

UNIVERSIDADE FEDERAL DO CEARÁ
DEPARTAMENTO DE FÍSICA

BFC/BU/BCT
Biblioteca Setorial de Física

CONTROLE DE CAOS EM REDES NEURAIS

D
006.32
L698c

N.Cham. D 006.32 L698c
Autor: Lima, Francisco Wellington de Sou
Título: Controle de caos em redes neura



13894767

Ac. 14780

BCF

Francisco Wellington de Sousa Lima

Orientador: José Evangelista de Carvalho Moreira

73599
13894767

#530
L698c

Dissertação apresentada ao Departamento de Física da Universidade Federal do Ceará, como parte dos requisitos para a obtenção do Título de Mestre em Ciências.

Fevereiro de 1995.

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

L698c Lima, Francisco Welington de Sousa.

Controle de caos em redes neurais / Francisco Welington de Sousa Lima. – 1995.
56 f. : il.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências, Programa de Pós-Graduação em Física, Fortaleza, 1995.

Orientação: Prof. Dr. José Evangelista de Carvalho Moreira.

1. Redes neurais (Computação). I. Título.

CDD 530

CONTROLE DE CAOS EM REDES NEURAIS

FRANCISCO WELINGTON DE SOUSA LIMA

Dissertação apresentada ao Departamento de Física da Universidade Federal do Ceará, como parte dos requisitos para a obtenção do Título de Mestre em Ciências.

Comissão Julgadora:

José Evangelista de Carvalho Moreira (UFC)

José Soares de Andrade Júnior
(CYBERNET SYSTEMS CO.,LTD.)

Antônio Fernandes Siqueira (UFC)

Aprovada em 15 de fevereiro de 1995.

Dedicatória

À minha mãe

Maria do Socorro Sousa

Aos meus filhos

Fernando Sousa Luz e

Felipe Sousa Luz

Agradecimentos

Ao professor José Evangelista de Carvalho Moreira pela inesgotável paciência para comigo, pela orientação deste trabalho e pela consideração demonstrada, além dos sábios ensinamentos que foram a mim transmitidos.

Ao Professor José Soares pela co-orientação e pela grande ajuda a mim prestada na arte da programação computacional.

Ao Professor Tony pela ajuda no uso dos computadores.

Aos amigos Paulo Rômulo e Chico Costa pela amizade e pela ajuda a mim prestada perante a burocracia da Secretaria de Educação do Piauí.

Aos amigos José Pimentel de Lima, João Batista Duarte pelas discussões travadas no desenrolar do meu trabalho.

Aos amigos Cláudia, Carlos Carneiro e Humberto pelo auxílio a mim prestado.

A Creusa e a Rejane pela ajuda a mim prestada e a todos os amigos em geral pelos bons momentos que passamos juntos.

Resumo

Apresenta-se um modelo de rede neural diluída e assimétrica, com neurônios excitatórios e inibitórios. O estado de cada neurônio pode ser +1 (ativo) ou 0 (inativo) e é regulado pelos estímulos recebidos por outros neurônios e por uma função limiar. Dependendo da função limiar escolhida a atividade apresenta os seguintes comportamentos: constante, periódica, intermitente e caótica. Neste trabalho estuda-se a atividade caótica e faz-se o controle desta levando a atividade da rede a regimes constantes e periódicos, através de pequenas perturbações internas a rede. O processo de controle é examinado e comparado com algoritmos usados em mapas de baixa dimensão. Possíveis associações com mecanismos que atuam em redes neurais naturais são discutidas.

Abstract

A model of Neural Network is presented. The network is diluted, asymmetric and has both excitatory and inhibitory neurons. The state of each neuron can be +1 (active) or 0 (inactive) and is determined by the input from other neurons and by a threshold function. Depending on the chosen threshold function, activity can be constant, periodic, intermittent or chaotic. In this work the chaotic activity is studied, and it is controlled, taking the network activity to constant and periodic regimes, by means of small perturbations inside the network. The control process is examined and compared to algorithms used in low-dimensional maps. Possible associations with mechanisms that are present in natural neural networks are discussed.

Indice

Introdução.....1

Capítulo 1 - Redes Neurais

1.1 - Introdução.....4

1.2 - Redes de neurônios discretos e contínuos.....5

Capítulo 2 - O modelo

2.1 - Introdução.....18

2.2 - Descrição e funcionamento do modelo.....19

Capítulo 3 - Controle de Caos

3.1 - Introdução.....25

3.2 - Métodos de controle de caos.....26

Capítulo 4 - Resultados.....34

Capítulo 5 - Conclusão.....51

Referências.....55

Introdução

O cérebro humano é a mais espantosa máquina de computações altamente paralelas criada pela natureza. Por milhões de anos este tem evoluído até um organismo contendo cerca de 10^{12} neurônios, cada um conectado a 10^4 outros neurônios, consumindo algo em torno de $\frac{1}{2}$ Watt. A compreensão detalhada de como o cérebro funciona é até agora um grande desafio. Isto sugere a possibilidade de se tentar construir aparelhos artificiais, baseados nos princípios de Sistemas Neurais. Esta situação leva a duas possibilidades: construir um modelo biológico tentando compreender como realmente o cérebro funciona ou construir aparelhos artificiais com capacidade similar a de computações altamente paralelas.

As pesquisas correntes sobre este assunto foram desenvolvidas através de uma longa história de esforços para capturar os princípios de computações biológicas em modelos matemáticos. Estes esforços começaram com investigações pioneiras de neurônios como aparelhos lógicos realizadas por Warren S. McCulloch e Walter H. Pitts em 1943. Em 1960, Frank Rosenblatt e Bernard Widrow criaram os “neurônios adaptativos” e uma rede

simples que tinha a capacidade de aprender. A Adaline (neurônios lineares adaptativos), criada por Widrow, consiste de um sistema de neurônios simples que pode aprender a reconhecer um objeto simples tal como uma letra, por exemplo. Entre 1960 e 1970 um pequeno número de pesquisadores, como Shunichi Amari, Leon N. Cooper, Kunihiko Fukushima e Stephen Grossberg tentaram modelar o comportamento de neurônios reais em redes computacionais mais sofisticadas. Desenvolveram paradigmas matemáticos para a extração de características de modelos, para a classificação de modelos e para a “memória associativa”, na qual pedaços de informação servem para recuperar uma memória inteira.

A partir dos anos de 1980 surgiu um grande interesse por modelos neurais e suas propriedades computacionais. Isto se deu porque os neurobiologistas foram adquirindo mais entendimento de como informações eram processadas na natureza e devido a fabricação de potentes computadores baratos que permitiram a implantação de circuitos neurais.

Neste trabalho usa-se um modelo simples de redes de neurônios artificiais (RNA) e estuda-se a evolução dinâmica desta rede, através de uma variável chamada *atividade da rede*. Este modelo reproduz atividades neurais que são encontradas em redes neurais naturais, tais como o córtex cerebral, e que podem ser verificados através de registros de séries temporais de eletroencefalogramas (EEG). Estas atividades neurais artificiais geradas podem ser caóticas, periódicas, intermitentes ou constantes. Estuda-se a atividade caótica e procedimentos para se obter o controle desta, ou seja, levá-la de um regime caótico a outro regime, através de pequenas perturbações na rede.

No capítulo 1 faz-se um breve apanhado histórico sobre redes neurais artificiais (RNA). No capítulo 2 descreve-se detalhadamente o modelo de rede neural utilizado neste

trabalho. No capítulo 3 cita-se e descreve-se alguns métodos de controle de comportamento caótico, como o método de OGY e a técnica OPF. Propõe-se então um método de controle de caos (PPI). No capítulo 4 apresentam-se os principais resultados obtidos com a utilização do método PPI e finalmente no capítulo 5 apresentam-se as conclusões gerais deste trabalho.

Capítulo 1

Redes Neurais

1.1. Introdução

Neste capítulo faz-se um breve apanhado histórico sobre redes neurais artificiais (RNA), enfatizando os objetivos e a motivação que levaram pesquisadores a se interessar por este assunto. Descrevem-se também os tipos de neurônios e de redes neurais existentes e os requisitos necessários para a formação e funcionamento de uma RNA, desde o primeiro modelo de neurônio abstrato proposto por McCulloch e Pitts, o perceptron de Rosemblat, as regras de aprendizagem de Hebb até o modelo de rede neural mais estudado pelos pesquisadores atuais, que é o modelo de Hopfield de neurônios analógicos.

1.2. Redes de neurônios discretos e contínuos

Redes Neurais são redes formadas por aglomerados de células nervosas vivas chamadas neurônios. O córtex cerebral é um exemplo de uma rede neural natural. De alguma maneira estas redes neurais naturais são capazes de pensar, aprender, perceber e relembrar. No passado, muitos pesquisadores construíram modelos para estudar estas redes neurais e seus modelos foram classificados em duas categorias: modelos biológicos e modelos tecnológicos. Os modelos biológicos tem por objetivo estudar a estrutura e o funcionamento do cérebro com o propósito de explicar dados biológicos e comportamentais. Nos modelos tecnológicos o objetivo é estudar o cérebro procurando extrair conceitos que possam ser usados em uma nova metodologia computacional.

Em linhas gerais, o objetivo principal das pesquisas feitas em redes neurais é de compreender como o cérebro comunica habilidades tipo interpretação perceptual, memória associativa, raciocínio e aprendizagem . Para atingir este objetivo é necessário compreender como “computações” são organizadas e lançadas fora do cérebro. Um segundo objetivo é compreender uma subclasse de modelos de redes neurais que enfatizam a potência computacional ao invés da fidelidade biológica. Além dos objetivos já citados existe a motivação e o desejo de se construir uma nova geração de computadores potentes que sejam capazes de resolver uma variedade de problemas que não são facilmente solucionados com os computadores digitais convencionais. Estes problemas envolvem tarefas cognitivas, tais como o reconhecimento de uma face familiar, aprender a falar e compreender a linguagem natural, recuperação contextual de uma apropriada informação da memória, e

direcionar uma mão mecânica para segurar objetos de diferentes formas e consistências, isto é, tarefas que são realizadas naturalmente pelo cérebro. Outra motivação é o desejo de desenvolver modelos cognitivos que possam servir como alicerces para a inteligência artificial, pois existem vários aspectos das funções do cérebro que ainda não foram eficientemente duplicadas em computadores convencionais, tais como: associação, categorização, generalização, classificação, extração de características, e otimização. Estas capacidades estão dentro de três categorias: pesquisa, representação e aprendizagem. Estes aspectos estão relacionados às propriedades associativas e à capacidade de autoorganização do cérebro. Por propriedade associativa, entende-se a capacidade de lembrar um complexo inteiro de informações usando-se uma pequena parte desta como uma chave para o processo de pesquisa. A autoorganização é a habilidade de se adquirir conhecimento através do processo de aprendizagem chamado ensaio-erro envolvendo a organização e a reorganização em resposta a um estímulo externo.

Os modelos de redes neurais de neurônios artificiais são especificados por três entidades básicas: modelos de neurônios, modelos das interconexões sinápticas e estrutura (topologia e estrutura), e as regras de aprendizagem e treinos (métodos de ajustamento dos pesos ou como a rede interpreta as informações que está recebendo). Os neurônios modelados como sendo simplesmente nódulos podem ser caracterizados por analógicos (contínuos) ou digitais (discretos), cada um deles podendo exibir comportamento não-linear.

Um dos primeiros modelos abstratos de neurônios foi introduzido em 1943 por McCulloch e Pitts [1]. O neurônio M-P é caracterizado por um número finito de estímulos (“inputs”) excitatórios (peso $\omega_i=+1$) e inibitórios (peso $\omega_i=-1$), $x_i, (i=1,2,\dots,n)$, um limiar L e

uma resposta (“output”) y . Os inputs e outputs podem adotar valores binários 0 ou 1 e o limiar pode ser qualquer inteiro positivo. O output de um neurônio M-P isolado é expressado matematicamente em função de seus inputs como

$$y = g\left(\sum_i \omega_i x_i - L\right) \quad (1-1)$$

onde $g(p)=0$ se $p<0$, e $g(p)=1$ se $p\geq 0$.

Isto significa que o neurônio pode ser ativado se o total de excitação recebida por este atingir ou exceder o valor do limiar. Grupos de neurônios artificiais podem ser interconectados de várias maneiras para formar as redes de neurônios artificiais. Com o passar dos anos, muitas configurações topológicas para estas redes foram propostas. Assim, redes compreendendo somente uma simples camada de neurônios como também muitas camadas de neurônios foram apresentadas e estudadas. Nas redes tipo “feed-forward” o fluxo de sinal de uma camada à camada seguinte é unidirecional, ver fig.(1-1). Nas redes tipo “feedback” existem tanto as conexões de avanço e retorno em uma mesma direção, dentro de uma mesma camada, como também de uma camada à camada anterior, fig.(1-2).




Fig.(1-1) Rede "feed-forward", onde o fluxo de sinal de uma camada a camada seguinte é unidirecional.




Fig. (1-2) Rede feedback , onde existe fluxo de sinal de avanço e retorno tanto para uma camada seguinte como dentro da mesma camada .

Uma simples rede de neurônios artificiais consistindo de uma única camada de neurônios M-P pode ser criada a partir de um vetor de n neurônios. Cada neurônio recebe inputs de m fontes x_1, x_2, \dots, x_n , via pesos ω_{ij} e tendo outputs y_1, y_2, \dots, y_n . O output do j -ésimo neurônio é descrito por

$$y_j = g\left(\sum_i \omega_{ij}x_i - L_j\right) \quad (1-2)$$

Inserindo o tempo como uma variável independente neste processo a eq.(1-2) torna-se

$$y_j(t+1) = g\left(\sum_i \omega_{ij} x_i(t) - L_j\right) \quad (1-3)$$

A variável y_j dá a evolução dinâmica da rede a instantes de tempo discreto. A dinâmica da rede pode ser síncrona ou assíncrona. Na dinâmica síncrona todos os neurônios processam seus estados de atividade simultaneamente a passos de tempo discreto n , onde $n=1,2,\dots$, e os inputs de cada neurônio na rede são determinados por um mesmo estado de atividade da rede num intervalo de tempo $(n-1)<t<n$. Já na dinâmica assíncrona ou seqüencial, os neurônios são processados um por um, em alguma seqüência prescrita ou de maneira aleatória; portanto, para cada neurônio atingir uma decisão ele tem que tomar conhecimento das informações de todos os outros neurônios que tenham sido processados antes dele.

Para uma melhor compreensão de como redes deste tipo funcionam, considera-se uma rede M-P de somente um neurônio ($n=1$), tendo inputs x_1 e x_2 e um output y . Fazendo-se cada input igual a +1 e o limiar igual a 2, o output y será a função lógica Booleana AND dos dois inputs. Colocando-se o limiar igual a 1, o output será a função lógica Booleana OR dos inputs ou fazendo-se o limiar igual 0 e tendo somente um input com peso -1, o output será a função Booleana NOT do input, figs.(1-3,1-4,1-5).




Fig. (1-3) Função Lógica Booleana AND.

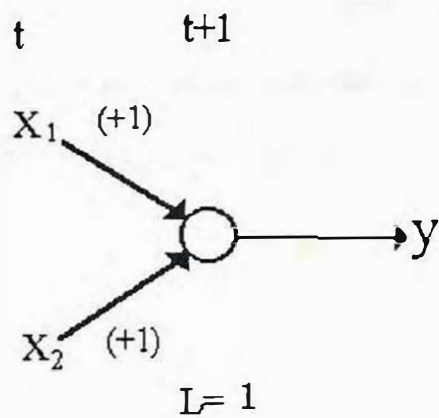


Fig. (1-4) Função Lógica Booleana OR.


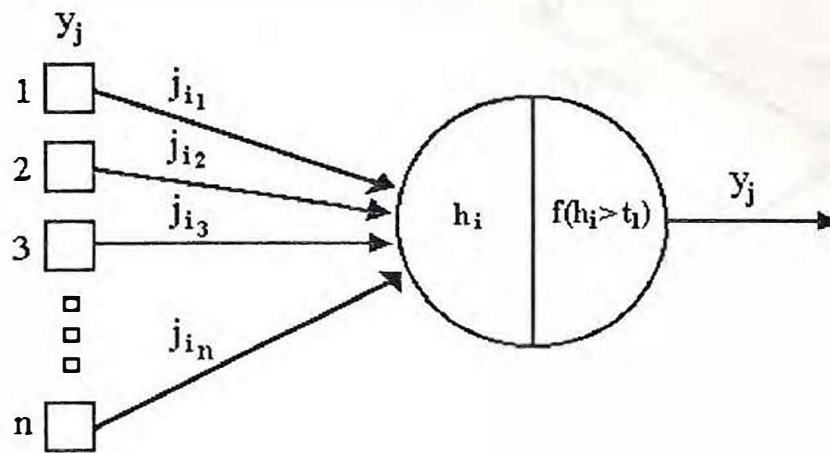


Fig. (1-5) Função Lógica Booleana NOT.

Em 1949, D.O.Hebb [1,2] propôs que a conectividade do cérebro está continuamente mudando quando o organismo aprende. Hebb postulou que repetidas ativações de um neurônio por outro, através de uma sinapse particular, aumentaria a condutância entre eles. Este postulado foi um passo fundamental na investigação de processos de aprendizagem em redes neurais. Nove anos depois, F. Rosemblat [1,2] publicou um artigo onde mostrava como uma rede de neurônios M-P com sinapses ajustáveis poderia ser treinada a classificar certos conjuntos de modelos. Rosemblat chamou esta rede de Perceptron. O perceptron consiste de três camadas. A primeira camada consiste de um conjunto de unidades sensoriais, a segunda ,ou camada interna, é composta de um conjunto de neurônios M-P, que recebem inputs da primeira camada via conexões pesos e providenciam outputs a terceira camada, chamada camada motor, fig.(1-6).



Fig(1-6) Perceptron. J_{ij} são as eficácias sinápticas chegando ao neurônio i , grande círculo. Y_j são as variáveis 1-0 representando a chegada ou a não chegada do sinal ao neurônio i . $F(h_j)$ é a função decisão do neurônio.

Inicialmente, os pesos eram postos aleatoriamente, tal que qualquer simulação da rede produziria respostas aleatórias. Assim para se obter uma resposta desejada, os pesos eram ajustados. Este ajustamento é o processo de treinamento da rede. Posteriormente, Minsky e Papert [2] provaram que o perceptron não era capaz de computar a função lógica Booleana XOR ou o OR exclusivo em um simples passo de tempo, mas sim em alguns passos posteriores, fig.(1-7), pois para tal procedimento teria que se ter duas unidades de limiar e portanto dois neurônios M-P, tal que um deles ficasse desligado da unidade motora.

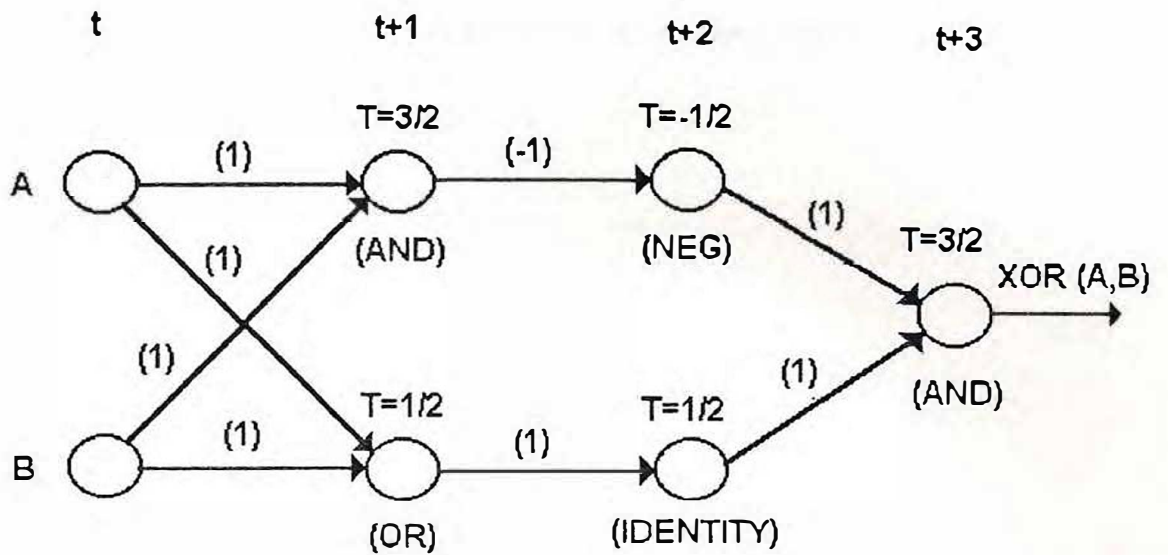


Fig. (1-7) Representação esquemática do OR exclusivo(XOR). A letra T(maiúscula) representa o limiar do neurônio M-P.

Além dos modelos de neurônios M-P discretos, existem modelos de neurônios que tratam o tempo como uma variável contínua. Agora a razão de ativação e o potencial da membrana (estado do neurônio) são parâmetros importantes [6]. Chamando-se de u o potencial da membrana, a evolução temporal deste no j -ésimo neurônio pode ser descrita por

$$\frac{du_j}{dt} = -u_j + \sum_{i=1}^n \omega_{ij}x_i - L_j \quad (1-4)$$

onde o output y_j está relacionado ao estado u_j por

$$u_j = h(y_j) \quad (1-5)$$

Se os inputs x_i são mantidos estacionários, ou se inputs variam lentamente, têm-se

$$\frac{du_j}{dt} \approx 0. \text{ Assim}$$

$$h(y_j) = \sum_{i=1}^n \omega_{ij} x_i - L_j \quad (1-6)$$

ou

$$y_j = h^{-1} \left(\sum_{i=1}^n \omega_{ij} x_i - L_j \right) \quad (1-7)$$

Identificando-se h^{-1} com g , a eq. (1-7) é idêntica a (1-2). Portanto as eqs. (1-4), (1-5) e (1-6) representam um ponto de partida do modelo discreto ao contínuo. Assim ao invés de tratarmos uma rede de neurônios artificiais como um sistema discreto de estados finitos, pode-se tratá-lo como uma coleção de estados contínuos, ou seja, modelado como um sistema de equações diferenciais ordinárias.

Em 1984, J.J. Hopfield [1] observando o comportamento de um grupo de neurônios e um grupo de átomos estabeleceu uma analogia formal entre seu modelo de rede neural, rede de Hopfield (rede de neurônios contínuos), e uma nova classe de materiais magnéticos chamados vidros de spin. Hopfield e seus colaboradores propuseram o seguinte modelo para um neurônio.

$$C_i \frac{du_i}{dt} = -\frac{u_i}{R_i} + \sum_{j=1}^n T_{ij} v_j + I_i \quad (1-8)$$

onde u_i é o estado do i -ésimo neurônio, T_{ij} são os pesos, e I_i representam inputs externos, os outputs v_j são da forma $g(u_j)$, onde g é sigmoïdal, C_i é a capacitância de input e R_i é a resistência da transmembrana. Eles definiram também uma função tipo energia descrita por

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n T_{ij} v_j + \sum_{i=1}^n \frac{1}{R_i} \int_0^{v_i} g_i^{-1}(\lambda) d\lambda + \sum_{i=1}^n I_i v_i \quad (1-9)$$

E posteriormente Hopfield e seus colegas provaram que o sistema descrito desta maneira evolui a uma configuração estável se T_{ij} são simétricos, onde esta configuração estável pode ser vista como um armazenamento de informações.

Neste modelo, cada neurônio pode estar em dois estados, ativo ou inativo (o i -ésimo neurônio é representado por uma variável de spin u_i que pode tomar valores ± 1) e é conectado a todos os outros neurônios através de conexões sinápticas simétricas, isto é, a influência T_{ij} do i -ésimo neurônio sobre o j -ésimo neurônio é a mesma quando i e j são trocados ($T_{ij}=T_{ji}$). A modificação destas eficácias sinápticas para o armazenamento de modelos de inputs é feita pela regra generalizada de Hebb definida por

$$T_{ij} = \frac{1}{N} \sum_{\mu=1}^P u_i^{\mu} u_j^{\mu} \quad (1-10)$$

O fato destas conexões sinápticas serem simétricas levam a uma dinâmica de relaxação, evitando comportamentos dinâmicos mais complicados. A função energia, eq.(1-9), implica que a $t=0$ seu valor sempre decresce quando o sistema evolui no tempo, ou seja, partindo-se de qualquer estado inicial, o sistema moverá com uma dinâmica assíncrona “ladeira abaixo” atingindo um estado em que E é um mínimo local. O sistema não pode oscilar. Portanto, neste modelo um input $\{u\}$ é lembrado se o estado assintótico é $\{u\}$ ou próximo de $\{u\}$ quando o estado inicial armazenado pela rede é igual a $\{u\}$. E a energia $E\{u\}$ deve ter um mínimo a cada um dos modelos que são lembrados [3]. Sob a forte suposição de que os modelos de inputs são não-correlacionados, tanto as simulações numéricas [3] quanto as computações analíticas [3] mostram que a capacidade de armazenamento da rede é proporcional a N . Se o número de modelos de inputs torna-se maior do que um valor crítico μ_c ($\mu_c \propto 0.14N$) a rede irá para um estado de total desordem e um número pequeno de modelos é lembrado. Ao contrário, se μ é menor do que μ_c , praticamente todos os modelos de inputs são lembrados.

O modelo de Hopfield é também muito interessante porque tem muitos pontos em comun com os vidros de spins e teorias muito ricas e sofisticadas tem sido recentemente construídas para vidros de spins [3].

Capítulo 2

O modelo

2.1. Introdução

Neste Capítulo descreve-se detalhadamente o modelo de rede neural utilizado neste trabalho . Estuda-se a atividade da rede neural, que depende da função limiar, constante ou dependente do tempo, podendo exibir um comportamento caótico, intermitente e periódico. Estes também são comportamentos característicos de uma rede neural natural, obtidos experimentalmente através de séries temporais de eletroencefalogramas da atividade neuronal de pequenas regiões do cérebro.



2.2. Descrição e funcionamento do modelo

O modelo de rede neural usado neste trabalho é uma variação do modelo de McCulloch e Pitts [1]. A rede é formada por N unidades chamadas de neurônios, onde cada neurônio está acoplado a n outros neurônios similares. O número de neurônios N foi fixado em 300 e o número n , que define o grau de diluição da rede e indica quantas conexões existem entre um determinado neurônio e seus vizinhos, foi fixado em 10, portanto a rede não é totalmente conectada e sim diluída. Por diluída, entende-se que o número de neurônios da rede é maior que o número de conexões existentes, ou seja, os neurônios não estão todos conectados entre si; existem, portanto, neurônios que não se conectam com seus vizinhos. Este acoplamento é feito de maneira aleatória, não existindo uma regra ou lei para conectá-los, de tal forma que a rede construída dessa maneira não apresenta uma forma geométrica definida. Assim, cada neurônio da rede pode ser influenciado por 10 outros neurônios quaisquer, acoplados a ele, mas não existe uma quantidade fixa de quantos neurônios este possa influenciar. Portanto, existe a possibilidade de um neurônio ser influenciado por outro neurônio a ele conectado, por mais de uma vez. No entanto, é proibida a autoconexão, ou seja, um neurônio não pode influenciar a si mesmo. As conexões que são usadas para acoplar os neurônios são chamadas de sinapses e são escolhidas de maneira aleatória. A estas associam-se pesos ou eficácias sinápticas para caracterizar a intensidade do acoplamento entre estes neurônios, veja fig.(2-1).




Fig. (2-1) Rede de neurônios de forma geométrica não definida.

A um passo de tempo t o estado de um neurônio pode ser ativo (1) ou inativo (0) e é representado por um elemento de vetor binário $x_i(t)$. A evolução dinâmica do estado de um neurônio é dado por

$$x_i(t+1) = \Theta(h_i + L(t)), \quad (2-1)$$

$$e \quad h_i = \sum_{j=1}^n S_{ij} x_j(t) \quad (2-2)$$

onde h_i , o potencial pós-sináptico [2], é a soma de todas as eficácias sinápticas dos canais chegando ao neurônio i , cada um multiplicado pelo correspondente estado $x_j(t)$ dos neurônios a ele conectado. Isto garante que somente os neurônios de canais ativados contribuem para a evolução do estado do neurônio x_i a um passo de tempo $t+1$. $L(t)$ é a função limiar do neurônio i , ou seja, é a função que estabelece um valor limite para a atualização do estado do neurônio i a um passo de tempo t e Θ é a função de Heaviside, isto é, $\Theta(z)=0$ se $z<0$ e $\Theta(z)=1$ se $z \geq 0$. S_{ij} são os pesos das conexões entre os neurônios i e j , às vezes descritos como sinapses e análogos aos elementos da matriz de acoplamento no sistema de spin de Ising. Os pesos são escolhidos de maneira aleatória, e não são necessariamente simétricos, isto é, $S_{ij} \neq S_{ji}$, portanto a influência que o neurônio i exerce sobre o neurônio j não é necessariamente igual a influência que o neurônio j exerce sobre o neurônio i . Estes pesos podem ser positivos (excitatórios) ou negativos (inibitórios) e são uniformemente distribuídos com $S_{ij} \in [-1,1]$. A dinâmica usada neste modelo para a atualização do estado de um neurônio é a dinâmica síncrona ou paralela, ou seja, cada neurônio é processado simultaneamente a passos discretos de tempo n_p , onde $n_p=1,2, \dots$, pela dinâmica descrita na eq.(2-1). Isto significa que os inputs de cada neurônio na rede são determinados por um mesmo estado de atividade da rede em um intervalo de tempo ($n_p-1 < t < n_p$), onde a decisão de cada neurônio de ativar ou não ativar a um mesmo instante de tempo não depende da decisão dos outros neurônios da rede. Assim, quando h_i , total dos pesos dos inputs que chegam a um neurônio i , exceder o limiar $L(t)$ a um passo de tempo t ,

Este neurônio estará ativo a um passo de tempo $t+1$. Neste modelo, o limiar instantâneo é o mesmo para todos os neurônios da rede e faz-se $L(t)=L$, ou seja, o limiar é considerado como sendo uma constante.

O estado da rede é definido por uma coleção de atividades instantâneas dos neurônios individuais descritos pela eq.(2-1) e este pode ser expressado como uma palavra de N bits, cujos elementos são x_i^I , onde o superescrito I classifica um estado particular da rede e o subscrito i classifica um neurônio particular. Assim esta rede possuindo N bits com cada um correspondendo a um neurônio específico com valores discretos 1 e 0 apresenta um total de 2^N estados, e a cada momento a rede estará em um destes estados. A evolução do estado da rede gera uma sucessão de estados que são chamados de trajetória da rede. Como o número de estados da rede é finito o sistema deve eventualmente reentrar em um estado visitado anteriormente, portanto o sistema procederá da mesma maneira para os estados sucessores deste e gerará ciclos de repetições de estados, que são chamados de atratores dinâmicos da rede.

A atividade de rede típica gerada pela dinâmica descrita anteriormente pode apresentar comportamentos de regime periódico, intermitente, constante e caótico [3] dependendo da função limiar utilizada. Para a função limiar $L=0$, observa-se um comportamento de regime caótico e para $L=-0.5$ o comportamento apresenta um regime periódico, veja figs.(2-2) e (2-3).




Fig. (2-2) Atividade da Rede Neural apresentando um comportamento de regime caótico. ($L=0$).




Fig. (2-3) Atividade da rede Neural apresentando um comportamento de regime periódico. ($L=-0.5$).

A um passo de tempo t a atividade é definida por

$$A(t) = \frac{\left(\sum_{i=1}^N x_i(t) \right)}{N} \quad (2-3)$$

onde $A(t)$ é a soma dos estados de todos os neurônios dividida pelo número de neurônios da rede e está confinada dentro do intervalo $[0,1]$; $x_i(t)$ é o estado discreto do neurônio i e N é o número de neurônios utilizados na rede.

Capítulo 3

Controle de Caos

3.1. Introdução

Neste capítulo citam-se e descrevem-se alguns métodos de controle de comportamentos caóticos dando uma maior ênfase ao método proposto por Ott, Grebogi e Yorke, a técnica de realimentações proporcionais ocasionais (OPF) e propõe-se um método de controle de caos que é aplicado na rede neural descrita no capítulo 2.

Métodos de controle de caos

Sistemas que apresentam comportamento caótico são abundantes, tanto na natureza quanto nos aparelhos construídos pelo homem. Estes sistemas são caracterizados por uma extrema sensibilidade a pequenas e suaves perturbações. Esta característica, conhecida como efeito borboleta, em algumas ocasiões é vista como benéfica quando, por exemplo, acelera reações químicas e providencia um mecanismo vigoroso para transporte de massa e calor. Entretanto, em outras ocasiões, esta característica é vista como incômoda e oportuna, tornando-se o caos um fenômeno indesejável que pode levar a vibrações, oscilações irregulares, falhas devido à fadiga de sistemas mecânicos, oscilações de temperatura que podem exceder o limite de segurança de condições operacionais em sistemas térmicos e aumento na resistência em sistemas de fluxo. Uma vez que o comportamento caótico é um fenômeno que não pode ser previsto em detalhes, este pode ser prejudicial a operações de vários aparelhos.

Durante muitos anos acreditou-se que os movimentos caóticos nunca são previsíveis e controláveis. A primeira referência que encontramos de um ponto vista diferente foi evidenciada por John Von Neumann, por volta de 1950. Segundo ele, pequenos distúrbios, cuidadosamente escolhidos e pré-planejados, poderiam levar, após algum tempo, a mudanças de larga escala no tempo. Embora esta aplicação específica possa ser problemática, a ideia básica de usar a sensibilidade caótica foi apreciada por John Von Neumann. Claramente, a habilidade de controlar o caos é de muita importância prática. A possibilidade de se obter formas de ondas complexas periódicas a partir de um sistema

caótico tem inspirado muitos trabalhos recentes teóricos e experimentais [6-15]. O conceito básico envolvido é que um atrator caótico tem embutidas um grande número de órbitas periódicas instáveis. Por uma órbita periódica entende-se que é uma órbita que repete-se após algum tempo (período). Se o sistema está precisamente sobre uma órbita periódica instável, pode se manter nela indefinidamente. Estas órbitas são instáveis no sentido que um desvio da órbita periódica devido a um ruído, por exemplo, cresce rapidamente e exponencialmente no tempo, e a órbita do sistema move-se completamente para longe da órbita periódica. Assim, embora estas órbitas periódicas estejam presentes, elas não serão tipicamente observadas. Portanto, este atrator caótico serviria como fonte rica de ondas periódicas complexas, se uma técnica dinâmica apropriada de controle fosse implantada para estabilizar o sistema.

O algoritmo de controle proposto por Ott, Grebogi e Yorke [6] (OGY) foi um avanço nesta direção. Eles demonstraram seu método numericamente controlando o mapa de Hénon. Ditto et al [7] foram os primeiros a demonstrar experimentalmente o controle de caos usando o método de OGY para a orientação periódica de uma fita magnetoelástica. Outros métodos tem sido utilizados em sistemas experimentais para controlar caos, tais como num sistema com curvas de convecção térmica [8], através de um controle de feedback, num oscilador Yttrium Iron Garnet (YIG) [9], diodo ressonante [10], num laser multimodo autonomamente caótico [11], na estabilização de arritmias cardíacas, através da técnica PPF [14] e na orientação periódica de um pêndulo [12], através da aplicação de uma força externa periódica fraca ao sistema. O controle obtido no diodo ressonante [10] e no laser multimodo autonomamente caótico [11], foi obtido através da técnica OPF. Enquanto

na referência [13] mostra-se claramente a relação entre a técnica OPF e o algoritmo de OGY.

O método de OGY é um método que pode ser aplicado em uma variedade de sistemas incluindo sistemas químicos, biológicos, ópticos, eletrônicos e mecânicos, e tem sido aplicado a muitos sistemas físicos tanto teóricos como experimentais. Entretanto, estes modelos de sistemas sempre têm poucos graus de liberdade. Por exemplo, Romeiras et al [15] aplicaram o método de OGY para controlar caos em um rotor mecânico com quatro graus de liberdade, assim como os exemplos já citados anteriormente. J. A. Sepulchre e A. Babloyantz [15] demonstraram, diferentemente dos casos já citados, o controle de caos utilizando o método de OGY para um sistema de tamanho moderado. Eles utilizaram o modelo de uma rede de unidades oscilatórias (neurônios artificiais), que geralmente possuem muitos graus de liberdade, de tamanho moderado.

Dos métodos mencionados anteriormente nós nos deteremos um pouco mais sobre o método de OGY e a técnica OPF e proporemos um método de controle de caos em redes neurais.

3.2.1. Método de OGY

O método de OGY é baseado na observação de que órbitas periódicas instáveis são densas num atrator tipicamente caótico. Este método pressupõe quatro pontos a serem seguidos [7]:

1º - A dinâmica do sistema pode ser representada como originada de um mapa não-linear de n-dimensões, e as interações deste mapa são dadas por $\zeta_{n+1} = f(\zeta_n, p)$, onde p é algum parâmetro acessível do sistema.

2º - Existe uma órbita periódica específica do mapa que conduz a um atrator ao redor do qual se deseja estabilizar a dinâmica.

3º - Existe uma perturbação máxima δp no parâmetro p pelo qual é aceitável variar p de um valor nominal p_0 .

4º - Assume-se que a posição de uma órbita periódica é uma função de p, mas que a dinâmica local ao redor desta não varia muito com a pequena mudança permitida em p.

Assim, enquanto a dinâmica é originada de um mapa, não há necessidade de modelar a dinâmica global. Esta suposição permite se fazer controle de qualquer sistema caótico para o qual pode-se construir uma secção de Poincaré. Portanto para controlar a dinâmica caótica necessita-se somente aprender a dinâmica local ao redor da órbita periódica desejada, observando-se as interações do mapa próximos a órbita desejada e ajustando-as a uma aproximação linear local do mapa f. Desta forma, encontram-se autovalores instáveis e estáveis. Em seguida muda-se o parâmetro p levemente observando-se como a órbita desejada muda a sua posição, estima-se as derivadas parciais da localização da órbita com respeito a p e tenta-se confinar as interações do mapa a uma pequena vizinhança da órbita desejada. Quando a interação cair próximo à órbita desejada, muda-se p do seu valor nominal p_0 por δp , mudando, portanto, a localização da órbita neste reservatório estável, tal que a interação seguinte força o sistema a retornar em direção ao reservatório estável da órbita original para $p=p_0$, veja fig.(3-1).




Fig.(3-1) Esquema do algoritmo e controle de OGY para um atrator de ponto fixo:
 (a) A n -ésima interação ζ_n cai próximo ao ponto fixo $\zeta_f(p_0)$. (b) Faz-se uma perturbação de p para aproximar do ponto fixo. (c) A interação seguinte força na direção do reservatório estável de $\zeta_f(p_0)$. Retira-se a perturbação.

Portanto, como vimos antes, o método de OGY possui algumas vantagens que são:

1. Nenhum modelo para a dinâmica é requerido.
2. A computação requerida a cada interação é mínima.
3. As mudanças requeridas no parâmetro do sistema podem ser completamente mínimas.
4. Diferentes órbitas periódicas podem ser estabilizadas para o mesmo sistema no intervalo do mesmo parâmetro.
5. O controle pode ser atingido até mesmo com medidas imprecisas dos autovalores e autovetores.
6. Este método não é restrito a orientação periódica de sistemas mecânicos, mas estende-se a qualquer sistema cuja dinâmica possa ser caracterizada por um mapa não-linear. As desvantagens deste método é que ele não pode ser diretamente aplicado a sistemas nas quais não se pode definir um mapa não-linear. Ou seja, ele está restrito a sistemas de poucos graus de liberdade.

3.2.2. Técnica OPF

A técnica OPF é uma modificação do método de OGY e, ao contrário deste, são permitidas largas perturbações que podem mudar o sistema rapidamente, permitindo órbitas de altos períodos. A idéia básica desta técnica consiste em se amostrar uma variável do sistema dentro de uma janela de comparação e largura selecionadas. A amostração da frequência é relacionada a uma frequência de oscilação e relaxação do sistema. Um sinal

proporcional ao desvio da intensidade amostrada do centro da janela é gerado e ampliado a perturbar um parâmetro do sistema do seu valor ambiente. Aplicando-se repetidamente o sinal controlado tenta-se conduzir o sistema a se fechar em torno de uma órbita periódica instável que está embutida no atrator caótico, fazendo com que esta se torne periódica com precisão limitada pela frequência e estendida por realimentação. Portanto esta técnica por ser uma variação do método de OGY tem as mesmas desvantagens e vantagens que este e ainda as vantagens de ser uma técnica rápida e pode estabilizar órbitas de altos períodos e a desvantagem de incorrer em uma pequena mudança no atrator do sistema através de largas perturbações levemente inferior a 10%.

3.3.3. Método da Pequena Perturbação Interna (PPI)

O método PPI foi desenvolvido especificamente para o presente trabalho, podendo ser usado em sistemas com um grande número de graus de liberdade, como redes neurais. Ele consiste em se fazer uma pequena perturbação interna ao sistema (rede neural), através do grampeamento de algumas variáveis do sistema, ou seja, dos estados dos neurônios. Estando o sistema com atividade caótica altera-se o estado de alguns neurônios previamente escolhidos. A partir do instante em que esta alteração é mantida diz-se que o controle foi ligado (ON). Normalmente, após um transiente, o controle age levando a atividade da rede de caótica a fixa ou periódica. Este regime se mantém enquanto o controle está ligado. Quando o controle é desligado (OFF) o regime caótico se restabelece. Existem vários modos de se ativar o controle. Cita-se, a seguir, alguns que utiliza-se no presente trabalho.

- 1) Impõe-se que os estados de alguns neurônios se mantenham fixos e iguais a +1 (ativo).
- 2) Impõe-se que os estados de alguns neurônios se mantenham fixos e iguais a 0 (inativo).
- 3) Impõe-se um sinal periódico a alguns neurônios. O sinal pode ser o mesmo para todos os neurônios de controle ou diferir de neurônio a neurônio.

Este método apresenta algumas vantagens: a perturbação feita ao sistema pode ser muito pequena, atuando um número ínfimo de neurônios, não alterando assim o atrator caótico do sistema; o método é muito rápido, fácil de ser aplicado e pode estabilizar órbitas periódicas instáveis de pequenos períodos e de grandes períodos.

A escolha dos neurônios de controle depende do estado (periódico ou fixo) que se quer obter. Mais adiante se comentará como esta escolha pode ser feita e como ela depende do processo de aprendizagem utilizado no estabelecimento da matriz de sinapses. No presente trabalho, como usa-se matrizes de sinapses totalmente aleatorias, esta escolha foi feita na base da tentativa. Nesta fase do trabalho interessa-se mais diretamente em entender o processo de controle na rede neural e não especificadamente na obtenção de estados pré-fixados. Uma extensão simples deste trabalho presente deve envolver um estágio de aprendizado tipo Hebb e estabelecimento de uma matriz de sinapses preparada.

Capítulo 4

Resultados

Através do método da pequena perturbação interna na rede (PPI) constata-se que utilizando um grupo de 15, 10, 5 e até mesmo um único neurônio, consegue-se uma mudança no regime do comportamento da rede de caótico para periódico, observando-se a presença de um transiente que varia de neurônio para neurônio e do instante em que se introduz o controle. Verifica-se que o controle para alguns neurônios é obtido com o estado fixo e igual a +1 (ativo), fig. (4-1)., e para outros com estado fixo e igual a 0 (inativo), fig. (4-2), ou ainda para outros com estados alternando entre 0 e +1 durante a evolução temporal da atividade da rede, fig. (4-3). Nestes três exemplos, a atividade controlada da rede resultou periódica, sendo diferente para cada caso. Observa-se que cada figura corresponde a um neurônio de controle diferente.




Fig. (4-1) Controle de Caos. Neurônio 150 com estado ativo (1) inserido a 1001 passos temporais. A seta indica o instante em que o controle foi ligado.




Fig. (4-2) Controle de Caos. Neurônio 134 com estado inativo (0) inserido a 1001 passos temporais.




Fig.(4-3) Controle de Caos. Neurônio 44 com estado alternando entre 0 e +1 inserido a 501 passos temporais.

Existem ainda neurônios que conseguem controlar a atividade caótica com os dois estados indistintamente, dependendo apenas da intensidade das sinapses e da configuração inicial da rede, figs.(4-4) e (4-5). Nestes dois exemplos, o neurônio de controle é o mesmo mas em um caso é fixado como ativo e no outro como inativo. Observa-se que o sinal periódico obtido no caso da figura (4-5) é bastante complexo, com período muito longo.




Fig. (4-4) Controle de Caos. Neurônio 28 com estado ativo (+ 1) inserido a 1001 passos temporais.




Fig. (4-5) Controle de Caos. Neurônio 28 com estado inativo (0) inserido a 1001 passos temporais.

Verifica-se ainda que para alguns neurônios com estado +1 (ativo) o controle leva a mudança da rede de um regime de comportamento caótico a um regime de comportamento constante, fig.(4-6), ou a diferentes formas de sinais periódicos, figs. (4-7) e (4-9)., dependendo apenas do instante em que é inserido o controle. Observa-se que, em ambos os casos, o valor da função limiar é o mesmo.




Fig. (4-6) Controle de Caos. Neurônio 3 com estado ativo (+1) inserido a 501 passos temporais




Fig. (4-7) Controle de Caos. Neurônio 3 com estado ativo (+1) inserido a 1501 passos temporais




Fig. (4-8) Controle de Caos. Neurônio 3 com estado ativo (+1) inserido a 2501 passos temporais.

Já para outros neurônios a forma periódica ou constante obtida se mantém inalterada quando a posição de inserção do controle é modificada, mudando-se apenas o tamanho do transiente do regime caótico para o regime controlado, figs. (4-9) e (4-10).




Fig. (4-9) Controle de Caos. Neurônio 28 com estado inativo (0) inserido a 1001 passos temporais.




Fig. (4-10) Controle de Caos. Neurônio 28 com estado inativo (0) inserido a 2001 passos temporais.

Estas observações podem ser sumariadas do seguinte modo.

- 1) O sinal controlado depende dos neurônios que são usados para controle.
- 2) Para os mesmos neurônios de controle o sinal controlado depende do tipo de controle utilizado (ativo, inativo ou periódico).
- 3) Para alguns neurônios de controle, mantendo-se o limiar, o sinal controlado depende do instante em que o controle é acionado. Para outros neurônios de controle, a mudança no instante de atuação só modifica o tamanho do transiente mas resulta sempre no mesmo tipo de sinal.

Observa-se ainda que dependendo do neurônio grampeado pode-se obter um regime periódico de órbitas periódicas de pequenos períodos, veja figs. (4-11) e (4-12), e órbitas periódicas de grandes períodos, figs. (4-13) e (4-14).




Fig. (4-11) Controle de Caos. Neurônios 1, 25, 158, 171, 245 com estados ativos (+1) inseridos a 1001 passos temporais




Fig. (4-12) Zoom da fig. (4-11) Órbita estabilizada de periodo 4.




Fig. (4-13) Controle de Caos. Neurônios 1, 25, 116, 171, 245 com estado ativo (+1) inseridos a 1001 passos temporais.




Fig. (4-14) Zoom da fig. (4-13) Órbita estabilizada de período 322.

Uma vez que o controle é atingido, a manutenção deste é obtido com a persistência da perturbação, pois após a retirada da perturbação o sistema retorna ao comportamento caótico de maneira instantânea, fig. (4-15), e se forem inseridas novas perturbações durante o regime periódico estas alterarão apenas a forma do periódico, ou seja, não existe a contrapartida em que o regime periódico poderia voltar a ser caótico mediante outras perturbações, fig. (4-16).




Fig. (4-15) Controle de Caos. Neurônio 3 com estado ativo (+1) inserido a 1001 e retirado a 3000 passos temporais.




Fig. (4-16) Controle de Caos. Neurônio 3 com estado ativo (+1) inserido a 501 e neurônio 4 com estado ativo (+1) inserido a 2001 passos temporais.

O controle da atividade caótica depende do neurônio escolhido, do limiar utilizado, da configuração inicial da rede e dos pesos das matrizes de sinapses. O limiar utilizado para cada neurônio da rede foi $L=0$, a densidade inicial de neurônios ativos foi de 0,5, ou seja, 50% dos neurônios escolhidos aleatoriamente mantiveram seu estado inicial ativo e os pesos das matrizes de sinapses foram escolhidos aleatoriamente. Para entender melhor como o controle atua, grampeamos alguns neurônios que conduzem a atividade da rede a um atrator de período 4, veja fig.(4-17), e observamos como a atividade é conduzida ao regime periódico. Para isto, usamos a secção de Poincaré, como visto na fig. (4-18). Este gráfico mostra a atividade a um passo de tempo $t+1$ contra a atividade a um passo de tempo t . A

linha pontilhada mostra a trajetória sem qualquer controle. A linha continua mostra a trajetória com controle. Enquanto o caminho não controlado vagueia através do mapa de Poincaré a atividade controlada é capturada numa bacia de atração e fixada num atrator de período 4 após poucos passos. Este atrator é normalmente instável (ponto de sela) mas torna-se estável pela ação do controle. Na figura (4-18) mostra-se também direções aproximadas dos autovetores estáveis e instáveis, obtidos empiricamente. Observa-se ainda que a atividade da rede, antes da aplicação do controle (linha pontilhada), vagueia em torno da região de estabilidade e após a aplicação do controle é rapidamente atraída para a bacia de atração do atrator instável. Com a permanência do controle a atividade termina se fechando na posição do atrator com órbita de período 4. Observando este comportamento, que é típico de todos os exemplos de controle que foi realizado, pode-se ver que o processo é uma implementação autônoma do método de OGY. Quase todos os ingredientes do método estão presentes em nosso modelo. Existe um atrator instável mas a dinâmica não consegue se fixar nele a menos que o controle seja ativado. O controle é uma perturbação muito pequena mas eficiente no processo de capturar a atividade dentro de bacias de atração do atrator. Através da computação da distância de Hamming, fig. (4-19), este processo fica mais evidente. A distância de Hamming é uma distância natural entre dois estados quando estes são palavras binárias de N-bits, ou seja, é o número de bits ao qual duas palavras binárias diferem. A distância de Hamming é definida por

$$d_h = \frac{N - N_G}{N} \quad (4-1),$$

onde d_h é a distância de Hamming, N é o número total de bits em cada palavra e N_G é o número de bits que são idênticos em duas palavras. Esta distância permite julgar o quanto está distante um atrator do estado inicial da rede. Eventualmente, a distância dá uma medida quantitativa da fidelidade de uma certa memória que é relembra ou como diferentes estímulos podem estar associados com a mesma memória. Observa-se que a distância de hamming, no instante em que o controle é ligado, cai rapidamente para um valor mais baixo mas não segue continuamente para zero. Esta queda indica que a influência dos neurônios de controle se espalhou por toda a rede. Durante o transiente a distância de Hamming permanece em torno deste valor intermediário até que, subitamente, é levada a zero quando o atrator é alcançado. Esta observação está intimamente de acordo com o que mostra o mapa de Poincaré.




Fig.(4-17) Controle de caos. Neurônios 25, 32, 37, 88, 97 com estados ativos (+1) inseridos a 1001 passos temporais.

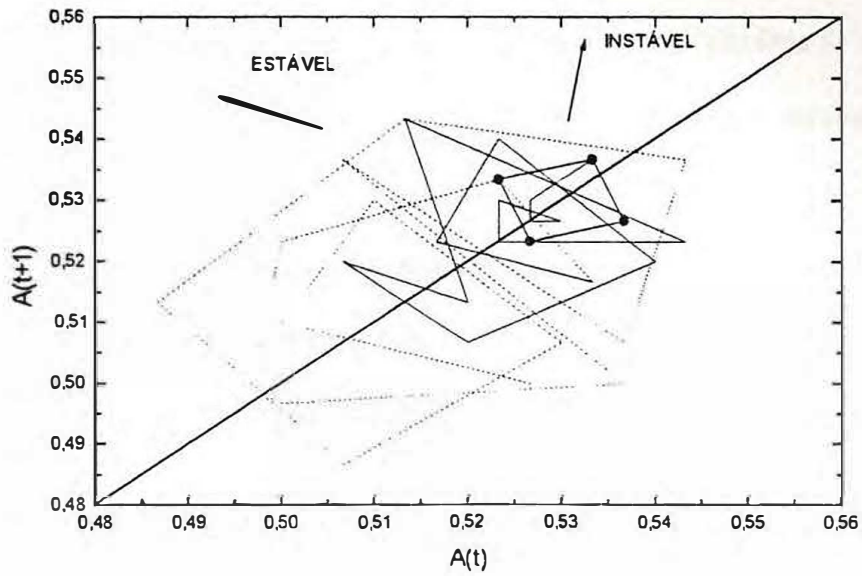


Fig. (4-18) Secção de Poincaré. linha pontilhada mostra a ausência de controle enquanto que a linha cheia mostra a presença do controle. Os pontos cheios mostram a órbita de período 4.




Fig. (4-19) Distância de Hamming. Controle inserido a 1501 passos temporais

O gráfico da figura (4-19) mostra a distância de Hamming calculada de acordo com a equação (4-1) para alguns neurônios inseridos a 1501 passos temporais levando a atividade para um atrator de período 1 ou ponto fixo onde esta após um determinado transiente cai para zero que significa que o controle foi atingido. Para atratores de períodos maiores que este como o que citou-se anteriormente, figs. (4-17) e (4-18), esta distância não será zero, mas terá um comportamento oscilante entre certos valores que dependerá do período do atrator.

Capítulo 5

Conclusão

O modelo de rede neural descrito neste trabalho reproduz uma vasta variedade de comportamentos dinâmicos. Dentre estes comportamentos dinâmicos, estudou-se o comportamento de regime caótico e fêz-se o controle deste, através do método PPI. O comportamento de regime caótico é abundante tanto na natureza como em aparelhos fabricados pelo homem e são caracterizados pela sua extrema sensibilidade a pequenas perturbações. O comportamento caótico é definido como sendo um atrator contendo, embutidas neste, um grande número de órbitas periódicas instáveis. Este comportamento é fundamental em situações como a evolução natural de organismos vivos, reações químicas, etc. Em muitos casos, a necessidade de se obter um controle deste comportamento é de suma importância.

No capítulo 3 foram citados e descritos alguns métodos de controle de caos em diversos sistemas tanto teóricos quanto experimentais. Um dos métodos mais investigados

atualmente é o método de OGY (Ott, Grebogi e Yorke). Este método pode ser aplicado tanto em sistemas teóricos quanto experimentais e em grande variedade de sistemas, incluindo sistemas químicos, biológicos, ópticos, eletrônicos, etc. O método de OGY possui as vantagens de não necessitar de nenhum modelo para a dinâmica do sistema, é rápido, as mudanças nos parâmetros são mínimas, no intervalo do mesmo parâmetro pode-se estabilizar diferentes órbitas para mesmo sistema, o controle pode ser obtido até mesmo com medidas imprecisas dos autovalores e autovetores e estende-se a qualquer sistema cuja dinâmica possa ser caracterizada por um mapa não-linear. Entretanto, possui desvantagens por não poder ser diretamente aplicado a sistemas nos quais não há como definir um mapa não-linear.

Aqui propõe-se um método de controle de regime caótico (PPI) que foi desenvolvido especificamente para o controle de comportamentos de regime caótico em redes neurais com muitos graus de liberdade como a que foi descrita no capítulo 2. Neste método os parâmetros acessíveis do sistema (rede neural) são os estados dos neurônios. O PPI mostra algumas vantagens como: a perturbação feita ao sistema pode ser muito pequena atuando apenas em um pequeno número de neurônios, não alterando assim o atrator caótico do sistema; é muito rápido, fácil de ser aplicado e pode estabilizar órbitas periódicas instáveis de pequenos e grandes períodos, como mostrado no capítulo 4.

Em suma, a possibilidade da identificação e estabilização de órbitas periódicas de um reservatório espaço-temporal caótico abre uma nova perspectiva para a compreensão de certos processos cognitivos. Consta-se através de registros de eletroencefalogramas (EEG) que a atividade cortical gera um caos espaço-temporal consistindo assim em um

reservatório de órbitas periódicas instáveis. Portanto pode-se pensar, que este grande número de órbitas periódicas representa um enorme depósito de codificações de informações. Assim, o controle de comportamentos de regime caótico através de métodos apropriados poderia funcionar como um mecanismo de codificação para o processamento de informações e até mesmo propor uma teoria da cognição baseada na dinâmica caótica. O interessante do método PPI é que a estabilização é atingida através de pequenas perturbações internas e portanto as transferências de informações não necessitam de apreciáveis mudanças na rede. Isto é muito importante em caos de redes corticais, onde não será necessário realizar dispendiosas mudanças metabólicas de larga duração. A aprendizagem e recuperação de informações de redes corticais se dá da seguinte maneira: supõe-se que a perturbação de uma dada natureza e magnitude estabilize uma órbita bem definida em ordem e frequência. Entretanto, tal órbita está ausente no reservatório de uma rede não ensinada. O processo de aprendizagem muda a eficácia das sinapses da rede de acordo com uma dada regra de aprendizagem. Somente nesta rede “ensinada”, as órbitas que podem ser estabilizadas por pequenas perturbações aparecem e desencadeiam o processo de reconhecimento e memória. Alguns autores conseguiram ensinar uma rede semelhante àquela usada neste trabalho através da utilização adequada de um processo de Hebb modificado [16]. Isto mostra que padrões de neurônios podem ser implantados propositalmente e não tomados aleatoriamente como no presente caso. Finalizamos especulando sobre a possibilidade da presença de um mecanismo de controle como o que descrevemos em redes neurais biológicas. A informação é transmitida no cérebro como seqüências de pulsos que levam sinais dos órgãos receptores ao córtex. Sabe-se que os

neurônios naturais operam perto do limiar de modo a serem sensíveis a modificação nos estímulos [17]. É possível que o processo de ativação de um trem de pulsos selecionados envolva o abaixamento do limiar e a ativação de neurônios especializados. Uma hipótese mais audaciosa foi apresentada por F. Crick [18]. Ele propõe que os sonhos são necessários para remover modos de excitação indesejáveis do córtex e reforçar aqueles que são importantes para a sobrevivência. Durante o sonho a atividade cerebral, observada em série de EEG, tem espectro de potência do tipo $\frac{1}{f}$. Portanto, durante os sonhos, a atividade cerebral visita todas as frequências neuronais acessíveis. Pode-se especular que, neste estágio, o sistema aprende que neurônios e que limiares deve escolher para desenvolver um trem de pulsos desejado. Recentemente [4], foi mostrado que nosso modelo de rede neural pode exibir atividade intermitente, com espectro de potência do tipo $\frac{1}{f}$.

A estabilização de órbitas instáveis numa rede neural caótica possui também um valor computacional. No entanto, como a princípio o número de órbitas periódicas até mesmo numa pequena rede é infinita, um aparelho de codificação que use tais órbitas terá de ter uma capacidade enorme.

Referências

- [1] - V. Vermuri, Davis/Livermore and L. Livermore, *IEEE*, 1 (1988).
- [2] - D. Amit, Modeling Brain Function, *Cambridge University Press*, Cambridge.
- [3] - G. Parisi, *J. Phys. A: Math. Gen.* **19**, L617 (1986).
- [4] - J. Moreira and D. M. Auto, *Europhysics Letters* **21** (6), 636 (1993).
- [5] - T. Shinbrot, C. Grebogi, E. Ott and J. A Yorke, *Nature* **363**, 411 (1993).
- [6] - E. Ott, C. Grebogi, and J. A. Yorke, *Phys. Rev. Lett.* **64**, 1196 (1990).
- [7] - W. L. Ditto, S. N. Rauseo, and M. L. Spano, *Phys. Rev. Lett.* **65**, 3211 (1990).
- [8] - J. Singer, Y-Z. Wang, and H. H. Bau, *Phys. Rev. Lett.* **66**, 1123 (1991).
- [9] - A. Azevedo and S. Rezende, *Phys. Rev. Lett.* **66**, 1342 (1991).
- [10] - E. R. Hunt, *Phys. Rev. Lett.* **67**, 1953 (1991).
- [11] - Rajarshi Roy, T. W. Murphy, Jr., T. D. Maier, Z. Gills e E. R. Hunt, *Phys. Rev. Lett.* **68**, 1259 (1992).

- [12] - Y. Braiman and I. Goldhirst, *Phys. Rev. Lett.* **66**, 2545 (1991).
- [13] - B. Peng, V. Petrov, and K. Showalter, *J. Phys. Chem.* **95**, 4957 (1991).
- [14] - A. Gartinkel, M. L. Spano, W. L. Ditto, J. N. Weiss, *Science* **257**, 1230 (1992).
- [15] - J. A. Sepulche and A. Babloyantz, *Phys. Rev. E* **48** (2), 945 (1993).
- [16] - A. Hertz, B. Sulzer, R. Kühn and J. L. van Hemmen, *Europhysics Letters* **7**, 663 (1988).
- [17] - T. Sejnoski, in *Parallel Models of Associative Memory* (laurence Erlbaum, N.Y., 1981).
- [18] - F. Crick and G. Mitchison, *Nature* **304**, 111 (1983).