser desenvolvidas no sentido de sua complementação.

Por fim, são indicados nas Referências Bibliográficas os livros, os artigos e os itens pesquisados, junto à rede Internet de computadores, que usamos neste trabalho.

# **CAPÍTULO 2**

## **Redes Neurais Artificiais**

### **2.1 Redes Neurais Artificiais**

O cérebro humano é constituído principalmente por dois tipos diferentes de células, que são as células glias e os neurônios. As células glias, em número aproximado de dez vezes maior do que o número de neurônios, são responsáveis pela sustentação cerebral, enquanto o neurônio é basicamente a unidade ou elemento de processamento dos sinais e estímulos que recebe e sobre ele estão sendo concentrados os principais estudos no sentido de se simular ou de se modelar mediante um algoritmo o seu comportamento. Ele, por sua vez, é constituído por um corpo celular ou soma, pelo axônio e pelos dendritos, conforme FIGURA 2.1. O cérebro humano através da rede de neurônios e de suas interconexões, também chamadas de sinapses, é responsável pelo pensamento, emoção, cognição. As sinapses ocorrem entre axônios de diferentes neurônios, entre o axônio e o soma e entre os dendritos, segundo WASSERMAN, 1989. Ainda, de acordo com o mesmo autor, o cérebro humano, que possui somente 2% da massa corporal, consome 20% de todo o oxigênio liberado no corpo e somente de 20 a 30w para o seu saudável funcionamento.

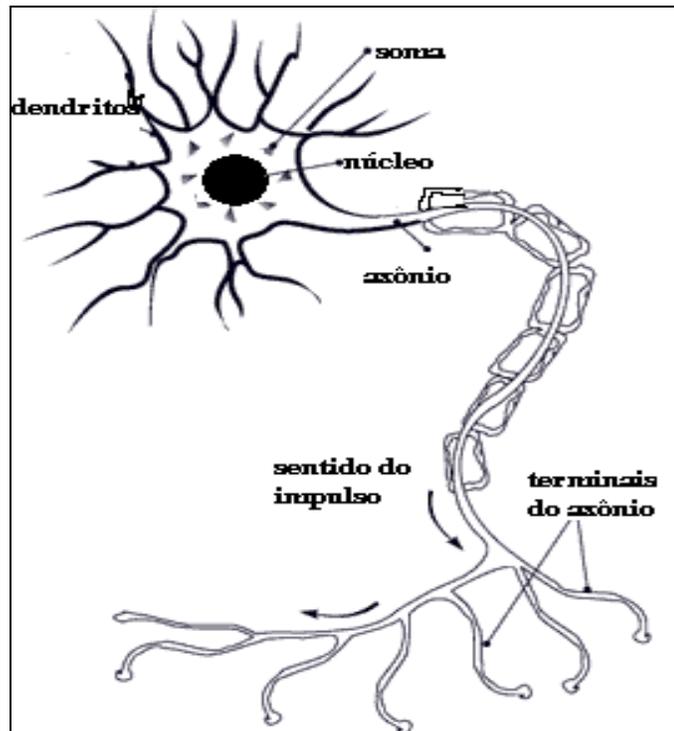


FIGURA 2.1 – O neurônio humano.

Através das sinapses é que um neurônio se interconecta a até outros 10.000 neurônios, num total de aproximadamente 100 bilhões de neurônios dentro do nosso cérebro. Eles não são todos idênticos, diferem quimicamente, estruturalmente ou funcionalmente e já foram encontrados mais de 250 tipos diferentes de neurônios no córtex cerebral. A região intersináptica é eletroquimicamente ativa, local onde já foram descobertas mais de 50 substâncias que executam a rápida intercomunicação, via corrente iônica, entre um neurônio pré-sináptico e um pós-sináptico, por isso elas são denominadas apropriadamente de neurotransmissores.

A membrana do neurônio em função dessa intensa intercomunicação é de extrema importância e é através dela que os neurotransmissores atuam podendo ser excitadores quando a despolarizam mediante o potencial elétrico de ação ou impulso nervoso

ou inibidores quando a hiperpolarizam, já que em repouso a membrana encontra-se a  $-70\text{mV}$ , segundo ECCLES, 1957. A complexidade do funcionamento de um único neurônio reside, principalmente, no fato de que a concentração dos neurotransmissores depende cada qual de uma série de fatores que até o momento não são bem conhecidos e por isso, ainda, encontra-se em fase de intensos estudos. É importante observar que o mesmo neurotransmissor pode ser excitatório para uma sinapse e inibitório para outra, segundo WASSERMAN, 1989.

O neurônio foi identificado pelo neurologista espanhol Ramón y Cajal e as suas manifestações elétricas foram observadas pela primeira vez por DuBois Reymond, com o auxílio de galvanômetros (KOVÁCS, 2002). O potencial de ação foi identificado pelo pesquisador E. D. Adrian. O potencial de ação na forma de um pacote de ondas é obtido pela despolarização da membrana do neurônio com o auxílio da chamada “Bomba de sódio/potássio”, a qual permite a entrada de sódio e a conseqüente saída do potássio. Depois de emitido o impulso ocorre a hiperpolarização com os íons fazendo o caminho inverso. Toda essa operação ocorre na faixa de tempo de 1 a 3ms, com a superposição de um período refratário e um estado de repouso ou relaxação, o que impossibilita uma retomada pelo neurônio de um novo impulso durante esse período de tempo (WASSERMAN, 1989), como pode ser visto na FIGURA 2.2. O neurônio natural apresenta muitas entradas (conexões sinápticas) e uma só saída (um único impulso nervoso), de forma que, dependendo dos sinais ou estímulos que recebe, um neurônio pode ou não emitir um pulso. A superposição de todos esses sinais ou estímulos, excitatórios ou inibitórios, é o que constitui a atividade cerebral.

Os neurônios organizados em sistemas são adaptativos já que com mudanças nas interconexões sinápticas eles aprendem e se auto-organizam fazendo emergir ordem da desordem e, também, o que é mais importante, esses sistemas apresentam propriedades coletivas (memória), mediante a competição e cooperação entre os neurônios constituintes, as quais diferem das propriedades individuais.

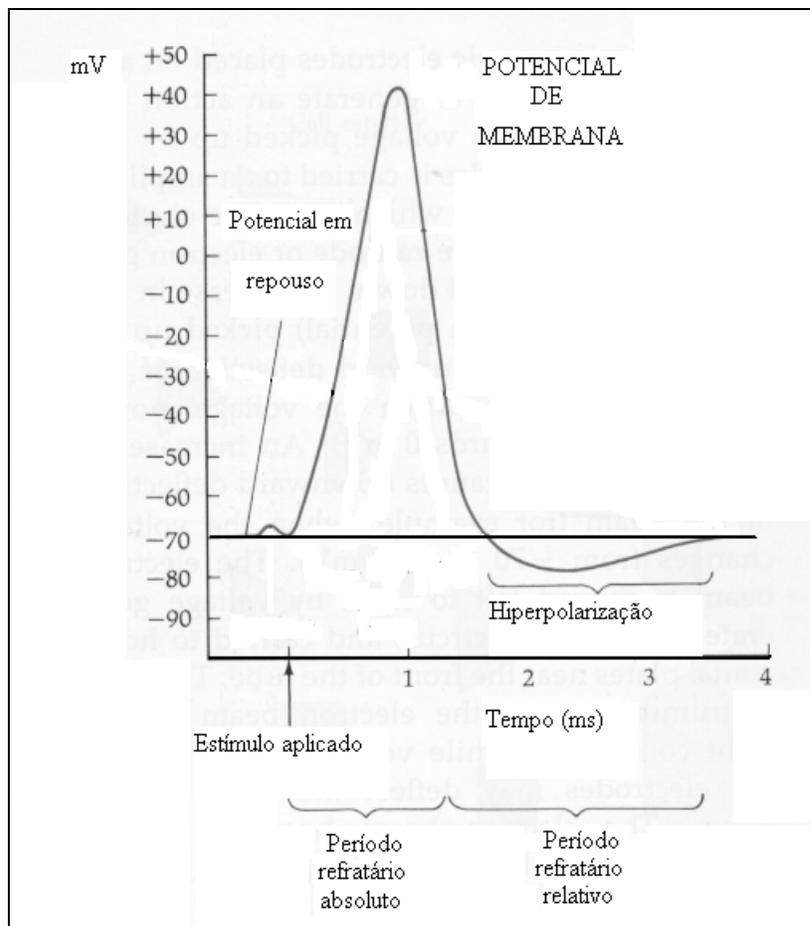


FIGURA 2.2 – O potencial de ação durante a aplicação de um estímulo.

O cérebro humano é um sistema dinâmico complexo com uma grande quantidade de elementos organizados em sistemas que, por sua vez, também se organizam em outros sistemas cada vez mais complexos, de maneira similar à própria origem da vida e a evolução das espécies, segundo DAMÁSIO, 1994. Em função dessa complexidade, atualmente existem pelo menos dois grandes ramos da neurociência; o primeiro que estuda a estrutura e o funcionamento dos sistemas nervosos da forma como interessam aos biólogos e aos profissionais de estudos correlacionados, enquanto que o segundo estuda o processamento computacional dos dados de maior interesse para os físicos e matemáticos no sentido de se construir computadores úteis ou máquinas mais efetivas, segundo NUSSENZVEIG, 1999.

As redes neurais artificiais constituídas de neurônios artificiais em uma analogia com os neurônios naturais são modelos matemáticos que simulam alguns processos biológicos do cérebro humano. As redes neurais são modelos adaptáveis, da mesma forma que os neurônios naturais, e dessa maneira devemos entendê-las, pois através da variação de alguns parâmetros de controle, elas conseguem aprender e, conseqüentemente, realizar operações de controle, de classificação e de reconhecimento de padrões previamente fixados, enquanto a simulação deve ser realizada com o auxílio de algoritmos e de programas computacionais. Esses modelos surgiram na mesma época em que eram construídos os primeiros computadores, na década de 40 do século passado, com a intenção de resolver problemas complexos, especialmente, aqueles da teoria matemática dos sistemas dinâmicos, conforme ABDI et al., 1999 e DAS, 2004, mediante uma consulta à rede Internet no sítio <http://www.atin.8k.com/emergence.htm>. Elas se constituem numa alternativa à computação programada conduzida pela elaboração de um algoritmo, por um conjunto de rotinas e por uma sólida base lógica, segundo texto elaborado no WORKSHOP EM APLICAÇÕES DE REDES NEURAIIS, 1993, pois são capazes de reagir e de se auto-organizar, elas aprendem, sua maior virtude, mas também, infelizmente, esquecem; elas geram as suas próprias regras. São muito utilizadas, em função dessas características, como simulação dos processos mentais na ciência da cognição (ABDI, 1999) e (DAS, 2004).

Originalmente, a idéia era a de se aproximar o máximo possível do funcionamento dos sistemas de neurônios humanos, mas apesar de todo o avanço tecnológico e de sua rápida aplicação aos modernos computadores, essa idéia teve que ser afastada, pois paralelamente avançou-se também na compreensão da fisiologia do neurônio biológico onde se percebeu que o funcionamento de um único neurônio era demasiadamente complexo e que reunidos em estruturas cada vez mais complexas dentro do cérebro seria impossível, e o é até o momento, seguir segundo essa trilha. No entanto, o estudo das redes neurais artificiais revelou-se muito importante para resolver problemas de controle, pois mesmo quando a informação é parcial, a rede pode escolher o padrão mais próximo ao desejado: como conseqüência ela é tolerante a falhas (NUSSENZVEIG, 1999). Elas são aplicadas em inúmeros campos do conhecimento humano, dentre algumas destacamos a filtragem de ruídos e a análise do eletrocardiograma e do eletroencefalograma, a compressão de imagens, a realização de efeitos especiais na indústria do entretenimento, a simulação de vôo e dos sistemas de controle do avião na indústria aeroespacial e a avaliação para aplicação de

créditos no sistema bancário, conforme texto elaborado no WORKSHOP EM APLICAÇÕES DE REDES NEURAIIS, 1993.

Na constituição de uma rede neural artificial as unidades ou elementos de processamento, denominados apropriadamente de neurônios artificiais, são organizados basicamente em camadas: uma camada de entrada, que recebe os dados, uma camada de saída, que dá a resposta, ambas interligadas ao exterior, e entre essas duas camadas algumas camadas internas chamadas de intermediárias ou ocultas. Os elementos de processamento são interligados por um conjunto de conexões, cada um deles acompanhado por um peso associado à sinapse. É através das mudanças desses pesos de ligação nas conexões que uma rede neural aprende. Essas redes são chamadas pela sua arquitetura de redes diretas ou feedforward (FIGURA 2.3). A este tipo de rede podemos acrescentar um outro tipo pelo interesse neste trabalho que é a rede neural recorrente ou rede com retroalimentação (FIGURA 2.4).

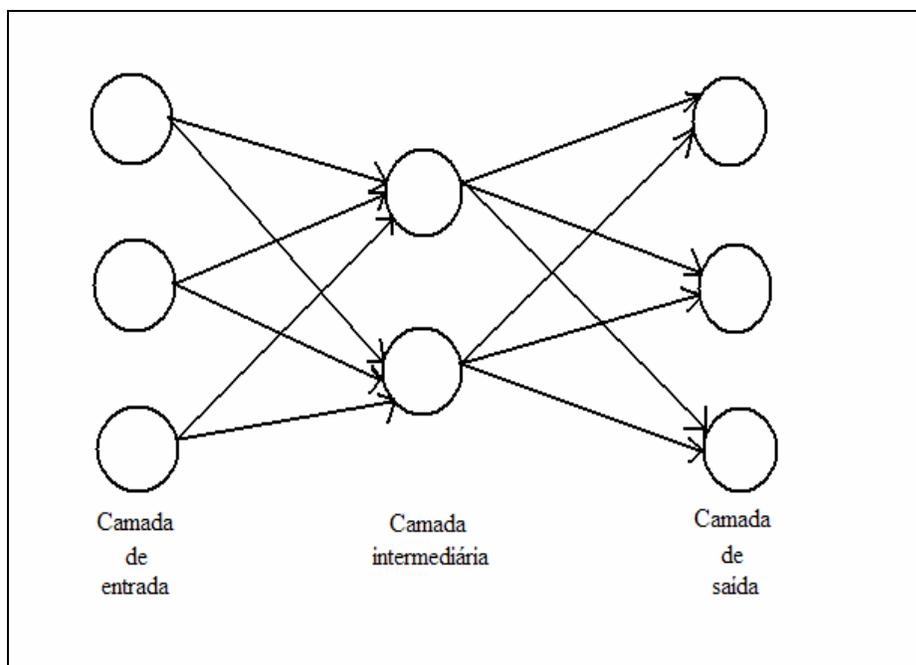


FIGURA 2.3 – Um modelo de rede direta.

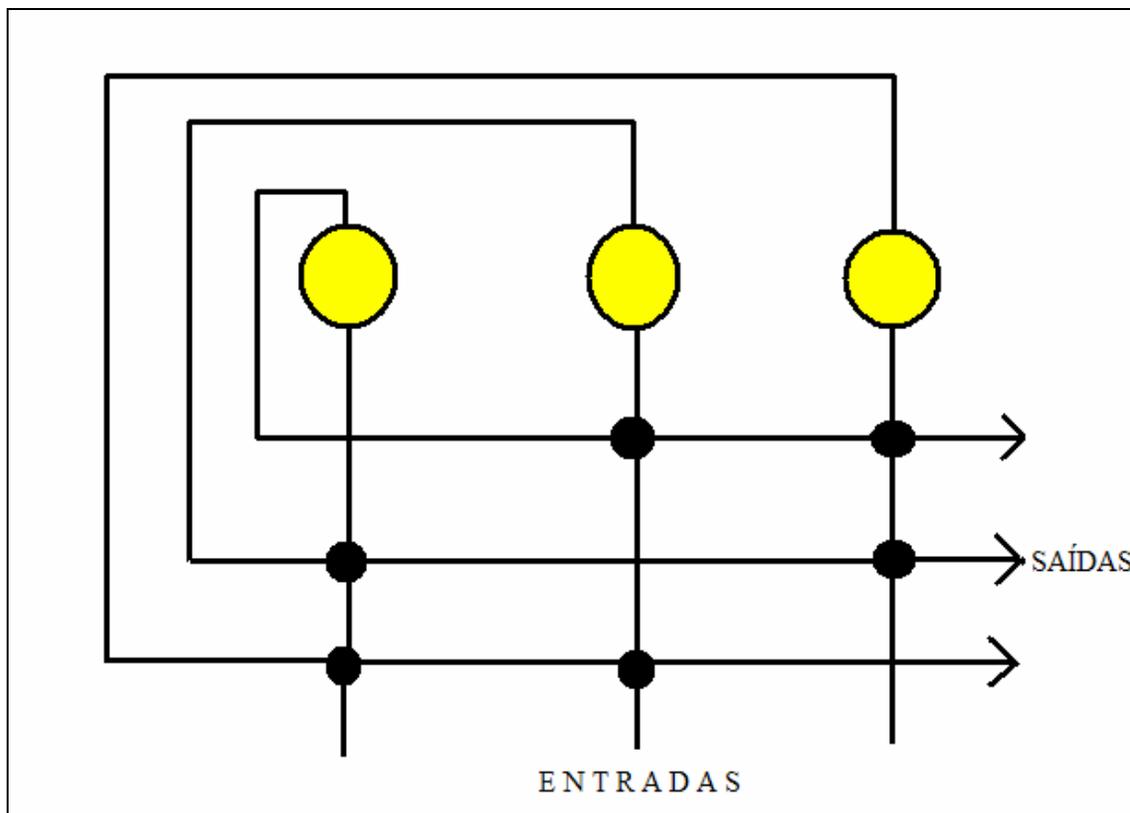


FIGURA 2.4 – Um modelo de rede recorrente.

A primeira simplificação que se introduziu na maioria dos modelos matemáticos foi a consideração de que cada neurônio pode assumir apenas dois estados: ativo quando o axônio emite um sinal ou inativo quando o axônio não emite sinal. Uma rede neural artificial exibe duas fases de operação: o aprendizado e a recapitulação. No aprendizado, os pesos sinápticos são adaptados ou modificados no sentido de se obter o resultado desejado. Quando a resposta é conhecida, dizemos que o aprendizado é supervisionado e quando a resposta não é conhecida, mas é esperada uma boa resposta para resolver o problema, dizemos que o aprendizado é não-supervisionado, pois neste caso não há a necessidade de um supervisor (ou um professor) que encaminhe a rede para o resultado esperado. Ainda, a rede pode ser heteroassociativa quando o vetor de saída for diferente do vetor de entrada e autoassociativa quando o vetor de saída for igual ao vetor de entrada. Na fase de recapitulação ou operação propriamente dita, tem-se simplesmente que o resultado é obtido em resposta a um dado exemplo, sem que ocorra qualquer modificação nos pesos das conexões, de acordo com CAMPANHA, 1994.

As características fundamentais de uma rede neural artificial são a sua arquitetura (ou a forma como as unidades de processamento estão interligadas), as suas próprias unidades de processamento e as suas regras de aprendizado.

Quanto à arquitetura, dentre os vários tipos de redes, destacam-se as redes diretas ou feedforward, como já foi colocado em parágrafo anterior, onde as unidades de processamento são interconectadas em camadas seqüencialmente colocadas da entrada até a saída, passando pelas camadas ocultas, e as redes recorrentes, dentre elas a rede de Hopfield, que é uma rede simétrica com ciclos ou com realimentação (ou retroalimentação).

Basicamente uma unidade de processamento é constituída de vários sinais de entrada  $(x_1, \dots, x_n)$ , cada qual com o seu peso sináptico associado  $(w_1, \dots, w_n)$ . A soma ponderada

$$\sum x_i \cdot w_i \quad (2.1)$$

é a entrada efetiva que dá origem a uma só saída. Se a soma ponderada for superior a um limiar previamente estabelecido, quando ele for necessário, então o sinal de saída é gerado mediante a aplicação de uma função de transferência ou função de saída do neurônio, a qual é aquela função que mais se aproxima do efeito de ativação do potencial de ação do neurônio natural e pode ser estabelecida por qualquer função contínua e monotonamente crescente com imagens no intervalo real  $[0,1]$  ou  $[-1,1]$ . Em caso contrário, nada acontece, ou seja, não há sinal de saída (FIGURA2.5).

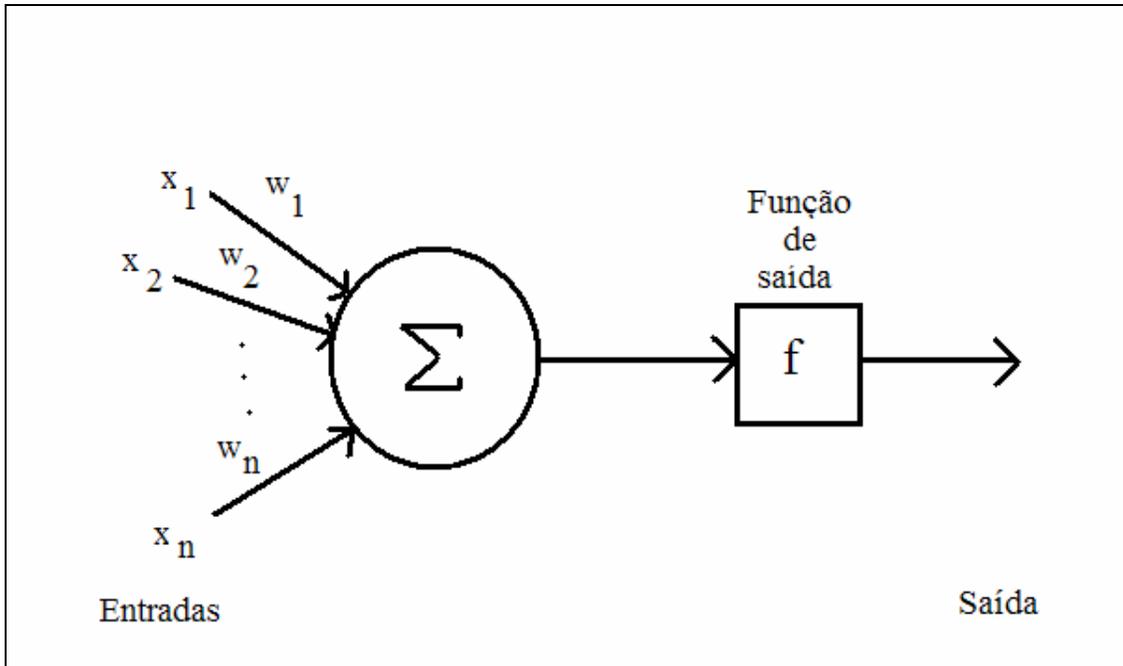


FIGURA 2.5 – Um neurônio artificial.

As principais funções de transferência são: a função linear

$$f(x) = kx, \quad (2.2)$$

a função logística (FIGURA 2.6)

$$f(x) = (1 + e^{-kx})^{-1} \quad (2.3)$$

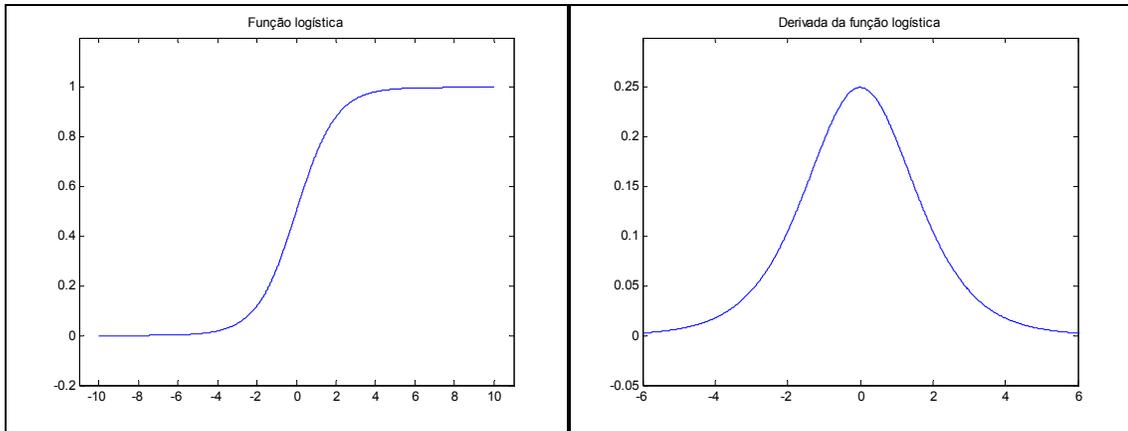


FIGURA 2.6 – A função logística e a sua derivada.

e a função tangente hiperbólica (FIGURA 2.7), aquela que será usada neste trabalho,

$$f(x) = \tanh(kx). \quad (2.4)$$

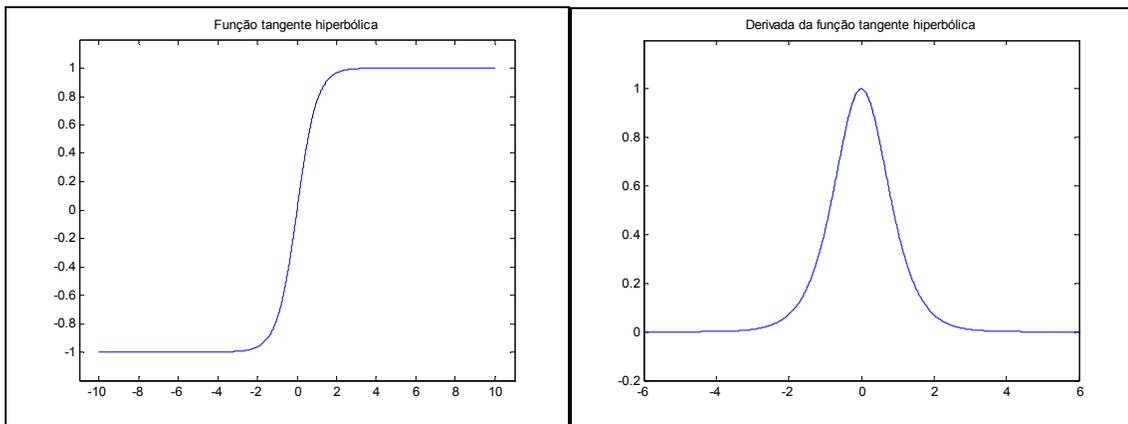


FIGURA 2.7 – A função tangente hiperbólica e a sua derivada.

As duas últimas funções apresentam as características sigmoidais (derivada).

O aprendizado está ligado a uma regra que modifica ou adapta os pesos das conexões. Em 1949, o psicólogo Donald Hebb propôs a regra que “quando um axônio da célula A está próximo o bastante para excitar uma célula B e repetidamente ou persistentemente a estimula, algum processo de crescimento ou mudança metabólica ocorre em uma ou em ambas as células de tal forma que a eficiência de A como uma das células que estimula B aumenta”, conforme texto traduzido de ABDI et al., 1999. Na década de 60, B. Widrow e M. Hoff desenvolveram a Regra Delta, que é baseada no método dos mínimos quadrados (WIDROW & HOFF, 1960), onde o mínimo da função do erro acontece no vértice do parabolóide, visto que a função de aproximação do método é quadrática. Ela foi generalizada por Rumelhart e outros na década de 80 com o nome de Regra Delta Generalizada ou Regra de Retropropagação do Erro (Backpropagation), tornando-se a mais poderosa regra de aprendizado das redes neurais. Essa regra foi desenvolvida originalmente por P. Werbos, em 1974, e redescoberta, independentemente, por D. Parker, em 1982, Y. LeCun, em 1985, e por D. Rumelhart et al., em 1986, de acordo com WERBOS, 1974, PARKER, 1982, Le CUN, 1985 e RUMELHART et al., 1986. Ela utiliza o método do gradiente descendente para a correção do erro. Como o gradiente é um vetor cujo sentido aponta sempre no sentido crescente da função sobre a qual ele é aplicado, quando invertemos o seu sentido, ele passa a apontar no sentido decrescente da função; a função do erro neste caso depende do gradiente com sinal negativo. Acrescentam-se a estas regras, dentre outras, a Regra de Aprendizagem de Kohonen, KOHONEN, 1982, a Regra de Aprendizagem por Cooperação-Competição de von der Malsburg e de Grossberg, segundo seus próprios criadores VON DER MALSBURG, 1973 e GROSSBERG, 1976 e 1980.

## **2.2 Um Breve Histórico Sobre as Redes Neurais**

A seguir destacamos os fatos relevantes para o escopo deste trabalho e para isto adotamos os textos do WORKSHOP EM APLICAÇÕES DE REDES NEURAIIS, 1993, de ABDI et al., 1999, de AZEVEDO et al., 2000, de KOVÁCS, 2002 e, mais especificamente, de CAMPANHA, 1994. Em 1943, o neurologista Warren S. McCulloch junto com o seu aluno Walter Pitts, estatístico, publicaram o artigo “A Logical Calculus of the Ideas Immanent in Nervous Activity” no Bulletin of Mathematical Biophysics, considerado então o marco zero no desenvolvimento das redes neurais artificiais, pois se acredita que tenha influenciado

cientistas como John von Neumann que voltou-se para a construção de cérebros eletrônicos ou computadores, Marvin Minsky que dedicou-se a aplicação da inteligência artificial em sistemas autônomos, Norbert Wiener que preocupou-se com o que veio a denominar-se de cibernética e, principalmente, Frank Rosenblatt, que preocupado com o aspecto computacional da visão criou o “Perceptron”. Alguns historiadores acreditam que McCulloch e Pitts foram, por seu turno, também influenciados pelas pesquisas de Alan Turing e do próprio John von Neumann. O neurônio de McCulloch/Pitts é do tipo lógico que admite somente dois estados (dispara ou não dispara o sinal ou pulso), as suas entradas pertencem ao conjunto formado pelos números 0 e 1, possui um limiar constante e igual a 1 e as sinapses tanto excitatórias quanto inibitórias possuem valores idênticos. As sinapses são excitatórias quando o peso da conexão é positivo e são inibitórias quando o peso da conexão é negativo. Se a soma ponderada for superior ao limiar o neurônio dispara o sinal; caso contrário, não dispara o sinal, segundo os próprios autores McCULLOCH & PITTS, 1943, (FIGURA 2.8).

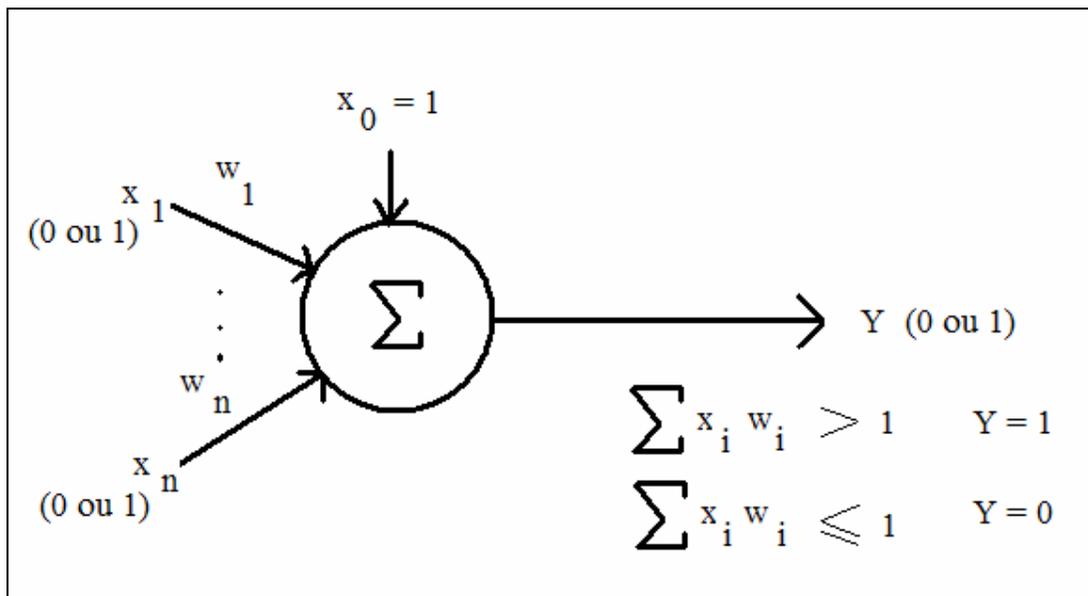


FIGURA 2.8 – O neurônio de McCulloch/Pitts.

Frank Rosenblatt, em 1957, na Universidade de Cornell, construiu o Perceptron (FIGURA 2.9), equipamento que se constituía em uma rede neural de uma só camada e que era um classificador de padrões capaz de identificar formas geométricas.

Também foi construído com neurônios do tipo lógico, entretanto tinha conexões modificáveis e a saída era dada por 0 e 1. Usava a regra Hebbiana para o aprendizado. Os neurônios do Perceptron eram discriminadores ou separadores lineares, tendo em vista que a soma ponderada

$$\sum w_i . x_i = \theta, \quad (2.5)$$

onde  $\theta$  é o limiar, comportava-se no caso em que  $n = 2$ , onde  $n$  é o número de entradas, como a equação de uma reta no plano formado pelos eixos  $x_1$  e  $x_2$ . Assim, se

$$w_1 . x_1 + w_2 . x_2 > \theta \quad (2.6)$$

obtemos uma parte do plano e se

$$w_1 . x_1 + w_2 . x_2 < \theta \quad (2.7)$$

obtemos a outra parte do plano. Quando  $n = 3$  tem-se o plano e para  $n$  superior a 3 temos o que os matemáticos chamam de hiperplanos, (ROSENBLATT,1958).

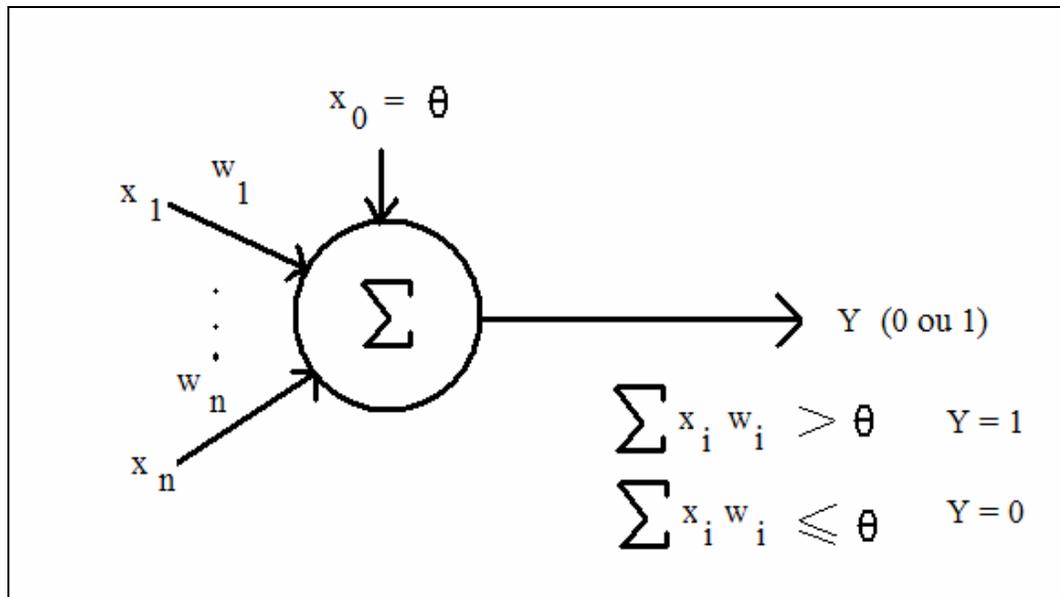


FIGURA 2.9 – O perceptron de Rosenblatt.

Entretanto, Minsky e Papert provaram, na década de 60, que o Perceptron não seria capaz de efetuar a operação lógica do tipo *ou exclusivo* (XOR) e o seu complemento, o que significa que para os conjuntos “mais interessantes” (linearmente não-separáveis) ele não consegue exibir nenhum conjunto de pesos ( $w_i$ ) para efetuar a sua classificação de padrões (MINSKY & PAPERT, 1969).

Na Universidade de Stanford, em 1959, Bernard Widrow desenvolveu filtros que eliminam ruídos em linhas telefônicas, que se confirmou como a primeira aplicação das redes neurais artificiais ao mundo real. Estudou também a aplicação das redes neurais no reconhecimento da fala e de objetos, na previsão do tempo, no ajuste de antenas parabólicas, na regulação da pressão sanguínea. Criou o ADALINE (ADAPtative LINear Element), onde as unidades de processamento são adaptadores lineares e também o MADALINE (Multiple Adaline) com várias camadas ADALINE. Com Marcian Hoff desenvolveu a Regra de Aprendizado Delta (ou de Widrow-Hoff), a qual estabelece que quando você comete um erro, preste menos atenção à célula de entrada que levou você a cometer esse erro e preste mais atenção à célula de entrada que não levou você a cometer esse mesmo erro, o que causou junto a todos os outros pesquisadores uma grande euforia com a

crença na imensa potencialidade de aplicações das redes neurais, já que se acreditou naquela ocasião que a chave da inteligência havia sido descoberta (WIDROW & HOFF, 1960). Entretanto, essa euforia durou somente alguns anos, pois Marvin Minsky e Seymour Papert publicaram o livro “Perceptrons”, onde demonstraram a incapacidade que uma rede neural do tipo perceptron tinha em resolver um simples problema lógico (as redes seriam incapazes de aprender a classificar funções não-linearmente separáveis) do tipo *ou exclusivo* (XOR), como já foi comentado, o que provocou uma estagnação nos estudos principalmente pela indisponibilização de verbas para as pesquisas por quase duas décadas na área das redes neurais artificiais, de acordo com as referências indicadas no início deste item.

Isso não impediu que Teuvo Kohonen, Stephen Grossberg e James Anderson, notadamente, continuassem os seus trabalhos dentro da computação neural e de acordo com WASSERMAN, 1989, o choque provocado pelo livro “Perceptrons” permitiu que houvesse um período de latência para a necessária maturação nesse campo de estudos. Hoje as redes neurais artificiais rotineiramente resolvem alguns dos problemas que foram colocados no livro de Minsky e Papert. As redes diretas necessitam de camadas intermediárias para solucionar os problemas não-linearmente separáveis. Posteriormente, provou-se que uma só camada bastava, mas a solução ainda ficava na dependência da quantidade de neurônios dessa camada. Devemos observar, entretanto, que a adição de mais camadas nas redes neurais não produziu um efeito imediato. Destacamos que Kohonen, da Universidade de Helsinque, nos anos 70, desenvolveu a Regra do Aprendizado Competitivo e a rede neural correspondente, onde as unidades de processamento competem entre si. Também desenvolveu uma grande quantidade de algoritmos adaptativos locais (mapa auto-organizável). James Anderson, na Universidade de Brown, desenvolveu um Modelo Associativo Linear similar aos modelos biológicos de memória e reconhecimento. Por seu turno, Stephen Grossberg utilizando-se da clássica experiência de Pavlov sobre reflexos condicionados construiu modelos em computação neural. Desenvolveu, também, a partir dos anos 60 a Teoria da Ressonância Adaptativa (ART), para classificar padrões, com os modelos ART1 (padrões binários), ART2 (padrões analógicos) e, com Gail Carpenter, o ART3, redes diretas espaço-temporais (1978), conforme as referências indicadas no início deste item.

Com a publicação do artigo “Neural Networks and Physical Systems with Emergent Collective Computational Abilities” na renomada Proceedings of the National Academy of Sciences por J. J. Hopfield, da Caltech, em 1982, promoveu-se o retorno à respeitabilidade dos estudos sobre redes neurais artificiais. Hopfield desenvolveu uma Rede Associativa com neurônios do tipo lógico, onde introduziu o conceito de função de energia (ou função de Lyapunov) para poder analisar a evolução da rede. Seu mecanismo de resposta é uma particularização do trabalho de Grossberg, o que denota que já havia precursores, entretantes ele concebeu uma notável síntese de idéias com um adequado tratamento matemático aos seus trabalhos, conforme destaca WASSERMAN, 1989. Dentre outros precursores destacaram-se o neuroanatomista Brian G. Gragg e o físico H. N. V. Temperley que ainda em 1954 estabeleceram uma analogia entre as Redes de Neurônios e as Redes de Átomos com Spins. Esta analogia foi aproveitada por William A. Little, em 1974, que associou as redes neurais e os sistemas de spins (Ising). Em 1976, D. Marr e T. Poggio estudando como o cérebro humano construía a noção de profundidade, que permite a visão tridimensional, desenvolveram um algoritmo cooperativo semelhante ao modelo de Hopfield .

Com a publicação, em 1986, do clássico “Parallel Distributed Processing” por D. Rumelhart e J. McClelland ocorreu um avanço decisivo nos estudos das redes neurais com a criação de associações de pesquisadores e estudiosos, com a fundação de empresas de software para a sua exploração comercial e uma proliferação de publicações e de periódicos.

Podemos dizer que com a ressurgência das redes neurais artificiais pela introdução do algoritmo da Retropropagação do Erro (Backpropagation), atualmente o de maior sucesso, que aplicado em redes multicamadas sobrepujou as limitações colocadas por Minsky e Papert, em obra já citada, aumentaram substancialmente as suas aplicações. Atualmente, há diversos grupos utilizando as redes neurais e aplicando-as em Neurologia, Psicologia, Medicina, Ciência da Computação e em outros ramos do conhecimento humano, demonstrando a imensa capacidade que elas possuem na resolução de problemas de grande complexidade com resultados impressionantes. Os pesquisadores Sejnowsky e Rosenberg, em 1987, desenvolveram redes para a conversão de texto e a consequente representação fonética. Ainda em 1987, Burr desenvolveu redes para o reconhecimento de caracteres escritos

manualmente enquanto que Cottrell, Munro e Zipser desenvolveram redes para a compressão de imagens, de acordo com as referências indicadas no início deste item.

### **2.3 Os Tipos de Redes**

É perceptível o avanço nos estudos e nas pesquisas sobre as redes neurais artificiais, levando-se em conta a proliferação dos tipos de redes com um vasto número de arquiteturas, como foi comentado no item anterior. As referências deste item são as mesmas do início do item anterior.

Stephen Grossberg nos anos 60 e 70, desenvolveu as chamadas redes espaço-temporais, já que as saídas eram funções do tempo, na tentativa de modelar o processo cognitivo de uma seqüência de eventos. Também contribuiu para o desenvolvimento da rede Interactive Activation and Competition (IAC), que será tratada posteriormente.

Donald Specht, em 1988, desenvolveu as redes neurais probabilísticas (PNN) para a otimização na classificação de padrões. Kunihiko Fukushima, Sei Miyake e Takayuki Ito, na década de 80, desenvolveram o Neocognitron, evolução do cognitron de Fukushima, de 1975, dentro daquilo que se chamou de redes hierárquicas, para o reconhecimento de imagens, em especial, os caracteres alfanuméricos. Bart Kosko, em 1987, e, posteriormente, com a colaboração de Guest, desenvolveu a Bidirectional Associative Networks, uma rede heteroassociativa e simétrica. James Anderson, em fins dos anos 60 e na década seguinte, desenvolveu um associador linear para trabalhos de otimização com aquilo que veio a ser chamado de Brain State in a Box (BSB). Scott Fahlmann, em 1990, desenvolveu a Cascade Correlation Network. G. Hinton e J. McClelland elaboraram redes de recirculação. Há também a Máquina de Boltzmann, a Delta Bar Delta (DBD), a Functional Link Networks (FLN) e as redes de Hamming.

Robert Hecht-Nielsen, entre 1987 e 1988, elaborou a rede Counter-Propagation para o mapeamento de padrões, utilizando na camada intermediária, um mapa auto-organizável de Kohonen e na camada de saída, uma de Grossberg.

Teuvo Kohonen apresentou, em 1986, a Learning Vector Quantification (LVQ), cujo objetivo era a classificação de padrões e para isso utilizava técnicas de otimização como o BSB, de aprendizado supervisionado, e era baseada no conceito de que o “o vencedor leva tudo”. Para alguns autores a LVQ é considerada como uma técnica de aprendizado supervisionado. Há as redes de Funções de Base Radial, desenvolvida por M. J. D. Powell, 1985, Park e Sandberg, 1991, Moody e Darken, 1990, Renals, 1989, Poggio e Girosi, 1990, para a classificação e aproximação funcional introduzindo a função de ativação gaussiana para os neurônios das camadas intermediárias. Há, também, a Optical Neural Networks, proposta por Carver Mead, de 1988. Apresentada originalmente por Rumelhart e McClelland no livro “Parallel Distributed Processing”, de 1986, posteriormente complementada por Grossberg e Azevedo, temos a rede IAC de memória associativa para implementar sistemas especializados.

Por outro lado, podemos dizer que Almeida, em 1987, como também Stornetta e Huberman, em 1987, e Pineda, em 1988, elaboraram algoritmos avançados para as regras de aprendizado da mesma maneira que Parker, ainda em 1987, que para aumentar a velocidade de convergência, apresentou a Second-Order Backpropagation, a qual usa as derivadas de segunda ordem.

## **2.4 Redes Neurais e Caos**

O renomado físico escocês James Clerk Maxwell (1831-1879), numa conferência proferida em 1873, exortou a todos os presentes de que eles deveriam se preocupar mais com aqueles fenômenos que conduziam aos conceitos de singularidades e instabilidades, pois eles seriam mais coerentes com a realidade física do que com a bem

cômoda e mais fácil análise dos fenômenos que eram estudados com base nas continuidades e estabilidades. Essa preocupação reflete claramente que alguns pensadores já haviam percebido que a estrutura linear para a compreensão da realidade física não combinava bem com a própria realidade. Naquela época o grande problema, infelizmente para eles, residia na complexidade matemática que a resolução dos sistemas exigia (ou mesmo, o que era exigido para a sua modelagem), o que fez com que eles fossem deixados involuntariamente para serem estudados a posteriori. Com os avanços nas técnicas e nos equipamentos e com o advento dos computadores foi possível analisar e resolver problemas de grande complexidade numérica e perceber que os fenômenos não-lineares eram bem mais freqüentes do que se imaginava.

O matemático francês Henri Poincaré (1854-1912) analisando o problema dos  $n$ -corpos da mecânica celeste percebeu que ele fazia parte de um sistema dinâmico de comportamento “caótico” e apresentou as características determinantes destes sistemas, as quais são a sensibilidade às condições iniciais e a complexidade das causas, tornando-se num de seus principais precursores.

Por volta de 1940, dois matemáticos americanos Mary Cartwright e John Littlewood, ambos da Universidade de Cambridge, fizeram alguns estudos com oscilações não-lineares. Alguns anos mais tarde, Lev D. Landau, E. M. Lifshitz e Floris Takens estudando a turbulência em escoamentos de fluidos também contribuíram sobremaneira para o desenvolvimento da “teoria do caos”. David Ruelle e Floris Takens chegaram a concluir, por volta de 1971, que escoamentos turbulentos são descritos por atratores estranhos (dependência hipersensível às condições iniciais), além de possuírem características fractais, afirmação do próprio RUELLE, 1993.

Na década de 60 do século passado, o meteorologista E. N. Lorenz do MIT (Massachusetts Institute of Technology), preocupado com a incapacidade de se prever o clima numa região com alguns dias de antecedência conseguiu, através da resolução numérica do sistema de equações diferenciais, que leva o seu nome, provar que ele apresentava uma dependência hipersensível às condições iniciais e era conduzido a um atrator estranho (atrator

de Lorenz); comportamento que conduziu ao chamado “efeito borboleta”, por ele mesmo cunhado. Em 1975, o matemático Jim Yorke cunhou definitivamente o nome “caos”, de acordo com LORENZ, 1993.

O caos encontrava definitivamente posição de destaque nas pesquisas, a tal ponto que Ary Goldberger da Escola de Medicina de Harvard, afirmou que “o caos dotava o corpo humano da flexibilidade necessária para responder a diferentes tipos de estímulos, de forma que até os ritmos cardíacos saudáveis são caóticos”.

Inicialmente, imaginou-se que modelos complexos evolutivos que conduzem para o regime caótico seriam raros na fisiologia dos mamíferos. Em 1987 e em 1988, o neurobiologista americano *W. J. Freeman* descobriu evidências de um comportamento caótico (*irregular e aperiódico*) nos eletroencefalogramas (EEG) do bulbo olfativo de coelhos; comportamento confirmado posteriormente por FREEMAN, 1987, YAO & FREEMAN, 1990, DUKE & PRITCHARD, 1991, BABLOYANTZ & LOURENÇO, 1994 e KLOTZ & BRAUER, 1999. Mais ainda, várias observações biológicas, realizadas pelos próprios estudiosos citados anteriormente indicaram que a dinâmica caótica estava envolvida em várias atividades neurocomputacionais no cérebro. Em adição, Freeman, no final dos anos 80, propôs um modelo de rede neural conforme a qual sua atividade não-perturbada oscilava caoticamente num atrator de acordo com FREEMAN, 1987, YAO & FREEMAN, 1990, BAIRD et al., 1993, HIRSCH & BAIRD, 1995, CHANG & FREEMAN, 1996 e KLOTZ & BRAUER, 1999.

*Entretanto, é necessário afirmar que o mecanismo de como o cérebro faz a transdução do sinal recebido dos neurônios receptores olfativos em um odor bem definido ainda é desconhecido (FREEDMAN, 1993)*

Além disso, os neurônios receptores olfativos são os únicos que ligam o mundo exterior diretamente ao cérebro. Diferentes dos outros neurônios que sobrevivem toda

uma vida, os neurônios receptores olfativos são substituídos a cada um ou dois meses, presumidamente, devido a saturação causada pelo constante fluxo de ar e pela exposição às substâncias estranhas que inalamos, como os vírus, as bactérias (FREEDMAN, 1993). O comportamento caótico na atividade cerebral através de sinais do EEG tem merecido bastante atenção desde os trabalhos de RAPP et al., 1985 e BABLOYANTZ et al., 1985 e 1986.

Originalmente os modelos de redes neurais artificiais com  $N$  neurônios, tendo em vista que os sistemas biológicos consistem em uma grande quantidade de neurônios, foram direcionados para quando o número  $N$  tendia para o infinito, conforme SOMPOLINSKY et al., 1988. Nesses modelos Sandler também encontrou comportamento caótico na memorização. No entanto, com os trabalhos de AIHARA et al., 1990, VAN DER MAAS et al., 1990, WANG, 1991 e SOLÉ & DE LA PRIDA, 1995, foi verificado que o caos é um fenômeno também em modelos simples de redes neurais. RENALS & ROHWER, 1990, conduziram um estudo com oito neurônios. KURTEN & CLARK, 1986, através de estímulos externos periódicos e estacionários, conseguiram comportamentos caóticos com redes de 26 neurônios e com apenas um neurônio. Da mesma forma, Wang et al., Fukai e Shiino e Kepler et al. modelaram redes com poucos neurônios, conforme material referenciado em DAS II, 1991.

Neste trabalho serão construídos modelos de redes neurais recorrentes, inicialmente com dois neurônios. Para verificar se o sistema exibe ou não um comportamento caótico serão aplicadas a Transformada Rápida de Fourier, algoritmo introduzido por Cooley e Tukey, em 1965, mediante a utilização do programa em MATLAB e calculados os Expoentes Característicos de Lyapunov, usando o método de Eckmann-Ruelle, conforme programa proposto no artigo de CAMPANHA et al., 1997, usando também o MATLAB, como veremos a seguir.

## CAPÍTULO 3

### Os Expoentes Característicos de Lyapunov e a Transformada Rápida de Fourier

#### 3.1 Os Expoentes Característicos de Lyapunov

A palavra de origem grega *caos* originariamente significava um estado desordenado antes da criação do universo ou uma grande confusão. Segundo LORENZ, 1996, quando James Yorke cunhou definitivamente o termo, em 1975, para o estabelecimento do termo *caos determinístico*, o seu significado já havia sido mudado e hoje, também, designa um sistema dinâmico que exhibe uma dependência sensível às condições iniciais, cuja medida pode ser obtida pelos expoentes característicos de Lyapunov (LCE).

De acordo com BAKER & GOLLUB, 1996, para um mapa unidimensional o expoente característico de Lyapunov pode ser rapidamente calculado. Se o sistema evolui a partir de dois pontos distintos, mas extremamente próximos,  $x$  e  $x + \varepsilon_0$ , então após  $n + 1$  iterações a divergência, ou seja, a medida do afastamento entre as órbitas originariamente próximas pode ser determinada aproximadamente por

$$\varepsilon(0) \cong \varepsilon_0, \quad (3.1)$$

$$\varepsilon(n) \cong \varepsilon(0).e^{\lambda n}, \quad (3.2)$$

onde o expoente de Lyapunov  $\lambda$  fornece a razão de divergência (ou de convergência ou, ainda, nenhum destes casos).

Ainda, segundo os mesmos autores e OLSEN & DEGN, 1985, ECKMANN & RUELLE, 1985, PEITGEN et al., 1992, e HILBORN, 1994, para um mapa

$$x_{n+1} = f(x_n), \quad (3.3)$$

após  $n + 1$  iterações obtemos

$$f^n(x + \varepsilon_0) - f^n(x) \cong \varepsilon_0.e^{\lambda n} \quad (3.4)$$

$$\ln \left| \frac{f^n(x + \varepsilon_0) - f^n(x)}{\varepsilon_0} \right| \cong n\lambda. \quad (3.5)$$

Para valores de  $\varepsilon_0$  muito pequenos, a expressão passa a ter a seguinte forma

$$\lambda \cong \frac{1}{n} \cdot \ln \left| \frac{df^n}{dx} \right|. \quad (3.6)$$

No limite, quando  $n \rightarrow \infty$  e usando a regra da cadeia, chegamos à conclusão que

$$\lambda = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=0}^{n-1} \ln |f'(x_i)|. \quad (3.7)$$

Para mapas n-dimensionais encontraremos  $n$  expoentes de Lyapunov, tendo em vista que a dependência existe em cada uma das  $n$  dimensões. Neste trabalho adotaremos o Método de Eckmann-Ruelle (QR decomposition) para a determinação dos expoentes característicos de Lyapunov, conforme artigo de CAMPANHA et al., 1997. Aplicamos este método sobre o mapa logístico

$$x_{n+1} = r \cdot x_n (1 - x_n), \quad (3.8)$$

onde  $r \in [3.25, 4]$ . O intervalo foi dividido em 200 pontos e sobre os quais foram aplicadas 200 iterações, excluídas as 20 iterações iniciais, conforme a FIGURA 3.1, cujo resultado é idêntico ao que consta na literatura, com  $x_0 = 0.9$ .

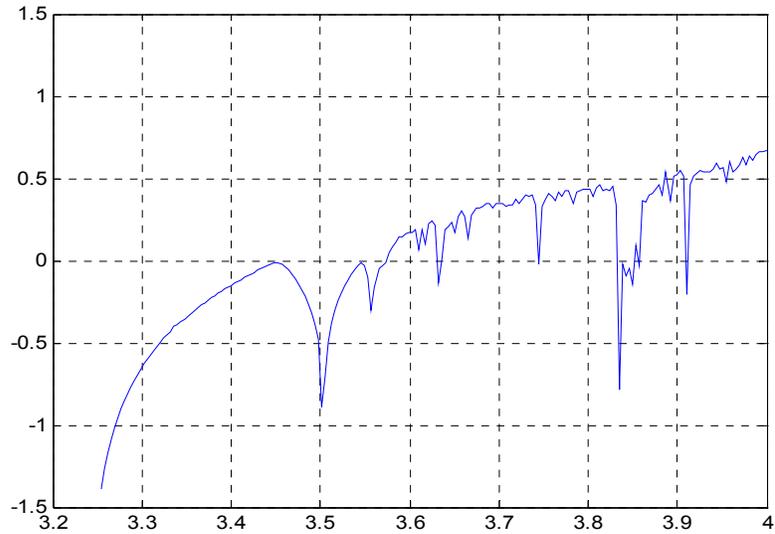


FIGURA 3.1 – O LCE aplicado sobre o mapa logístico.

Reaplicamos o mesmo programa também sobre o mapa definido pela fórmula (3.9), a seguir, o qual será denominado doravante de mapa  $z$  e que foi estudado por Campanha e outros em trabalho não-publicado. Neste caso, dividimos o intervalo em 100 pontos e sobre cada um deles aplicamos 500 iterações, excluídas as 100 iterações iniciais. Após várias simulações, escolhemos o intervalo  $[10,20]$  e dentro dele o parâmetro  $r = 19.2485$ , o qual encontra-se na vizinhança da mudança do comportamento caótico para o não-caótico do referido mapa, como aparece na FIGURA 3.2.

$$z_{n+1} = \tanh((r/2)z_n) - \tanh(r \cdot z_n), \quad (3.9)$$

de fundamental importância para o nosso trabalho.

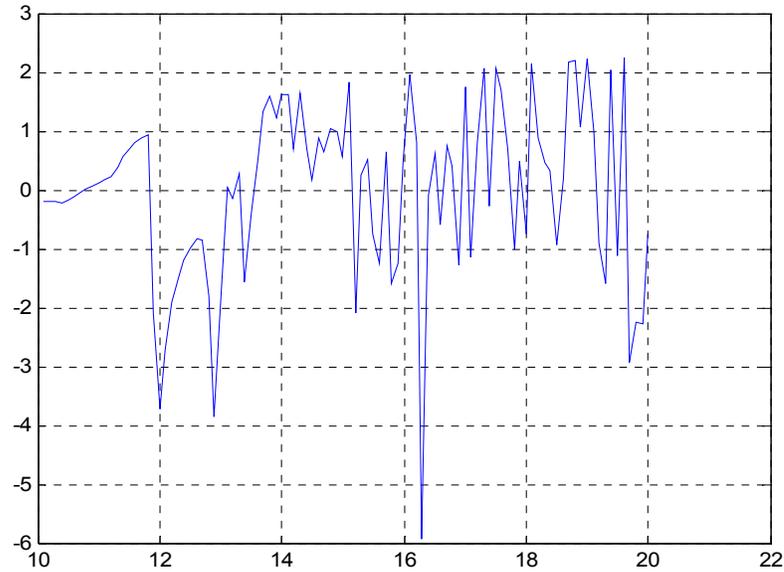


FIGURA 3.2 – O LCE aplicado para  $r$  em  $[19,20]$ , sobre o mapa  $z$ .

### 3.2 A Transformada Rápida de Fourier

O algoritmo FFT (Transformada Rápida de Fourier) foi introduzido por Cooley e Tukey, em 1965, para diminuir o número de operações com relação à aplicação da Transformada de Fourier, para isso retirando os cálculos redundantes. Para séries longas a economia de tempo é considerável, de acordo com MORETTIN, 1979.

A FFT apresenta um espectro de frequências do sistema e é um indicador de que ele apresenta um comportamento caótico ou não-caótico. De acordo com STEWART, 1991, os picos indicam frequências bem definidas num movimento periódico ou quase-periódico, enquanto que a presença de “todas” as frequências indica que há indícios de que o sistema exibe um comportamento caótico.

Usaremos o programa FFT do MATLAB. Segundo IFEACHOR & JERVIS, 1993, no eixo horizontal podemos trabalhar dentro do intervalo  $[0,0.6]$ , tendo em vista que ela apresenta simetria no intervalo integral  $[0,1]$ . Para validar o programa nas condições em que ele foi utilizado, como será visto no capítulo a seguir, fizemos um teste com o mapa logístico, que é bem conhecido, e confirmamos que o algoritmo FFT do MATLAB funcionou muito bem.

## **CAPÍTULO 4**

### **O Olfato Humano e uma Tentativa de Simulação Computacional dos Neurônios Receptores Olfativos**

#### **4.1 Um Breve Relato do Sistema Olfativo Humano**

Iniciamos este capítulo com uma descrição do sistema olfativo humano, responsável pela detecção de produtos químicos (odorantes) dissolvidos no ar, destacando os aspectos que mais interessam ao nosso trabalho e que está de acordo com os resultados mais recentes obtidos pelos pesquisadores que investigam nessa área. Parte do material encontra-se no sítio <http://www.nobelprize.org>, do qual retiramos a FIGURA 4.1.

Quando o ar é aspirado e penetra através das narinas no nosso aparelho respiratório, ele é forçado pelo formato anatômico das cavidades nasais a efetuar um movimento turbilhonado de tal maneira que uma pequena quantidade das moléculas odoríferas inaladas consegue atingir o epitélio olfativo. Nele encontramos os neurônios receptores olfativos em número aproximado de 5,000,000, cada um deles terminando num tufo de 8 a 50 cílios, os quais estão repletos de receptores de membrana que se ligam, identificam e reconhecem as diferentes moléculas odoríferas, apesar da limitada quantidade

delas e que contêm os mecanismos bioquímicos para a emissão do sinal olfativo. Além das células receptoras olfativas, o epitélio possui também as células basais e as células de suporte. As células basais, de formato esférico, desempenham um papel importante na gênese dos neurônios receptores olfativos, pois sabemos que cada um deles é substituído por um outro equivalente em intervalos de 40 a 60 dias, contrariamente ao que acontece com a grande maioria dos neurônios cerebrais que sobrevivem por toda uma vida!

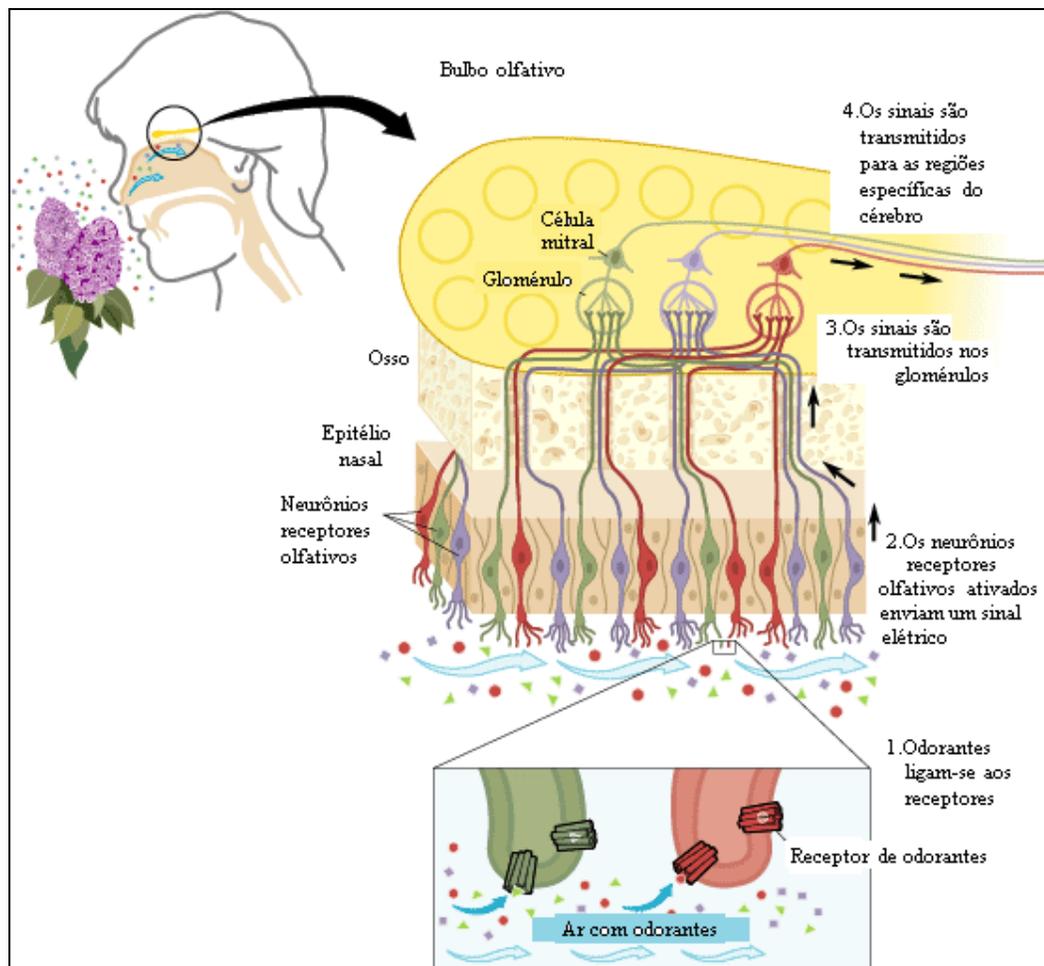


FIGURA 4.1 – O sistema olfativo humano, conforme figura retirada do sítio

<http://www.nobelprize.org>.

Sabemos, atualmente, de acordo com os trabalhos de BUCK & AXEL, 1991 e de MALNIC et al., 1999, que cada neurônio receptor possui somente um tipo funcional de receptor de odores, como numa relação de chave com a sua fechadura.

De acordo com o mesmo artigo, os mamíferos possuem aproximadamente 1,000 genes que produzem proteínas receptoras decodificadoras de odorantes e que pertencem a uma grande família chamada GPCR (G-protein-coupled receptors, do original em inglês). Linda Buck e Richard Axel, ganhadores do prêmio Nobel de Fisiologia (Medicina) de 2004, encontraram 347 genes que funcionalmente decodificam os odorantes para mais de 10,000 diferentes odores que podemos reconhecer. Este número pode variar de um indivíduo para outro, da mesma forma que entre grupos étnicos diferentes. Além disso, da mesma forma que outros pesquisadores, eles acreditam que o cérebro humano estabelece um padrão ao efetuar uma combinação das informações recebidas, as quais incluem os próprios odorantes, as suas concentrações e as suas razões de fluxo em função do turbilhamento do ar aspirado, conforme já foi citado.

Os neurônios receptores olfativos que expressam o mesmo receptor são reunidos em feixes de 10 a 100 e se ligam num mesmo glomérulo (FIGURA 4.1), estrutura que concentra as conexões sinápticas dos próprios neurônios olfativos e os neurônios do nervo olfativo (trato olfativo lateral, conforme a FIGURA 4.1). Uma molécula odorífera reconhecida por uma célula receptora olfativa, através dos seus cílios, faz com que ela emita um sinal que converge para um dos 2,400 glomérulos que possuímos. Em seguida o sinal é transmitido para as células mitrais, que são excitatórias (pesos sinápticos positivos), para as células granulares, as quais não aparecem representadas na FIGURA 4.1, que são inibitórias (pesos sinápticos negativos) e atingem o trato olfativo lateral. Dentro do nosso cérebro, o sinal termina nas células piramidais da área piriforme no córtex olfativo. Usamos o nome de sinal de forma simplificada, pois de acordo com SOUZA, 2002, os canais de potássio, de sódio e de cálcio dos neurônios produzem complexos padrões de potenciais de ação, incluindo disparos em rajadas.

## 4.2 A Estrutura Básica de uma Rede Neural com Dois Neurônios

*A dinâmica caótica foi observada em neurônios naturais de alguns vertebrados de acordo com as pesquisas conduzidas por Freeman, segundo BAIRD, 1986, KLOTZ & BRÄUER, 1999, DAS, 2004, LE et al., 2004, em especial os neurônios do sistema olfativo. Não há uma resposta conclusiva para este fato, mas os próprios pesquisadores citados acreditam que a natureza teria dotado esses vertebrados estudados do comportamento caótico dos seus neurônios receptores olfativos, quando no seu estado fundamental em repouso, para provê-los de uma resposta rápida e eficiente, principalmente para se protegerem dos predadores através do rápido reconhecimento dos odores por eles exalados.*

Um dos mais primitivos dos órgãos sensoriais, junto com o paladar, o olfato dotou os seres vivos, além da flexibilidade e da agilidade para escaparem aos seus predadores, da capacidade para se alimentarem, para se reproduzirem e para selecionarem o mais propício meio ambiente, indispensável aos seus próprios desenvolvimentos evolutivos.

Partindo dos trabalhos publicados por DAMASK, 1981, OLSEN & DEGN, 1985, BAIRD, 1986, KÜRTEEN & CLARK, 1986, GUTFREUND et al., 1988, WASSERMAN, 1989, BAUER & MARTIENSSEN, 1989 e 1991, RENALS & ROHWER, 1990, TIROZZI & TSODYKS, 1991, DAS II et al., 1991, KAZAKOVA & DOTSENKO, 1992, EVANS et al., 1992, FREEDMAN, 1993, CESSAC et al., 1994, CESSAC, 1995, KLOTZ & BRÄUER, 1999, DAS, 2004, *tentamos simular o funcionamento dos neurônios do bulbo olfativo somente naquilo que se refere à mudança de comportamento caótico para o não-caótico como sendo uma resposta à percepção de um odor (FIGURAS 4.2(a) e 4.2(b)).*

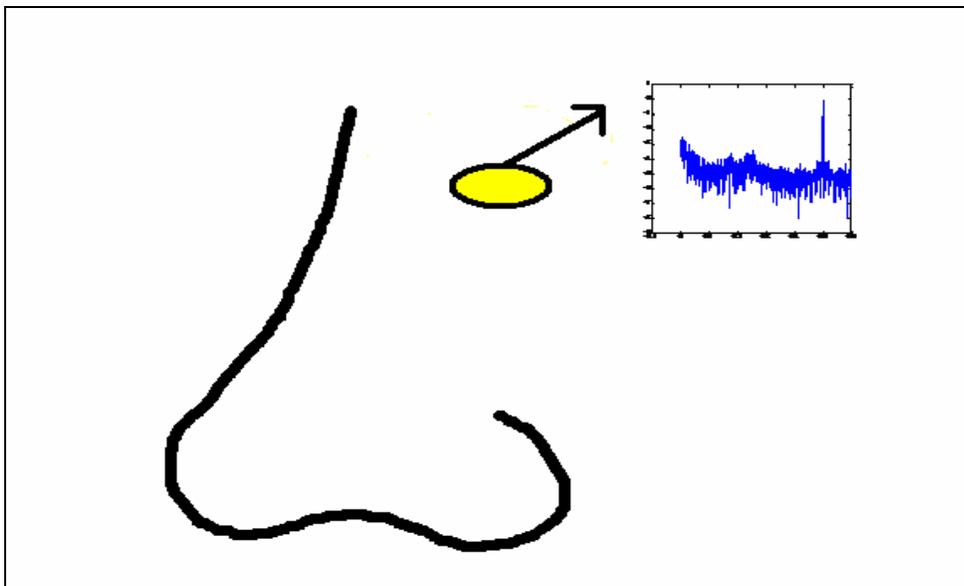


FIGURA 4.2(a) – Na ausência de odorantes, o comportamento da rede é caótico, conforme quadro, onde aparece o espectro de freqüências de bandas largas, após a aplicação da FFT sobre o sinal emitido.

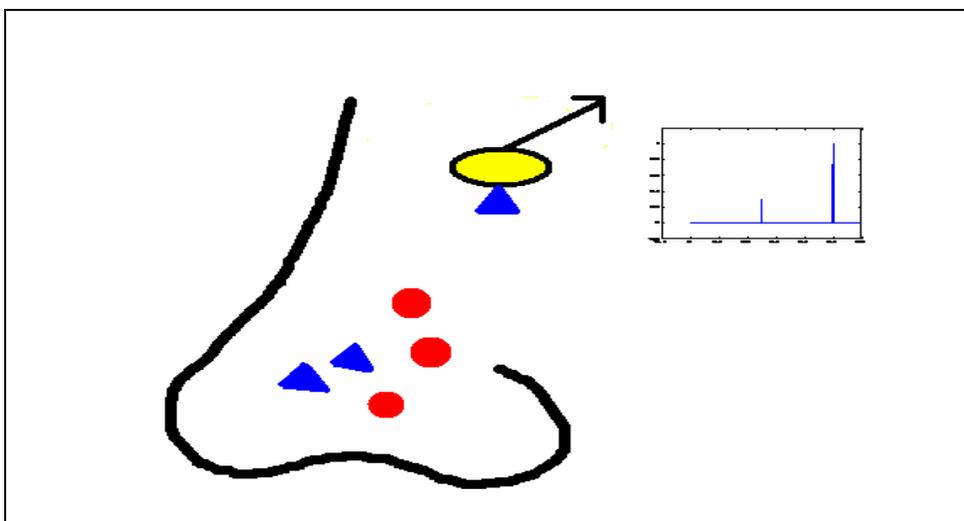


FIGURA 4.2(b) – Quando a rede reconhece um odorante, o seu comportamento deixa de ser caótico, como é mostrado no quadro onde aparecem somente duas amplitudes (ou magnitudes) no espectro de freqüências, após a aplicação da FFT sobre o sinal emitido.

O modelo de sistema olfativo sobre o qual nos baseamos para este trabalho foi proposto originalmente por Amoore e outros, ainda em 1964, de acordo com DAMASK, 1981, que é o modelo espacial (ou da configuração espacial) do olfato; ele estabelece que as ligações dos odorantes com os respectivos receptores seriam feitas em função das configurações espaciais das moléculas dos próprios odorantes. Para isso estabeleceram que há sete odores básicos e que cada um deles apresentaria uma forma espacial diferente; todos os outros odores seriam combinações deles. Esses odores básicos seriam a cânfora, o almiscarado (cujo exemplo químico seria o pentadecanolactona), o floral (feniletilmetil etil carbinol), a hortelã-pimenta (mentona), o cheiro de éter (dicloro etileno), o cheiro picante (ácido fórmico ou acético) e o cheiro da matéria em decomposição (butil mercaptana). Apesar das controvérsias, já que foram propostos outros modelos como o da teoria da punção (puncture) que analisa a parte química e a parte física para a produção do potencial de ação (sinal) após a recepção de um odor, como também o modelo da configuração espacial fraca (ou teoria odotópica), ela permanece atual e dela nos utilizamos principalmente da idéia das combinações, tendo em vista que efetuaremos todas as combinações de dois odorantes (ou moléculas odoríferas) diferentes e o fato de que é perceptível através da FIGURA 4.1 que os glomérulos, concentrando estruturas semelhantes e repetitivas, estabelecem de alguma forma combinações com os neurônios receptores olfativos (BUCK & AXEL, 1991, BUCK, 1996, MALNIC et al., 1999 e BUCK, 2000). Iniciamos os trabalhos com uma rede composta de apenas dois neurônios, que será a nossa estrutura básica de uma rede neural artificial recorrente e sem limiares, cujos diagramas a seguir (FIGURAS 4.3(a) e (b)) mostram o arranjo para a análise da dinâmica da rede.

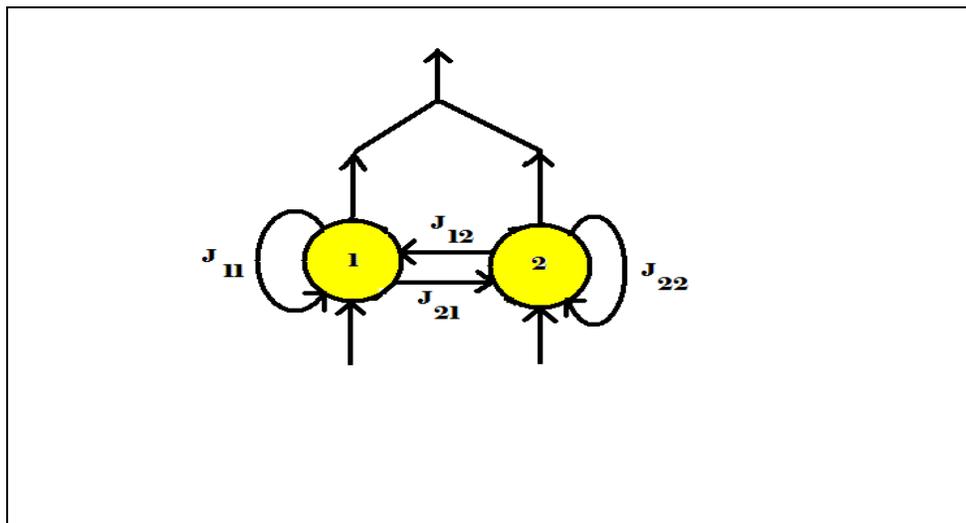


FIGURA 4.3(a) – Estrutura básica da rede neural recorrente de dois neurônios.

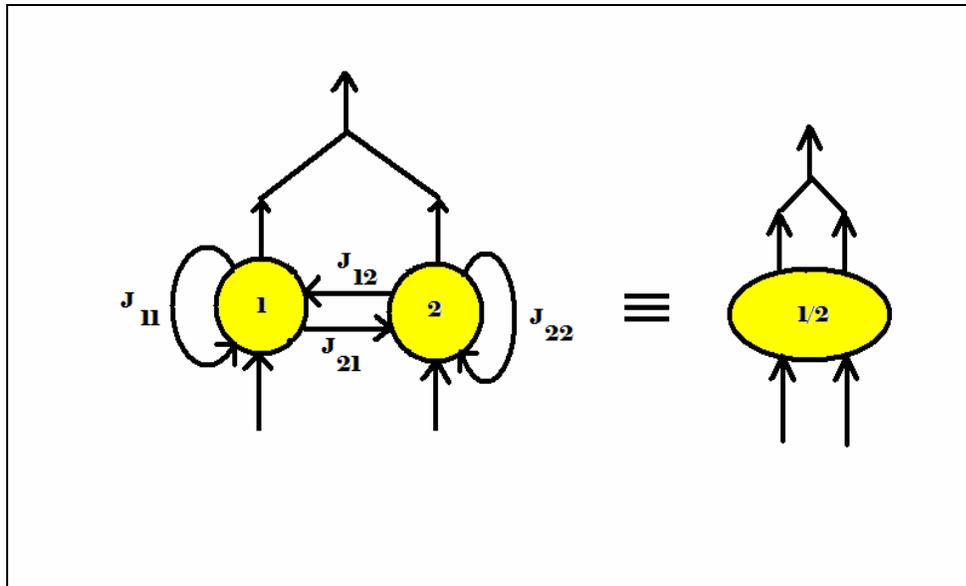


FIGURA 4.3(b) – Estrutura básica da rede de dois neurônios e a sua forma simplificada equivalente.

A dinâmica é dada pelo conjunto de equações

$$S_1(t+1) = \tanh[r(J_{11}S_1(t) + J_{12}S_2(t))] \quad (4.1)$$

$$S_2(t+1) = \tanh[r(J_{21}S_1(t) + J_{22}S_2(t))], \quad (4.2)$$

onde a matriz  $J$  é dada por

$$J = \begin{pmatrix} -1 & 1 \\ -0.5 & 0.5 \end{pmatrix}, \quad (4.3)$$

que nos convém pois está de acordo com os trabalhos dos pesquisadores KÜRTEEN & CLARK, 1986, BAUER & MARTIENSSEN, 1989 e 1991.

A função

$$f(x) = \tanh(x) \quad (4.4)$$

não é a principal e nem a mais importante, mas foi uma das mais usadas pelos estudiosos BAUER & MARTIENSSEN, 1989 e 1991, DAS II et al., 1991, TIROZZI & TSODYKS, 1991, CESSAC et al., 1994 e CESSAC, 1995, e cuja principal característica, é a de que se aproxima do efeito de disparo de um potencial de ação (função sigmoideal). Também, segundo CRISANTI & SOMPOLINSKY, 1988, GUTFREUND et al., 1988, e RENALS & ROHWER, 1990, decompos a matriz  $J$  em suas componentes simétrica e antissimétrica

$$J^S = J + J^T, \quad (4.5)$$

$$J^A = J - J^T, \quad (4.6)$$

de forma que

$$J = mJ^S + (1 - m)J^A, \quad (4.7)$$

onde  $0 \leq m \leq 1$ . Quando  $m = 0.5$  retornamos à matriz original  $J$ , mas para evitar o aparecimento do logaritmo do número zero no Jacobiano, como consta do algoritmo, usamos  $m = 0.499999999$ .

Ao substituírmos os valores da matriz  $J$  em  $S_1$  e  $S_2$  e fazendo a diferença entre eles, encontramos

$$S_2 - S_1 = \tanh((r/2).(S_2 - S_1)) - \tanh(r(S_2 - S_1)). \quad (4.8)$$

Fazendo  $z = S_2 - S_1$ , obtemos

$$z = \tanh(rz/2) - \tanh(rz), \quad (4.9)$$

cuja dinâmica foi analisada no Capítulo anterior, quando da aplicação do programa para o cálculo do LCE sobre o mapa  $z$ , conforme artigo não-publicado de Campanha e outros. O parâmetro de ganho  $r$  foi fixado, então, em 19.2485. Para efeito de comparação, a FIGURA 4.4 mostra o resultado do mesmo programa aplicado sobre o sistema formado por  $S_1$  e  $S_2$ , nas mesmas condições usadas para encontrar o gráfico da FIGURA 3.2 (mapa  $z$ ).

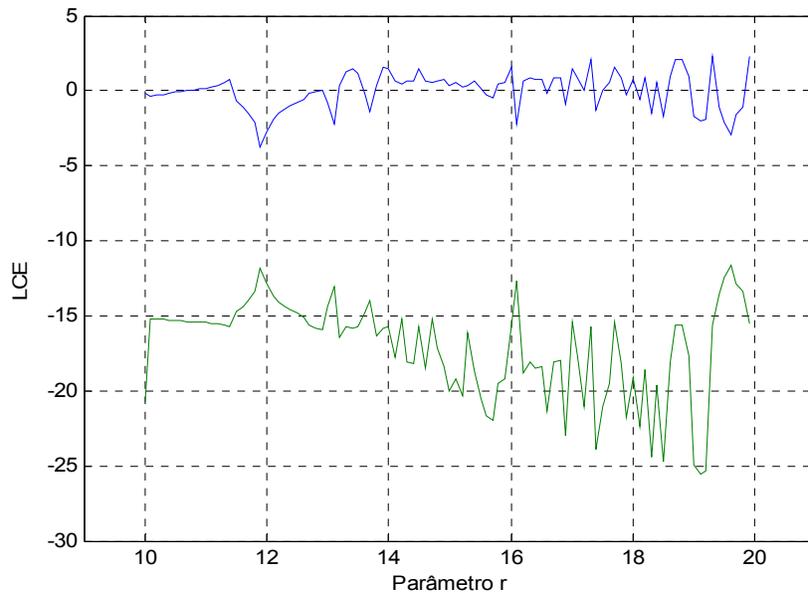


FIGURA 4.4 – Os expoentes de Lyapunov para o parâmetro de ganho  $r \in [10,20]$ .

Inicialmente, chegamos a avançar nesse caminho modelando sistemas com até 32 neurônios ( $S_1, \dots, S_{32}$ ), reduzidos, em seguida, naturalmente para 16 com o mapa  $z$ , mas a única regra evolutiva que encontramos envolvia somente os sinais (+ ou -). Além disso, essa idéia, infelizmente, não prosperou principalmente por dois motivos. O primeiro é devido ao fato de que para cada um dos mais de 10,000 odores que podemos reconhecer teríamos que ter em correspondência mais de 10,000 valores para o parâmetro de ganho  $r$ , o que não seria razoável tendo em vista que temos somente 347 genes para o reconhecimento de odores. O segundo é que não teríamos condições de incluir os parâmetros de controle ou de acoplamento para efetuar as combinações de estruturas semelhantes, como fazem os glomérulos, e que está de acordo com os resultados mais recentes das pesquisas, conforme os trabalhos de BUCK & AXEL, 1991, BUCK, 1996, MALNIC et al., 1999 e de BUCK, 2000, e, ademais, não teríamos como modelar sistemas com 4, 6, 8 ou mais neurônios numa seqüência evolutiva mediante o acoplamento de estruturas semelhantes. Por estes motivos abandonamos a idéia da redução do número de neurônios com a aplicação do mapa  $z$ .

Para executar os programas de simulação com os expoentes de Lyapunov, utilizamos o valor do parâmetro de ganho  $r$  dentro do intervalo [19.248,19.249] porém o dividimos, agora, em 200 pontos, de forma que a amplitude de cada subintervalo seja igual a 0.00005, sobre os quais executamos 10,000 iterações, excluindo as 20 iterações iniciais. Para executar os programas de simulação com o algoritmo FFT, usamos  $r = 19.2485$  e aplicamos 4,000 iterações, de onde aproveitamos as 2,048 finais. As condições iniciais foram escolhidas aleatoriamente, mas a partir deste momento serão fixadas em  $S_1(1) = 0.69$  e  $S_2(1) = 1.39$ . Usamos a FFT em função dos seguintes fatos a) ela é contínua e igual a zero para um atrator de ponto fixo, b) ela exhibe um pico para os ciclos periódicos, c) para resultados quase-periódicos, ela mostra importantes picos nas frequências dos períodos, e d) para resultados caóticos, ela mostra algo entre a FFT de resultados quase-periódicos e a FFT de resultados randômicos (o espectro de potência reflete, neste caso, um ruído de banda larga) e os expoentes de Lyapunov para correlacionarmos os resultados, tendo em vista que eles se complementam nas análises de comportamento dos estados. Naturalmente, os expoentes característicos de Lyapunov confirmam os indícios de comportamento do sistema encontrados pelo algoritmo da FFT.

Estamos, agora, em condições de operarmos sobre a estrutura básica da nossa rede neural e iniciarmos os trabalhos de simulação. Considerando

$$m = 0.499999999 \quad S_1(1) = 0.69$$

$$r = 19.2485 \quad S_2(1) = 1.39$$

começamos aplicando o algoritmo da FFT ao sistema formado pelos neurônios (1) e (2) isoladamente. Em seguida, aplicamos também a FFT ao neurônio soma  $S = S_1 + S_2$ . Os resultados são apresentados nas FIGURAS 4.5, 4.6 e 4.7 onde observamos o comportamento nitidamente caótico em face da total dispersão dos resultados, mesmo efetuadas apenas 4,000 iterações, antes da aplicação do algoritmo da FFT.

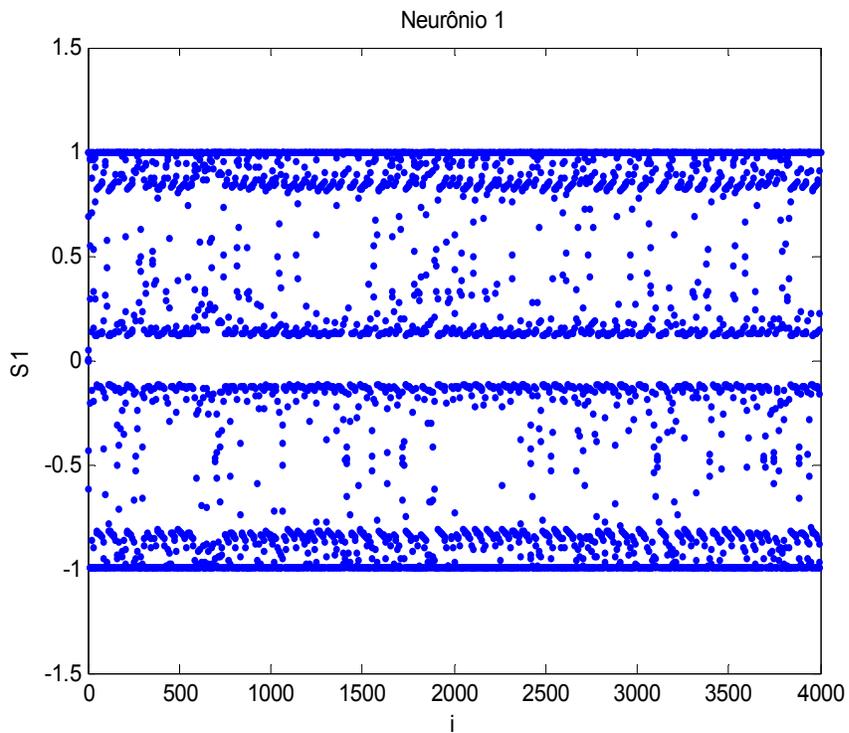


FIGURA 4.5 – Gráfico do neurônio (1) da estrutura básica da rede, após 4,000 iterações.

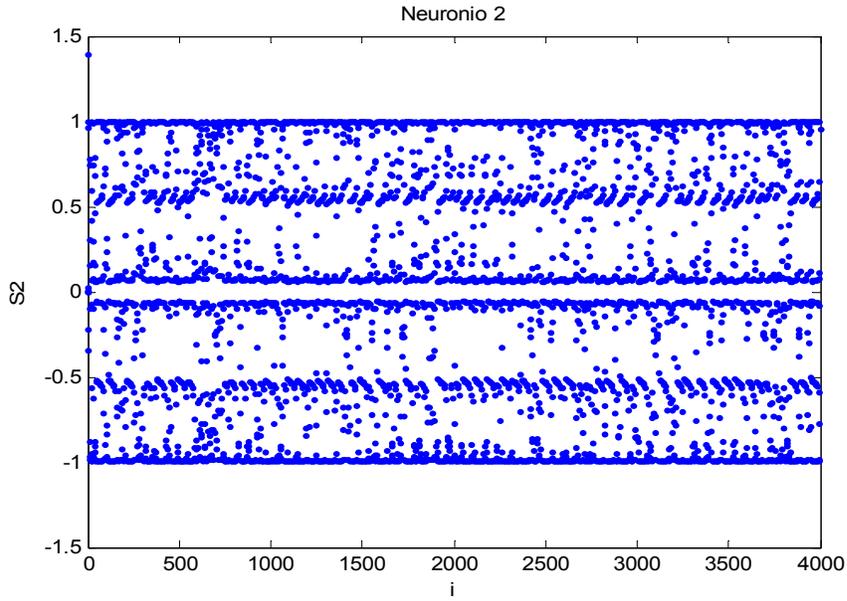


FIGURA 4.6 – Gráfico do neurônio (2) da estrutura básica da rede, após 4,000 iterações.

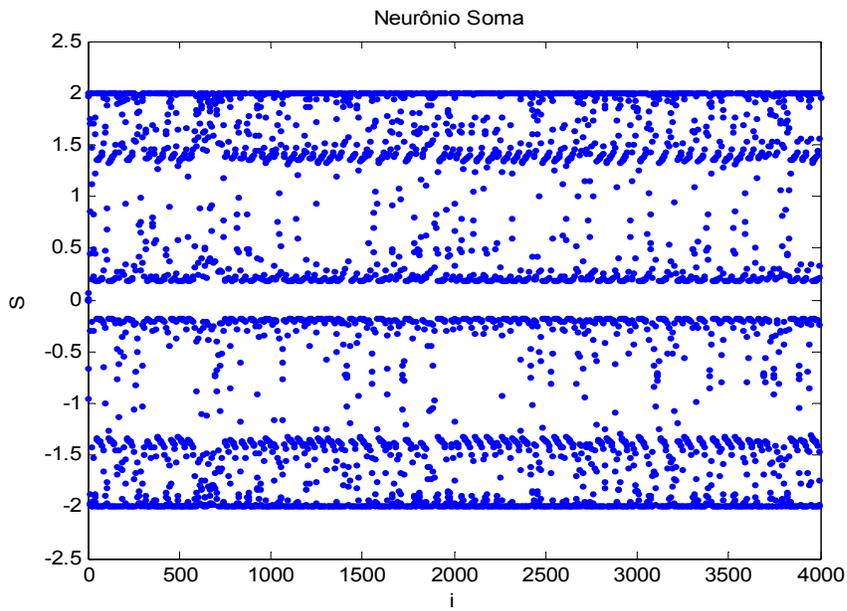


FIGURA 4.7 – Gráfico do neurônio soma (S) da estrutura básica da rede, após 4,000 iterações.

Em seguida, isolamos as cem últimas iterações do restante dos cálculos do neurônio soma (S) e encontramos o gráfico da FIGURA 4.8, que corrobora os resultados encontrados anteriormente. Elaboramos também os gráficos de  $S(i-1)$  por  $S(i)$ , mas com as últimas 2,100 iterações (número ligeiramente superior aos 2,048 quando da aplicação da FFT) e ligamos os pontos do gráfico encontrado mediante segmentos de reta. Neste caso, o gráfico não se mostrou interessante, de forma que não colocamos a figura correspondente. A FIGURA 4.9 mostra o gráfico com os pontos na forma isolada.

Conseguimos, também, o atrator da FIGURA 4.10, similar ao artigo de KLOTZ & BRÄUER, 1999 e do artigo não-publicado de Campanha e outros, quando efetuamos o gráfico correspondente do neurônio (1) versus neurônio (2).

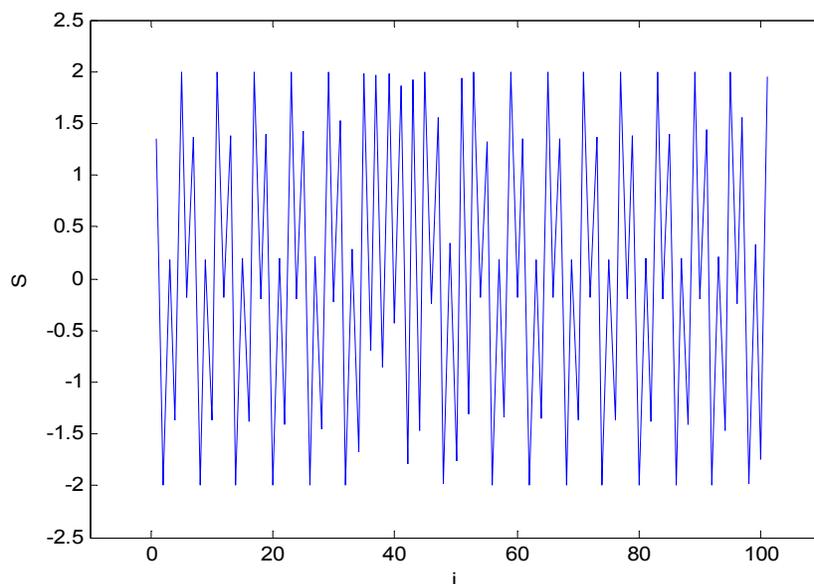


FIGURA 4.8 – Gráfico do neurônio soma (S). Cem últimas iterações.

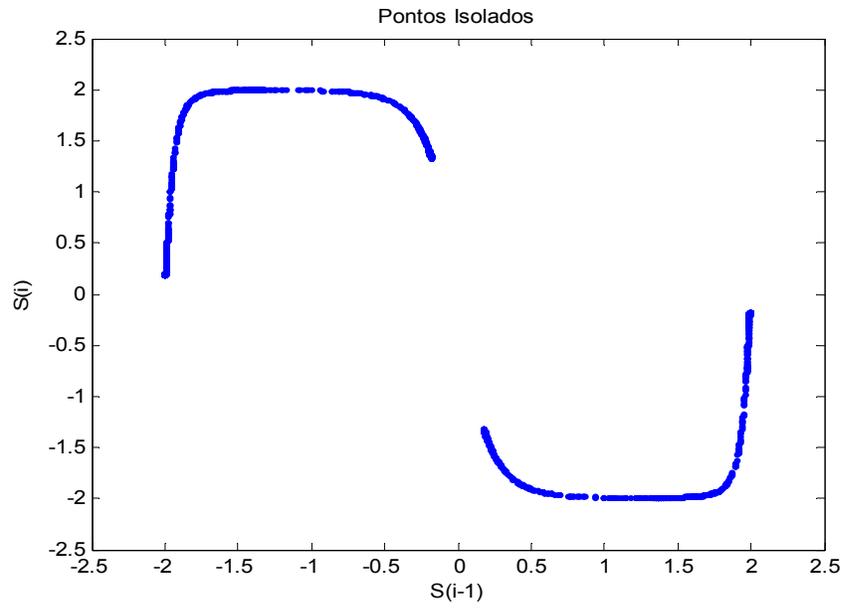


FIGURA 4.9 – Gráfico das 2,100 últimas iterações do neurônio soma (pontos isolados de  $S(i) \times S(i-1)$ ).

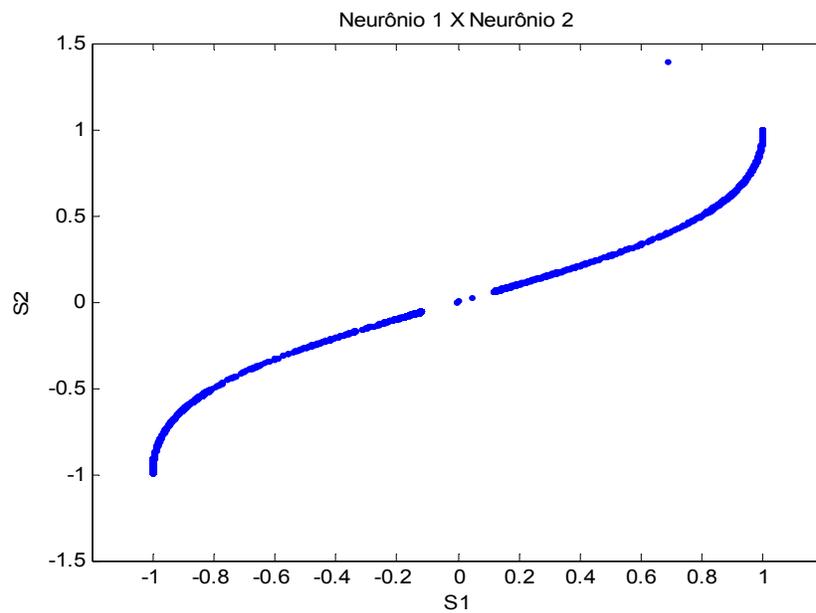


FIGURA 4.10 – O atrator da estrutura básica da rede de dois neurônios.

Na aplicação do algoritmo FFT, como já foi ressaltado no capítulo anterior, verificamos que ele apresenta um espectro de frequência simétrico dentro do intervalo  $[0,1]$ , razão pela qual no eixo horizontal das frequências reduzimos o intervalo para  $[0,0.6]$ , como pode ser visto na FIGURA 4.11. Em seguida, aplicamos o logaritmo decimal, o qual fez com que as amplitudes (ou magnitudes) do espectro de frequências ficassem delimitadas dentro do intervalo  $[0,10]$ , para o neurônio soma (S), conforme a FIGURA 4.12. Percebe-se que o comportamento é caótico em virtude das bandas largas. É importante ressaltar que o comportamento caótico já é perceptível na FIGURA 4.11 e que a aplicação do logaritmo decimal somente realça este resultado.

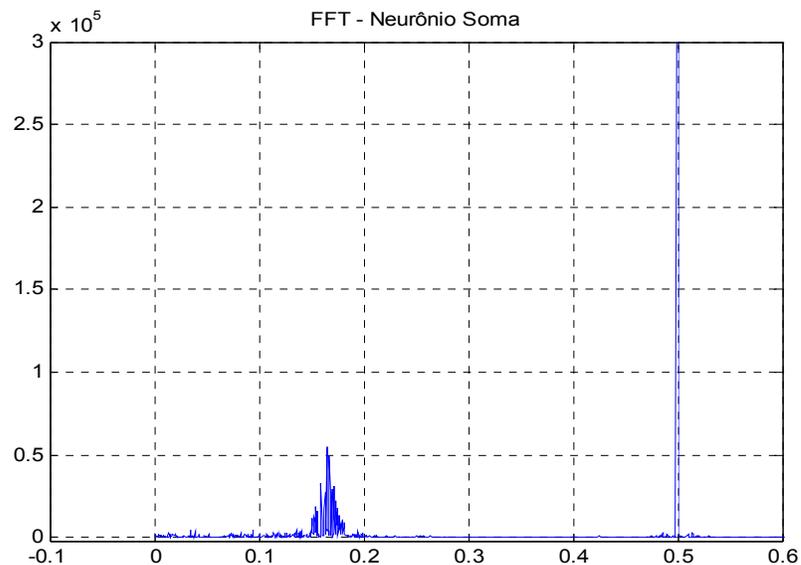


FIGURA 4.11 – A FFT aplicada ao neurônio soma (S).

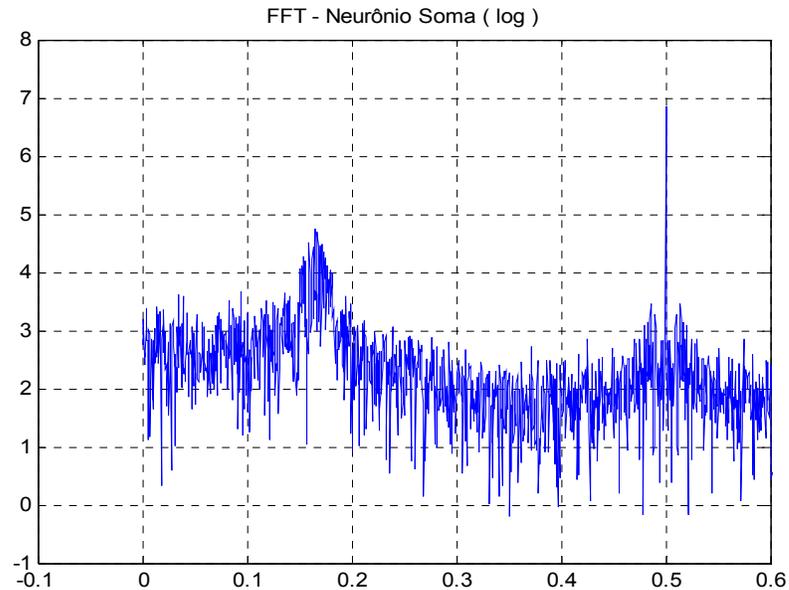


FIGURA 4.12 – A FFT aplicada ao neurônio soma (com o logaritmo decimal).

Para finalizar e confirmar que de fato o nosso sistema dinâmico é caótico, calculamos os expoentes característicos de Lyapunov e encontramos  $\lambda_1 = 2.2325$ ,  $\lambda_2 = -15.561$  com  $\lambda_1 + \lambda_2 = -13.3285$ . Segundo SANDRI, 1996, podemos concluir que o nosso sistema dinâmico discreto aplicado sobre a estrutura básica da rede neural recorrente de dois neurônios exibe o comportamento caótico, da forma como ele foi definido e como era nossa intenção demonstrar. O programa em MATLAB para o cálculo dos expoentes característicos de Lyapunov consta do ANEXO 1.

### 4.3 Rede Neural de Quatro Neurônios

Reunimos dois sistemas dinâmicos de dois neurônios idênticos àquele do item anterior e com eles temos um só sistema que gera uma rede neural de quatro neurônios, conforme os arranjos das FIGURAS 4.13(a) e (b).

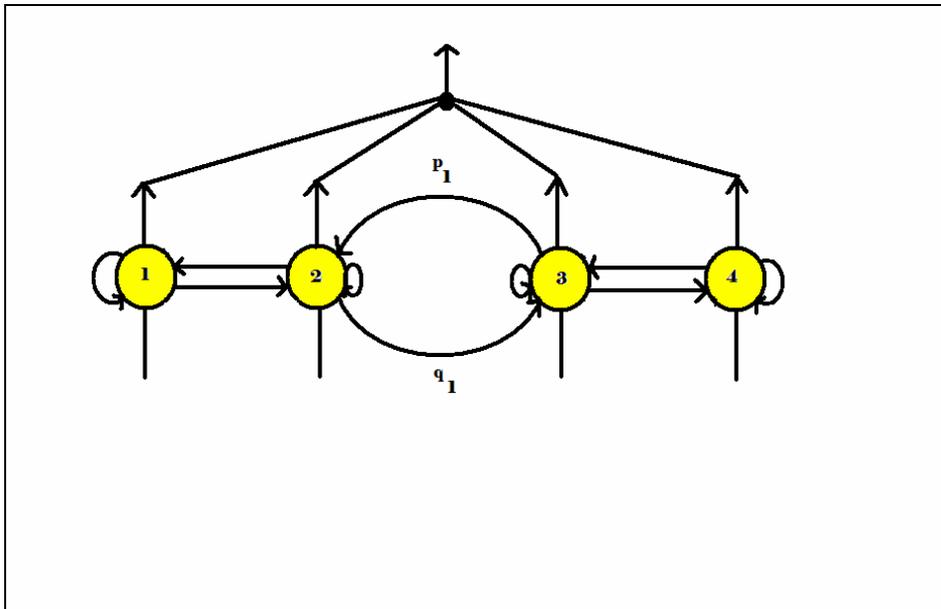


FIGURA 4.13(a) – Arranjo da rede de quatro neurônios.

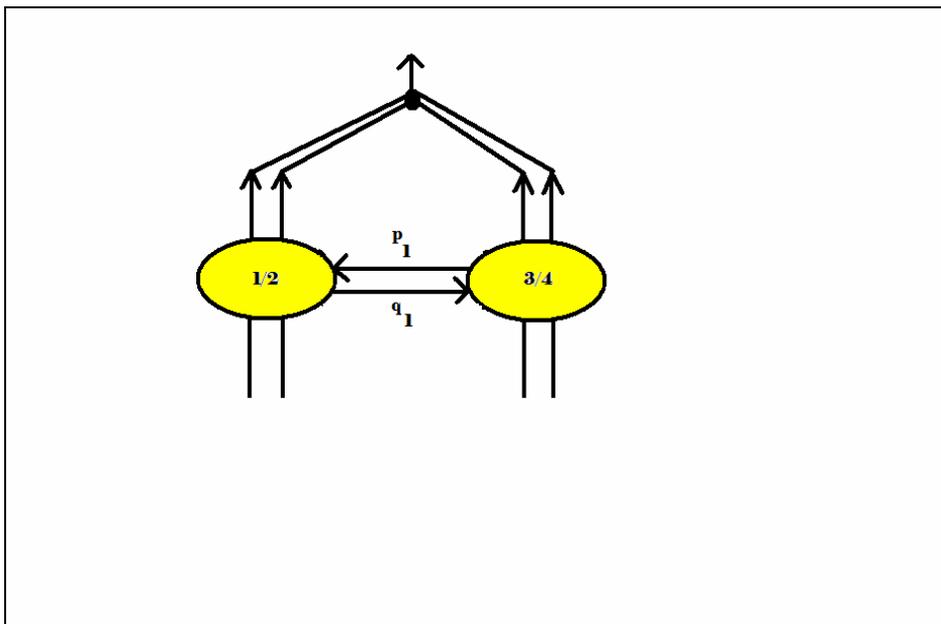


FIGURA 4.13(b) – Arranjo simplificado da rede de quatro neurônios.

Na FIGURA 4.13(a) evidenciamos os parâmetros de acoplamento ou de controle  $p_1$  e  $q_1$  inseridos para efetuarem a ligação do sistema formado pelos neurônios (1) e

(2) com o sistema formado pelos neurônios (3) e (4). Dessa interação é que o sinal emitido desde os cílios, onde estão os receptores de membrana dos odorantes, segue ou não, para o cérebro. O nosso sistema dinâmico discreto formado pela rede neural artificial de quatro neurônios simula o funcionamento de todo o processamento do sinal. A dinâmica desse sistema é dada pelo conjunto de equações

$$\begin{aligned}
 S_1(t+1) &= \tanh(r(J_{11}S_1(t) + J_{12}S_2(t))) \\
 S_2(t+1) &= \tanh(r(J_{21}S_1(t) + J_{22}S_2(t) + p_1S_3(t))) \\
 S_3(t+1) &= \tanh(r(q_1S_2(t) + J_{33}S_3(t) + J_{34}S_4(t))) \\
 S_4(t+1) &= \tanh(r(J_{43}S_3(t) + J_{44}S_4(t))),
 \end{aligned} \tag{4.10}$$

onde a matriz  $J_4$  é dada por

$$J_4 = \begin{pmatrix} -1 & 1 & 0 & 0 \\ -0.5 & 0.5 & p_1 & 0 \\ 0 & q_1 & -1 & 1 \\ 0 & 0 & -0.5 & 0.5 \end{pmatrix}. \tag{4.11}$$

Neste caso, fixamos  $S_1(1)=S_3(1)=0.69$ ,  $S_2(1)=S_4(1)=1.39$  e  $r = 19.2485$ .

Após as simulações computacionais, escolhemos os parâmetros de controle ( $p_1$  e  $q_1$ ) entre os valores  $0$ ,  $0.0097$ ,  $0.035$  e  $0.1189$ , tendo em vista que fizemos todas as simulações possíveis com os valores  $0.1$ ,  $0.01, \dots, 0.000000001$  e  $0$ , onde encontramos os valores  $0.0097$  e  $0.035$  próximos da mudança de comportamento do sistema, enquanto os outros dois afastados dela. Feita a escolha, aplicamos os dois programas, sempre com o

algoritmo FFT em primeiro lugar e depois com o cálculo dos expoentes de Lyapunov para confirmar os resultados encontrados em todas as combinações possíveis destes valores. Concluimos, após os testes, que para a definição de um padrão de identificação e de reconhecimento de um odorante específico que o parâmetro de controle  $p_1$ , da forma como o nosso sistema dinâmico foi definido, deveria assumir o valor fixo  $0.0097$ . Em seguida, fizemos o outro parâmetro  $q_1$  assumir o valor 0 (zero). A dinâmica encontrada, como já era o esperado para este caso, é de estado caótico significando a ausência de odorante no epitélio olfativo e, conseqüentemente, os neurônios receptores olfativos permanecem no seu estado fundamental.

Cada um dos quatro neurônios da rede apresenta um movimento de estado caótico justificado pelo espalhamento dos dados nos gráficos correspondentes, confirmado inclusive pelo neurônio soma

$$S = S_1 + S_2 + S_3 + S_4, \quad (4.12)$$

por intermédio da FIGURA 4.14, a qual apresenta o mesmo estado. Em função da similaridade de todos esses gráficos, doravante nos fixaremos somente no neurônio soma (S), o qual estabelece o estado da rede.

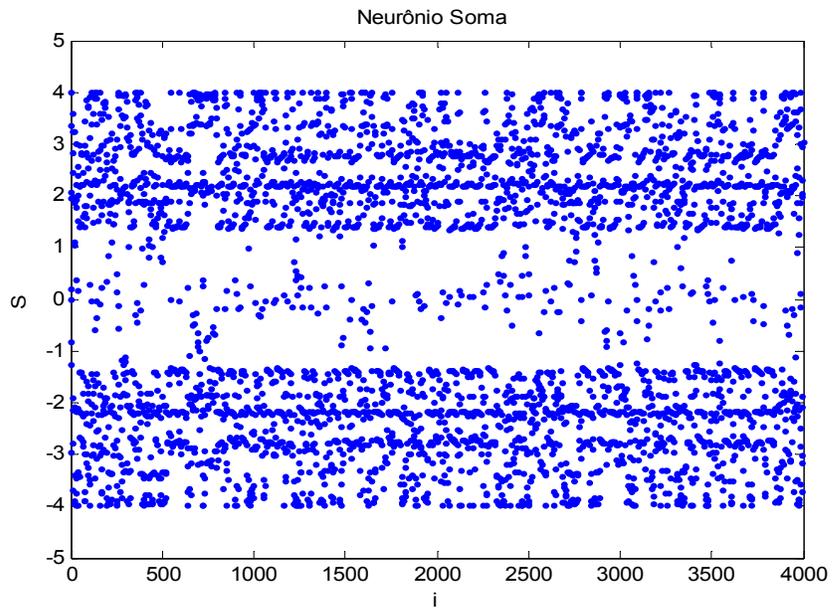


FIGURA 4.14 – Gráfico do neurônio soma (S), após 4,000 iterações.

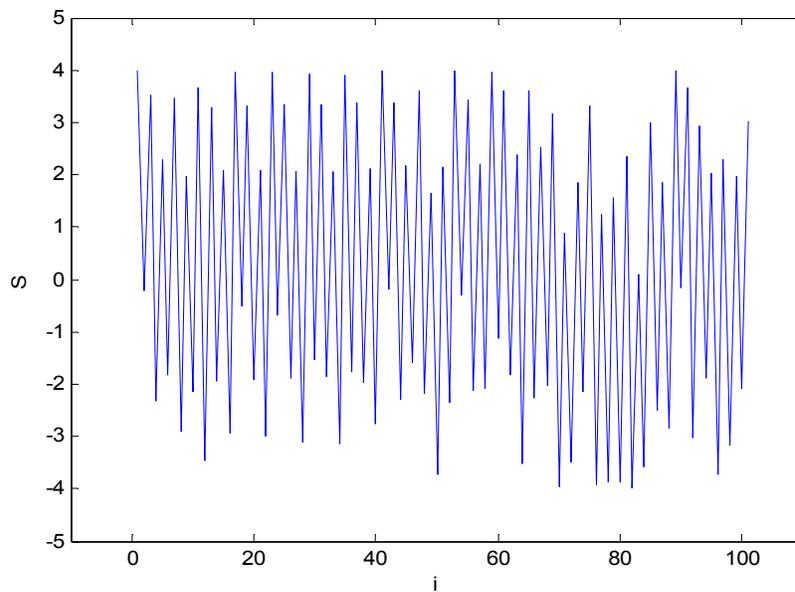


FIGURA 4.15 – Gráfico do neurônio soma (S). Com últimas iterações.

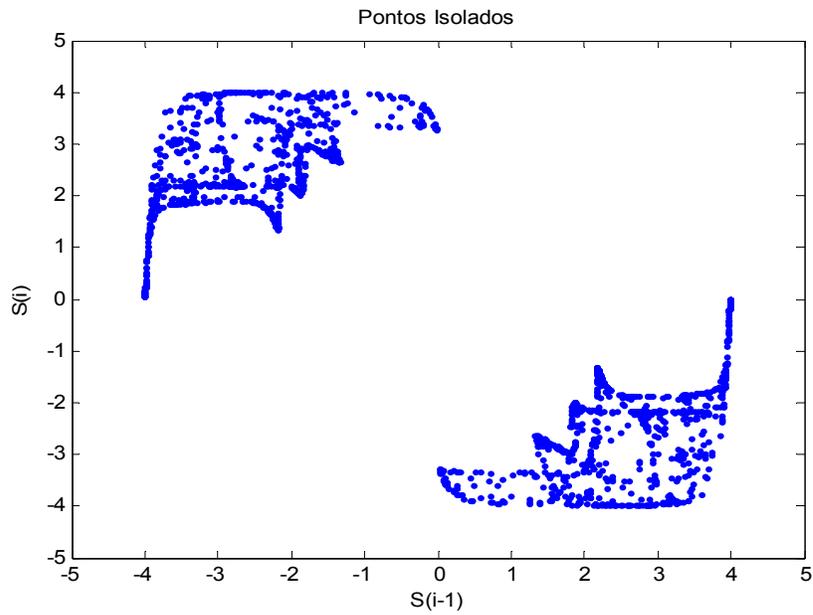


FIGURA 4.16 – Gráfico das 2,100 últimas iterações do neurônio soma (pontos isolados de  $S(i)$  por  $S(i-1)$ ).

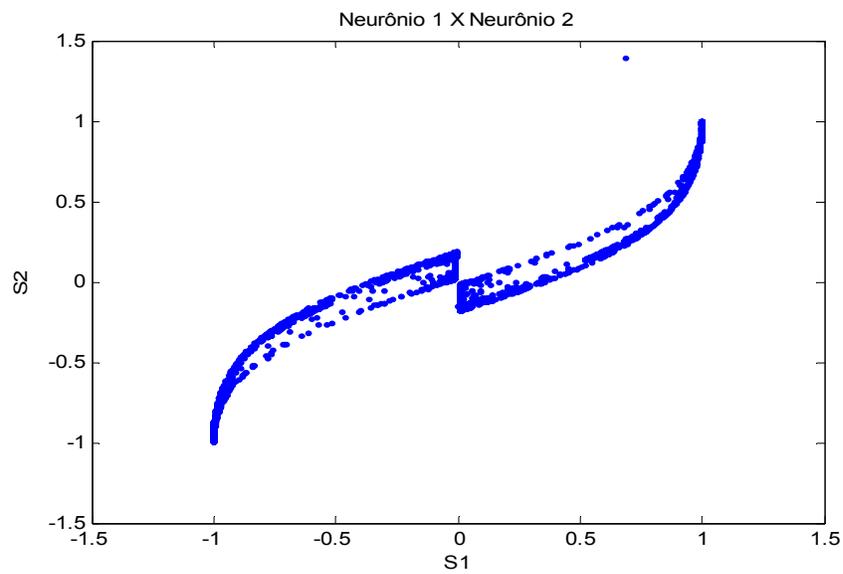


FIGURA 4.17 – O atrator formado pelos neurônios (1) e (2).

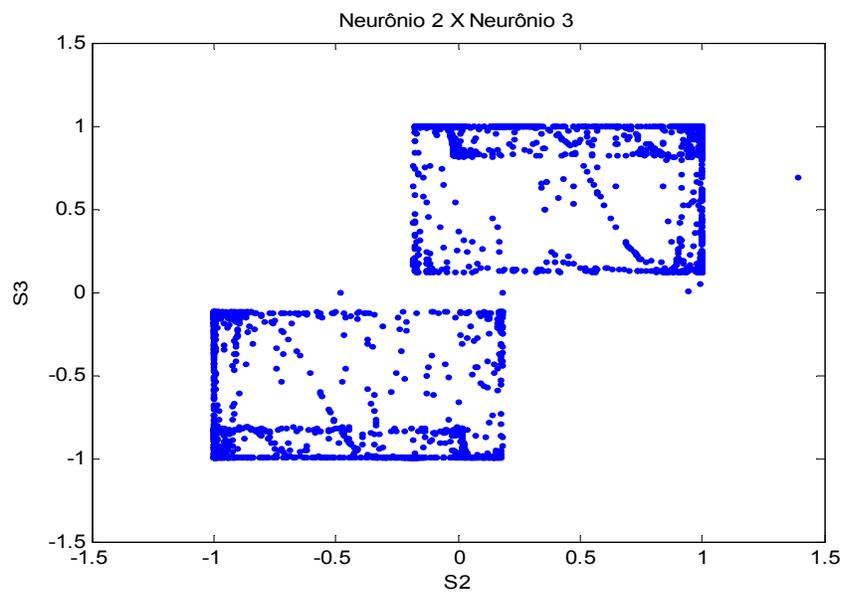


FIGURA 4.18 – O atrator formado pelos neurônios (2) e (3).

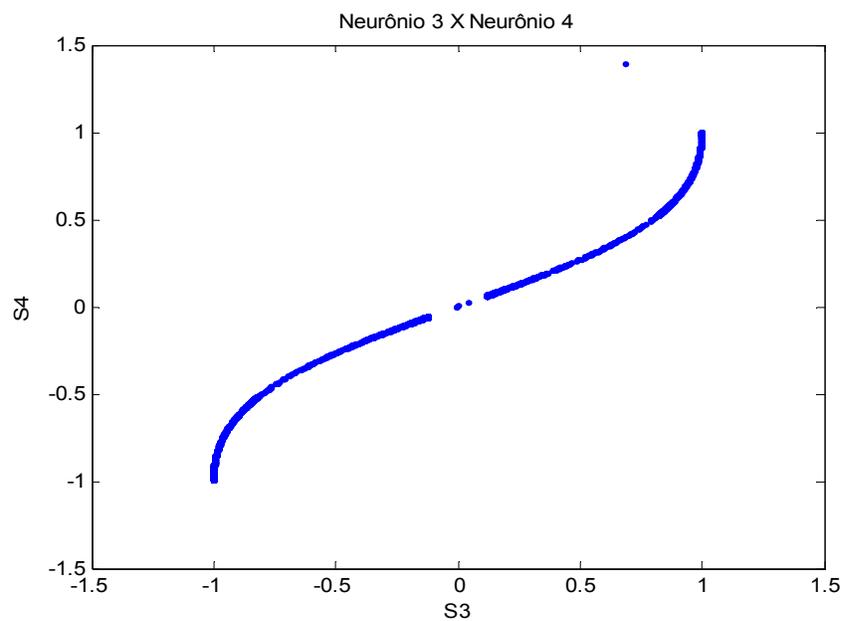


FIGURA 4.19 – O atrator formado pelos neurônios (3) e (4).

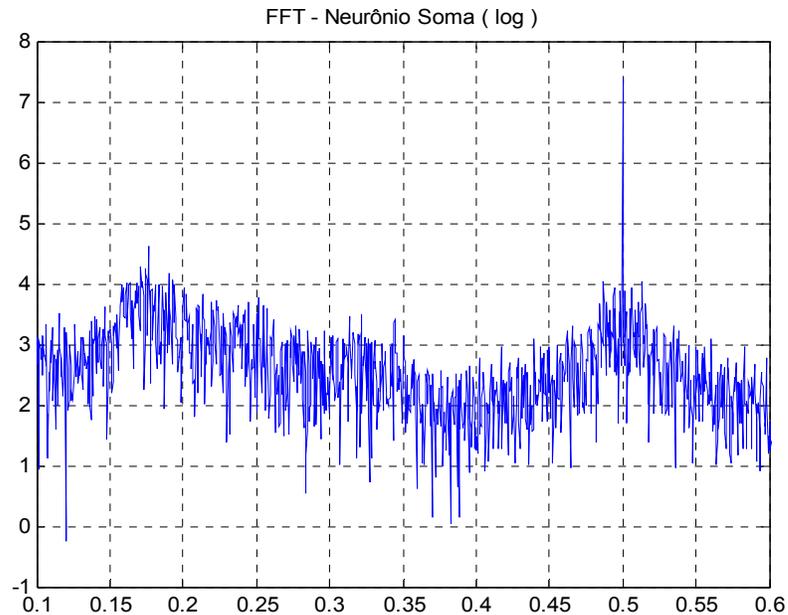


FIGURA 4.20– A FFT aplicada ao neurônio soma (com o logaritmo decimal).

A FIGURA 4.15 mostra o gráfico do neurônio soma ( $S$ ) quando isolamos os últimos cem valores das 4,000 iterações quando da aplicação do algoritmo FFT que, novamente, confirma os resultados já encontrados. A FIGURA 4.16, em seqüência, mostra o gráfico quando fizemos  $S(i)$  versus  $S(i-1)$  para os últimos 2,100 valores, deixando-os na forma isolada. A FIGURA 4.17 mostra o atrator quando fizemos o gráfico do neurônio (1) versus neurônio (2); análogo ao anterior para a rede de dois neurônios (estrutura básica), mas com um ligeiro alargamento na vizinhança do centro, no ponto (0,0), e com aquele da FIGURA 4.19 que retrata o neurônio (3) versus o neurônio (4). Enquanto isso, a FIGURA 4.18 mostra o atrator justamente na junção entre o neurônio (2) do primeiro sistema e o neurônio (3) do segundo sistema. Neste caso, são dois retângulos bem definidos.

Da mesma maneira que no item anterior deste capítulo, introduzimos o logaritmo decimal sobre as amplitudes no espectro de frequências para evidenciar o comportamento da rede e encontramos o que consta da FIGURA 4.20.

Finalmente, para confirmar que a nossa rede, de fato, apresenta um comportamento caótico quando  $q_1 = 0$  aplicamos o algoritmo para o cálculo dos expoentes de Lyapunov. Encontramos então, que  $\lambda_1 = 2.1894$ ,  $\lambda_2 = 0.1172$ ,  $\lambda_3 = -10.535$ ,  $\lambda_4 = -10.678$  e  $\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 = -18.9664 < 0$ , o que valida todos os resultados anteriores, pois, de acordo com SANDRI, 1996, o sistema dinâmico discreto da nossa rede neural artificial exibe um comportamento caótico.

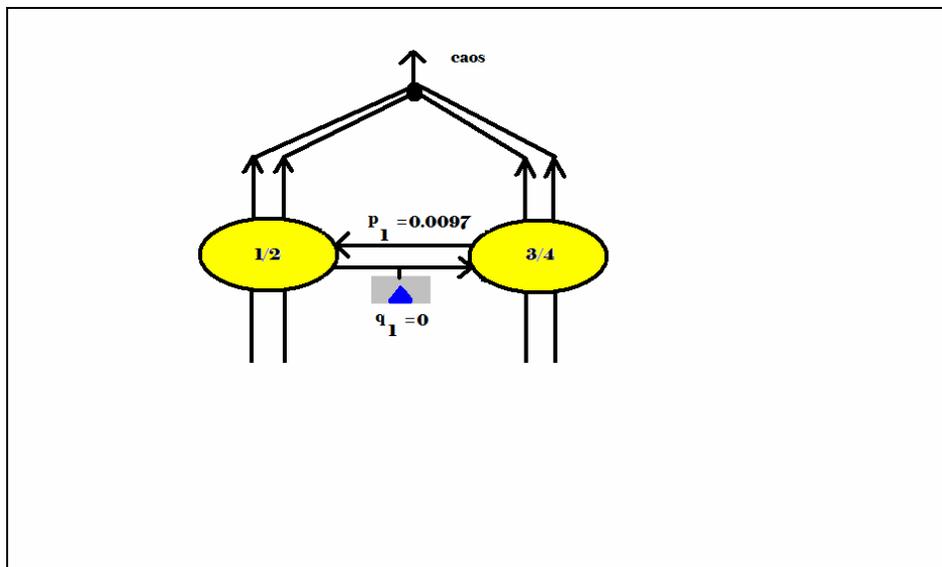


FIGURA 4.21(a) – Na ausência de odorantes, o comportamento da rede é caótico.

Colocando  $q_1 = 0.035$ , o sistema dinâmico da nossa rede passa do comportamento caótico para o não-caótico de maneira bem definida. A FIGURA 4.22 apresenta o gráfico correspondente obtido sobre as cem últimas iterações, como já foi feito anteriormente, que é periódico. A FIGURA 4.23 mostra a modificação sofrida pelo atrator em virtude da mudança de estado, quando elaboramos o gráfico “Neurônio 1 X Neurônio 2”; o

mesmo acontece nos outros dois casos (Neurônio 2 X Neurônio 3 e Neurônio 3 X Neurônio 4). Quando aplicamos o algoritmo FFT ao neurônio soma (S), o gráfico correspondente apresenta dois picos nas frequências 0.25 e 0.5 em correspondência ao gráfico da FIGURA 4.22; com a introdução do logaritmo decimal nas amplitudes do espectro de frequências do gráfico anterior encontramos somente dois pontos, motivo pelo qual não os colocamos. Entretanto, os valores encontrados constam da TABELA 4.1. Novamente, para finalizar, calculamos os expoentes de Lyapunov e encontramos que  $\lambda_1 = -0.1195$ ,  $\lambda_2 = -7.1477$ ,  $\lambda_3 = -13.843$ ,  $\lambda_4 = -13.889$ , todos negativos o que confirma que o estado da nossa rede não é caótico e significa que ela foi capaz de identificar e reconhecer uma molécula com um odor específico (padrão A, relativo ao valor da sinapse em 0.035). Em acréscimo, podemos dizer que isto significa que, quando um odorante ligou-se ao receptor correspondente, o valor da sinapse passou de 0 para 0.035, mudando conseqüentemente o estado da rede, o qual é verificado pelas mudanças no espectro de frequências. Neste ponto devemos colocar, também, que o sinal emitido pela nossa rede é transformado, após a aplicação da FFT, num espectro de frequências e que moléculas odoríferas diferentes emitem sinais diferentes e, conseqüentemente, exibem espectros de frequências diferentes, ou seja, exibem valores de amplitudes distintos.

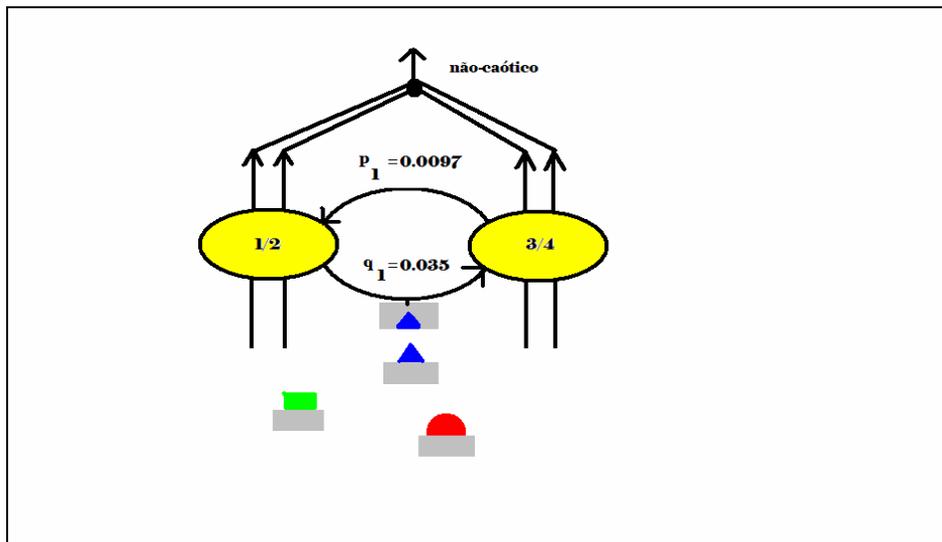


FIGURA 4.21(b) – Quando o odorante se fixa no receptor, o valor da sinapse  $q_1$  muda de 0 para 0.035 e faz com que a rede mude para o comportamento não-caótico.

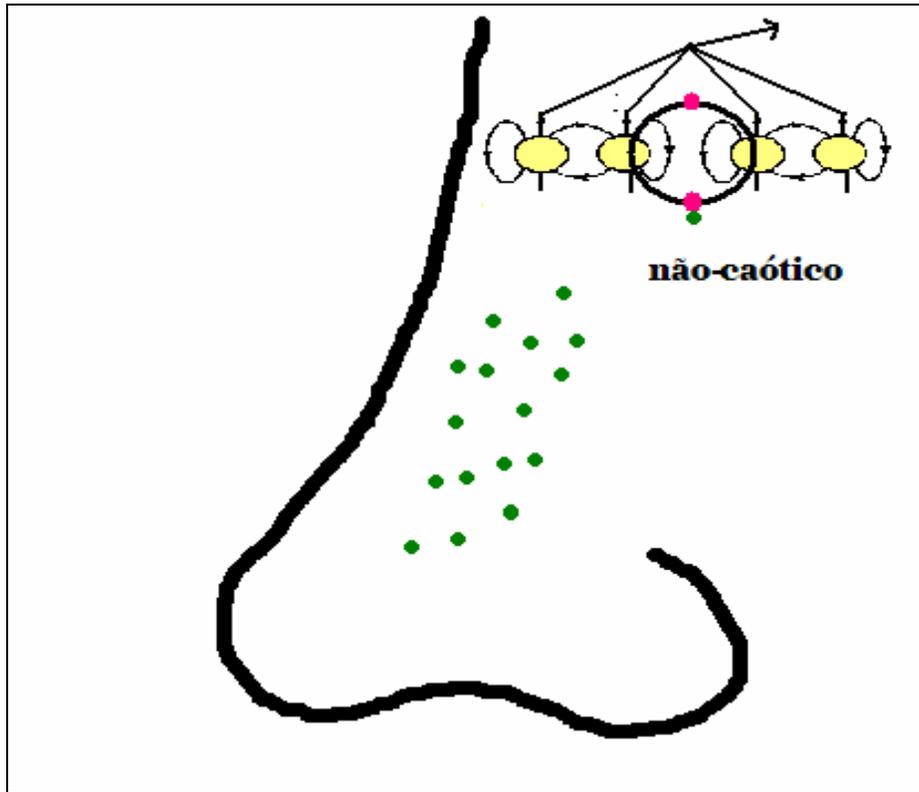


FIGURA 4.21(c) – Estilização da FIGURA 4.21(b).

Analogamente, colocando agora,  $q_1 = 0.1189$ , encontramos  $\lambda_1 = -0.1234$ ,  $\lambda_2 = -15.012$ ,  $\lambda_3 = -20.553$  e  $\lambda_4 = -23.913$ , todos negativos, o que significa que o estado da nossa rede não é caótico e que ela foi capaz de reconhecer um outro odorante específico (padrão B, relativo ao valor da sinapse em  $0.1189$ ).

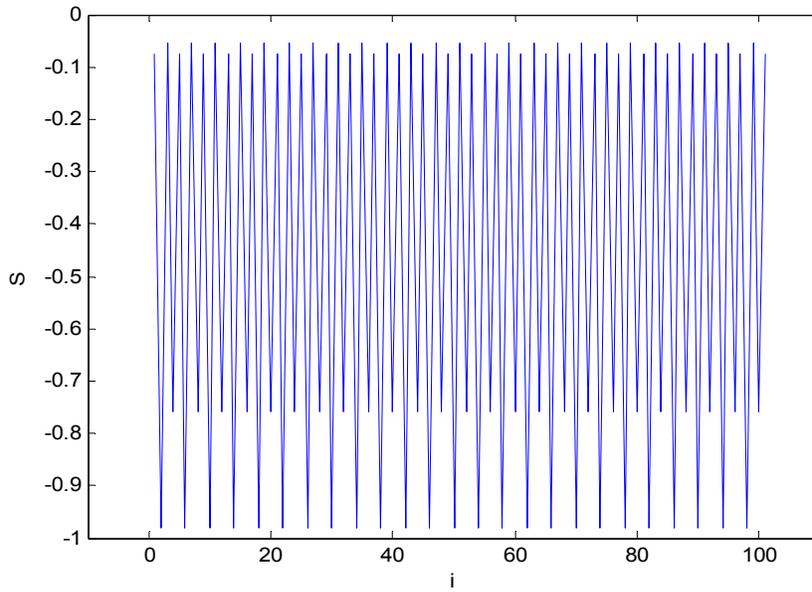


FIGURA 4.22 – Gráfico do neurônio soma (S). Com últimas iterações.

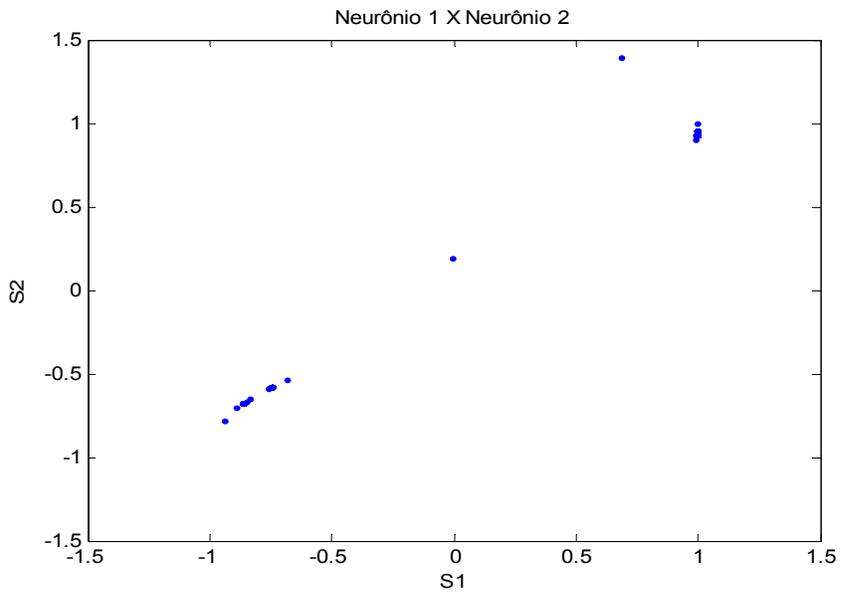
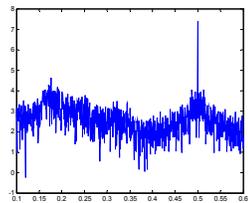
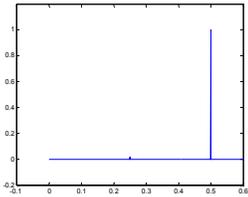
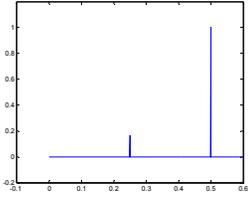


FIGURA 4.23 – O atrator para o caso não-caótico.

TABELA 4.1 – Quadro resumo dos padrões CAÓTICO, A e B (as figuras representam o neurônio soma na forma normalizada).

$q_1$	Padrão	Figura	Amplitudes (log)
0	Caos		Bandas Largas
0.035	A		4.1207 (0.25) 5.8319 (0.50)
0.1189	B		4.3766 (0.25) 5.1508 (0.50)

#### 4.4 Rede Neural de Seis Neurônios

O arranjo da rede neural recorrente de seis neurônios com diagrama simplificado aparece representado na FIGURA 4.24.

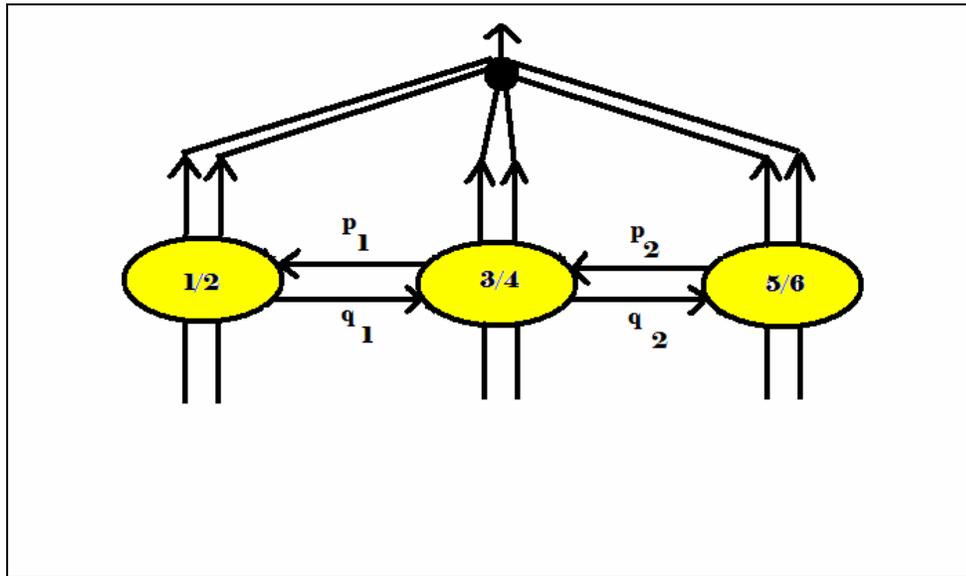


FIGURA 4.24 – O arranjo da rede de seis neurônios.

Neste caso, os parâmetros de controle são  $p_1$ ,  $q_1$ ,  $p_2$  e  $q_2$ , responsáveis pela ligação entre os três sistemas, aquele dos neurônios (1) e (2) com aquele dos neurônios (3) e (4) e deste com o dos neurônios (5) e (6), cuja dinâmica é dada pelo conjunto de equações

$$S_1(t+1) = \tanh(r(J_{11}S_1(t) + J_{12}S_2(t)))$$

$$S_2(t+1) = \tanh(r(J_{21}S_1(t) + J_{22}S_2(t) + p_1S_3(t)))$$

$$S_3(t+1) = \tanh(r(q_1 S_2(t) + J_{33} S_3(t) + J_{34} S_4(t))) \quad (4.13)$$

$$S_4(t+1) = \tanh(r(J_{43} S_3(t) + J_{44} S_4(t) + p_2 S_5(t)))$$

$$S_5(t+1) = \tanh(r(q_2 S_4(t) + J_{55} S_5(t) + J_{56} S_6(t)))$$

$$S_6(t+1) = \tanh(r(J_{65} S_5(t) + J_{66} S_6(t))).$$

A matriz  $J_6$  é dada por

$$J_6 = \begin{pmatrix} -1 & 1 & 0 & 0 & 0 & 0 \\ -0.5 & 0.5 & p_1 & 0 & 0 & 0 \\ 0 & q_1 & -1 & 1 & 0 & 0 \\ 0 & 0 & -0.5 & 0.5 & p_2 & 0 \\ 0 & 0 & 0 & q_2 & -1 & 1 \\ 0 & 0 & 0 & 0 & -0.5 & 0.5 \end{pmatrix}. \quad (4.14)$$

As condições iniciais são  $S_1(1) = S_3(1) = S_5(1) = 0.69$ ,  $S_2(1) = S_4(1) = S_6(1) = 1.39$  e  $r = 19.2485$ . Escolhendo  $p_1 = p_2 = 0.0097$ , como no caso anterior, e  $q_1 = q_2 = 0$  encontramos a nossa rede no estado caótico, significando a ausência de moléculas odoríferas, confirmado pelo cálculo dos expoentes de Lyapunov, que após 10,000 iterações, como em todos os casos estudados, nos forneceu os seguintes resultados  $\lambda_1 = 2.229$ ,  $\lambda_2 = 1.8089$ ,  $\lambda_3 = 0.1051$ ,  $\lambda_4 = -10.185$ ,  $\lambda_5 = -10.201$ ,  $\lambda_6 = -14.496$ , cuja soma é negativa.

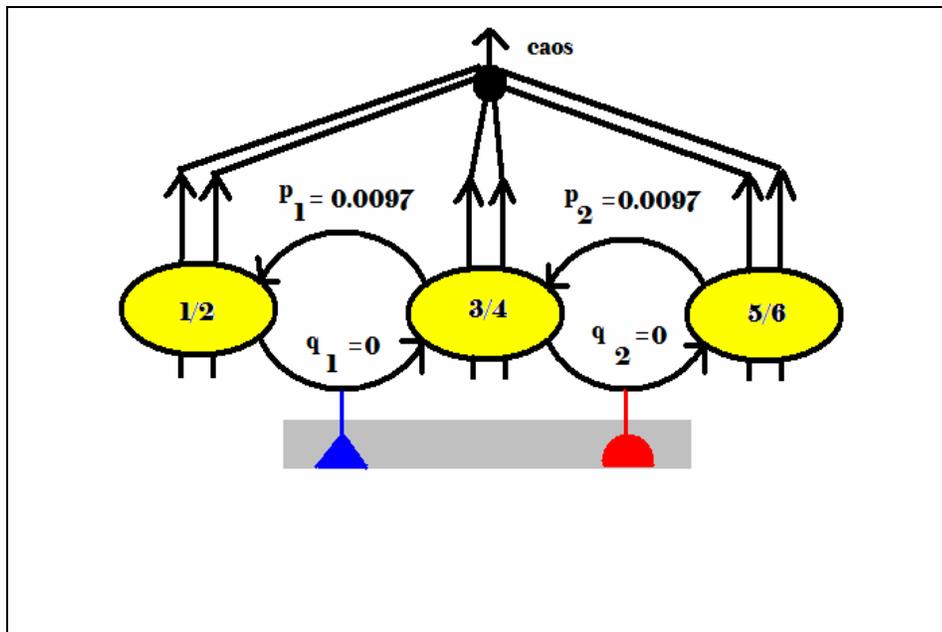


FIGURA 4.25(a) – Na ausência de odorantes, o comportamento da rede é caótico.

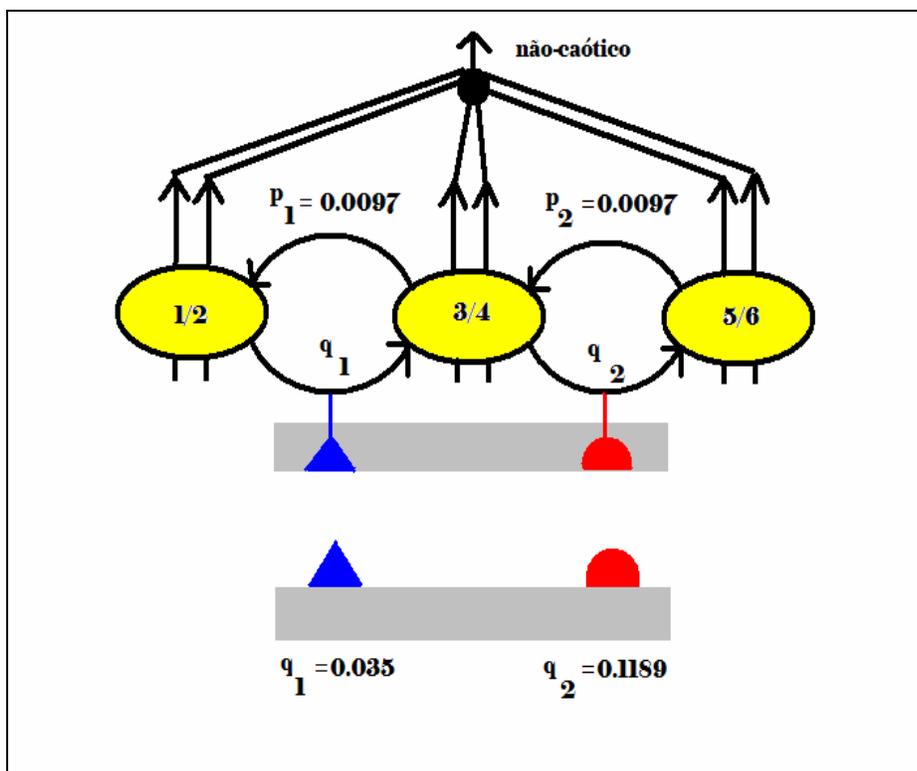


FIGURA 4.25(b) – Quando a molécula odorífera se liga ao receptor o comportamento da rede passa a ser não-caótico (padrão AB, neste caso).

Este caso é análogo ao do item anterior deste capítulo e pode ser considerado como uma sua extensão; da mesma forma, também, que pode ser considerado como um caso particular da rede neural com oito neurônios do item a seguir, de maneira que todas as figuras foram omitidas neste item, pois elas são similares às figuras dos dois itens acima referidos.

Colocando  $q_1 = q_2 = 0.035$ , no algoritmo FFT bem como no programa que calcula os expoentes de Lyapunov, obtemos que a nossa rede apresenta um comportamento não-caótico, o que significa que ela é capaz de identificar e reconhecer o cheiro de dois odorantes com a forma AA (A :  $q_1 = 0.035$ ). Os expoentes de Lyapunov são  $\lambda_1 = -0.1236$ ,  $\lambda_2 = -3.7787$ ,  $\lambda_3 = -7.651$ ,  $\lambda_4 = -10.346$ ,  $\lambda_5 = -10.347$ ,  $\lambda_6 = -25.814$ , de soma negativa. Ademais, quando as sinapses  $q_1$  e  $q_2$  passam de 0 para 0.035 temos que uma molécula odorífera com os dois odorantes (AA) ligou-se ao receptor correspondente e o estado da rede mudou de caótico para o não-caótico, tendo em vista as mudanças no espectro de frequências.

Com  $q_1 = 0.035$  e  $q_2 = 0.1189$ , obtemos um resultado análogo e da mesma forma a nossa rede neural foi capaz de identificar e reconhecer o cheiro da molécula com dois odorantes na forma AB (B :  $q_2 = 0.1189$ ). Aplicando o programa para o cálculo dos expoentes de Lyapunov, encontramos que  $\lambda_1 = -0.1231$ ,  $\lambda_2 = -3.9164$ ,  $\lambda_3 = -10.3380$ ,  $\lambda_4 = -10.3390$ ,  $\lambda_5 = -15.2060$ ,  $\lambda_6 = -40.3240$ , de soma negativa, o que de acordo com SANDRI, 1996, demonstra que o sistema dinâmico exibe um comportamento não-caótico. Quando  $q_1 = 0.1189$  e  $q_2 = 0.035$ , temos a molécula odorífera no formato BA e quando  $q_1 = q_2 = 0.1189$ , temos, finalmente, a molécula odorífera no formato BB, o que mostra que todas as combinações de dois odorantes podem ser identificadas e reconhecidas pela rede neural de seis neurônios, uma vez que ocorrem mudanças nas amplitudes do espectro de frequências. É natural que operando na vizinhança desses valores podemos estabelecer novos padrões de moléculas com outros odorantes.

Quando da aplicação do programa para o cálculo dos expoentes de Lyapunov, encontramos todos negativos, como era o esperado. No primeiro caso (BA), eles são iguais a  $\lambda_1 = -0.1234$ ,  $\lambda_2 = -7.6625$ ,  $\lambda_3 = -11.6750$ ,  $\lambda_4 = -18.6790$ ,  $\lambda_5 = -18.6800$ ,  $\lambda_6 = -25.819$  e, no segundo caso (BB), eles são iguais a  $\lambda_1 = -0.1234$ ,  $\lambda_2 = -11.8240$ ,  $\lambda_3 = -15.2090$ ,  $\lambda_4 = \lambda_5 = -18.6790$  e  $\lambda_6 = -40.2900$ .

Ao finalizar este item, é importante observar que o sistema dinâmico da nossa rede neural recorrente de seis neurônios, da maneira como ela foi definida para este trabalho, contempla também o caso OA, em que há somente um odorante na molécula, visto que o zero, como foi bem determinado significa a ausência de um odorante. Isto demonstra a permanência da memória para um só odorante. Por outro lado, fizemos o teste com o outro valor (*0.1189*) e conseguimos um resultado idêntico ao anterior, de forma que encontramos também a forma OB. Todos os expoentes de Lyapunov calculados para estes dois casos são negativos e, da mesma forma que nos casos anteriores, ocorrem mudanças significativas nas amplitudes (ou magnitudes) do espectro de frequências. Todos estes resultados constam das TABELAS 4.2(a) e 4.2(b).

TABELA 4.2(a) – Quadro resumo dos padrões CAÓTICO, OA e OB (as figuras representam o neurônio soma na forma normalizada).

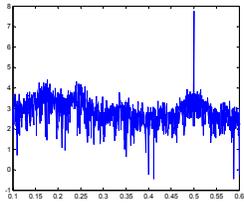
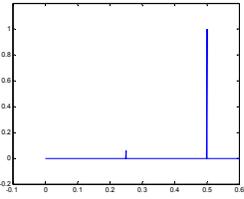
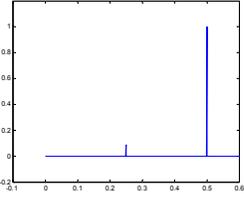
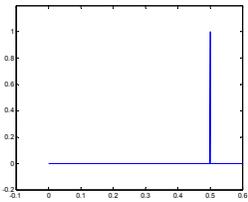
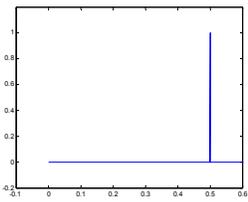
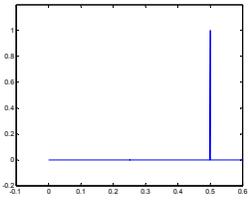
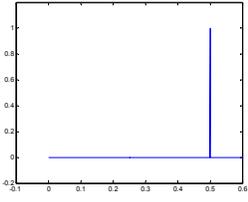
$Q_1$	$q_2$	Padrão	Figura	Amplitudes (log)
0	0	Caos		Bandas largas
0	0.035	OA		5.8504 (0.25) 7.0611 (0.50)
0	0.1189	OB		5.8831 (0.25) 6.9398 (0.50)

TABELA 4.2(b) – Quadro resumo dos padrões AA, AB, BA e BB (as figuras representam o neurônio soma na forma normalizada).

$q_1$	$q_2$	Padrão	Figura	Amplitude (log)
0.035	0.035	AA		4.1575 (0.25) 7.0267 (0.50)
0.035	0.1189	AB		4.1524 (0.25) 7.1283 (0.50)
0.1189	0.035	BA		4.3602 (0.25) 6.9056 (0.50)
0.1189	0.1189	BB		4.3603 (0.25) 7.0204 (0.50)

## 4.5 Rede Neural de Oito Neurônios

Para a rede neural artificial recorrente de oito neurônios temos o arranjo da FIGURA 4.26, que estabelece a forma como a rede foi construída, evolução dos casos anteriores, e que desta maneira pode ser generalizada.

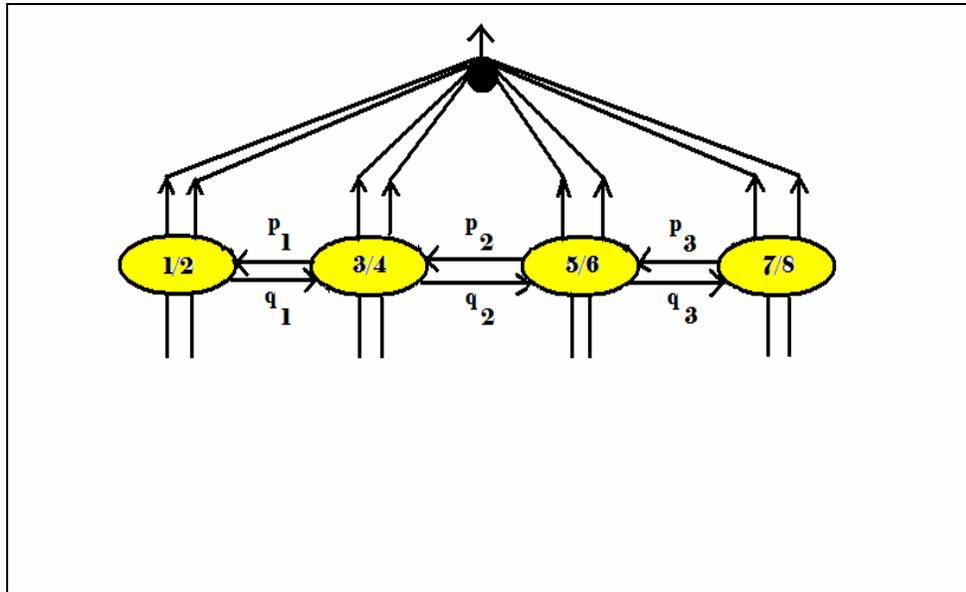


FIGURA 4.26 – O arranjo da rede neural de oito neurônios.

Neste caso, os parâmetros de acoplamento ou de controle são denotados pelas letras  $p_1$ ,  $q_1$ ,  $p_2$ ,  $q_2$ ,  $p_3$  e  $q_3$ . Os valores iniciais são fixados em  $S_1(1) = 0.69$ ,  $S_2(1) = 1.39$ ,  $S_3(1) = 0.69$ ,  $S_4(1) = 1.39$ ,  $S_5(1) = 0.69$ ,  $S_6(1) = 1.39$ ,  $S_7(1) = 0.69$ ,  $S_8(1) = 1.39$ , o neurônio soma é  $S = S_1 + S_2 + S_3 + S_4 + S_5 + S_6 + S_7 + S_8$ . A dinâmica da rede é dada pelo conjunto de equações

$$S_1(t+1) = \tanh(r(J_{11}S_1(t) + J_{12}S_2(t)))$$

$$S_2(t+1) = \tanh(r(J_{21}S_1(t) + J_{22}S_2(t) + p_1S_3(t)))$$

$$\begin{aligned}
S_3(t+1) &= \tanh(r(q_1 S_2(t) + J_{33} S_3(t) + J_{34} S_4(t))) \\
S_4(t+1) &= \tanh(r(J_{43} S_3(t) + J_{44} S_4(t) + p_2 S_5(t))) \quad (4.15) \\
S_5(t+1) &= \tanh(r(q_2 S_4(t) + J_{55} S_5(t) + J_{56} S_6(t))) \\
S_6(t+1) &= \tanh(r(J_{65} S_5(t) + J_{66} S_6(t) + p_3 S_7(t))) \\
S_7(t+1) &= \tanh(r(q_3 S_6(t) + J_{77} S_7(t) + J_{78} S_8(t))) \\
S_8(t+1) &= \tanh(r(J_{87} S_7(t) + J_{88} S_8(t))), \text{ com}
\end{aligned}$$

$$J_8 = \begin{pmatrix} -1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.5 & 0.5 & p_1 & 0 & 0 & 0 & 0 & 0 \\ 0 & q_1 & -1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.5 & 0.5 & p_2 & 0 & 0 & 0 \\ 0 & 0 & 0 & q_2 & -1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.5 & 0.5 & p_3 & 0 \\ 0 & 0 & 0 & 0 & 0 & q_3 & -1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & -0.5 & 0.5 \end{pmatrix} =$$

$$= mJ_8^S + (1-m)J_8^A. \quad (4.16)$$

Da mesma forma que nos itens anteriores deste capítulo, colocamos  $p_1 = p_2 = p_3 = 0.0097$ . Iniciamos as análises fazendo  $q_1 = q_2 = q_3 = 0$  e obtivemos que a rede apresenta o movimento de estado caótico, confirmando o que já havíamos previsto com a condição de que não há nenhum odorante no epitélio olfativo. Na FIGURA 4.27 temos o gráfico das 4,000 iterações aplicadas ao neurônio soma (S), na FIGURA 4.28 temos o diagrama quando utilizamos os últimos cem pontos e na FIGURA 4.29 temos os pontos isolados no gráfico quando efetuamos os cálculos para os últimos 2,100 pontos  $S(i) \times S(i-1)$ . Acrescentamos através das FIGURAS 4.30, 4.32, 4.34 e 4.36 os atratores “internos” dos sistemas, associados à estrutura básica dos dois neurônios, formados pelos neurônios (1) e (2),

neurônios (3) e (4), neurônios (5) e (6) e neurônios (7) e (8), respectivamente, e através das FIGURAS 4.31, 4.33 e 4.35 os atratores “externos” quando efetuamos o acoplamento entre os sistemas citados anteriormente. Para melhor observarmos o estado do sistema aplicamos o logaritmo decimal ao gráfico da FFT aplicada ao neurônio soma (S), cujo resultado é mostrado na FIGURA 4.37 com bandas largas bem definidas. Para confirmar, enfim, que o sistema dinâmico é de comportamento caótico, calculamos os expoentes de Lyapunov, os quais foram incluídos na TABELA 4.3, no fim deste capítulo.

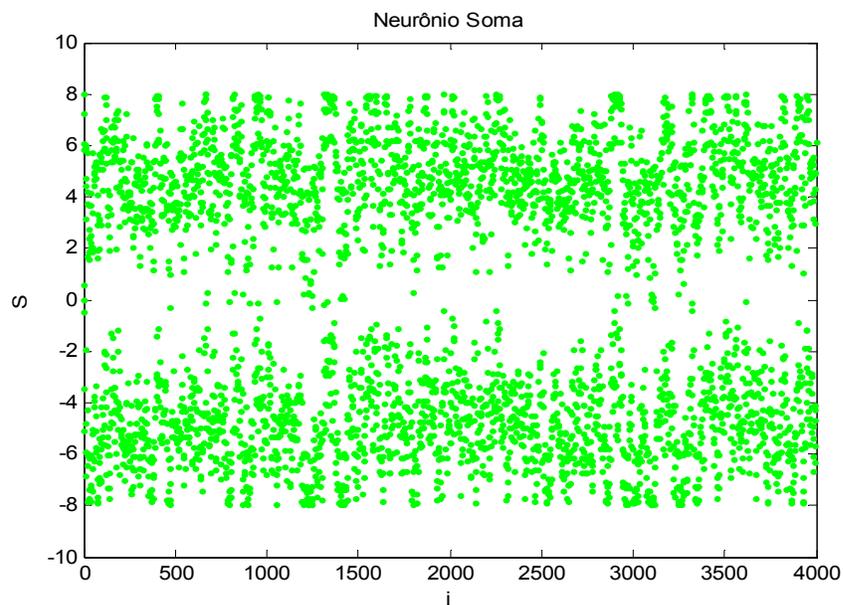


FIGURA 4.27 – Gráfico do neurônio soma (S), após 4,000 iterações.

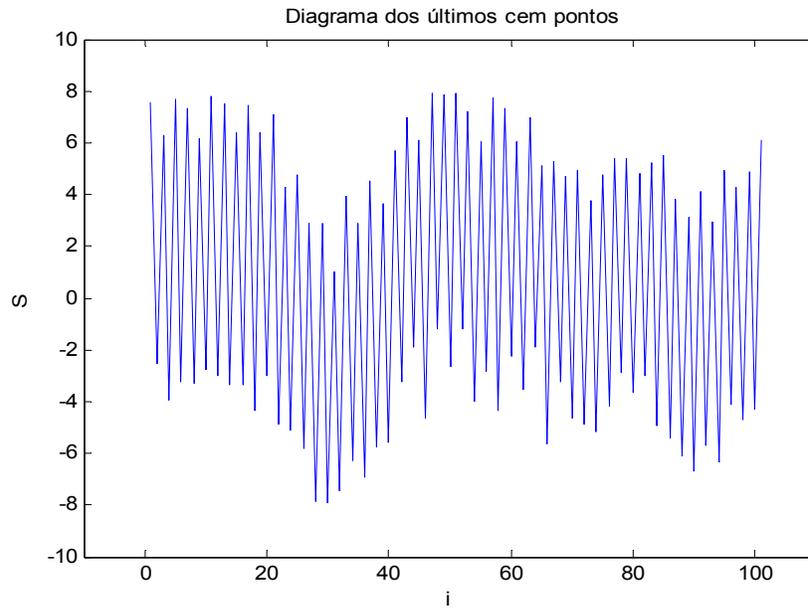


FIGURA 4.28 – Gráfico das cem últimas iterações do neurônio soma (S).

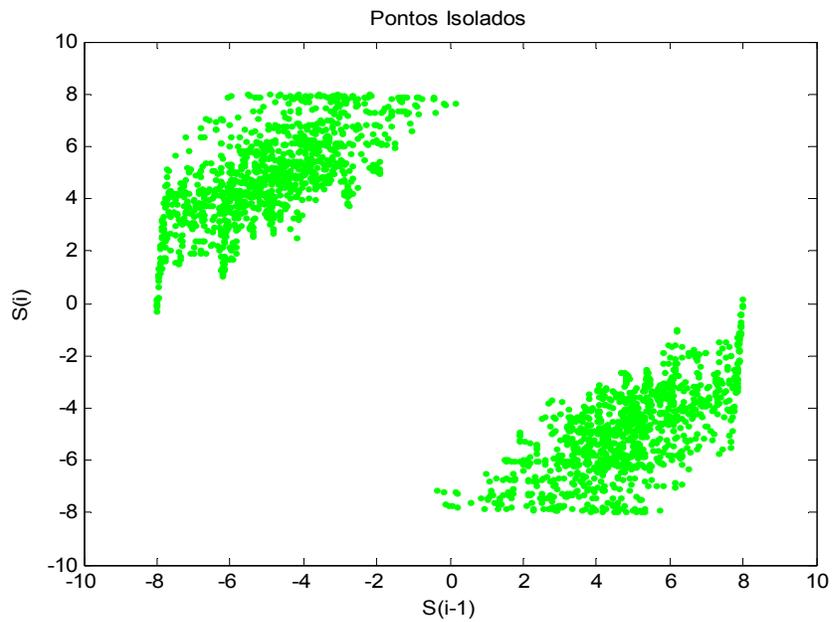


FIGURA 4.29 – Gráfico das 2,100 últimas iterações do neurônio soma (pontos isolados de S(i) por S(i-1)).

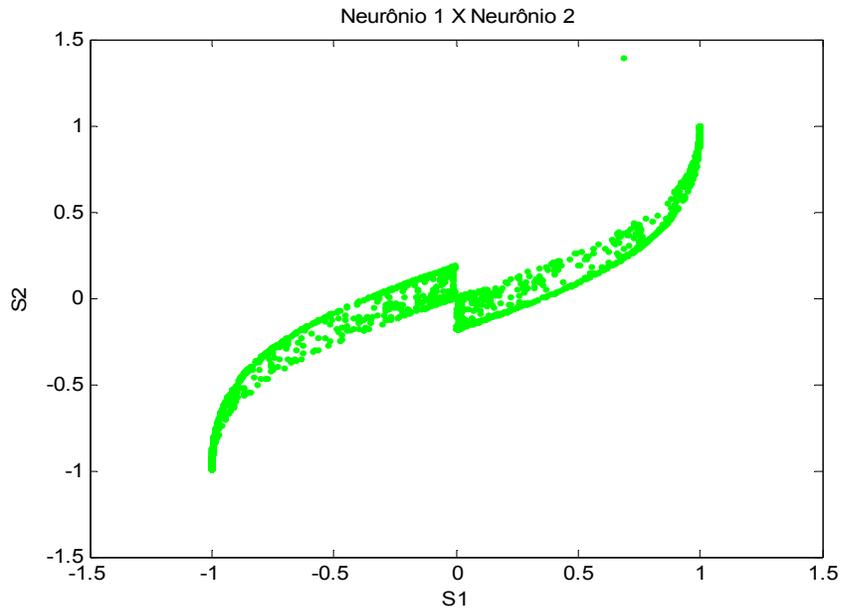


FIGURA 4.30 – O atrator formado pelos neurônios (1) e (2).

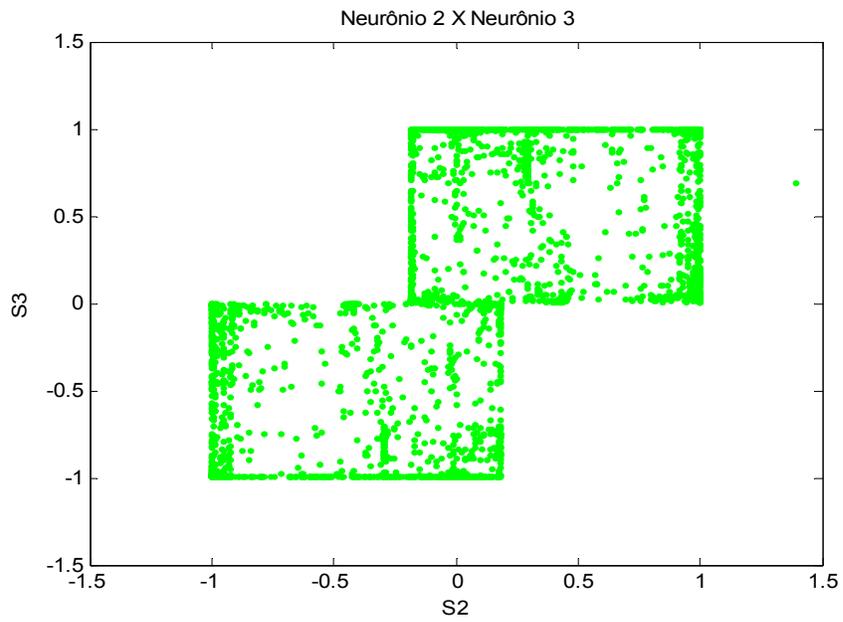


FIGURA 4.31 – O atrator formado pelos neurônios (2) e (3).

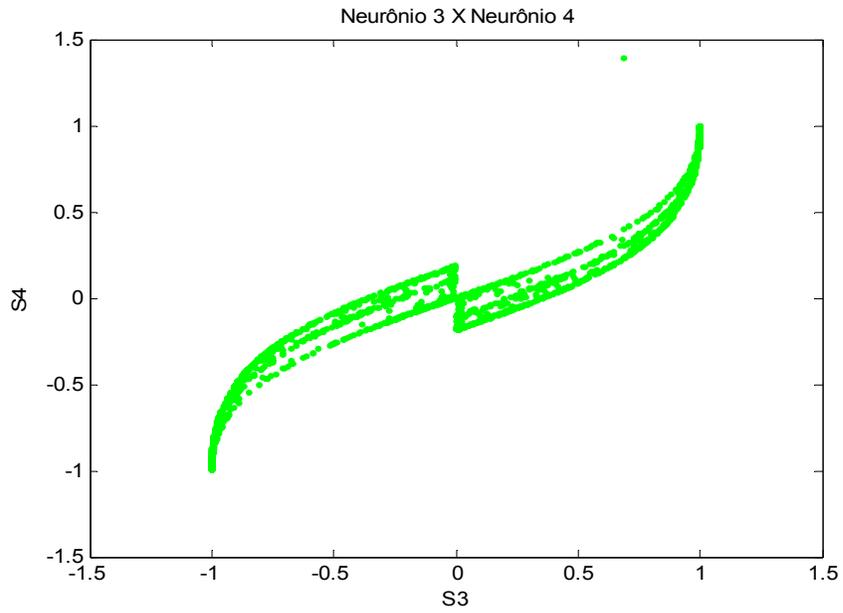


FIGURA 4.32 – O atrator formado pelos neurônios (3) e (4).

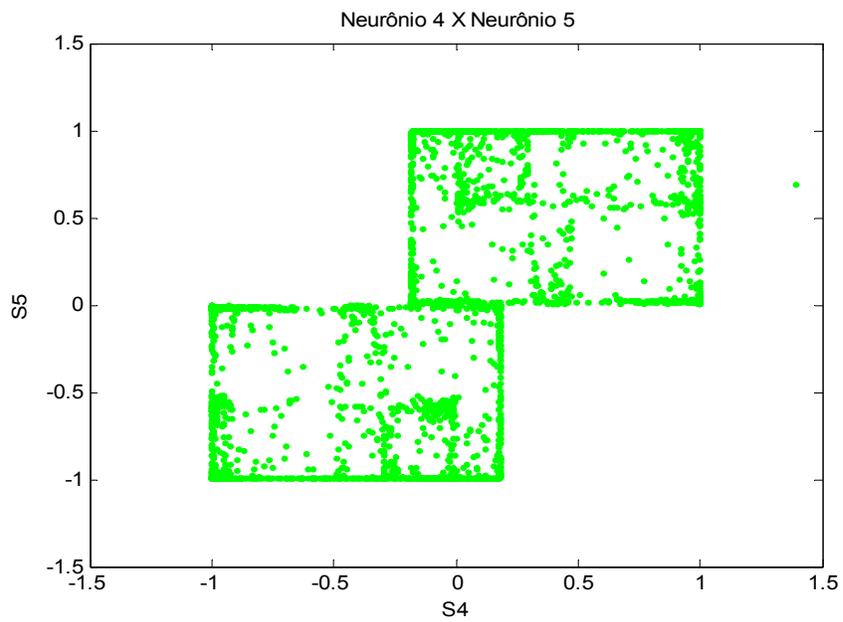


FIGURA 4.33 – O atrator formado pelos neurônios (4) e (5).

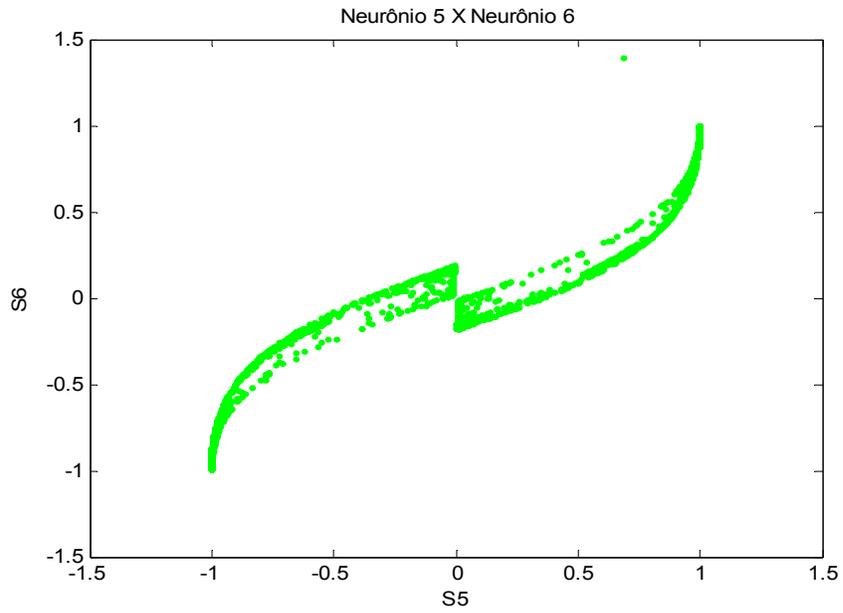


FIGURA 4.34 – O atrator formado pelos neurônios (5) e (6).

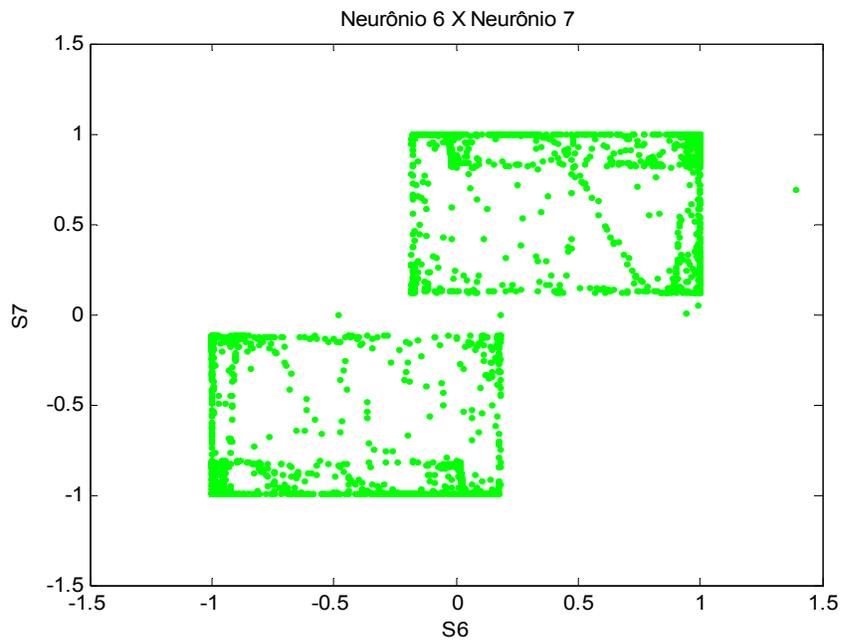


FIGURA 4.35 – O atrator formado pelos neurônios (6) e (7).

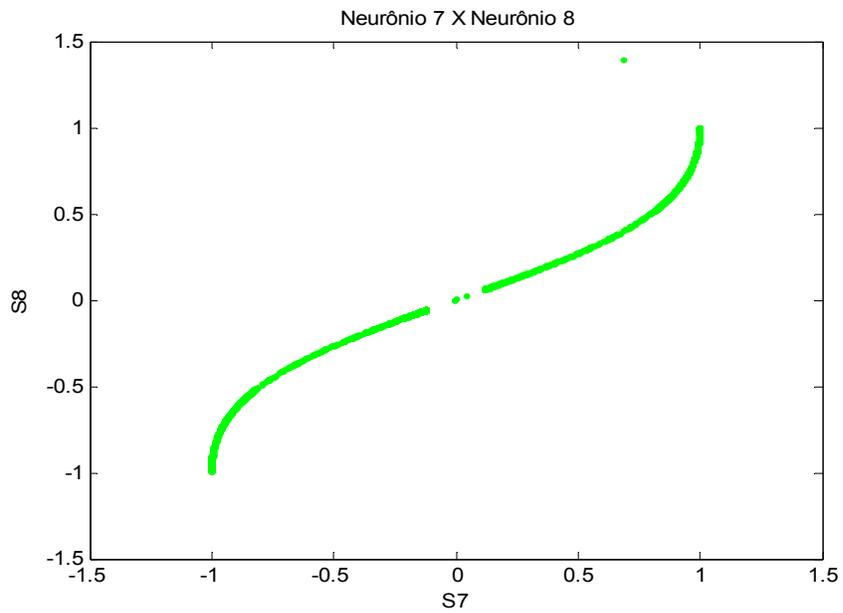


FIGURA 4.36 – O atrator formado pelos neurônios (7) e (8).

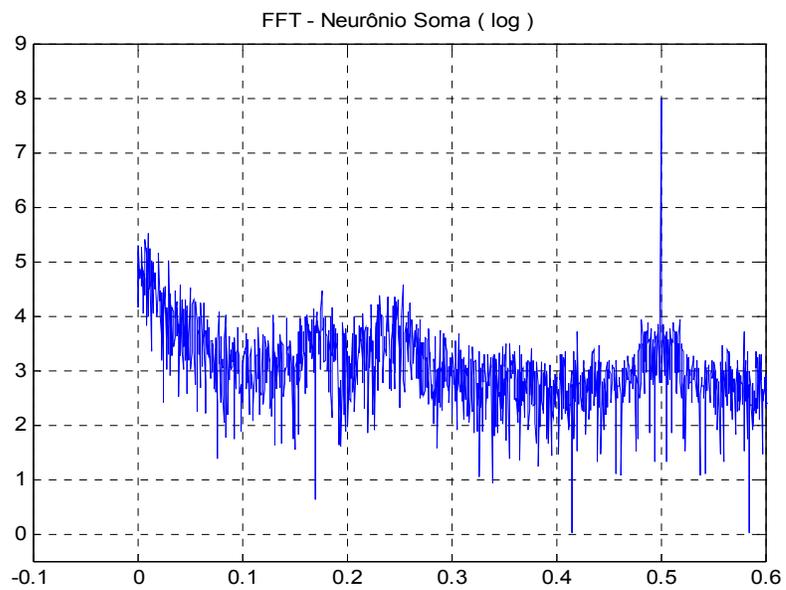


FIGURA 4.37 – A FFT aplicada ao neurônio soma (com o logaritmo decimal).

Agora, estamos em condições de encontrarmos os padrões de reconhecimento das moléculas odoríferas com até três odorantes. Colocando  $q_1 = 0.035$ ,  $q_2 = 0$  e  $q_3 = 0.035$ , observamos que o sistema dinâmico apresenta um comportamento não-caótico. Os expoentes de Lyapunov correspondentes são todos negativos (TABELA 4.3), o que confirma para estes valores que o sistema dinâmico apresenta um comportamento não-caótico e, dessa forma, estabelecemos o padrão AOA para a molécula odorífera não esquecendo, porém, que o zero significa ausência de odorante.

Fixando  $q_1 = 0.035$ ,  $q_2 = 0$  e  $q_3 = 0.1189$ , encontramos o padrão AOB com os expoentes de Lyapunov assumindo valores negativos (TABELA 4.3), demonstrando que o sistema dinâmico exibe o comportamento não-caótico.

O padrão BOA acontece quando colocamos  $q_1 = 0.1189$ ,  $q_2 = 0$  e  $q_3 = 0.035$ , cujos expoentes de Lyapunov são todos negativos (TABELA 4.3). O sistema dinâmico exibe um comportamento não-caótico.

O padrão de reconhecimento de odores no formato BOB é devido ao fato de que  $q_1 = q_3 = 0.1189$  e  $q_2 = 0$ . Os expoentes de Lyapunov são todos negativos e em correspondência o sistema dinâmico é não-caótico (TABELA 4.3).

Colocando  $q_1 = q_2 = q_3 = 0.035$ , obtemos o padrão AAA. Resultado ratificado pelos expoentes de Lyapunov, todos negativos (TABELA 4.3), o que de acordo com SANDRI, 1996, significa que a nossa rede exibe um comportamento não-caótico.

Continuando com as combinações, encontramos o padrão AAB, quando  $q_1 = q_2 = 0.035$  e  $q_3 = 0.1189$ , de acordo com o gráfico mostrado pela FIGURA 4.38,

nitidamente periódico; os expoentes de Lyapunov são todos negativos e constam da TABELA 4.3.

O padrão ABA, quando  $q_1 = q_3 = 0.035$  e  $q_2 = 0.1189$ , é confirmado pelos expoentes de Lyapunov, todos negativos (TABELA 4.3).

O padrão BAA, quando  $q_1 = 0.1189$  e  $q_2 = q_3 = 0.035$ , é demonstrado por meio dos expoentes de Lyapunov, que são todos negativos, conforme TABELA 4.3.

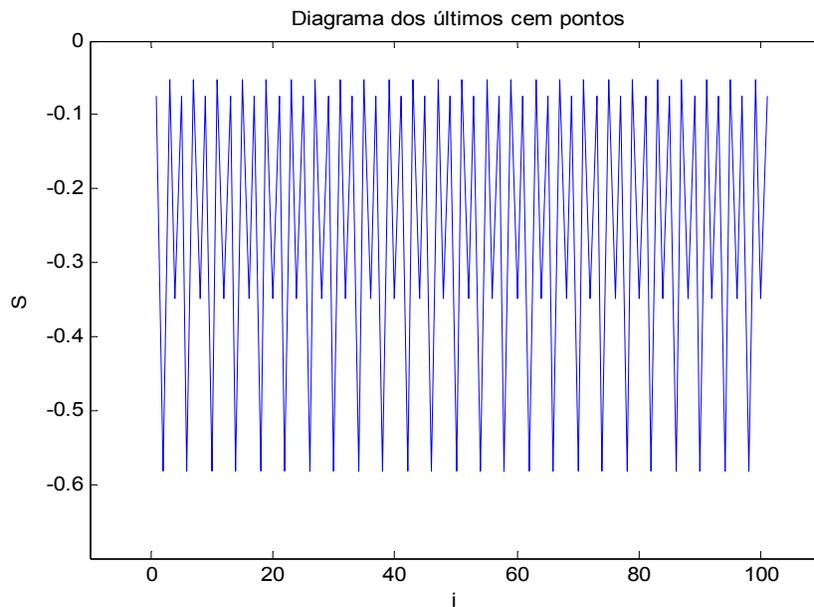


FIGURA 4.38 – Gráfico das cem últimas iterações do neurônio soma (S).

O padrão ABB, que acontece quando fixamos  $q_1 = 0.035$  e  $q_2 = q_3 = 0.1189$ , o padrão BAB, que acontece quando  $q_1 = q_3 = 0.1189$  e  $q_2 = 0.035$ , quando fixamos  $q_1 = q_2 = 0.1189$  e  $q_3 = 0.035$ , encontramos o padrão BBA e, para finalizar, o padrão BBB, quando  $q_1 = q_2 = q_3 = 0.1189$ . Em todos estes casos os expoentes de Lyapunov são todos negativos e foram incluídos na TABELA 4.3.

A rede neural artificial recorrente de oito neurônios, da maneira como ela foi construída, mantém a memória mesmo quando a molécula odorífera que atinge o epitélio olfativo apresenta somente um ou dois odorantes. De forma que o padrão OOA ( $q_1 = q_2 = 0$  e  $q_3 = 0.035$ ) e o padrão OOB ( $q_1 = q_2 = 0$  e  $q_3 = 0.1189$ ) são confirmados pelo fato de que os expoentes de Lyapunov são todos negativos e também foram colocados na TABELA 4.3.

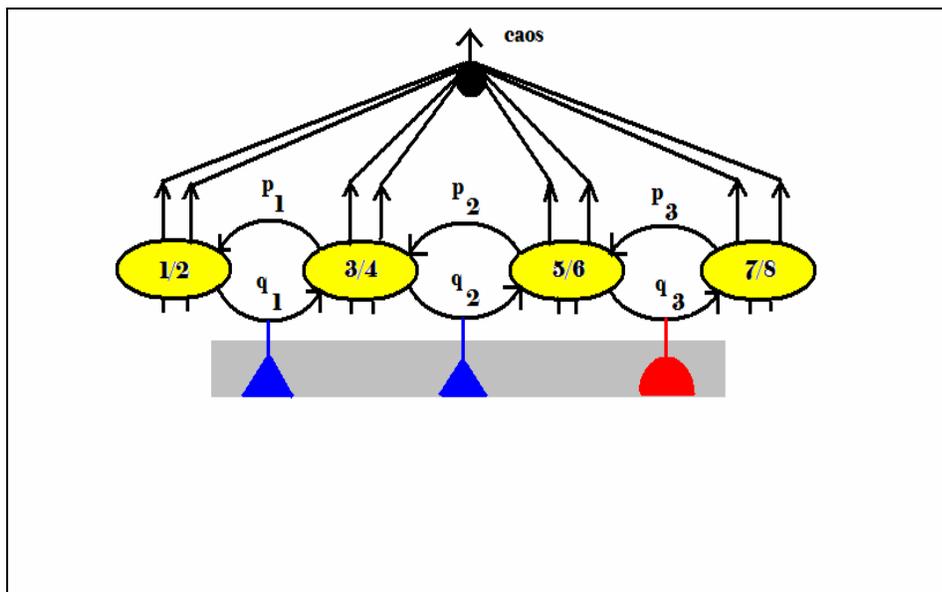


FIGURA 4.39(a) - Na ausência de odorantes, o comportamento da rede é caótico.

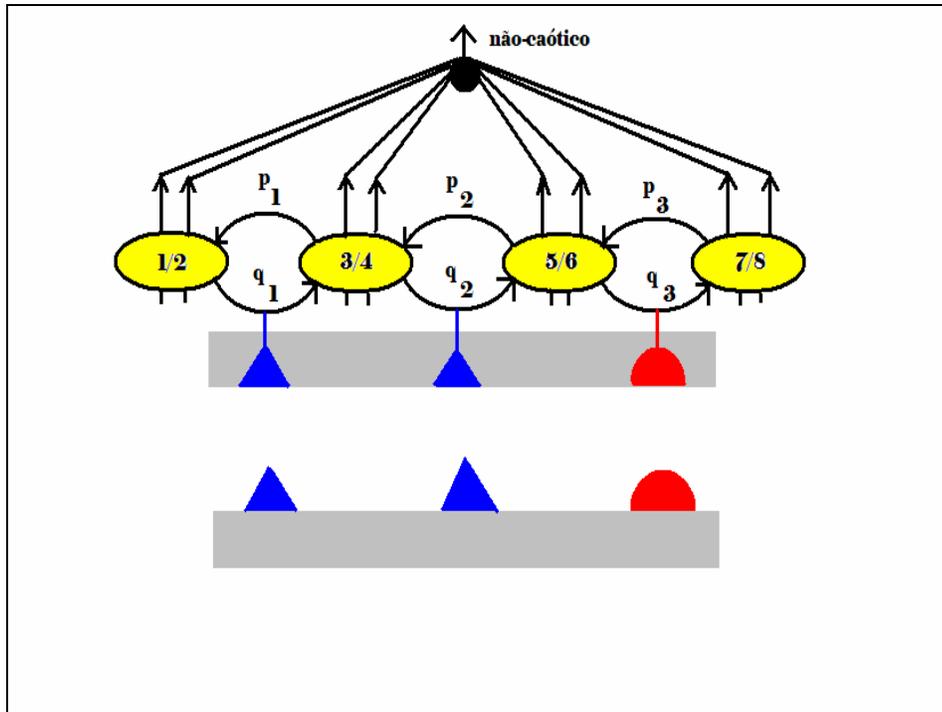


FIGURA 4.39(b) – Quando a molécula odorífera se liga ao receptor o comportamento da rede passa a ser não-caótico (padrão AAB, neste caso).

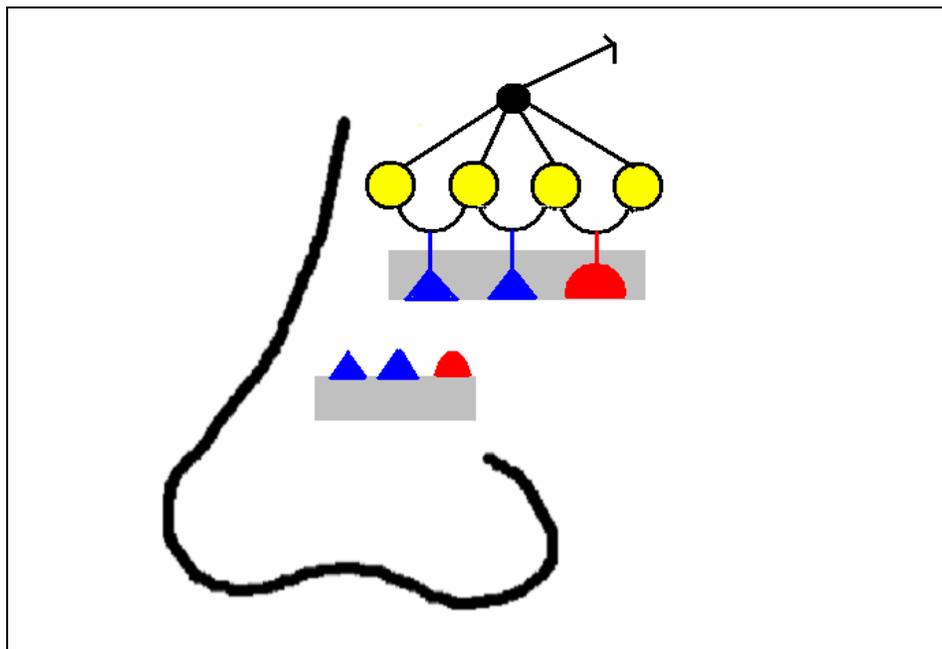


FIGURA 4.39(c) – Estilização da FIGURA 4.39(b).

Por outro lado, o padrão OAA é estabelecido quando  $q_1=0$ ,  $q_2 = q_3 = 0.035$ , o padrão OAB acontece quando  $q_1=0$ ,  $q_2 = 0.035$  e  $q_3 = 0.1189$ , o padrão OBA aparece quando  $q_1=0$ ,  $q_2 = 0.1189$  e  $q_3 = 0.035$  e, finalmente, é estabelecido o padrão OBB, quando  $q_1=0$ ,  $q_2 = q_3 = 0.1189$ . Em todos estes casos os expoentes de Lyapunov são negativos e os seus valores foram colocados na TABELA 4.3

As TABELAS 4.4, 4.5, 4.6, 4.7(a) e 4.7(b) apresentam um quadro resumo dos padrões encontrados, caótico e não-caótico, com a aplicação dos diferentes parâmetros de controle à nossa rede de oito neurônios. Delas constam os parâmetros  $q_1$ ,  $q_2$  e  $q_3$  com os padrões correspondentes e a figura com as amplitudes (ou magnitudes) do espectro de frequências, as quais foram normalizadas, ou seja, o seu valor máximo foi igualado a um. Em vista disso, colocamos também as amplitudes do espectro de frequências, com o logaritmo decimal, para realçar que a amplitudes diferentes haviam sinais diferentes emitidos pela nossa rede.

TABELA 4.3 – Os expoentes de Lyapunov

Padrão	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$	$\lambda_5$	$\lambda_6$	$\lambda_7$	$\lambda_8$
Caos	2.2613	2.2266	1.8089	0.1029	-10.154	-10.189	-11.424	-11.65
AOA	-0.1233	-0.1239	-3.8883	-7.0446	-10.355	-10.356	-13.832	-13.833
AOB	-0.1235	-0.1278	-3.93	-10.375	-10.376	-15.012	-20.553	-23.913
BOA	-0.1234	-0.1264	-7.0451	-11.789	-13.831	-13.833	-18.691	-18.693
BOB	-0.1234	-0.1303	-11.829	-15.011	-18.709	-18.712	-20.553	-23.913
AAA	-0.1236	-3.7815	-4.3588	-7.6545	-10.346	-10.347	-18.652	-18.653
AAB	-0.1236	-3.7811	-4.5	-10.347	-10.347	-15.209	-18.775	-33.017
ABA	-0.1231	-3.9164	-7.662	-10.337	-10.338	-11.872	-26.479	-26.481
BAA	-0.1234	-4.3702	-7.6549	-11.677	-18.653	-18.655	-18.679	-18.681
ABB	-0.1231	-3.9164	-10.338	-10.339	-12.019	-15.21	-33.715	-33.717
BAB	-0.1234	-4.5514	-11.677	-15.208	-18.678	-18.681	-18.779	-33.016
BBA	-0.1234	-7.6651	-11.822	-11.875	-18.677	-18.679	-24.462	-26.465
BBB	-0.1234	-11.824	-12.022	-15.211	-18.678	-18.68	-33.698	-33.7
OOA	-0.1267	-4.473	-4.8618	-7.0446	-13.831	-13.833	-27.202	-27.257
OOB	-0.1306	-4.4859	-4.8641	-15.011	-20.444	-23.096	-27.333	-27.73
OAA	-0.1268	-3.7806	-4.4677	-7.6516	-10.347	-10.347	-25.811	-31.006
OAB	-0.1262	-3.9183	-4.4676	-10.338	-10.338	-15.208	-31.061	-40.264
OBA	-0.1265	-4.4827	-7.6618	-11.677	-18.679	-18.68	-25.817	-31.113
OBB	-0.1265	-4.4827	-11.823	-15.211	-18.68	-18.681	-31.129	-40.272

TABELA 4.4 – Quadro resumo dos padrões OOA e OOB (as figuras representam o neurônio soma na forma normalizada).

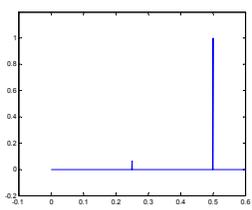
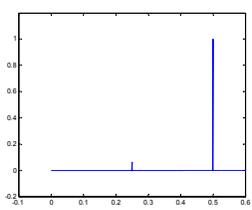
$q_1$	$q_2$	$q_3$	Padrão	Figura	Amplitude (log)
0	0	0.035	OOA		6.3309 (0.25) 7.5354 (0.50)
0	0	0.1189	OOB		6.3498 (0.25) 7.4656 (0.50)

TABELA 4.5 – Quadro resumo dos padrões OAA, OAB, OBA e OBB (as figuras representam o neurônio soma na forma normalizada)

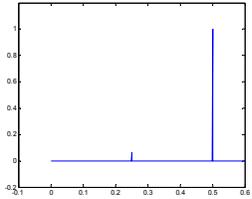
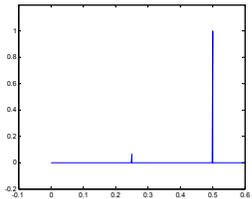
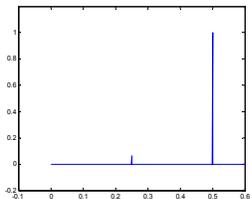
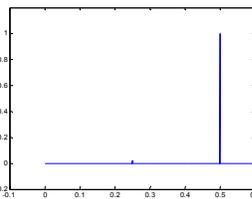
$q_1$	$q_2$	$q_3$	Padrão	Figura	Amplitude (log)
0	0.035	0.035	OAA		5.8552 (0.25) 7.5313 (0.50)
0	0.035	0.1189	OAB		5.8546 (0.25) 7.5896 (0.50)
0	0.1189	0.035	OBA		5.8844 (0.25) 7.4650 (0.50)
0	0.1189	0.1189	OBB		5.8850 (0.25) 7.5272 (0.50)

TABELA 4.6 – Quadro resumo dos padrões CAÓTICO, AOA, AOB, BOA e BOB (as figuras representam o neurônio soma na forma normalizada).

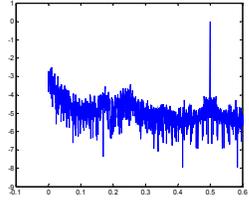
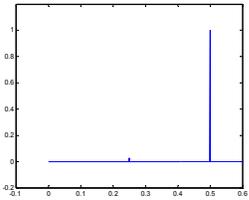
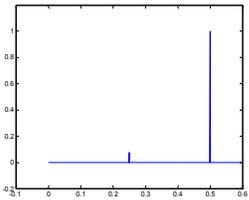
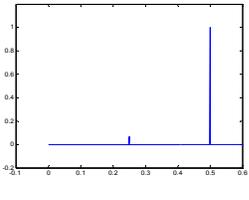
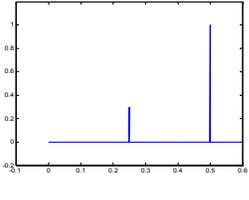
$q_1$	$q_2$	$q_3$	Padrão	Figura	Amplitude (log)
0	0	0	Caos		Bandas largas
0.035	0	0.035	AOA		4.7386 (0.25) 6.3157 (0.50)
0.035	0	0.1189	AOB		4.8696 (0.25) 5.9914 (0.50)
0.1189	0	0.035	BOA		4.8551 (0.25) 6.0098 (0.50)
0.1189	0	0.1189	BOB		4.9766 (0.25) 5.5020 (0.50)

TABELA 4.7(a) – Quadro resumo dos padrões AAA, AAB, ABA e BAA (as figuras representam o neurônio soma na forma normalizada).

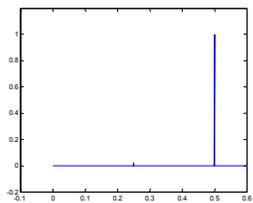
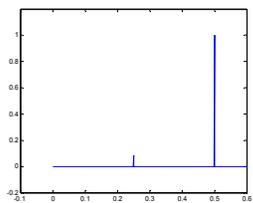
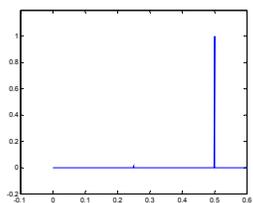
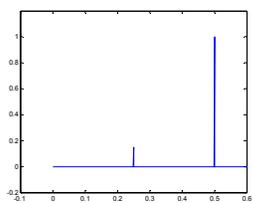
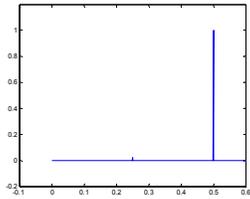
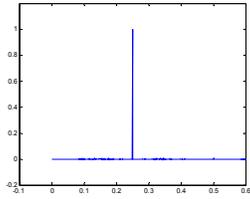
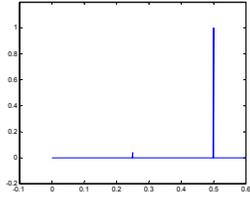
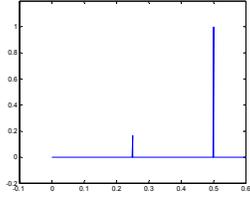
$q_1$	$q_2$	$q_3$	Padrão	Figura	Amplitude (log)
0.035	0.035	0.035	AAA		4.1575 (0.25) 5.8213 (0.50)
0.035	0.035	0.1189	AAB		4.1575 (0.25) 5.2274 (0.50)
0.035	0.1189	0.035	ABA		4.1524 (0.25) 6.1618 (0.50)
0.035	0.035	0.035	BAA		4.3610 (0.25) 5.1803 (0.50)

TABELA 4.7(b) – Quadro resumo dos padrões ABB, BAB, BBA e BBB (as figuras representam o neurônio soma na forma normalizada).

$q_1$	$q_2$	$q_3$	Padrão	Figura	Amplitude (log)
0.035	0.1189	0.1189	ABB		4.1524 (0.25) 5.8100 (0.50)
0.1189	0.035	0.1189	BAB		4.3804 (0.25) 2,2289 (0.50)
0.1189	0.1189	0.035	BBA		4.3620 (0.25) 5.7804 (0.50)
0.1189	0.1189	0.1189	BBB		4.3734 (0.25) 5.1503 (0.50)

## **CAPÍTULO 5**

### **Conclusões e Sugestões**

Concluimos, então, que com a construção de uma estrutura básica de dois neurônios interligados pela regra Hebbiana e acoplando esta rede neural recorrente a uma outra estrutura similar, conseguimos montar uma rede com quatro neurônios artificiais que é capaz de estabelecer um padrão para a identificação e o reconhecimento de um odor com apenas um odorante, no formato A (0.035) ou no formato B (0.1189), a qual atinge o epitélio olfativo dentro das cavidades nasais.

Com a introdução de mais uma estrutura básica em série com a rede de quatro neurônios, formando uma rede neural artificial recorrente de seis neurônios, fomos capazes de estabelecer um padrão de identificação e de reconhecimento de um odor com dois odorantes distintos, nos formatos AA, AB, BA, BB (A: 0.035, B: 0.1189); é importante ressaltar que esta rede conserva a memória para a identificação e o reconhecimento de um odor com apenas um odorante, no formato OA ou no formato OB.

Com uma rede neural artificial recorrente de oito neurônios, como foi montada para este trabalho, é possível estabelecer um padrão de identificação e de reconhecimento de um odor com até três odorantes entre dois odorantes distintos, com os

formatos, tanto das moléculas como dos receptores, AOA, AOB, BOA, BOB, num primeiro bloco; AAA, AAB, ABA, BAA, ABB, BAB, BBA, BBB, no segundo bloco, não esquecendo que A corresponde ao parâmetro  $0.035$  e que B corresponde ao parâmetro  $0.1189$ . A fixação dos valores em  $0.035$  e  $0.1189$  não delimitou o fato de que a odorantes diferentes devem corresponder parâmetros diferentes, pois que na vizinhança destes dois valores há uma grande quantidade de possibilidades que podem ser utilizadas por diferentes odorantes, na medida da necessidade. Novamente, esta rede foi capaz de memorizar os casos em que a molécula contém um só odorante ou dois odorantes nos formatos OOA, OOB, para o primeiro caso e OAA, OAB, OBA, OBB, no segundo caso, com todas as combinações possíveis. Todos estes resultados foram mostrados nas TABELAS 4.1, 4.2, 4.4, 4.5, 4.6, 4.7(a) e 4.7(b).

Fizemos também uma tentativa de minimizar a quantidade de neurônios com a introdução do mapa  $z = S_2 - S_1$ , mas a idéia não prosperou, pois não podíamos inserir na rede os parâmetros de controle ou de acoplamento. Entretanto, o mapa mostrou-se útil na determinação do parâmetro de ganho  $r = 19.2485$ .

Sugerimos, então, para trabalhos futuros, alguns caminhos que podem evoluir a partir deste tipo de rede. O primeiro, seria o de interligar mais sistemas em série aos já existentes formando redes neurais com 10, 12, 14, ..., neurônios, de forma a ampliar o número de odorantes distintos que podem ser identificados e reconhecidos. O segundo, seria o de modificar o tipo de acoplamento atingindo, talvez, o acoplamento total, com a inclusão de alguns parâmetros fixos enquanto os outros permaneceriam variáveis, conforme modelos referenciados. Uma terceira possibilidade seria a de modificar a matriz  $J$  ( $2 \times 2$ ), desde que o seu determinante permaneça nulo. Há também a possibilidade de se desenvolver uma regra de aprendizado envolvendo as redes neurais artificiais recorrentes, como as que foram modeladas para este trabalho.

# ANEXO 1

Programa em MATLAB para o cálculo dos LCE, de acordo com o método de Eckmann-Ruelle e proposto por CAMPANHA et. al., 1997.

```
somaout = [ ];  
  
rout = [ ];  
  
soma = [0;0];  
  
s0 = [0.69 1.39];  
  
ri = 19.248;  
  
rf = 19.249;  
  
m = 0.499999999;  
  
n = input ('Número de iterações por ponto:');  
  
if n == [ ]  
  
n =200;  
  
end;
```

```

iterinicial = input('Iterações iniciais para cada ponto:');

if iterinicial == [ ]

iterinicial = 20;

end;

pontos = input('Número de pontos:');

if pontos == [ ]

pontos = 200;

end;

passo = (rf - ri)/pontos;

r = ri;

while r < rf

t = 0;

s = s0;

while t < iterinicial

s = [tanh(-2*m*r*s(1)+(1.5-m)*r*s(2));tanh((2*m-1.5)*r*s(1)+m*r*s(2))];

t = t + 1;

end;

t = 0;

soma = [0;0];

s;

Tr = Jacobiano (s);

[Q,R] = qr(Tr);

```

```
soma = soma + log(abs(diag(R)));

while t<n

s;

H = Tr;

H = H*Q;

[Q,R] = qr(H);

soma = soma + log(abs(diag(R)));

t = t + 1;

end;

soma = (1/n)*soma;

somaout = [somaout soma];

rout = [rout r];

r = r + passo;

end;

plot(rout,somaout(1,:), rout,somaout(2,:); pause; close;
```

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABDI, H.; VALENTIN, D.; EDELMAN, B. (1993).** *Neural Networks*. Sage University Papers Series on Quantitative Applications in the Social Sciences, 07-124. Thousand Oaks, CA.
- AIHARA, K.; TAKABE, T.; TOYODA, M. (1990).** Chaotic Neural Networks. *Phys. Lett.A. 144*, p.333-340.
- AMIT, D. J.** *The Properties of Models of Simple Neural Networks*. Racah Institute of Physics, Hebrew University, Jerusalem.
- AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L. (2000).** *Redes Neurais com aplicações em Controle e em Sistemas Especialistas*. Florianópolis, Bookstore.
- BABLOYANTZ, A.; NICOLIS, C.; SALAZAR, J.M. (1985).** Evidence of Chaotic Dynamics of Brain Activity During the Sleep Cycle. *Phys. Lett. A 111*, p. 152-156.
- BABLOYANTZ, A.; LOURENÇO, C. (1994).** Computation with Chaos, a Paradigm for Cortical Activity. *Proceedings of the National Academy of Sciences USA*, 91, p. 9027.
- BAI-LIN, H. (1990).** *Chaos II*. Singapore, World Scientific Publishing Co. Pte. Ltd.
- BAIRD, B. (1986).** Nonlinear Dynamics of Pattern Formation and Pattern Recognition in the Rabbit Olfactory Bulb. *Physica 22D*, p. 150-175.

- BAIRD, B.; HIRSCH, M. W.; EECKMAN, F. (1993).** A Neural Network Associative Memory for Handwritten Character Recognition Using Multiple Chua Attractors. In: IEEE TRANSACTIONS ON CIRCUITS AND SYSTEMS II: *Analog & Digital Signal Processing*, 40, p. 667-674.
- BAKER, G. L.; GOLLUB, J.P. (1996).** *Chaotic Dynamics: An Introduction*. 2. ed. New York, Cambridge University Press.
- BARNA, G.; TSUDA, A. I. (1993).** New Method for Computing Lyapunov Exponents. *Phys. Lett. A*, v. 175, n.6, p. 421-427.
- BARTLET, M. S. (1990).** Chance or Chaos?. *J. R. Statist. Soc. A* 153, Part 3, p. 321-347.
- BAUER, M.; MARTIENSEN, W. (1989).** Quasi-periodic Route to Chaos in Neural Networks. *Europhys. Lett*, v. 10, n.5, p. 427-431.
- BAUER, M.; MARTIENSEN, W. (1991).** Lyapunov Exponents and Dimensions of Chaotic Neural Networks. *J. Phys. A*, Gen. 24, p. 4557-4566.
- BREMEN, H. F.; UDWADIA, F. E.; PROSKUROWSKI, W. (1997).** Computation of Lyapunov Exponents Using Householder Factorization. *RBCM, J. of the Braz. Soc. Mechanical Sciences*, v. XIX, n. 2, p. 253-261.
- BREMEN, H. F.; UDWADIA, F. E.; PROSKUROWSKI, W. (1997).** An Efficient QR Based Method for the Computation of Lyapunov Exponents. *Physica D101*, p. 1-16.
- BUCK, L. B.; AXEL, R. (1991).** A Novel Multigene Family May Encode Odorant Receptors: A Molecular Basis for Odor Recognition. *Cell* 65, p. 157-167.
- BUCK, L. B. (1996).** Information Coding in the Vertebrate Olfactory System. *Ann. Rev. Neurosci.* 19, p. 517-544.
- BUCK, L. B. (2000).** The Molecular Architecture of Odor and Pheromone Sensing in Mammals. *Cell* 100, p. 611-618.
- CAMPANHA, J. R. (1994).** *Determinação dos Parâmetros de Ordem de Redes Neurais pelo Método dos Cumulantes*. Campinas. 129p. Tese (Doutorado) – Faculdade de Engenharia Elétrica, Universidade de Campinas.

- CAMPANHA, J. R.; TANCREDO, A. (1991).** Um modelo Físico para Redes Neurais. *Cad. Cat. Ens. Fís.*, v. 8, n.1, p. 56-63.
- CAMPANHA, J. R.; TORNICE, A.; TANCREDO, A. (1997).** Exponents of Lyapunov by the Eckmann-Ruelle Algorithm. *Nonlinear Dynamics, Chaos, Control and their Applications to Engineering Sciences*, v. 1, p. 169-173.
- CESSAC, B.; DOYON, B.; QUOY, M.; SAMUELIDES, M. (1994).** Mean-field Equations, Bifurcation Map and Route to Chaos in Discrete Time Neural Networks. *Physica D* 74, p. 24-44.
- CESSAC, B. (1995).** Increase in Complexity in Random Neural Networks. *J. Phys. I France* 5, p. 409-432.
- CHANG, H. J.; FREEMAN, W. J. (1996).** Parameter Optimization in Models of the Olfactory System. *Biological Cybernetics*, 56, p. 139-150.
- CHUAH, M. I.; ZHENG, D. R. (1992).** The Human Primary Olfactory Pathway: Fine Structural and Cytochemical Aspects During Development in Adults. *Microsc. Res. Techn.* 23, p. 76-85.
- CHUTCHFIELD, J. et al. (1980).** Power Spectral Analysis of a Dynamical System. *Physics Letters*, v. 76A, n. 1, p. 1-4.
- CIÊNCIA HOJE.** Rio de Janeiro, Revista da Sociedade Brasileira para o Progresso da Ciência, v. 14, n. 80.
- CONTE, R.; DUBOIS, M.** Lyapunov Exponents of Experimental Systems. *Centre d'Etudes Nucleaires de Saclay-Gif-sur-Yvette Cedex, France*, p. 441-454.
- CRISANTI, A.; SOMPOLINSKY, H. (1988).** Dynamics of Spins Systems with Randomly Asymmetric Bonds Ising Spins and Glauber Dynamics. *Physical Review A*, v. 37, n. 12, p. 4865-4874.
- CVITANOVIC, P. (1984).** Universality in Chaos. XXII.nd Gracow School of Theoretical Physics, Zakopane. *Acta Physica Polonica*, v. A65, p. 3-32.
- DAMASK, A. C. (1981).** *Medical Physics: External Senses*. Vol. II, New York, Academic Press.

- DAS, A.; DAS, P.** *Emergence and Control of Chaos in a Three Dimensional ANN*, U. de Jadaupur, Free Debt Analysis. Retirado do sítio <http://www.atin.8k.com/emergence.htm> em 22 de junho de 2004.
- DAS II, P. K.; SCHIEVE, W. C.; ZENG, Z. J. (1991).** Chaos in an Effective Four-Neuron Neural Network. *Physics Letters A 161*, p. 60-66.
- DUKE, W.; PRITCHARD, W. S. (1991).** *Proceedings of the Conference on Measuring Chaos in Human Brain*. Singapore, World Scientific, p. 158-171.
- ECCLES, J. C. (1957).** *The Physiology of Nerve Cells*. John Hopkins University Press.
- ECKMANN, J. P.; RUELLE, D. (1985).** Ergodic Theory of Chaos and Strange Attractors. *Reviews of Modern Physics*, v. 57, n. 3, Part I, p. 373-412.
- EKELAND, I. (1987).** *O Cálculo e o Imprevisto*. Trad. Por Maria Clara Constantino. São Paulo, Livraria Martins Fontes Editora Ltda.
- EVANS, N. W.; ILLNER, R.; KWAN, H. C. (1992).** On Information-processing Abilities of Chaotic Dynamical Systems. *J. Stat. Phys.* V. 66, n. ½, p. 549-561.
- FIEDLER-FERRARA, N.; PRADO, C. P. C. (1994).** *Caos: Uma Introdução*. São Paulo, Ed. Edgard Blücher Ltda.
- FREEDMAN, D. H. (1993).** In the Realm of the Chemical. *Discover*, p. 69-76.
- FREEMAN, W. J. (1975).** *Mass Action in the Nervous System*. New York, Chapter 7, Academic Press, p. 489.
- FREEMAN, W. J. (1979).** Nonlinear Gain Mediating Cortical Stimulus: Response Relations. *Biol. Cybernetics 33*, p. 237.
- FREEMAN, W. J. (1979).** Nonlinear Dynamics of Paleocortex Manifested in the Olfactory EEG. *Biol. Cybernetics 35*, p. 21.
- FREEMAN, W. J. (1979).** EEG Analysis Gives Model of Neuronal Template Matching Mechanism of Sensory Search with Olfactory Bulb. *Biol. Cybernetics 35*, p. 221.
- FREEMAN, W. J. (1986).** Petit Mal Seizures in Olfactory Bulb and Cortex Caused by Runaway Inhibition After Exhaustion of Excitation. *Brain Res. Rev. 11*, p. 259-284.

- FREEMAN, W. J. (1987).** Simulation of Chaotic EEG Patterns with a Dynamic Model of the Olfactory System. *Biol. Cybern.* 56, p. 139-150.
- GEIST, K.; PARLITZ, U.; LAUTERBORN, W. (1990).** Comparison of Different Methods for Computing Lyapunov Exponents. *Progress of Theoretical Physics*, v. 83, n.5.
- GLEICK, J. (1989).** *Caos: A Construção de uma Nova Ciência.* Trad. Por José Carlos Fernandes e Luís de Carvalho Rodrigues. Lisboa, Gradiva Publicações Ltda.
- GROSSBERG, S. (1976).** Adaptive Pattern Classification and Universal Recording. *Biological Cybernetics*, v. 23, n. 1, p. 121-134.
- GROSSBERG, S. (1978).** *A Theory of Visual Coding, Memory and Development: Formal Theories of Visual Perception.* New York, John Wiley & Sons.
- GROSSBERG, S. (1980).** How Does the Brain Build a Cognitive Code? *Psychological Review*, v. 89, n. 1, p. 529-572.
- GUTFREUND, H.; REGER, J. D.; YOUNG, A. P. (1988).** The Nature of Attractors in an Asymmetric Spin Glass with Deterministic Dynamics. *J. Phys. A. Math. Gen.* 21, p. 2775-2797.
- HEBB, D. (1949).** *The Organization of Behavior: A Neurophysiological Theory.* New York, John Wiley & Sons.
- HILBORN, R. C. (1994).** *Chaos and Nonlinear Dynamics: An Introduction for Scientists and Engineers.* New York, Oxford University Press.
- HIRSCH, M. W.; BAIRD, B. (1995).** Computing with Dynamic Attractors in Neural Networks. *Biosystems*, 34, p. 173-195.
- HOPFIELD, J. J. (1982).** Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences*, v. 79, p. 2554-2558.
- IFEACHOR, E. C.; JERVIS, B. W. (1993).** *Digital Signal Processing: A Practical Approach.* New York, Wesley Publishing Company.

- KAZAKOVA, N.; DOTSENKO, V. (1992).** Olfactory Neural Network Model. *Modern Physics Letters B*, v. 6, n. 27, p. 1721-1728.
- KLOTZ, A.; BRÄUER, K. (1999).** A Small-size Neural Network for Computing with Strange Attractors. *Neural Networks 12*, p. 601-607.
- KOHONEN, T. (1982).** Clustering, Taxonomy and Topological Maps of Pattern: Pattern Recognition.
- KOHONEN, T. (1984).** *Self Organization and Associative Memory*. 1. ed. Berlim, Springer-Verlag.
- KOSMA, R.; FREEMAN, W. J. (2001).** Chaotic Resonance – Methods and Applications for Robust Classification of Noisy and Variable Pattern. *International Journal of Bifurcation and Chaos*, v. 11, n. 6, p. 1607-1629.
- KOVÁCS, Z. L. (2002).** *Redes Neurais Artificiais: Fundamentos e Aplicações – Um texto básico*. 3. ed. São Paulo, Editora Livraria da Física.
- KÜRTEEN, K. E.; CLARK, J. W. (1986).** Chaos in Neural Systems. *Phys. Lett.*, v. 114A. n. 7, p. 413-418.
- LE, W.; GUANG, L.; XU, L.; HONG-JI, G.; FREEMAN, W. J. (2004).** A Chaotic Neural Network Mimicking an Olfactory System and its Application on Image Recognition. *Journal of Bionics Engineering*, v. 1, n. 3, p. 191-198.
- LE CUN, Y. (1985).** A Learning Procedure for Assymmetric Threshold Network. *Proceedings of Cognitiva 85*, p. 599-604.
- LEFFINGWELL, J. C. (2002).** General Physiology of Olfaction. *Leffingwell*, v. 2, n.1.
- LI, Z.; DAYAN, P. (1999).** Computational Differences Between Asymmetrical and Symmetrical Networks. *Network: Comput. Neural Syst.* 10, p. 59-77.
- LOPES, A. O. (2000).** Medidas Maximizantes para o Expoente de Lyapunov. *Matemática Universitária*, n. 29, p. 115-123.
- LORENZ, E. N. (1996).** *A Essência do Caos*. Trad. Por Cláudia Bentes David. Brasília, Ed. Universidade de Brasília.

- MALNIC, B.; HIRONO, J.; SATO, T.; BUCK, L.B. (1999).** Combinatorial Receptor Codes for Odors. *Cell* 96, p. 713-723.
- McCULLOCH, W.; PITTS, W. (1943).** A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, v. 5, n. 1, p. 115-133.
- MINSKY, M.; PAPERT, S. (1969).** *Perceptrons: An Introduction to Computational Geometry*. Cambridge, The MIT Press.
- MIRZAI, A. R., org. (1999).** *Artificial Intelligence: Concepts and Applications in Engineering*. Cambridge, The MIT Press.
- MORETTIN, P. A. (1979).** *Análise Harmônica de Processos Estocásticos*. In: DÉCIMO SEGUNDO COLÓQUIO BRASILEIRO DE MATEMÁTICA, Poços de Caldas, 1979, IMPA.
- NUSSENZVEIG, H. M., org. (1999).** *Complexidade e Caos*. Rio de Janeiro, Ed. UFRJ/COPEA.
- OIWA, N. N.; FIEDLER-FERRARA, N. (1998).** The Algorithm of Moving Boxes to Estimate Lyapunov Exponents and the Singularity Spectrum. *Physica A* 257, p. 460-464.
- OLSEN, L. F.; DEGN, H. (1985).** Chaos in Biological Systems. *Quarterly Review of Biophysics*, v. 18, n. 2, p. 165-225.
- OSLER, T. J.** A Quick Look at Liapunov Space. *New Jersey Mathematics and Computer Education*, v. 28, n. 2, p. 183-197.
- PALIS, J. (1989).** Sistemas Caóticos ou Turbulentos – Atratores e Bifurcações Homoclínicas. *Matemática Universitária*, n. 9/10, p. 167-191.
- PARKER, D. (1982).** Learning Logic. Invention Report, Stanford University, File 1, Office of Technology Licensing.
- PEAK, D.; FRAME, M.** *Chaos under Control: The Art and Science of Complexity*. New York, W. H. Freeman and Company.
- PEITGEN, H. O.; JÜRGENS, H.; SAUPE, D. (1992).** *Chaos and Fractals: New Frontier on Science*. Springer-Verlag New York Inc.

- RAPP, P. E.; ZIMMERMAN, I. D.; ALBANO, A. M.; DE GUSMAN, G. C.; GREENBAUM, N. N.; BASHORE, T. R. (1985).** Experimental Studies of Chaotic Neural Behavior: Cellular Activity and Electroencephalographic Signals. *Non Linear Oscillations in Biology and Chemistry*, p. 175-205. New York, Springer-Verlag.
- RENALS, S.; ROHWER, R. (1990).** A Study of Network Dynamics. *Journal of Statistical Physics*, v. 58, n. 5/6.
- ROSENBLATT, F. (1958).** The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, v. 65, n. 1, p. 386-408.
- RUELLE, D. (1993).** *Acaso e Caos*. Trad. por Roberto Leal Ferreira. São Paulo, Editora da Unesp.
- RUMELHART, D. E.; HINTON, G. E.; McCLELAND, J. L. (1986).** *A General Framework for Parallel Distributed Processing*. Cambridge, MIT Press.
- SALIHOGU, U. (2004).** *Chaos in small Recurrent Neural Networks: Theoretical and Practical Studies*. Université Libre de Bruxelles..
- SANDRI, M. (1996).** Numerical Calculation of Lyapunov Exponents. *The Mathematical Journal*. Miller Freeman Publications, v. 6, Issue 3, p. 78-84.
- SHAFFER, W. M. (1985).** Can Nonlinear Dynamics Elucidate Mechanisms in Ecology and Epidemiology? *IMA Journal of Mathematics Applied in Medicine and Biology* 2, p. 221-252.
- SHERRINGTON, D.** *Magnets, Microchips and Memories: From Spin Glasses to the Brain*, p. 319-330.
- SOLÉ, R. V.; DE LA PRIDA, L. M. (1995).** Controlling Chaos in Discrete Neural Networks. *Physics Letters A*, 199, p. 65-69.
- SOMPOLINSKY, H.; CRISANTI, A.; SOMMERS, H. J. (1988).** Chaos in Random Neural Networks. *Phys. Rev. Lett.* 61, p. 259-262.
- SOUZA, F. M. S. (2002).** *Simulação Computacional do Sistema Olfativo de Vertebrados*. Ribeirão Preto. 86p. Dissertação (Mestrado) – Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo.

- STEWART, I. (1991).** *Será que Deus Joga Dados? A nova Matemática do Caos.* Trad. por Maria Luiza X. da A. Borges. Rio de Janeiro, Jorge Zahar Editor.
- TIROZZI, B.; TSODYKS, M. (1991).** Chaos in Highly Diluted Neural Networks. *Europhys. Lett.*, v. 14, n. 8, p. 727-732.
- VAN DER MASS, H. I. J.; VERSCHURE, P. F. M. J.; MOLENAAR, P. C. M. (1990).** A Note in Chaotic Behavior in Simple Neural Network. *Neural Network* 3, p. 119-122.
- VOGLIS, N.; CONTOPOULOS, G.; EFTHYMIPOULOS, C. (1998).** Method for Distinguishing Between Ordered and Chaotic Orbits in Four-dimensional Maps. *Phys. Review E*, v. 57, n. 1, p. 372-377.
- VON DER MARLSBURG, C. (1973).** Self-organizing of Orientation Sensitive Cells in the Striated Cortex. *Kibernetik*, v. 14, n.1, p. 66-82.
- WANG, X. (1991).** Chaos-based Learning. *Complex Systems*, 5, p. 359-370.
- WASSERMAN, P. D. (1989).** *Neural Computing: Theory and Practice.* New York, Van Nostrand Reinhold.
- WERBOS, P. (1974).** *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences.* Ph. D. Thesis, Cambridge, Harvard University.
- WEST, B. J.** *Fractal Physiology and Chaos in Medicine.* Singapore, World Scientific Publishing Co. Pte. Ltd.
- WIDROW, B. (1962).** Generalization and Information Storage in Networks of Adaline Neurons. In: SELF-ORGANIZING SYSTEMS. Washington, Spartan Books, p. 435-461.
- WIDROW, B.; HOFF, M. (1960).** Adaptive Switching Circuits. In: IRE WESCON CONVENTION RECORD. New York, Neurocomputing, p. 96-107.
- WORKSHOP EM APLICAÇÕES DE REDES NEURAIS,** São Paulo, 1993, LSI/EPUSP/IPT.
- YAO, Y.; FREEMAN, W. J. (1990).** Model of Biological Pattern Recognition with Spatially Chaotic Dynamics. *Neur. Netw.* 3, p. 153-170.

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)