

Universidade Estadual Paulista
Campos de Marília
Faculdade de Filosofia e Ciências
Programa de Pós-graduação em Filosofia

O PROCESSO DE AQUISIÇÃO DE HÁBITOS NAS
REDES NEURAIS DE KOHONEN

ADRIANA CRISTINA FERRARI DOS SANTOS

Marília - SP
2003



Universidade Estadual Paulista
Campus de Marília
Faculdade de Filosofia e Ciências
Programa de Pós-graduação em Filosofia

**O PROCESSO DE AQUISIÇÃO DE HÁBITOS NAS
REDES NEURAIS DE KOHONEN**

ADRIANA CRISTINA FERRARI DOS SANTOS

**Marília –SP
2003**



ADRIANA CRISTINA FERRARI DOS SANTOS

**O PROCESSO DE AQUISIÇÃO DE HÁBITOS NAS
REDES NEURAIS DE KOHONEN**

1410001487



*Dissertação para obtenção do título de mestre
apresentada junto ao Programa de Pós-
Graduação em Filosofia, na Área de
Concentração em Ciência Cognitiva e
Filosofia da Mente, da Universidade Estadual
Paulista.*

Orientadora: Dra. Maria Cláudia Cabrini Grácio

Marília - SP
2003



UN071135965

Nº cham. 006.3
5237p

Nº Tombo 1487
Aquisição D
Preço R\$ 5,00
Data 11/09/2003
Proced. Autor

Santos, Adriana Cristina Ferrari.

S237p O processo de aquisição de hábitos nas redes neurais de
Kohonen / Adriana Cristina Ferrari Santos. -- Marília, 2003.
120 f. ; 30 cm.

Tese (Mestrado em Filosofia) – Faculdade de Filosofia e
Ciências – Universidade Estadual Paulista, 2003.

Bibliografia: f. 117-120.

Orientador: Dra. Maria Cláudia Cabrini Grácio

1. Redes neurais artificiais. 2. Inteligência artificial. 3.
Auto-organização. 4. Hábito. I. Autor. II. Título.

CDD 005.3



ADRIANA CRISTINA FERRARI DOS SANTOS

O PROCESSO DE AQUISIÇÃO DE HÁBITOS NAS REDES NEURAIS DE KOHONEN

*Dissertação para obtenção do título de mestre
apresentada junto ao Programa de Pós-
Graduação em Filosofia, na Área de
Concentração em Ciência Cognitiva e
Filosofia da Mente, da Universidade Estadual
Paulista.*

Comissão Julgadora

Presidente e orientadora	Dra. Maria Cláudia Cabrini Grácio - Unesp
2º Examinador	Dr. Lauro Frederico Barbosa da Silveira - Unesp
3º Examinador	Dr. Marcos Luíz Mucheroni - FEESR

Marília, 21 de março de 2003



Dedico este trabalho à minha mãe, Odete Cavina Ferrari, em
agradecimento a tanto carinho, dedicação, amor, compreensão,
companheirismo e amizade para comigo durante toda a minha vida
e principalmente durante os anos de estudos aqui em Marília. Sem
a força e o incentivo dela, teria sido tudo muito mais difícil.

AGRADECIMENTOS

Primeiramente gostaria de agradecer à minha orientadora Dra. Maria Cláudia Cabrini Grácio pela dedicação e apoio constantes no período em que cursei o mestrado. Agradeço, também ao Dr. Lauro Frederico Barbosa da Silveira, à Dra. Silvana Ap. B. Gregório Vidotti, ao Dr. Marcos Luíz Mucheroni, à Dra. Maria Eunice Quilici Gonzalez, à Dra. Maria Cândida Soares Del-Masso, ao Dr. Michael Beaumont Wrigley, à Dra. Mariana Claudia Broens e à José Carlos Cavassini, pelas constantes lições que sempre ajudaram em meu desenvolvimento pessoal e acadêmico. Aos colegas de mestrado, João Luís da Silva Santos, Maurizio de Queiroz Oliveira, Max Rogério Vicentini, Ruben Carlo Benante, e Alex S. R. de Souza Poletto, agradeço por terem-me ajudado com trocas de bibliografias e experiências. Também é necessário agradecer aos meus familiares, meu marido Juliano Rodrigues dos Santos, minha mãe Odete Cavina Ferrari, meu pai Mauro Ferrari e meu irmão José Tomaz Ferrari, pela compreensão, paciência, incentivo e carinho durante esse período.



RESUMO

SABIDO, et al. P. O processo de aquisição de hábitos nos estudos filosóficos de Aristóteles. *Revista de Filosofia da UFPA*. 2016. Disponível em: <http://www.revista.ufpa.br/revista-de-filosofia>. Acesso em: 10/04/2016. Publicado em: 10/04/2016. Título: "Hábitos e a Filosofia de Aristóteles".

Este trabalho tem por finalidade a apresentação da metodologia de trabalho de Aristóteles, bem como a análise da sua filosofia. Para isso, o trabalho de Aristóteles é dividido em duas partes: a primeira, que trata da filosofia de Aristóteles, e a segunda, que trata da filosofia de Aristóteles. A metodologia de trabalho de Aristóteles é baseada na observação e na experiência. A metodologia de trabalho de Aristóteles é baseada na observação e na experiência. A metodologia de trabalho de Aristóteles é baseada na observação e na experiência.

“... assim como dizemos que um corpo está em movimento, e não que o movimento está num corpo devemos dizer que estamos em pensamento e não que os pensamentos estão em nós.” (Peirce, 1976)

“O universo não é uma idéia minha,
A minha idéia do universo é que é uma idéia minha,
A noite não anoitece pelos meus olhos,
A minha idéia da noite é que anoitece por meus olhos.”
(Fernando Pessoa – poemas inconjuntos).

RESUMO

SANTOS, A. C. F. *O processo da aquisição de hábitos nas Redes Neurais de Kohonen*. Marília, 2003. 120f. Dissertação (Mestrado em Filosofia) — Faculdade de Filosofia e Ciências, Campus de Marília, Universidade Estadual Paulista “Júlio de Mesquita Filho”.

Este trabalho tem por finalidade a discussão da possibilidade de as redes neurais de Kohonen adquirirem hábitos. Por ser o conceito de hábito muito amplo e estudado por diversos pesquisadores, este presente trabalho limita-se a abordar o conceito de hábito da teoria peirciana. Como Peirce estuda muitas classes de hábitos, restringe-se a focalizar atenção apenas na classe de hábitos gerais desse autor. Para dar sustentação a essa discussão, aborda-se os conceitos de Redes Neurais Artificiais, suas estruturas, esquemas de alimentação, técnicas de aprendizagens e alguns de seus modelos, tais como o Perceptron de camada simples e de várias camadas, o Backpropagation e, em especial, o modelo de Kohonen, que é de grande interesse para essa discussão. O modelo de Kohonen utiliza a técnica de aprendizagem conhecida como não-supervisionada ou por auto-organização e a fim de compreendê-la, analisa-se o conceito de Auto-Organização e suas modalidades na visão de dois pesquisadores da área: Ashby (1962) e Debrun (1996). Trabalha-se também o conceito de hábito geral da teoria peirciana em suas duas abordagens: o hábito geral constituído logicamente por idéias e o hábito geral constituído fisicamente por seres dotados de sistema nervoso. Definidos tais conceitos fundamentais, os mesmos são confrontados com um simulador da rede de Kohonen, chamado de *Kohonen Network Simulator*, versão 1.1, dos autores Caudill e Butler (1992), o qual faz o reconhecimento de padrões de *inputs* informacionais. O trabalho é finalizado com uma comparação do resultado desse simulador com o hábito geral peirciano, para saber se o resultado apresentado pela rede de Kohonen pode ser considerado um hábito geral adquirido, tal como proposto por Peirce.

Palavras-chave: Redes Neurais Artificiais; Inteligência Artificial; Auto-Organização; Hábito Geral.



ABSTRACT

The work's aim is to discuss if the Kohonen neural network can acquire habits. The work will be focused in the peircean habit theory as the habit concept is comprehensive. We have chosen to use the peircean general habit theory considering that exists many habit classes. To support properly the theme, artificial neural network concepts are presented including their structures, pattern of connectivity, learning algorithms and models as the single layer Perceptron, multiple layers Perceptron, the Backpropagation and specially Kohonen's model, that is very relevant. The Kohonen's model uses the learning algorithms known as non supervised or self organized. In order to understand it we analyze the self organization's concept and their modalities according Ashby (1962) and Debrun (1996) analysis. Peircean general habit theory is also extensively analyzed in two approaches:

- General habit established logically by ideas;
- General habit established physically by creatures with nervous systems.

Defined the fundamental concepts, they are faced against Kohonen network simulator (Kohonen Network Simulator, version 1.1 from Caudill and Butler, 1992) which has the ability to recognize the informational input pattern. This work is concluded with the a comparison trying to prove that the results shown could be considered as a general acquired habit, as proposed by Peirce.

Keywords: Artificial Neural Networks; Artificial Intelligence; self-organization; general habit.

LISTA DE ILUSTRAÇÕES

FIGURA 1: Neurônio Natural (WASSERMAN, 1989, p. 13).	27
FIGURA 2: Representação fundamental de um neurônio artificial básico (SIMPSON, 1990, p. 5).	29
FIGURA 3: Rede Neural Artificial (RNA) (GONZALES, 1996, p. 281)	33
FIGURA 4: Perceptron de Camada Simples (LIPPMANN, 1987, p.13)	39
FIGURA 5: Regiões de Decisão de um Perceptron (LIPPMANN, 1987, p.13).....	40
FIGURA 6: Funções lógicas de duas variáveis representadas no plano binário (KOVÁCS,1996, p. 33).....	43
FIGURA 7: Perceptron MLP de duas Camadas (LIPPMANN, 1987, p.14)	44
FIGURA 8: Perceptron MLP de três Camadas (LIPPMANN, 1987, p. 14).	44
FIGURA 9: Modelo Backpropagation (WASSERMAN, 1989, p. 46).....	47
FIGURA 10: Rede de duas dimensões com UNS's de <i>output</i> usadas para formar mapas característicos. Cada <i>input</i> está conectado com cada nó de <i>output</i> por meio do peso variável da conexão (LIPPMANN, 1987, p.18).....	53
FIGURA 11: A função do Chapéu Mexicano descreve a relação entre a distância do neurônio vencedor e a força da conexão na camada. Vizinhos próximos têm efeito excitatório forte; vizinhos remotos têm efeito inibitório moderado; e vizinhos muito remotos têm um efeito excitatório insignificante (KOHONEN, 1987, p. 123)	54
FIGURA 12: Exemplo da existência de condicionalidade para Ashby (D'OTTAVIANO; GONZALES, 2000, p. 85).	58
FIGURA 13: Exemplos de Máquinas em Geral na concepção de Ashby (1962).....	61
FIGURA 14: Exemplo de um Mapa de Kohonen com neurônios de saída usados de forma bidimensional. Neste exemplo todas as entradas $X_0...X_N$ estão conectadas com as saídas (KOHONEN, 1987, p. 128)	82

FIGURA 15: Definição do Raio de Vizinhança em diferentes tempos em que os mapas de medidas são formados (BEALE; JACKSON, 1994, P. 118).....	88
FIGURA 16: Exemplo dos modelos quadrado e hexagonal (KOHONEN, 1987, p. 132)	89
FIGURA 17: Definição da Rede de Kohonen antes de inicializar o treinamento, extraído da tela do <i>software</i> de simulação utilizado	95
FIGURA 18: Tela extraída do <i>software</i> SOM, no final de 104 iterações	96
FIGURA 19: Tela extraída do <i>Software</i> SOM, no final de 520 iterações	98
FIGURA 20: Tela extraída do <i>Software</i> SOM no final de 1560 iterações	100
FIGURA 21: Tela extraída do <i>Software</i> SOM no final de 3016 iterações	102
FIGURA 22: Tela extraída do <i>Software</i> SOM no final de 10036 iterações	103

LISTA DE TABELAS

<u>TABELA 1:</u> Tabela de correspondência, onde zero (0) e um (1) representam respectivamente falso e verdadeiro	43
<u>TABELA 2:</u> Exemplos das representações das letras do alfabeto no arquivo de <i>input</i> (<i>Alphabet.dat</i>). Destacamos em negrito e itálico os valores 1.0 na tabela para facilitar a visualização das letras	94
<u>TABELA 3:</u> Resumo do resultado obtido no arquivo Alfa.rpt, nas últimas 26 iterações de um total de 104. A linha com preenchimento contém a UNS com a diferença maior em relação ao padrão de <i>input</i>	97
<u>TABELA 4:</u> Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 520.....	99
<u>TABELA 5:</u> Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 1560.....	100
<u>TABELA 6:</u> Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 3016.....	102
<u>TABELA 7:</u> Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 10036.....	104



LISTA DE ABREVIATURAS

ANS's (Artificial Neural System) = Sistemas Neurais Artificiais

A-O = Auto-Organização

CP = Collected Papers

IA = Inteligência Artificial

LMS = Least Mean Square

LVQ (Learning Vector Quantization) = algoritmo de ajuste da rede neural

MLP = Multi Layer Perceptron

NN's = Neurônios Naturais

PDP (Parallel Distributed Processing) = Processo Distribuído e Paralelo

PE's (Processing Element) = Elementos de Processamento

RNA = Rede Neural Artificial

UNS (Unidade Neurônio-Símile) = Neurônio Artificial

SUMÁRIO

1. INTRODUÇÃO.....	15
2. REDES NEURAIS ARTIFICIAIS (RNA's).....	26
2.1 Apresentação.....	26
2.2 Os neurônios naturais e os artificiais	27
2.3 Desenvolvimento das Redes Neurais Artificiais (RNA's)	31
2.4 Alguns modelos de RNA's	38
2.4.1 Peceptron de Camada Simples e de Várias Camadas	39
2.4.2 Backpropagation	47
2.4.3 Rede Neural de Kohonen.....	50
3. SISTEMAS AUTO-ORGANIZADOS	56
3.1 Apresentação.....	56
3.2 Organização	56
3.3 Máquinas.....	59
3.4 Sistemas Auto-Organizados.....	62
4. O CONCEITO DE HÁBITO GERAL NA TEORIA DE PEIRCE.....	69
4.1 Apresentação.....	69
4.2 Aquisição de Hábitos	70
5. AQUISIÇÃO DE HÁBITO NA REDE DE KOHONEN	81
5.1 Apresentação.....	81
5.2 Os mapas auto-organizáveis de Kohonen	81
5.3 O ajuste fino da rede	89
5.4 Treinamento de uma rede de Kohonen para reconhecimento de padrões informacio- nais.....	92

5.5 Rede de Kohonen versus Hábito peirciano.....	105
6. CONSIDERAÇÕES FINAIS.....	111
REFERÊNCIAS.....	117
BIBLIOGRAFIA CONSULTADA	120

1. INTRODUÇÃO

Jean Pierre Dupuy (1996, p.9) apresenta, em seu livro *Nas Origens das Ciências Cognitivas*, uma análise pertinente a respeito da origem da Ciência Cognitiva. Segundo Dupuy, a Ciência Cognitiva teve início na década de 40 do século XX, com o reagrupamento de uma equipe de matemáticos, engenheiros e neurobiólogos que tencionavam fundar uma ciência da mente, denominada por eles de Cibernética. Esse grupo, reunia-se regularmente em conferências, denominadas de Conferências Macy. O objetivo era o de “edificar uma ciência geral do funcionamento da mente” (DUPUY, 1996, p.9).

O movimento cibernético caracterizou-se por colaborar com a modificação de muitos conceitos da ciência contemporânea da época, uma vez que se acreditava ser capaz de responder cientificamente ao problema filosófico das relações entre a matéria e a mente que há muito tempo existia (DUPUY, 1996, p.25). No entanto, modificar conceitos em relação ao mundo à nossa volta é um processo difícil, pois muitos deles estão enraizados em nós. Não podemos nos esquecer, contudo, de que os conceitos, em geral, não são coisas acabadas e imutáveis. E para que possamos entendê-los verdadeiramente, não podemos simplesmente aceitá-los. Antes, temos de questioná-los e investigá-los, para evoluirmos e adquirirmos novos e verdadeiros conceitos.

A Ciência da Cibernética possui uma postura evolucionista frente ao seu principal objetivo: analisar o **comportamento** dos organismos e das máquinas. Esse interesse, segundo Dupuy, surgiu com a construção de máquinas modernas, cuja complexidade “tenta copiar”, cada vez mais, o comportamento animal. Contudo, para Dupuy (1996), a Cibernética foi marcada por três momentos no decorrer de sua evolução:



“o primeiro momento assimila a mente a uma máquina lógica; o segundo, faz o mesmo com o cérebro, e já que se trata da mesma máquina, o cérebro e a mente são uma mesma coisa” (DUPUY, 1996, p. 76-77). E somente no terceiro, é que a máquina lógica pode ser materializada e chamada de máquina artificial.

A máquina lógica, a que Dupuy (1996) se refere nos dois primeiros momentos da Cibernética é equivalente à “máquina de Turing”, a qual define que “toda função calculável mecanicamente é calculável por uma máquina de Turing” (DUPUY, 1996, p.31).

Segundo Dupuy (1996), Alan M. Turing foi um dos primeiros pesquisadores a descrever o procedimento envolvido no ato de computar. Este último aceita como verdade que a máquina pode aprender, pois, para ele os computadores podem fazer aquilo para o qual foram programados, inclusive aprender. Turing sugeriu que algumas computações poderiam ser realizadas em se trabalhando com conjuntos de 0(s) e 1(s), escritos em uma fita de papel e executando-se instruções simples como: escreva o símbolo 1; escreva o símbolo 0; mova uma posição à direita; mova uma posição à esquerda; leia o símbolo corrente e execute a próxima operação; pare. É o que podemos apreender em Dupuy:

Uma máquina de Turing compreende três órgãos: a máquina *stricto sensu*, suscetível a qualquer momento (o tempo é discretizado) de se achar num estado, chamado “estado interno”, pertencente a uma lista finita; uma fita ilimitada nos dois sentidos, que representa a memória da máquina: essa fita é dividida em casas, cada uma delas comportando ou não uma certa marca; e, por fim, uma cabeça de ler-escrever-apagar capaz de realizar as seguintes operações: colocada diante de uma das casas, ela lê se esta contém a marca ou não; pode apagar a marca, se ela existir, ou escrevê-la, no caso contrário; pode deslocar-se uma casa para a direita ou para a esquerda (DUPUY, 1996, p.32).

Já a máquina material, a que Dupuy (1996, p.77) faz referência no terceiro momento da Cibernética, é a construção de um computador que recebeu o nome de ENIAC. Não podemos deixar de enfatizar que houve um grande esforço na fase

Cibernética em tornar as ciências interdisciplinares, o que por vezes causou vários mal-entendidos e enormes discussões entre os cientistas. A interdisciplinaridade continua sendo a busca da Ciência Cognitiva para melhor compreensão da mente.

Gardner (1985, p. 28) sustenta, em seu livro *The Mind's New Science: a history of cognitive revolution*, que, apesar de ter suas raízes nos anos quarenta do século XX, a Ciência Cognitiva surgiu, de fato, por volta de 1956. Essa Ciência, segundo Dupuy (1996, p.11), é caracterizada por um estudo interdisciplinar, levando ao diálogo e à aproximação entre os neurofisiologistas e os psicólogos, os filósofos e os computólogos, os engenheiros e os lingüistas, buscando uma nova linguagem, com alguns termos em comum às várias Ciências.

Temos, em geral, segundo Gardner (1985, p. 40-41), duas abordagens para o termo “Ciência Cognitiva”: Ciência Cognitiva (no singular) e Ciências Cognitivas (no plural). O termo *Ciência Cognitiva* refere-se à elaboração de modelos explicativos sobre a natureza da inteligência, por meio do uso do computador, sendo, desse modo, o computador um instrumento fundamental para modelar seus estudos empíricos. O termo *Ciências Cognitivas* é utilizado, por Gardner, para referir-se ao conjunto de disciplinas específicas: Filosofia, Psicologia, Inteligência Artificial, Lingüística, Antropologia e Neurociência, em que o computador desempenha um papel menor nos estudos, podendo inclusive ser dispensado. Usaremos, neste trabalho, o termo Ciência Cognitiva, pois analisaremos modelos computacionais que tentam explicar a natureza da inteligência.

A Ciência Cognitiva, como podemos ler em Gardner (1985, p.393-394), possui duas principais correntes que investigam a natureza dos estados mentais: a *Inteligência Artificial (IA)* ou *Cognitivismo Ortodoxo*, que aponta para um modelo lógico e serial e o *Conexionismo ou Redes Neurais Artificiais (RNA)*, também conhecido por *PDP –*

Parallel Distributed Processing –, que aponta para um modelo de processamento distribuído em paralelo.

Estas duas correntes, segundo Gardner (1985), têm alguns pressupostos em comum, como o uso do computador para criar modelos que expliquem a mente nos seus aspectos cognitivos, apresentando assim uma tese mecanicista da mente. Deixam de lado os aspectos sociais e emocionais do sujeito cognoscente, numa tentativa de simplificar os estudos da inteligência, concentrando-se nos aspectos racionais, lógicos, e na capacidade de abstração que um sujeito inteligente pode demonstrar.

Diferem, porém, tais vertentes entre si em outros pontos. Gardner (1985, p. 319) nos alerta para o fato de que para a IA, a inteligência é um processo mecânico, regido por regras abstratas (algoritmos), ao passo que para a RNA, a inteligência é um processo mecânico, mas regido por leis físicas. Nessa busca da compreensão da inteligência, o autor aponta os esforços dos cientistas cognitivos, os quais muitas vezes se uniram e outras se separaram, conforme as suas tendências e objetivos.

Segundo Gardner (1985, p. 138-139), o primeiro a utilizar o termo IA foi John McCarthy, que juntamente com Simon, Newell, Minsky e outros cientistas lógicos e matemáticos, se reuniram em 1956, com o propósito de realizar um estudo sobre a natureza da mente inteligente, fundamentado na hipótese de que todos os aspectos da inteligência podem ser precisamente descritos, a ponto de se criar uma máquina que os simulem. De acordo com Gardner (1996, p. 155), em seu livro *A nova Ciência da Mente*, a IA tem duas vertentes principais, que são, em suma:

- ♦ **IA no sentido restrito ou fraco:** tem uma preocupação menor com o grau de realidade psicológica dos seus modelos computacionais, os quais constituem apenas ferramentas para testar as teorias sobre os processos que caracterizam o pensamento e;

- ♦ **IA no sentido forte:** em contraste, ao apresentar um computador adequadamente programado, tem o objetivo de “reproduzir” estados mentais interligados, usando eliminação de diferenças, regras de associação, tentativa e erro, etc.

Em um pequeno parágrafo, Gardner resume o interesse dos pesquisadores dessas duas vertentes da IA: “Alguns profissionais querem simular os processos exatamente como o pensamento humano, enquanto outros estão contentes com qualquer programa que conduz a conseqüências inteligentes.” (GARDNER, 1985, p.140, tradução nossa).

Gardner (1996) cita que os cientistas da IA desenvolveram muitos trabalhos e também sofreram muitas críticas. Dessas críticas, a maioria focalizava o fato de toda informação manipulada pelo computador ser fornecida pelos humanos, processadas somente por regras pré-definidas em seqüência lógica e de que as soluções dos problemas pelo computador nada mais ser do que a resposta para a qual ele fora programado.

Das tantas críticas feitas à IA, citaremos duas: a de Dreyfus (1975) e a de Searle (1997). Para Dreyfus (1975, p. 41), o processamento de informações nos seres humanos é diferente do processamento de informações dos modelos propostos pela IA, os quais seguem, em seu processamento, regras pré-definidas, fixas e em seqüência lógica. Para este autor, nem todo comportamento inteligente dos seres humanos são definidos por regras rígidas, como por exemplo, a capacidade contextual envolvido na tradução de idiomas. Aponta vários fracassos dos modelos da IA ao tentar simular os processos cognitivos, tais como: tradução automática de idiomas, reconhecimento de padrões, entre outros (DREYFUS, 1975, p. 270).

Outro crítico da vertente da IA foi Searle (1997), o qual acredita que os aspectos biológicos influenciam no comportamento inteligente humano, contestando a crença da IA de que a mente é equivalente a um programa de computador, cujo suporte

físico (*hardware*) dos modelos não é importante. Para Searle (1997), os modelos da IA são baseados somente na manipulação de símbolos por meio de regras, enquanto a atividade mental envolve também aspectos semânticos.

Já a outra vertente da Ciência Cognitiva, denominada RNA ou Conexionismo, segundo Wasserman (1989), tem por objetivo investigar a possibilidade de simular comportamentos inteligentes através de modelos inspirados na estrutura e funcionamento do nosso cérebro.

Dupuy (1996) afirma que o primeiro artigo sobre RNA, intitulado *A Logical Calculus of the Ideas Immanent in Nervous Activity*, foi publicado no ano de 1943 e assinado por Warren McCullock e Walter Pitts. McCullock e Pitts foram os primeiros a propor um modelo do cérebro sob a forma de uma rede de neurônios idealizados, pois para eles o neurônio biológico pode ser modelado em termos matemáticos.

Segundo Kovács (1996, p. 28-29), o neurônio formal de McCullock e Pitts é muito simples, podendo ser entendido como um dispositivo binário, para o qual se o resultado dos cálculos da saída do neurônio for maior ou igual a um dado limiar, a saída do neurônio é um pulso; caso contrário, é um não pulso.

A partir dessa época, outros pesquisadores se destacaram e contribuíram para se chegar a um modelo geral de RNA, tais como Donald Hebb (1949) e Frank Rosenblatt (1962) (RUMELHART; McCLELLAND, 1986).

O psicólogo Donald Hebb, sugeriu em 1949, um princípio de aprendizagem baseado no aumento da intensidade das conexões entre os neurônios (RUMELHART; McCLELLAND, 1986, p. 36). Esclareceu, com o seu princípio, que quando dois neurônios, A e B, são simultaneamente excitados, o peso da conexão entre eles é aumentado. Tal princípio, segundo Rumelhart e McClelland (1996), baseou-se na

aprendizagem que ocorre no cérebro humano, e serviu de base para formular as regras de aprendizagem das redes neurais artificiais.

Posteriormente, Roseblatt em 1962, desenvolveu um modelo de RNA denominado de Perceptron¹. O Perceptron é uma rede que pode possuir em sua arquitetura apenas uma unidade ou um conjunto de neurônios de McCulloch e Pitts organizados (RUMELHART; McCLELLAND, 1986). A grande novidade deste modelo, foi ele possuir a propriedade de poder aprender a reconhecer padrões informacionais, por meio de procedimento simples de treinamento (RUMELHART; McCLELLAND, 1986). Assim, o Perceptron pode ser treinado, modificando continuamente os pesos das conexões entre os neurônios das camadas da rede.

Apesar do impacto desse modelo, ele foi muito criticado por Marvin Minsky e Seymour Pappert (1969), pela sua incapacidade de solucionar alguns problemas muito simples, uma vez que o Perceptron só era capaz de resolver problemas linearmente separáveis, nos quais uma linha reta é usada para separar os padrões informacionais de entradas em apenas duas classes.

As declarações feitas por Minsky e Pappert (1969), levou a um desestímulo de estudo nesse campo da RNA, iniciando nos anos 70, um período de estagnação das pesquisas. Contudo, apesar das dificuldades de pesquisa na área, a RNA não foi abandonada e renasceu nos anos 80, especialmente após a contribuição do físico John Hopfield (1982), que enfatizava a relação entre modelos de memória associativa e sistemas físicos, tornando-se a nova linha de pesquisa desta área.

Uma diferença que podemos constatar entre as vertentes IA e RNA, é que para a IA não importa a arquitetura da máquina computacional que está executando o algoritmo de simulação da inteligência. Seus cientistas acreditam que a mente é um

¹ O modelo de RNA Perceptron será melhor abordado na seção 2.4.1 deste capítulo.



programa de manipulação de símbolos, com regras algorítmicas seguindo um procedimento serial e que seu suporte físico não é importante. Em oposição aos modelos propostos na IA, o Conexionismo, ou RNA, não leva em conta somente os aspectos racional-lógicos dos sistemas cognitivos como a IA. A arquitetura dos seus modelos é importante e se inspira nas propriedades do processamento local em paralelo e na representação distribuída que seus cientistas acreditam existir no cérebro. A atividade cognitiva de tais modelos é uma propriedade emergente da interação entre seus elementos, interconectados em redes de neurônios artificiais (UNS's)² e cuja aprendizagem é regida por leis físicas.

Contribuindo, atualmente, para o desenvolvimento das RNA's, encontramos o conceito de A-O. Os processos auto-organizados, segundo Debrun (1996), são estudados por diversas áreas, que estudam tanto os sistemas biológicos e físicos, quanto os sistemas artificiais, na tentativa de entender e explicar a dinâmica do processo de surgimento espontâneo de padrões, formas ou organizações, a partir das interações entre elementos, sem a necessidade de um supervisor externo, ou de um centro organizador. Seja na biologia com o estudo da decodificação do DNA efetuada na célula, seja em eventos sociais como um jogo de futebol, seja na música, ou em outras áreas, existem muitos estudos sendo desenvolvidos sobre o processo da A-O. O interesse dos pesquisadores das RNA's por A-O surgiu a partir do momento em que padrões foram reconhecidos por máquinas, sem que para tanto tivessem um supervisor forte no controle. Neste trabalho, abordaremos os conceitos de auto-organização nas visões de Ashby (1962), e de Debrun (1996a, 1996b).

Conceitualmente, Ashby (1962, p. 267) sugere que um sistema auto-organizável seria aquele que muda de partes separadas para partes conectadas, isto é, que

² UNS's (Unidade Neurônio-Símile): terminologia utilizada por Gonzales (1996).



as partes independentes, incondicionadas, desconectadas, se encontram em um determinado momento, tornando-se dependentes, condicionadas, conectadas e enfim, organizadas. No mesmo sentido, Debrun (1996a) argumenta que, durante o processo de auto-organização, ocorre uma interação entre elementos distintos (elementos sem vínculos preexistentes de dependência), sem uma intervenção externa dominante, o que possibilita a constituição de uma forma organizada, ou a reorganização de uma forma já existente:

Há auto-organização cada vez que, a partir de um encontro entre elementos realmente (e não analiticamente) distintos, desenvolve-se uma interação sem supervisor (ou sem supervisor onipotente) – interação essa que leva eventualmente à constituição de uma ‘forma’ ou à reestruturação, por ‘complexificação’, de uma forma já existente (DEBRUN, 1996a, p.13).

Tanto na definição de Ashby (1962), quanto na definição de Debrun (1996a), para haver auto-organização, o funcionamento, a manutenção e a organização de tais processos devem depender somente dos seus elementos internos, os quais devem possuir o mesmo grau de influência.

Nesta pesquisa, analisaremos as RNA's no contexto da Auto-Organização, uma vez que ela pode nos ajudar a entender o processo de aprendizagem na rede de Kohonen, pois esta rede utiliza algoritmos de aprendizagem baseados nos conceitos de auto-organização e será por nós estudada.

Na presente investigação, o nosso objetivo será o de verificar se uma RNA de Kohonen pode adquirir hábito geral. Noutros termos: será que quando a rede de Kohonen apresenta uma resposta correta, segundo os critérios de erros em RNA's, podemos dizer que ela adquiriu um hábito geral?

Devido à ampla teorização existente acerca dos hábitos, restringiremos nosso estudo ao conceito de hábito geral tal como proposto por Charles Sanders Peirce. Embora para Peirce existam muitas classes de hábitos mais particulares, ditos degenerados,

e que precisam de experimentos para serem testados, nosso objetivo restringe-se a investigar se as redes de Kohonen adquirem hábitos gerais.

Para encontrarmos a resposta à questão central acima levantada, faz-se necessário um embasamento teórico acerca de conceitos, tais como, RNA's, Auto-Organização e hábito geral peirciano. Desse modo, no percurso desta investigação, dividiremos o trabalho em seis capítulos. No Capítulo 2, mostraremos como é o processo de recepção e transmissão de estímulos em um neurônio artificial, apresentaremos as noções básicas sobre as RNA's, as etapas do seu desenvolvimento e encerraremos citando alguns dos vários tipos de RNA's existentes, como: o Perceptron de camada simples e de várias camadas, o Backpropagation e o modelo de Kohonen.

No Capítulo 3, apresentaremos os conceitos de Auto-Organização, tanto na visão de Ashby (1962) quanto na visão de Debrun (1996), passando pelas definições de organização e máquinas em geral. Encerraremos o capítulo abordando os conceitos de Auto-organização Primária e Secundária. Os conceitos desse capítulo são importantes, pois nos permitirão entender como as RNA's de Kohonen funcionam, as quais são nosso principal objeto de estudo.

No Capítulo 4, exploraremos o conceito de hábito genuinamente geral da teoria de Charles Sanders Peirce, para nos embasar conceitualmente na discussão que pretendemos fazer do processo de aprendizagem de uma RNA A-O com a aquisição de hábito geral peirciano.

No Capítulo 5, trataremos com mais detalhes a RNA A-O de Kohonen, abordando seu algoritmo de aprendizagem, a técnica de ajuste fino aplicada a esta rede para aumentar a sua eficiência em reconhecer padrões informacionais e analisaremos um modelo de Kohonen (SOM) que faz o reconhecimento de padrões. Encerraremos este

capítulo, comparando o resultado apresentado por esta rede com a aquisição de hábito geral peirciano.

Finalizando o trabalho, apresentaremos algumas considerações que constituem uma síntese do estudo, mostrando os limites da área, e algumas possibilidades para novos trabalhos sobre o tema, tanto do ponto de vista técnico quanto das aplicações computacionais.

CAPÍTULO 2 – REDES NEURAIS ARTIFICIAIS (RNA's)

2.1 Apresentação

Considerando que a nossa finalidade neste trabalho é investigar se uma rede neural de Kohonen adquire hábitos gerais, faz-se necessário o entendimento do que é uma rede neural artificial, sua história, funcionamento, estrutura física, seus diversos modelos e também em quais problemas ela está sendo aplicada. Abordaremos tais conceitos no decorrer deste capítulo.

Inicialmente, é importante esclarecermos que os pesquisadores da área das Redes Neurais Artificiais (RNA's) têm a finalidade de criar modelos matemáticos, chamados *modelos computacionais conexionistas*, a partir do entendimento do funcionamento do cérebro. Em seu livro *Artificial Neural Systems*, no capítulo 2, Simpson escreve que “modelos neurais são baseados em como o cérebro processa informação”(SIMPSON, 1990, p.5, tradução nossa).

Os modelos de redes neurais têm sido estudados há muitos anos na esperança de se explicar o desenvolvimento humano nos campos da fala, da visão, do olfato, do tato, do reconhecimento de padrões e do controle motor. Para tanto, essas redes utilizam duas propriedades que seus cientistas acreditam existirem no cérebro: “o processamento local maximamente paralelo e a representação distribuída” (SIMPSON, 1990, p.1, tradução nossa).

Não podemos continuar a explorar a área das redes neurais sem enfatizar também que a abordagem conexionista não determina os comportamentos inteligentes por meio da execução de programas ou regras pré-determinadas e em sequência lógica, como

no computador convencional ou de Von Neumann. Por outro lado, de acordo com Lippmann (1987, p.13), as RNA's utilizam competições simultâneas em redes paralelas, compostas de muitos neurônios artificiais, conectados com pesos variados que, com treinamentos, irão definindo o comportamento inteligente da rede. Para compreendermos como as RNA's funcionam, abordaremos os neurônios naturais e os artificiais na próxima seção.

2.2 Os neurônios naturais e os artificiais

O nosso cérebro, segundo Simpson (1990, p.3), pode ser visto como uma grande rede de células nervosas ou neurônios naturais (NN's), altamente interconectados. De acordo com a sua localização e estrutura morfológica, haverão diversos tipos de NN's, que, por sua vez, podem possuir diferentes funções. Mas, em geral, os NN's são constituídos dos mesmos componentes: a soma (corpo da célula), os axônios (fibra nervosa) e os dendritos, como mostra a figura 1.




Figura 1: Neurônio Natural (WASSERMAN, 1989, p. 13).

Como observa Kovács (1997, p.19-21), a soma, também chamada de corpo do neurônio, é constituída do núcleo e tem a função de processar as informações (*inputs*) vindas de outros neurônios. Os axônios são constituídos por uma fibra tubular que pode alcançar até alguns metros, sendo os responsáveis por transmitir os estímulos processados para outras células (*output*). Os dendritos são prolongamentos menores em forma de ramificações (arborizações terminais) que emergem do final do axônio, os quais têm por função receber os estímulos transmitidos pelos outros neurônios. Esses NN's estão conectados uns aos outros por meio de sinapses ou fendas sinápticas, já que não há um contato real, mas um espaço muito pequeno, que se constitui de conexões eletroquímicas entre os neurônios. O neurônio que transmite a informação para a sinapse por intermédio de seu axônio é chamado de pré-sináptico, e o que recebe tais informações das sinapses para seus dendritos é chamado de pós-sináptico.

Segundo Kovács (1997), dados experimentais recentes têm provado que os neurônios biológicos, ou naturais, são estruturalmente mais complexos do que uma explicação simplista como esta. Porém, vale lembrar que, neste trabalho, interessam-nos exclusivamente as funções básicas dos NN's, mencionadas no parágrafo anterior, as quais inspiram a construção dos neurônios artificiais ou UNS's (Unidade Neurônio-Símile).

As RNA's são constituídas por UNS's interligadas, que, apesar de serem de materiais diferentes dos NN's, simulam algumas funções básicas destes, como podemos ver na figura 2.





Figura 2: Representação fundamental de um neurônio artificial básico (SIMPSON, 1990, p. 5).

Na figura 2, o processo de receber e transmitir informação em uma UNS ocorrerá de um modo geral, de acordo com três etapas, descritas em Caudill & Butler (1992, p.5-6). Na primeira etapa, os vários padrões de *inputs* ou estímulos de entrada que chegam a uma UNS, representados pelos símbolos matemáticos ($x_0, \dots, x_n$), são multiplicados pelos pesos ($w_0, \dots, w_n$) das conexões, também denominados de *pesos sinápticos*, e então somados, obtendo-se o valor total (I) ou *net input* das entradas. Assim, formalmente:

$$I = \sum_{i=0}^n w_i x_i \quad (2.1)$$

Na segunda etapa, o valor da soma dos estímulos (I) é convertido pela função de ativação (F), que determinará o nível de ativação ou excitação da UNS. Vários fatores da implementação, como por exemplo, o limiar a ser alcançado, os estados

anteriores, entre outros, podem influenciar na determinação da ativação ou desativação da UNS. A função de ativação mais utilizada nesta etapa é a *sigmóide*³:



$$F(I) = \frac{1}{1 + e^{-I}} \quad (2.2)$$

onde:

e é um valor constante e igual a 2,71...

Nessa função, o valor mínimo tende para 0 (zero) e o valor máximo para 1 (um). A transformação do *net input* em ativado (1) ou desativado (0) é comum a todas as UNS's.

Finalmente, na terceira etapa, estando determinado o nível de ativação da UNS, deve-se calcular o valor que essa UNS passará para as outras que a seguem, convertendo o nível de ativação em um sinal de saída. Geralmente, utiliza-se a seguinte expressão:

$$Y_I = \begin{cases} f(I), & \text{se } f(I) > \theta \\ 0, & \text{caso contrário} \end{cases} \quad (2.3)$$

Em que:

Y_I = valor do sinal de saída da unidade;

³ Na função sigmóide, o gráfico tem a forma parecida com a letra S.

θ = valor limite ou *Threshold*, fixado de acordo com o objetivo da rede (GONZALES, 1996, p. 278).

Nessas três etapas, os estímulos de entrada internos e aqueles provenientes do meio ambiente externo são processados nas UNS's, as quais constituirão os modelos de RNA's para a simulação de determinados estados mentais, e que serão melhor definidos na próxima seção.

2.3 Desenvolvimento das Redes Neurais Artificiais (RNA's)

De acordo com Kovács (1996, p.27-29), o primeiro modelo de RNA foi proposto por McCulloch e Pitts, em 1943, inspirado nas primeiras descobertas das propriedades dos neurônios e também nos resultados de Alan Turing e John von Neumann. Estes últimos, segundo Kovács (1996, p. 27), por sua vez, demonstravam que a natureza da inteligência era booleana e resultava da capacidade neural, esclarecendo cientificamente a ligação entre inteligência e atividade nervosa.

O modelo de McCulloch e Pitts, bem como outros modelos baseados nele e no Perceptron de Rosenblatt, considerados muito simples, segundo Gardner (1993), devido à pequena capacidade computacional e ao pouco conhecimento neurobiológico da época em questão, simbolizam a primeira geração das RNA's. Atualmente, as redes estão na sua segunda geração e diferem da primeira em diversos pontos, tais como arquitetura, funcionalidade e tecnologia. Apesar de terem evoluído, para Gardner (1993), os modelos de rede da segunda geração continuam tão implausíveis biologicamente quanto aqueles da primeira geração, pois não alteraram substancialmente a sua neuromorfologia. Devido a isso, Gardner sugere que as redes deveriam avançar para a terceira geração, unindo os

modelos de RNA's com a teoria neurológica do cérebro. Esta terceira geração seria similar ao modelo realista do cérebro, definido por Hanson e Olson (1990, p.8-9).

O modelo realista do cérebro, para Hanson e Olson (1990), tenta incorporar o máximo possível de detalhes celulares. Embora, por um lado, tal aproximação com o sistema real possa ser útil, por outro, pode tornar o modelo tão superficialmente entendido quanto o próprio sistema real.

Segundo Hanson e Olson (1990, p.9), caracterizando os modelos de primeira e segunda gerações estariam as RNA's, também denominadas de modelos simplificados do cérebro. As RNA's incorporam em sua estrutura apenas as propriedades essenciais dos sistemas reais. Ao contrário do que sugere Gardner (1993), os modelos da segunda geração continuam em desenvolvimento.

A arquitetura das RNA's para Lippmann (1987), é formada por UNS's, conectadas e organizadas em camadas. Associado a cada par de UNS's conectadas, existe um valor ajustável, também chamado de *peso*, que pode ser alterado durante a execução da rede para melhorar o seu desempenho. Como escreve Lippmann:

Os modelos são compostos de muitos elementos computacionais não lineares operando em paralelo e arranjados em padrões, lembrando uma rede neural biológica. Os elementos computacionais ou nós são conectados via pesos e são tipicamente adaptados durante o uso para melhorar seu desempenho (LIPPMANN, 1987, p.13, tradução nossa).

Embora existam RNA's que possuam somente uma camada, ou até mesmo um único elemento de processamento, ou UNS, a maioria das aplicações requer redes que possuam três tipos de camadas: camada de entrada ou *input*, camada intermediária ou *hidden* e camada de saída ou *output*, como mostra a figura 3.




Figura 3: Rede Neural Artificial (RNA) (Gonzales, 1996, p. 281).

Segundo Gardner (1993, p. 24), na camada de entrada, as UNS's recebem os dados de *inputs* (estímulos de entrada) de arquivos ou diretamente de sensores eletrônicos. A camada de saída envia o resultado final do processamento diretamente para o mundo externo, para um computador de processamento secundário, ou para outros dispositivos como um sistema de controle mecânico. Entre essas duas camadas pode haver de zero a n camadas intermediárias. Essas camadas fazem a maior parte do processamento, por meio de conexões ponderadas. Os *inputs* e *outputs* de cada uma das UNS's das camadas intermediárias vão para outras UNS's. Em grande parte das redes, cada UNS das camadas intermediárias recebe sinal de todas as UNS's da camada anterior a ela. Depois que uma UNS executa sua função, ela passa seu *output* para todas as UNS's da camada posterior a ela, produzindo um caminho de *output* chamado "*feedforward*" ou alimentação direta. Há ainda redes que trabalham com outro tipo de caminho de *output* chamado "*feedback*" ou realimentação, na qual os *outputs* dos neurônios da camada retornam para a camada anterior.

Desse modo, as UNS's da rede, realizam o processo de receber e transmitir estímulos por meio das suas conexões, também chamadas de *sinapses*. Tais conexões entre as UNS's podem ser de dois tipos: *excitatória* ou *inibitória*. Na figura 3, as UNS's preenchidas (escuras) representam as UNS's que possuem conexões fortes (excitadas) e as UNS's vazias (claras) representam as UNS's que possuem conexões fracas (inibidas). A conexão, ou sinapse, excitatória causa o mecanismo de soma da próxima UNS, ao passo que a conexão, ou sinapse, inibitória causa o mecanismo de subtração. Segundo Simpson (1990):

As conexões excitatórias aumentam a ativação dos elementos de processamento (PE's) e são representadas tipicamente por sinais positivos. As conexões inibitórias diminuem a ativação dos PE's e são tipicamente representados por sinais negativos (SIMPSON, 1990, p.9, tradução nossa).

Rumelhart e McClelland (1986, p.47) propuseram uma estrutura geral para os diferentes tipos de modelos de RNA's. Esta estrutura é composta por oito componentes fundamentais e comuns à maioria desses modelos:

1. um conjunto de unidades de processamento (UNS's);
2. definição do estado de ativação;
3. uma função de saída para cada UNS;
4. um esquema de conectividade entre as UNS's;
5. uma regra de propagação;
6. uma regra de ativação;
7. uma regra de aprendizado;
8. uma representação do meio ambiente no qual a RNA deve operar.

Cada um desses itens pode ser descrito da seguinte maneira:

- **o conjunto de unidades de processamento (UNS's):** deve estar organizado em uma estrutura e pode ser representado pelo esquema da figura 3 mencionada anteriormente;

- **o estado de ativação:** refere-se ao valor que uma UNS deverá apresentar quando estiver ou não ativada. Este valor deverá ser pré-estabelecido, pois o estado de ativação da rede como um todo define o que a rede está representando naquele momento. Ainda, deve haver um vetor $A(t)$ com N elementos que contenha, a cada instante do tempo t , o padrão de ativação da rede composta de N UNS's. Portanto, $A_i(t)$ é o estado de ativação da UNS i no tempo t (RUMELHART; McCLELLAND, 1986, p.48);
- **a função de saída para cada UNS:** faz o cálculo do valor que esta UNS deve passar para todas as UNS's da próxima camada, conectadas a ela. É a terceira etapa do processo de recepção e transmissão de estímulos de uma UNS, definida por Caudill & Butler (1992, p.5-6) e já citada na seção 2.2 deste capítulo;
- **o esquema de conectividade entre as UNS's:** já definido nesta seção, refere-se à forma como as UNS's de uma camada estão conectadas com as UNS's das outras camadas. Esta conectividade pode ser do tipo: *feedforward* ou *feedback*;
- **a regra de propagação e a regra de ativação:** são, respectivamente, a primeira e a segunda etapa do processamento de recepção e transmissão de estímulos de uma UNS, definida por Caudill & Betler (1992, p.5-6), e também apresentada na seção 2.2 deste capítulo;
- **a regra de aprendizado:** é utilizada na fase de treinamento da RNA, quando a saída ou resposta desta não for satisfatória. Esse conceito será detalhado ainda nesta seção;
- **a representação do meio ambiente no qual a rede deve operar:** é um fator que interfere diretamente no processo de aprendizagem de uma RNA. O ambiente é caracterizado pela presença dos estímulos ou dos padrões do meio ambiente sendo recebidos pelas UNS's da camada de *input* da rede.

Ao executarmos uma RNA pela primeira vez, ela pode errar e não apresentar o padrão correto de saída. Entretanto, segundo Caudill e Butler (1992), a

propriedade mais importante das RNA's é a habilidade de aprender por meio da correção de seus erros, por intermédio da fase de treinamento da rede. O treinamento, segundo esse autor, é feito mediante o mecanismo de modificações dos pesos das conexões das suas UNS's, de forma a influenciar a rede a aprender, ou seja, a apresentar um padrão de saída correto, conforme podemos ler em Caudill e Butler:

As redes neurais aprendem a resolver um problema; elas não são programadas para fazer isso. A aprendizagem e o treinamento são assim fundamentais para aproximadamente todas as redes neurais. A aprendizagem não é realizada através da modificação dos neurônios da rede, mas através da modificação dos pesos das interconexões da rede (CAUDILL; BUTLER, 1992, p.7, tradução nossa).

As modificações nos pesos das conexões das UNS's das RNA's são feitas por intermédio de um mecanismo, ou algoritmo de aprendizagem, que irá treinar a rede por meio de instruções, até que a mesma aprenda uma determinada tarefa. As instruções dos algoritmos de aprendizagem são elaboradas por um agente externo e fornecem parâmetros para ajustar os pesos e as funções matemáticas da rede, não possuindo, segundo Caudill e Butler (1992), valores pré-definidos. Os valores que irão alterar os parâmetros ajustáveis e as funções matemáticas da rede serão definidos por meio dos estímulos de entradas recebidos pela rede, o que gera mudanças adaptáveis no seu próprio algoritmo também.

Nesse contexto, é pertinente esclarecer que treinamento e aprendizagem são duas coisas diferentes: "o treinamento é um procedimento através do qual a rede aprende; a aprendizagem é o resultado final do procedimento."(CAUDILL; BUTLER, 1992, p.8, tradução nossa); sendo o primeiro um procedimento externo à rede e o segundo, um processo ou atividade interna a ela.

De acordo com o relacionamento da RNA com seu meio ambiente, seu treinamento pode ser de três tipos diferentes, como cita Caudill e Butler (1992, p.8):

⇒ **treinamento supervisionado**: esta técnica utiliza um agente externo que apresenta à rede um padrão de estímulos de entrada, juntamente com um padrão de *output* desejado. A rede precisa encontrar os pesos corretos das conexões que lhe permitam associar o padrão de estímulos de entrada ao padrão de saída correto, ou desejado;

⇒ **treinamento por reforço**: esta técnica de aprendizagem utiliza um agente externo que apresenta à rede o padrão de estímulos de entrada como no treinamento supervisionado, mas não apresenta o padrão de saída desejado. O padrão de saída desejado deverá ser encontrado pela rede. Para associar o padrão de estímulos de entrada a um padrão de saída correto, a rede terá de ser orientada pelo agente externo, que fornecerá sinais de reforço, orientando o processo de ajuste dos pesos;

⇒ **treinamento não supervisionado (auto-organização)**: esta técnica de treinamento é muito importante dentro do presente trabalho. Neste procedimento, somente um padrão de estímulos de entrada é apresentado à rede. Sem nenhuma ajuda ou orientação do supervisor, a rede terá que, sozinha, encontrar o padrão de resposta correto. Um dos mecanismos de ajustes de pesos utilizados nesse treinamento é conhecido como *princípio de aprendizagem por competição* (Kohonen, 1987), do qual trataremos mais detalhadamente no Capítulo 5.

Até agora, exploramos as RNA's de uma forma geral. Porém, existem vários modelos de RNA's, que, devido à sua aplicação, podem diferir uns dos outros quanto à sua estrutura, mecanismo de treinamento, etc. São esses diferentes modelos que passaremos a investigar na próxima seção deste mesmo capítulo.



2.4 Alguns modelos de RNA's

A maioria dos modelos de RNA's é, ainda hoje, implementada em computadores seriais, também conhecidos como computadores convencionais ou de von Neumann, os quais simulam logicamente o processamento em paralelo. Mas, fisicamente, o processamento das RNA's nos computadores convencionais é seqüencial, diminuindo sua velocidade de execução, o que limita o tamanho das redes as quais elas têm suporte para executar. Para Widrow e Lehr (1990, p.1417), os computadores convencionais conseguem desenvolver uma rede neural pequena, com aproximadamente 150 UNS's. Contudo, para esse autor, mesmo realizando RNA's pequenas em computadores convencionais, muitos problemas têm sido resolvidos. Concomitantemente, o desenvolvimento de máquinas neurais paralelas tem sido bem sucedido e deverá estar mais disponível em um futuro próximo, o que permitirá investigar problemas mais difíceis que as simulações em computadores convencionais não consegue.

Mesmo quando implementamos os modelos de RNA's em um computador convencional ou em uma máquina neural paralela, eles continuam sendo uma coleção de UNS's que trabalham juntas para resolver problemas, relativamente embasadas na estrutura neural do cérebro, prometendo um entendimento maior do mecanismo do pensamento natural. Mas, os vários modelos diferem uns dos outros quanto ao seu treinamento, organização, classificação, etc. A seguir, abordaremos alguns modelos de redes neurais artificiais, a saber: o Perceptron pois foi o primeiro modelo de RNA desenvolvido, o Backpropagation por ser um dos modelos de RNA's muito utilizado, e, em especial, o modelo de Kohonen, que é o modelo de maior interesse para o estudo e compreensão deste trabalho.



2.4.1 Perceptron de Camada Simples e de Várias Camadas

Conforme Lippmann (1987, p.13), o modelo de rede neural artificial, desenvolvido por Frank Rosenblatt em 1962, recebeu o nome de Perceptron de Camada Simples, uma vez que possui um único neurônio artificial (UNS) o qual recebe várias entradas ($X_0, \dots, X_{n-1}$) e uma única saída (Y), como mostra a figura 4.




Figura 4: Perceptron de Camada simples (LIPPMANN, 1987, p.13).

onde:

$X_0, \dots, X_{n-1}$ são os valores que representam o padrão de entrada;

$W_0, \dots, W_{n-1}$ são os pesos das conexões entre a entrada e o perceptron;

θ é o valor do limiar (*threshold*) definido inicialmente;

Σ é a soma de todos os estímulos recebidos e propagados por meio da função:

$$I = \Sigma w_i x_i - \theta \quad (2.4)$$

$f(I)$ é uma função não-linear de saída da rede, que pode ser bipolar $\{-1, +1\}$, discreta e binária $\{0, +1\}$, ternária $\{-1, 0, +1\}$, contínua, com valores reais no intervalo $[0, 1]$, ou outra qualquer;

Y é a saída da rede. A função não-linear de saída bipolar pode ser representada pela fórmula:

$$f(I) = \begin{cases} +1 & \text{se } I \geq 0 \\ -1 & \text{caso contrário} \end{cases} \quad (2.5)$$

O modelo *perceptron* gerou muito interesse quando foi desenvolvido, por ter habilidade em reconhecer padrões simples e trabalhar com entradas binárias e valores contínuos, conforme apresenta Lippmann (1987, p.13). A rede simples é capaz de classificar um vetor de entrada em uma de duas classes (A e B). A UNS recebe a entrada e calcula a soma ponderada da entrada pelos pesos; subtrai um valor limiar e passa o resultado por meio de uma função de transferência não-linear bipolar, para que a saída seja +1 ou -1. A regra de decisão é: responder classe A, se o resultado for +1; e classe B se o resultado for -1.

O funcionamento dessa rede pode ser mais bem entendido se for traçado um gráfico bidimensional representando as regiões de decisão para suas classes. Essas regiões podem ser vistas na figura 5. Para a geração dessa figura foram usadas apenas duas entradas, X_0 e X_1 , conectadas ao neurônio.




Figura 5: Regiões de Decisão de um Perceptron (LIPPMANN, 1987,p. 13).

Desse modo, a figura 5 mostra a representação da linha limite (a linha pontilhada), que separa o espaço do problema em dois semiplanos. No semiplano superior, o perceptron classifica corretamente a classe A, ao passo que no inferior classifica, corretamente, a classe B. Cabe ressaltar que esta figura é um exemplo simplificado, que separa apenas dois valores de entrada, e para tanto só é necessária uma reta. Os pesos e o *threshold* no Perceptron podem ser definidos ou corrigidos pelo uso de um algoritmo de convergência, que, segundo Lippmann (1987, p.13), é descrito em cinco passos:

Passo 1: atribuir um valor aleatório próximo de zero ao vetor peso $w_i(t)$, com $(0 \leq i \leq n-1)$, e ao limiar θ ;

Passo 2: apresentar um novo padrão de entrada $x_0, x_1, \dots, x_{n-1}$, juntamente com a saída desejada $d(t)$;

Passo 3: calcular a saída da rede:

$$Y(t) = f \left[\sum_{i=0}^{n-1} w_i(t) x_i(t) - \theta \right] \quad (2.6)$$

Passo 4: adaptar os pesos, usando a seguinte equação:

$$w_i(t+1) = w_i(t) + \eta [d(t) - Y(t)] x_i(t), \quad 0 \leq i \leq n-1 \quad (2.7)$$

em que:

$$d(t) = \begin{cases} +1 \rightarrow \text{Classe A} \\ -1 \rightarrow \text{Classe B;} \end{cases}$$

Quanto a η (a taxa de aprendizado), esta é $0 < \eta < 1$. Quando a rede classifica corretamente uma entrada, os pesos não se alteram, pois a subtração $d(t) - Y(t)$ é anulada (Lippmann, 1987);

Passo 5: repita novamente o algoritmo retornando a partir do passo 2, até o final das amostras e a convergência do processo.

As redes *Perceptron* têm muitas limitações, das quais enumeramos: primeiro, os valores de saída dessa rede podem assumir somente dois valores (verdadeiro ou falso); segundo, *Perceptrons* podem apenas classificar grupos de vetores linearmente separados. Se os vetores não são linearmente separados, o *Perceptron* nunca chegará a um ponto em que todos os vetores são classificados adequadamente. O exemplo mais conhecido da inabilidade desse modelo para resolver problemas de vetores que linearmente não são separáveis, segundo Lippmann (1987), é o problema do OU-EXCLUSIVO ou XOR, uma vez que não consegue separar ambas as classes (A e B), cada qual em uma única região.

O conectivo, ou função lógica, OU-EXCLUSIVO assume o valor “verdadeiro” quando apenas uma de suas entradas (A e B) é verdadeira. Pode ser representado pela expressão: $(A \text{ OU } B) \text{ E NÃO } (A \text{ E } B)$, ou seja, pode ter a ocorrência de qualquer uma das entradas, mas não a ocorrência das duas simultaneamente. Já o conectivo, ou função lógica, OU assume “verdadeiro” se pelo menos uma das duas entradas for verdadeira. Para melhor visualizar o problema do OU-EXCLUSIVO, a figura 6 mostra uma representação geométrica do domínio das entradas (X_1 e X_2) das funções E, OU e XOR. Para auxiliar na compreensão da figura 6, criamos uma tabela, de nossa autoria, indicando a correspondência entre os gráficos e estas funções.




Figura 6: Funções lógicas de duas variáveis representadas no plano binário (KOVÁCS, 1996, p. 33).

X ₁	X ₂	"E"	"OU"	"XOR"
0	0	0	0	0
0	1	0	1	1
1	0	0	1	1
1	1	1	1	0

Tabela 1: Tabela de correspondência., onde zero (0) e um (1) representam respectivamente falso e verdadeiro.

Na figura 6, o ponto escuro significa que ali a saída Y do Perceptron deve ser 1, ao passo que no ponto claro a saída é nula (0). O problema fica claro quando se verifica que no gráfico XOR, se o 1 representar a classe A, e o 0 (zero) representar a classe B, então as duas letras “A” não podem ser separadas das letras “B” por apenas uma reta, como ocorre no conectivo E e no OU.

Já o Perceptron de Várias Camadas, também chamado de redes MLP – *Multi Layer Perceptron*, não é tão limitado quanto o Perceptron de Camada Simples. Para Lippmann (1987, p.15), as redes MLP são redes *feedforward*, que podem ter uma ou mais camadas de UNS’s entre as camadas de entrada e de saída. Um Perceptron de duas camadas pode ser visto na figura 7.




Figura 7: Perceptron MLP de duas camadas (LIPPMANN, 1987, p. 14).

Com apenas duas camadas, segundo Lippmann (1987, p.16), esse modelo consegue solucionar o problema do XOR, o que possibilita uma separação mais precisa das classes com regiões entrelaçadas de alguns tipos, como mostra a figura 7. A quantidade de UNS's da primeira camada definirá quantos lados terá a figura delimitadora do espaço-problema. Na primeira camada, cada uma das UNS's criará um semiplano que sofrerá uma intersecção feita pelas UNS's da segunda camada. Essa intersecção corresponde à operação lógica E.

Já uma rede de perceptron MLP, com três camadas como apresentada na figura 8, poderá, segundo Lippmann (1987, p.16), separar melhor as classes com regiões entrelaçadas, podendo essas regiões serem de qualquer tipo.




Figura 8: Perceptron MLP de três camadas (LIPPMANN, 1987, p. 14).

A função de saída do modelo perceptron, de acordo com a concepção de Lippmann (1987, p.16), independentemente de ser proporcionada por uma função não-linear descontínua como por uma função contínua do tipo sigmóide, incorrerá praticamente

no mesmo resultado. No entanto, as redes de perceptron de várias camadas, com funções de saída contínuas do tipo sigmóide, podem ser treinadas por um dos algoritmos mais utilizados na maioria das redes: o algoritmo de retropropagação (*backpropagation*). Esse algoritmo se difere do apresentado anteriormente por ser capaz de lidar com pesos em conexões internodais; ele é iterativo e reduz o erro entre a saída real e a saída desejada de uma rede de perceptrons de várias camadas com alimentação direta (*feedforward*) e pode ser descrito em cinco etapas como as que seguem (LIPPMANN, 1987, p. 17):

Primeira etapa:

inicializar os pesos ($w_0, w_1, \dots, w_{n-1}$) com valores aleatórios pequenos e próximos de zero;

Segunda etapa:

apresentar um vetor ($X_0, X_1, \dots, X_{n-1}$) do padrão e definir as saídas desejadas ($d_0, d_1, \dots, d_{m-1}$) para cada uma das UNS's de saída;

Terceira etapa:

propagar, calculando a saída de cada camada e usando-a como entrada para a próxima, até calcular a saída da rede ($Y_0, Y_1, \dots, Y_{n-1}$). Utilizar para cada UNS's a função:

$$F(I_k) = \frac{1}{1 + e^{-(I_k - \theta)}} \quad (2.8)$$

em que:

I_k é o valor propagado à UNS k e θ é o limiar;

Quarta etapa:

retropropagação, ajustando-se os pesos das conexões desde a última camada e calculando-se os mesmos até chegar a primeira camada, com a equação:

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta_j x_i \quad (2.9)$$

em que:

$w_{ij}(t)$ é o peso da conexão entre a UNS i ou a entrada i e a UNS atual j , t é o tempo atual, $t+1$ representa o próximo instante de tempo;

η é a taxa de aprendizagem ou termo de ganho;

$\dot{x}_i$ é originário de x_i , podendo ser ou a saída da UNS i , ou a entrada;

δ_j é o erro apresentado pela saída da UNS j , e é calculado por:

(I) Caso a UNS j seja uma UNS da camada de saída:

$$\delta_j = f' (d_j - Y_j) \quad (2.10)$$

em que:

f' é a derivada primeira da função de saída (neste caso a sigmóide dada acima);

Y_j é a saída atual da UNS j , e d_j é a saída desejada;

(II) Caso a UNS j seja uma UNS de alguma camada intermediária:

$$\delta_j = f' \sum_{k=0}^{N-1} \delta_k w_{jk} \quad (2.11)$$

Quinta etapa:

repetir, retornando-se desde a segunda etapa em diante, até que o erro entre a saída real e a saída desejada do perceptron seja um valor baixo aceitável, ou zero.

O modelo perceptron de várias camadas, para Lippmann (1987, p. 15), não foi muito utilizado no passado, mesmo superando muitas limitações do perceptron de camada simples, haja vista que naquela época não existiam muitos algoritmos efetivos de treinamento disponíveis.

2.4.2 Backpropagation

O algoritmo *Backpropagation* permite o aprendizado supervisionado nas RNA's com qualquer número de camadas, servindo inclusive para trabalhar com o caso do *XOR*. O esquema de alimentação é do tipo *feed-forward*, mas seu aprendizado é por retropropagação (*feedback*) do erro. Wasserman (1989, p. 43) afirma que é difícil dizer quem foi o real criador deste modelo de rede, pois vários trabalhos foram feitos em lugares diferentes e na mesma época. No entanto, foi Rumelhart quem mais difundiu este método. A figura 9 exemplifica uma rede *Backpropagation* com múltiplas camadas.




Figura 9: Modelo *Backpropagation* (WASSERMAN, 1989, p. 46).

De acordo com Wasserman (1989, p.47), o algoritmo *Backpropagation* tem como finalidade ajustar os pesos da rede até o conjunto de *inputs* aplicado à rede apresentar o conjunto de *outputs* desejado. Os conjuntos de *inputs* e *outputs* desejados são aplicados à rede via vetores e são chamados de *pares de treinamento* ou *conjunto de treinamento*. Antes do início do treinamento, devem-se atribuir valores baixos e aleatórios

aos pesos. Então, inicia-se o treinamento, que, conforme a descrição de Wasserman (1989, p.47-50), segue as seguintes etapas:

- 1- inicializar os pesos (w_i) com valores aleatórios pequenos e próximos de zero;
- 2- selecionar o par de *input* e *output* do conjunto de treinamento e inseri-lo na camada de *input* da rede, por meio de um vetor;
- 3- calcular o *output* da rede, o qual é desenvolvido camada por camada, começando na camada de *input* da rede, passando por todas as camadas intermediárias, até chegar na camada de *output*. Olhando a figura 9, observamos que primeiro os *outputs* das UNS's da camada de *input* são calculados e então usados como *inputs* na camada intermediária, e assim sucessivamente até a camada de *output*. Na camada de *output*, as UNS's são calculadas e constituem o vetor de *output* da rede, seguindo desde a camada de *input*, a expressão descrita:

$$Y = f(x_i w_i) \quad (2.12)$$

onde x_i é o *input* e w_i o peso da UNS i .

- 4- calcular o erro entre o *output* atual da rede e o *output* desejado, através da equação:

$$\delta = (d - Y) \text{ (caso seja uma UNS da camada de saída) ou} \quad (2.13)$$

$$\delta = (\sum \delta w) \text{ (caso seja uma UNS da camada intermediária)} \quad (2.14)$$

onde:

δ = erro entre o *output* atual e o desejado;

Y = *output* atual;

d = *output* desejado.

- 5- ajustar os pesos da rede de forma a minimizar o erro, através das equações:

$$\Delta w_{ij} = \eta \delta_j Y_i \quad (2.15)$$

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij} \quad (2.16)$$

onde,

Δw_{ij} é o valor da variação que deverá ser aplicado no peso (w_{ij}) da conexão da UNS i da camada intermediária com a UNS j da camada de *output*;

η é a taxa de aprendizagem, que são valores entre 0.01 e 1.0 (WASSERMAN, 1989, p. 50);

Y_i é o *output* da UNS i na camada intermediária;

$w_{ij}(n)$ é o valor do peso da conexão entre a UNS i da camada intermediária com a UNS j da camada de *output* no passo n (antes do ajustamento);

$w_{ij}(n+1)$ é o valor do peso no passo $n+1$ (após o ajustamento);

- 6- repetir as etapas de 2 a 5 para cada vetor de *input* do conjunto de treinamento que chega à rede, até que o erro do conjunto inteiro seja de um valor pequeno, conseqüentemente aceitável, ou igual a zero.

Portanto, de acordo com Wasserman (1989, p.47), as etapas de número 2 e 3 do treinamento *Backpropagation* definem o caminho *feedforward* de todas as camadas da rede. Supondo que o treinamento esteja sendo aplicado em uma rede com duas camadas, primeiro calculam-se os *outputs* das UNS's da camada de *input*, que serão os *inputs* da camada seguinte, a qual será, então, uma camada de *output*. Logo, os *outputs* das UNS's dessa última camada são calculados e constituem o vetor de *output* da rede. Na etapa de número 4 do treinamento, cada *output* da rede é subtraído dos componentes correspondentes do *output* desejado, obtendo-se um erro quando os mesmos forem diferentes. Esse erro é usado na etapa de número 5 do treinamento, a fim de promover o

ajuste dos pesos da rede. Repete-se as etapas supracitadas um número de vezes suficiente para que o erro entre o *output* atual da rede e o *output* desejado diminua gradativamente até ser um valor aceitável ou zero. A rede é considerada, dessa forma, treinada, e seus pesos não são mais alterados.

Observando as etapas propostas por Wasserman (1989), podemos constatar que, nas etapas de número 2 e 3, a propagação do sinal de *input* e *output* da rede segue caminho *feedforward* (alimentação direta, sempre para frente) e, por outro lado, nas etapas de número 4 e 5, o sinal do erro calculado para ajustar os pesos é propagado na rede para trás (retropropagação).

Mesmo com o aparente sucesso do modelo *Backpropagation*, Widrow (1990, p.1437) chama a atenção para o fato de que existem alguns aspectos que fazem com que ele não possa ser utilizado em todo o tipo de aplicações. Segundo esse autor, o maior problema é o longo processo de treinamento, o que requer uma máquina com rápida capacidade de processamento. O modelo pode também resultar numa taxa de sucesso da aprendizagem ou numa taxa de generalização ruins, pois não há garantia de que os erros mínimos globais sejam encontrados. Em outras palavras, algumas vezes, dependendo dos pesos iniciais, da taxa de aprendizagem e dos dados de entrada, a rede neural artificial pode até não aprender.

2.4.3 Rede Neural de Kohonen

Como já esclarecemos anteriormente, o objetivo central deste trabalho é investigar se uma RNA do tipo Kohonen adquire hábitos gerais, de acordo com a definição

de hábito proposta por Peirce. A presente seção tratará, especificamente, de nos direcionar para a resposta a tal questionamento.

Cabe ressaltar agora, que os modelos de RNA's apresentados nas seções anteriores a esta possuem a técnica de aprendizagem supervisionada e alimentação (*feedforward*) ou realimentação (*feedback*) para encontrar a resposta similar à resposta desejada e pré-definida.

Neste momento, exploraremos a técnica de aprendizagem não-supervisionada ou por auto-organização e alimentação (*feedforward*) e retroalimentação lateral, por intermédio do modelo da rede de Kohonen, que também recebe o nome de *Mapas Auto-Organizáveis de Kohonen*, uma vez que tal como o cérebro, essa rede forma “representações neurais que são imagens de experiências sensoriais, projetadas sobre várias áreas corticais” (KOHONEN, 1997, p. 79).

Segundo Kohonen (1987, p.119-120), o cérebro usa mapas espaciais para modelar dados complexos em suas estruturas internas. Tais mapas são unidades de processamento do cérebro que, graças às alterações em seus parâmetros, se organizam significativamente, produzindo representações reduzidas do mundo observável que pode ser formado em várias áreas corticais do mesmo. Como escreve o autor:

Uma propriedade do cérebro que tem sido ignorada na “aprendizagem das máquinas” é a ordem significativa das suas unidades de processamento. Ordenar não significa mover as unidades para um novo lugar. As unidades podem ser estruturalmente idênticas; a atuação especializada é determinada por seus parâmetros internos, os quais [...] produzem uma organização significativa. [...] Isso significa que cada organização espacial necessariamente representa uma informação dentro dos modelos. Os vários mapas formados pela auto-organização são capazes de descrever as relações topológicas do sinal de *input*, usando uma representação com uma ou duas dimensões. Tais mapas, dimensionalmente reduzidos, parecem ser operações fundamentais também na formação de abstrações (KOHONEN, 1987, p. 119, tradução nossa).

Inspirado nos estudos dos mapas espaciais produzidos em várias áreas corticais do cérebro, Kohonen (1997) desenvolveu uma RNA capaz de realizar a

compressão dos dados em vetores, os quais serão armazenados e representados de uma maneira significativa na rede, por meio de uma técnica conhecida como *vetor quântico*. A compressão dos dados em vetores permite representar os dados multidimensionais em um espaço reduzido.

O modelo de Kohonen classifica e atua por si próprio, sem a intervenção forte de um agente externo para orientá-lo ou apresentar a resposta desejada. Desse modo, segundo Kohonen (1997, p. 81), estes modelos se auto-organizam, visto que a propriedade principal da formação dos mapas ou organizações das áreas específicas do cérebro, decorre das características dos padrões sensórios presentes no meio ambiente. Apoiando-se neste conceito, Kohonen (1997, p. 82), produziu um algoritmo de aprendizagem para simular o mapeamento auto-organizável em sistemas artificiais, inspirados em propriedades biológicas.

Outro princípio do funcionamento do cérebro no qual Kohonen (1997) se inspirou para desenvolver sua RNA, foi o mecanismo da inibição lateral, que nos circuitos neurais excitam as unidades vizinhas da unidade com nível de ativação mais elevado ou inibem a ativação das unidades mais remotas a essa. De acordo com Kohonen (1997, p. 122), no cérebro dos mamíferos o comportamento das inibições laterais variam de acordo com a distância ao longo dos circuitos neurais. Esse *princípio de vizinhança*, foi incorporado por Kohonen em sua rede, permitindo o desenvolvimento de um algoritmo de aprendizagem competitivo, conhecido como auto-organizado.

Uma rede típica de Kohonen é mostrada na figura 10, com o padrão de *input* codificado pelo vetor $x(t) = (x_0, \dots, x_{n-1})$ sendo passado para a camada de Kohonen, a qual possui muitas conexões laterais ligando cada uma das UNS's dessa camada com as outras UNS's vizinhas. Essas conexões laterais, freqüentemente encontradas na rede neural

biológica, são a característica mais interessante do modelo de Kohonen. Como cita este estudioso:

A maioria das redes neurais do cérebro, especialmente aquelas no neocórtex cerebral, é constituída essencialmente por camadas bidimensionais de unidades de processamento (células ou módulos celulares), nas quais as unidades são interconectadas densamente via retroalimentação lateral (KOHONEN, 1987, p.122, tradução nossa).




Figura 10: Rede de duas dimensões com UNS's de output usadas para formar mapas característicos. Cada input está conectado com cada nó de output por meio do peso variável da conexão (Lippmann, 1987, p.18).

A inibição lateral, ou retroalimentação lateral, cria uma competição entre as UNS's da camada de Kohonen, com o objetivo de determinar qual UNS dessa camada é a vencedora, sem a intervenção externa de um supervisor. Para isso, é calculada a menor distância entre o vetor de *input* e os pesos das conexões de cada UNS, como veremos mais detalhadamente na seção 5.2. Considera-se, assim, a UNS com menor distância como a vencedora e a representante dessa classe de padrões. Essa UNS terá suas conexões fortalecidas, juntamente com as suas vizinhas. Então, as conexões tendem a ser mais fortes entre UNS's vizinhas e mais fracas entre UNS's mais distantes fisicamente. A relação entre a força das conexões interna da camada e a distância entre as UNS's é expressada freqüentemente pela função do Chapéu Mexicano, ilustrada na figura 11.




Figura 11: A função do Chapéu Mexicano descreve a relação entre a distância do neurônio vencedor e a força da conexão na camada. Vizinhos próximos têm efeito excitatório forte; vizinhos remotos têm efeito inibitório moderado; e vizinhos muito remotos têm um efeito excitatório insignificante (KOHONEN, 1987, p. 123).

Conforme podemos visualizar na figura 11, x representa a distância entre a UNS vencedora e as demais UNS's e $f(x)$ a função que expressa a força da conexão entre a UNS vencedora e as demais UNS's. O ponto zero representa a UNS vencedora, uma vez que a distância da UNS vencedora em relação a ela mesma é zero, em qualquer métrica. Quanto mais próxima está uma UNS da UNS vencedora, isto é, quanto mais próximo de zero está o valor de x (distância da UNS em relação à UNS vencedora), maior (e positivo) é o valor de $f(x)$, ou seja, maior é o valor da força de conexão entre a UNS em questão e a UNS vencedora. A medida que se distancia uma UNS em relação à UNS vencedora, diminui a sua força de conexão ($f(x)$), tendendo a zero. Após uma certa distância, a força de conexão entre a UNS vencedora e uma UNS da rede, torna-se fraca e negativa.

A quantidade de vizinhas que serão afetadas varia com o tempo, começando bem abrangente e diminuindo mais tarde. É a vizinhança, nesse procedimento de ajustes de pesos, que dá ao mapa gerado a característica das UNS's topologicamente próximas terem pesos semelhantes, respondendo conseqüentemente a estímulos semelhantes. Segundo Kohonen:

A vizinhança topológica [...] pode ser definida também por vários caminhos. Numerosas simulações têm mostrado que melhores resultados na auto-organização são obtidos se a vizinhança for selecionada fartamente e então reduzida com o tempo (KOHONEN, 1987, p. 132, tradução nossa).

As regras gerais para os vários processos básicos auto-organizáveis são, para Kohonen (1987, p. 133), as seguintes: (1) primeiro deve-se localizar a UNS vencedora e (2) depois deve-se aumentar a ligação dessa UNS com suas vizinhas. O algoritmo proposto por Kohonen para este fim, será abordado no capítulo 5, na seção 5.2.

O modelo de Kohonen pode ser usado nas diversas aplicações em que comumente se utilizam outros modelos de redes neurais, como reconhecimento de padrões, robótica, processamento de sinais, etc. Porém, ele se torna eficiente naquelas aplicações em que os padrões possuam alguma relação entre si, podendo desta forma ser classificados. Essa rede será mais detalhada no quinto capítulo da presente dissertação.

Com o intuito de compreendermos a técnica de aprendizagem não-supervisionada ou por auto-organização da rede de Kohonen, passaremos para o terceiro capítulo, no qual investigaremos o conceito de auto-organização na visão de dois autores: Ashby (1962) e Debrun (1996).



CAPÍTULO 3 – SISTEMAS AUTO-ORGANIZADOS

3.1 Apresentação

Por havermos escolhido a rede de Kohonen para investigarmos a aquisição do hábito geral peirciano, faz-se necessário apresentarmos o que é auto-organização (A-O), visto que essa rede trabalha com a técnica de aprendizagem auto-organizada, conforme mencionado anteriormente. Neste capítulo abordaremos, então, os conceitos de A-O, propostos por Ashby (1962) e Debrun (1996).

Começaremos nosso estudo da A-O, apresentando os conceitos de organização e máquinas em geral, nas seções 3.2 e 3.3, respectivamente. Segundo Ashby (1962), tais conceitos são a base para a compreensão da A-O. Passaremos, então, a abordar os conceitos de sistemas auto-organizados e suas modalidades na seção 3.4.

3.2 Organização

Nesta seção abordaremos os conceitos de organização na visão de Ashby. Em seu artigo de 1962, intitulado *Principles of Self-Organizing System*, Ashby estabelece os conceitos básicos, os limites e as contradições do termo A-O, quando aplicado aos sistemas naturais e artificiais. Iniciando tal artigo, Ashby (1962), aborda o conceito de organização, enfatizando que, subjacente à noção de organização está o conceito de condicionalidade:

O núcleo da concepção é, na minha opinião, a “condicionalidade”. Como a relação entre 2 entidades A e B condicionalmente tornam-se o valor ou estado C, então o componente necessário à “organização” está presente (ASHBY, 1962, p. 255-256, tradução nossa).

Em suma, a condicionalidade, para Ashby, refere-se a uma dada relação entre elementos, conectando-os, ligando-os, direcionando-os. Para explicar melhor o conceito de condicionalidade, Ashby (1962, p.256) define qual é o conceito contrário a ela. O contrário de condicionalidade é a desconexão entre esses elementos, o aumento de liberdade entre eles, enfim, a separabilidade, isto é, a redutibilidade desses elementos a si próprios. Como escreve Ashby:

Nós podemos olhar por outro ângulo perguntando “o que é seu contrário?”. O contrário de “condicional” é “não condicional”, assim o contrário de “organização” deve ser então, como a teoria da matemática mostra claramente, a concepção de “redutibilidade” (também chamada de separabilidade) (ASHBY, 1962, p. 256, tradução nossa).

Para nos ajudar a entender o conceito de condicionalidade, Ashby (1962) utiliza-se também de um *espaço de possibilidades de condicionalidade entre elementos*, o qual chamou de *product space*. Este recurso permite representar uma avaliação das condições do mundo real, segundo o ponto de vista de um observador. Com a representação feita através do *product space*, o observador ao constatar se existe realmente vínculos ou comunicação entre os elementos observados, está verificando, na verdade, se existe organização ou condicionalidade entre tais elementos, visto que, para Ashby (1962), a presença de vínculos ou comunicação equivale a dizer que os elementos estão organizados. No exemplo dado por Ashby (1962, p.257), A e B são dois elementos de uma organização. Em um tempo t_1 , para um estado a_1 do elemento A, existe um conjunto de possíveis estados do elemento B, ($b_1, b_2, b_3, \dots, b_n$). Se no momento t_2 , houver uma probabilidade de ocorrência do estado de A para todos os possíveis estados de B, então, não está havendo, do ponto de vista de Ashby, nenhuma condicionalidade, uma vez que não há restrição de A no conjunto de estados em que B possa ser encontrado. Por outro lado, se no momento t_2 houvesse a possibilidade de ocorrência do estado A apenas para b_2 ou b_3 , haveria condicionalidade, pois o elemento A restringiu as possibilidades de

ocorrências do elemento B. A figura 12, exemplifica a idéia de condicionalidade de Ashby (1962).




Figura 12: Exemplo da existência de condicionalidade para Ashby (D'OTTAVIANO; GONZALES, 2000, p. 85).

Além da condicionalidade, para Ashby (1962, p.258), há outro componente necessário ao conceito de organização: a suposição de que estamos tratando a organização como um todo composto por partes. E, para que um todo seja considerado organizado, para o autor, deve haver restrições mútuas entre seus elementos. Olhando a figura 12, podemos considerar o *product space* Y, como um todo e seus elementos A e B como suas partes. Já o *product space* X não pode ser considerado um todo, na concepção de Ashby (1962), pois suas partes não se condicionam ou não se restringem de alguma forma. De fato, a noção de organização para Ashby está baseada na idéia de restrição e vínculo, nas possibilidades de interações de seus elementos ou partes.

Até aqui, o conceito de organização tratado por Ashby foi apresentado em termos de condicionalidade entre as partes e regularidade em seu comportamento, sem qualquer referência à sua utilidade, como por exemplo, se a organização é *boa*, segundo certos aspectos, ou *ruim*, segundo outros.

Uma organização será considerada boa, na visão de Ashby (1962, p. 263), se promover a estabilidade (sobrevivência ou durabilidade) do sistema; e ruim se não

conseguir tal intento. Assim, não parece haver para este autor uma organização boa em um sentido absoluto, isto é, válido em todos os contextos: uma organização que é considerada boa num contexto, sendo capaz de manter adequadamente os parâmetros fundamentais para a sua sobrevivência diante de perturbações ambientais, pode ser considerada ruim se transferida para outro contexto ou ambiente.

Quando trabalhamos com o conceito de organização temos que aceitar, segundo Ashby, que “[...] (1) a maioria das organizações são ruins; (2) a boa organização tem que ser procurada; e (3) o termo *boa* deve ser claramente definido, se necessário, em cada caso” (ASHBY, 1962, p. 262, tradução nossa). Desta maneira, uma organização somente pode ser considerada boa para uma determinada situação particular.

Assim, para Ashby (1962), quando uma condicionalidade se estabelece, fazendo a comunicação entre elementos distintos, pode-se dizer que os elementos tornaram-se organizados, isto é, que o comportamento de um elemento afeta o comportamento de outro elemento. Tal organização é dependente do observador, emergindo da relação entre o observador e o mundo real observável.

Na próxima seção, abordaremos a organização das máquinas em geral, tal como proposta por Ashby (1962).

3.3 Máquinas

Sempre que ouvimos a palavra máquina, logo imaginamos algo similar ao nosso computador pessoal. Um aparelho dotado de dispositivos eletrônicos que efetuam cálculos, avaliações e numerosas operações. Mas, Ashby (1962) amplia muito a nossa visão, ao definir o que são máquinas.




Na concepção de Ashby (1962, p. 261), máquinas, em geral, podem ser entendidas como qualquer função que apresente um procedimento mecânico, cujos estados internos e de suas vizinhanças, definam o estado futuro para o qual irá. Para chegar a essa concepção geral de máquina, Ashby (1962) deixa de lado tanto a materialidade, pois para ele a máquina não precisa ser feita de material real, quanto a energia, já que o importante é a regularidade do comportamento e não o ganho ou perda de energia. Como escreve Ashby:

Antes de a essência poder ser vista, tivemos de compreender que dois fatores deveriam ser excluídos por serem irrelevantes. O primeiro é a “materialidade” – a idéia de que uma máquina deve ser feita de material real [...] Também é excluída, por ser irrelevante, qualquer referência a energia; algumas máquinas de calcular mostram que o que importa é a regularidade do comportamento, se se ganha, perde ou cria energia é simplesmente irrelevante (ASHBY, 1962, p. 260-261, tradução nossa).

Com essa definição geral de máquinas apresentada por Ashby (1962), não podemos ver somente aquele computador pessoal como uma máquina, até nós mesmos podemos ser considerados máquinas. Tal concepção abstrata de máquina complementa o conceito de organização da seção anterior, decorrendo naturalmente dela. Do mesmo modo que a essência do conceito de organização foi definido por Ashby por meio da idéia de condicionalidade, ou comunicação entre partes, também o conceito geral de máquinas irá firmar, como sua essência, a idéia de função.

Ashby (1962, p. 261) define máquinas como um autômato finito, isto é, como um conjunto de estados internos ($S1$), um conjunto de *inputs* (i) e uma função (f), que fornecerá um resultado $S2$ para a interação de $S1 \times i$. Na figura 13, de nossa autoria, podemos ver dois exemplos de máquinas, segundo essa definição.

Máquina 1:



Máquina 2:




Figura 13: Exemplos de máquinas em geral na concepção de Ashby (1962).

em que:

$S1$ = conjunto de estados internos;

$S2$ = conjunto de estados futuros;

f = função, isto é, regra que faz a comunicação, a condicionalidade, entre o domínio (estado interno ($S1$) $\times$ *input* (i)) e o contra-domínio (estado futuro ($S2$));

i = conjunto de *inputs*.

$S1 \times i$ = produto cartesiano de $S1$ com i , gerando pares ordenados onde o primeiro elemento do par pertence a $S1$ e o segundo elemento pertence a i , ou seja, $S1 = \{2, 1\}$ e $i = \{1, 0\}$.

Dessa forma, como mostra a figura 13, a função além de fornecer uma formalização para as máquinas em geral, determina a organização efetiva desta máquina, na medida em que determina a condicionalidade mútua entre os elementos que a constituem. Sendo assim, para identificarmos uma máquina, basta especificarmos seus estados e suas condições (funções). Contudo, segundo Ashby, a organização e a função não passam de duas formas de olhar a mesma coisa: “a organização é notada pelo observador

do sistema real e a função é registrada por uma pessoa que representa o comportamento na matemática ou em outro simbolismo”(ASHBY, 1962, p. 262, tradução nossa).

Essa correspondência entre o conceito de máquina e o de organização é bastante interessante, na medida em que permite discutir até que ponto uma máquina pode modificar o ajuste de condicionalidade entre os seus elementos por si mesma, ou seja, pode se auto-organizar. A partir dos conceitos de organização e máquina apresentados até aqui, ficará mais fácil entendermos o que é A-O, o que será abordada na próxima seção.

3.4 Sistemas auto-organizados

Antes de apresentarmos a definição de sistemas auto-organizados, analisaremos, de forma breve, o conceito de “auto” do termo auto-organização, visto que o de organização já foi abordado na seção 3.2. Segundo Debrun (1996a, p. 6-9), existem três significados para o “auto” do termo A-O, a saber: o de **autonomia**, que permite ao sistema extrapolar suas condições de partida e prosseguir de acordo com o seu próprio processamento; o de **independência** do processo de organização, que se desenvolve do trabalho dele sobre ele mesmo, sem um elemento central dominante; e o de **manutenção do sistema**, como resultado da evolução do processo.

Segundo Ashby (1962, p. 258), ao assumir-se a definição de sistemas como “um todo composto de partes”, isto é, sistemas são sempre partes menores de um sistema maior, a segunda noção de *auto*, a de independência, torna-se contraditória. Esse autor afirma que ao assumir a definição lógica-matemática de *auto* como uma função que não pode ser alterada por ela própria, perde-se a noção de independência, pois para haver a alteração da função deve existir um agente externo, atuando no sistema.



Tanto para Ashby (1962) quanto para Debrun (1996a), um sistema será considerado auto-organizado se o seu processamento e a sua manutenção se organizarem sem depender de qualquer elemento que não esteja dentro do contexto do sistema. Contudo, para que possamos definir melhor o conceito de A-O, analisemos sucintamente mais algumas noções que envolvem a A-O, tais como: *condições de partida, elementos distintos e forma ou organização final*.

As condições de partida, segundo Debrun (1996a), ocorrem quando os elementos que constituem o sistema se encontram com outros, sem a influência de um agente externo, dando início, assim, a um novo processo e deixando de lado o passado e o contexto anterior. Isso significa que houve uma desvinculação ou perda do passado e conseqüente ganho de liberdade, na ligação entre os elementos que estarão envolvidos no novo processo, o qual será considerado auto-organizado. Como cita Debrun:

O começo funcionaria como uma lei de construção do que vem depois. Mas o processo de auto-organização apenas “herda” esse começo, que ele vai levar em conta do modo variável. O começo é importante porque introduz um corte com o passado e com o contexto – o que permite ao processo em conjunto tornar-se independente, em parte, do “resto do universo”. O começo também fornece uma orientação ou um impulso numa certa direção. De um modo ou outro, será incorporado ao processo, contribuindo para dar-lhe sentido ou pujança (DEBRUN, 1996a, p. 6).

Outra noção citada acima, importante para o conceito de A-O, é a noção de elementos distintos, isto é, elementos sem nenhuma afinidade ou vínculos preexistentes de dependência entre eles. No início dos processos de A-O faz-se necessária a existência de tais elementos, a fim de garantir a ocorrência do acaso ou “aproximação casual” entre os elementos do sistema. Como escreve Debrun:

Entre as condições de partida constam elementos de um certo tipo. Por um lado são “realmente”, e não “analiticamente” distintos, já que não são redundantes entre si, isto é, não têm conexões, afinidades, etc., atuais ou potenciais, fora do fato de que todos são igualmente submetidos às leis gerais da natureza. Isso faz com que esses elementos, em vez de se condicionarem (um ao outro, ou um e outro reciprocamente), se “encontrem”, ficando livres, portanto, para conexões novas, inauditas – que vão surgir “aqui e agora” – e não apenas para se atualizar ou se revelar (DEBRUN, 1996a, p. 6-7).

A partir dos encontros entre elementos distintos, começam a surgir as interações entre eles. Com o passar do tempo, mais e mais interações tendem a ocorrer entre os elementos e, conseqüentemente, o acaso vai deixando de existir. Entretanto, para que o processo permaneça “auto”, nenhum elemento ou conjunto de elementos podem dominar absolutamente (e o tempo todo) os demais, isto é, os elementos envolvidos devem ter o mesmo grau de influência, em caso contrário seriam considerados processos de hetero-organização. Nos processos de hetero-organização, as organizações ou formas são planejadas e implantadas por um ou mais elementos dominantes ou superiores, do começo ao fim do processo.

A noção de forma (Debrun, 1996a), ou organização (Ashby, 1962) final do sistema, refere-se à constituição de um estado relativamente estável, evidenciando a diferença entre o passado e o presente. Como a A-O é um processo que requer tempo, com o passar desse, as interações dos elementos do sistema irão ocorrendo e definindo provisoriamente várias formas, as quais se desmancham até a forma ou organização final ser definida. Essa forma final não é dada de antemão. Como define Debrun:

Há auto-organização cada vez que, a partir de um encontro entre elementos realmente (e não analiticamente) distintos, desenvolve-se uma interação sem supervisor (ou sem supervisor onipotente) – interação essa que leva eventualmente à constituição de uma “forma” ou à reestruturação, por complexificação”, de uma forma já existente (DEBRUN, 1996a, p. 13).

De fato, os processos auto-organizados tendem, com o passar do tempo, a um “fechamento”, quando bem sucedidos. Porém, essa organização final poderá ser quebrada, segundo Debrun (1996a), por um ruído ou perturbações aleatórias, vindas do ambiente externo, fato que provoca mudanças internas no sistema.

De acordo com Ashby (1962) e Debrun (1996a), a A-O, isto é, o surgimento espontâneo de padrões, formas ou organização, podem ocorrer em duas

modalidades: na *primária* e na *secundária*. A A-O primária enfatiza a participação de elementos distintos que interagem, desenvolvendo uma forma ou organização, sem a presença de um elemento responsável para supervisionar o processo. Assim na concepção de Ashby (1962, p. 267), a A-O primária trata de partes separadas, independentes, incondicionadas, encontrando-se, numa auto-conexão em um certo momento, tornando-as unidas, condicionadas e, enfim, organizadas: “Tal sistema é auto-organizado no sentido que muda de partes separadas para partes unidas” (ASHBY, 1962, p. 267, tradução nossa).

No mesmo sentido, Debrun (1996a) define a A-O primária como ocorrência de encontros entre elementos sem nenhum vínculo ou dependência no passado, os quais, com o passar do tempo e sem uma organização pré-definida, geram interações entre seus elementos, cujas influências são iguais, vindo a constituir uma forma ou organização. Como podemos ler em Debrun:

Há auto-organização primária quando a interação, seguida de eventual integração, se realiza entre os elementos totalmente distintos (ou havendo, pelo menos, predominância de tais elementos), num processo sem sujeito, nem elemento central, nem finalidade imanente –situando-se as possíveis finalidades ao nível dos elementos (DEBRUN, 1996a, p. 13).

Um exemplo de A-O primária, citado por Gonzales (1996, p. 284), é uma rede neural, cujo treinamento é não supervisionado ou auto-organizado que, em sua condição de partida, possui elementos físicos ou UNS's conectadas, de acordo com a arquitetura utilizada, mas sem nenhum grau de vínculo, condicionalidade, ou interação pre-existent neste estágio. A partir do momento que o treinamento é iniciado, as UNS's da camada de entrada da rede recebem os padrões de *inputs* por meio de vetores, processando-os e distribuindo-os, através das conexões excitatórias ou inibitórias entre as UNS's, na direção das outras UNS's da camada superior à ela. Se essa camada superior for uma camada intermediária, as UNS's desta camada, ao receberem os estados de ativação das

UNS's da camada de entrada, também computam seus novos estados de ativação individuais, de acordo com os estados de ativação recebidos e dos pesos das suas conexões. Tais estados de ativação obtidos, são propagados na direção das UNS's da camada de saída, as quais também computarão seus estados de ativação. Este processo de interação entre as UNS's se repetirá durante o treinamento, até que a rede aprenda a representar corretamente os estados de ativação do vetor de entrada, isto é, até que a rede constitua uma forma ou padrão final corretos dos invariantes que lhe deu origem, o qual emerge de acordo com a interação das UNS's da rede, sem intervenção externa e sem que a forma ou padrão final, também chamado de *estado de equilíbrio do sistema*, fosse dado de antemão.

Esse exemplo também se enquadra no conceito de sistemas auto-organizados de Ashby (1962, p.269-271). Dentro desse conceito, para um sistema ser considerado auto-organizado, deve ser capaz de fazer seleção. No exemplo citado acima, com o avanço do processo, o sistema passa de um grande número de estados possíveis para um único. Assim, o sistema faz uma seleção, rejeitando alguns estados e mantendo outros.

Já a A-O secundária diz respeito a um aperfeiçoamento da A-O primária. Não se trata mais, segundo Ashby (1962), de um encontro entre elementos ou partes independentes. Trata-se agora de uma forma já dada e a partir da qual se caminha em direção à sua melhoria. Para tanto, o sistema procura manter as características que garantam sua perpetuação e eliminar as que possam acarretar uma inadaptação ao sistema, retornando à incondicionalidade ou separabilidade entre os seus elementos. Então, a A-O secundária, segundo Ashby (1962), é a passagem de uma organização ruim para uma boa, a partir dela mesma:

“Organizar” pode ter o primeiro significado já discutido de “mudar de o não-organizado para organizado”. Pode também significar, por outro lado, “mudar de uma organização ruim para uma boa”, e esse é o caso que desejamos discutir agora (ASHBY, 1962, p. 267, tradução nossa).

Em um mesmo sentido, Debrun (1996b) defende que a A-O secundária ocorre entre elementos durante os processos de aprendizagem, aumentando qualitativa e quantitativamente a interação entre as partes dessa forma já constituída pela A-O primária ou outra forma. Como lemos em Debrun: “[...] a auto-organização secundária, em que uma identidade já mais ou menos constituída (por auto-organização ‘primária’ ou de outra maneira) serve de *ponto de partida* a um novo processo [...]” (DEBRUN, 1996b, p. 50).

Nesse sentido, para Ashby (1962, p. 268), não é possível que máquinas realizem este tipo de reorganização espontânea ou A-O secundária, pois, para que isso seja possível, a sua função (f) deveria ser alterada por um agente externo e, então, fugiria à sua definição geral de máquinas. A única forma possível, segundo Ashby (1962, p. 269), de se pensar em ocorrência de A-O secundária em máquinas, seria acoplando uma função na outra, para que uma função alterasse a outra função, sem a intervenção externa de um agente. Contudo, para Ashby (1962), isso seria uma ilusão de A-O secundária, visto que teríamos máquinas distintas trabalhando em conjunto, organizando uma a outra (os *outputs* de uma seriam os *inputs* da outra) e não uma A-O secundária como descrita acima.

Por outro lado, sabe-se que algumas máquinas, como as RNA’s, apresentam o mecanismo de aprendizagem, do tipo competição, ou variante da “regra de Hebb”. Por meio desses mecanismos e da dinâmica do meio ambiente, as redes podem, ao longo do processo, ir-se corrigindo e aprimorando sua habilidade de desenvolver padrões informacionais a partir dos invariantes (constantes, regularidades) que lhe deram origem, sempre com o intuito de melhorar a sua adequação ao seu meio ambiente. Esta aprendizagem, se ocorrer, segundo Gonzales (1996, p. 285), é uma propriedade da A-O secundária; e em tais condições, algumas RNA’s podem ser consideradas auto-organizadas secundariamente em um certo grau.

Vemos em Gonzales (1996, p. 285) que duas situações podem criar a possibilidade de evolução ou aprendizagem em uma RNA: as que requerem correção de erro por meio de *feedback* e as que empregam o princípio da ordem a partir do ruído. Na primeira situação, quando ocorre um erro na rede, ou seja, quando sua resposta está incorreta, o erro (como vimos na seção 2.4.2) é propagado da camada de saída em direção à camada de entrada (de volta à rede). Esse processo se repete até que esse erro apresente um valor aceitável. Portanto, pode-se conceber que, nesse sentido, as RNA's compartilham de uma das propriedades da A-O secundária.

A segunda possibilidade de evolução emprega o princípio da ordem a partir do ruído. Nesse caso, sistemas abertos, submetidos a vários tipos de perturbações, podem vir a desenvolver mecanismos de adaptação, introduzindo variedade às suas formas já estabelecidas de organização, ou seja, alterando sua organização pré-estabelecida, tornando-se mais complexo e mais resistente. Logo, alguns sistemas auto-organizados não se alimentam somente de informação ordenada, mas também de ruído ou perturbações aleatórias.

Na sequência, analisaremos um outro conceito fundamental para nosso trabalho: o que Peirce entende por hábito?



CAPÍTULO 4 – O CONCEITO DE HÁBITO GERAL NA TEORIA DE PEIRCE

4.1 Apresentação

Até o presente momento, temos apresentado a A-O e as RNA's. Vimos o que são as redes neurais, suas estruturas, tipos e diversos métodos de aprendizagem. Contudo, deixamos claro que a RNA relevante para esta pesquisa é a rede de Kohonen, a qual possui um método de aprendizagem muito interessante. Para compreender melhor tal método de aprendizagem, abordamos o que é a A-O, seus conceitos básicos e suas modalidades. Mas, para que a nossa base conceitual seja suficiente, e assim possamos prosseguir na busca da resposta à questão inicial: "Uma RNA de Kohonen adquire hábito geral peirciano?", faz-se necessário, neste capítulo, abordarmos o conceito de hábito na visão de Peirce. Salientamos que, embora para ele existam muitas classes de hábitos mais particulares, ditos degenerados e que precisam de experimentos para ser testados, não os abordaremos aqui, apesar de julgá-los muito interessantes. Nesta dissertação, nos restringiremos a apresentar apenas o conceito de hábito geral peirciano em seus dois níveis de abordagens: o hábito geral constituído logicamente e o hábito geral constituído fisicamente por seres dotados de sistema nervoso.

Assim, quando, no capítulo 5, compararmos o conceito de hábito geral peirciano com um padrão de resposta dado por uma rede de Kohonen, estaremos conceitualmente preparados a responder à nossa questão. Para tanto, na seção 4.2, expomos as duas abordagens do hábito geral peirciano.



4.2 Aquisição de Hábitos

Todo o conhecimento que temos do mundo à nossa volta, é, para Peirce, impulsionado pela nossa admiração. Para interagirmos com o mundo real em um futuro, representamos mentalmente os passos necessários que nos direcionam, cada vez mais, a alcançar a meta que escolhemos, por sentirmos essa admiração (SILVEIRA, 2001). Este trabalho representativo, na visão peirciana, é chamado de conhecimento. Entretanto, embora o conhecimento tenha o objetivo de representar rigorosamente o real, segundo Peirce (CP 2.335)⁵, poderá estar sujeito a erros, à evolução e ao aperfeiçoamento.

Assim, tendo em mente que o conhecimento, para Peirce, é adquirido por meio da correção de erros, de acordo com sua evolução, pensemos na seguinte questão: “Como seria a aquisição de conhecimento se o ser humano tivesse que refletir conscientemente o tempo todo e decidir cada pequeno movimento ou atitude a ser tomada?”. A resposta é imediata: “Seria extremamente lenta”.

Para que a aquisição de conhecimento possa ser rápida, é essencial adquirirmos hábitos, pois assim, o cérebro irá dispor de tempo suficiente para se dedicar a tarefas altamente complexas, tendo mais espaço para criações e aprendizagens. Segundo Gonzales, Broens e Serzedello (2000), o que favorece a sobrevivência dos organismos vivos é a sua habilidade de aprender e alterar hábitos, de acordo com as exigências do meio ambiente em que vive. Por isso, hábitos bem sucedidos para a manutenção da vida são parte integrante do comportamento dos indivíduos.

Se é certo que criamos hábitos para melhorar nossa forma de vida, para facilitar e dinamizar a evolução de nossa capacidade, então, o que é um hábito, afinal? Existem muitas definições, pois é um assunto complexo e estudado por diversos

⁵ Nesta referência, CP é a abreviação de *Collected Papers* e (2.335) é o número do volume seguido por um ponto e o número do parágrafo.



pesquisadores. Mas, como já dissemos acima, neste trabalho, exploraremos o conceito de hábito geral na teoria peirciana.

Através dos *Collected Papers* (CP), fica claro que, para Peirce (CP 3.329), o hábito está presente em diversos domínios. Tantos nos fluídos e nos cristais, como na constituição dos seres vivos (plantas e animais), e até num objeto real concebível, Peirce reconhece a presença de hábitos em formação. Contudo, segundo Silveira (2001), Peirce não ignora os estreitos limites do conhecimento científico disponível em sua época: ele insistiu em avançar as investigações sobre o assunto, esperando que essas explicações pudessem contribuir e direcionar para pesquisas futuras.

Para Peirce (CP 1.348), cada hábito individualmente é uma lei, e essa lei pode se modificar por seu próprio controle. Por não ser o hábito, de acordo com Peirce (CP 1.409), um privilégio somente do ser humano, ele afirma que tudo no universo tem uma tendência a obedecer a leis, isto é, a adquirir hábitos. A tendência a obedecer a leis será sempre crescente, tanto que, segundo este pesquisador, ao observarmos o curso de um evento, constatamos que, no seu passado distante, não existia lei, mas apenas indeterminação, ao passo que no seu futuro distante, não existirá mais indeterminação ou mudança, somente o domínio da lei. Apesar de que, em algum ponto do passado, Peirce acredita que já tenha existido alguma tendência a direção rumo a uma uniformidade da ação e que, com o tempo, foi sendo aumentada até tornar-se no futuro, uma lei. De acordo com isso, para Peirce, três elementos são ativos no mundo: “primeiro a mudança, segundo a lei e terceiro a aquisição de hábito” (PEIRCE, CP1.409). Como escreve Peirce:

[...] todas as leis resultam de uma evolução, sendo assim, nenhuma lei é absoluta. A evolução do mundo procede de um estado em um passado distante para um estado diferente em um futuro distante. O estado dos eventos em um passado distante é o caos, isto é, a total ausência de regularidade. O estado dos eventos no futuro distante é a morte, a qual consiste no triunfo completo da lei e ausência de qualquer espontaneidade. Entre o passado e o futuro, nós temos o estado dos eventos no qual existe alguma espontaneidade agindo contra a lei e

algum nível de conformidade com a lei, que é constantemente aumentada devido ao crescimento do hábito. A tendência a formar hábitos, ou a tendência a generalizar, cresce por sua própria ação; pelo hábito do próprio hábito em crescer.” (PEIRCE, CP 8.317, tradução nossa).

Segundo Peirce (CP 4.157), existem duas abordagens dos hábitos gerais: os constituídos logicamente por idéias e os constituídos fisicamente por atos de reação em seres dotados de sistema nervoso. Os hábitos gerais constituídos logicamente decorrem do mundo interno; e os hábitos gerais constituídos fisicamente, do mundo externo. Peirce entende que toda pessoa sadia vive nestes dois mundos: “O mundo externo e um interno, o mundo de percepções e o mundo das idéias” (CP 5.487, tradução nossa). O que mantém, segundo o autor, a junção desses dois mundos é que as idéias podem ser modificadas por um esforço não-muscular, sendo que um esforço muscular pode em algum grau, modificar a percepção; logo, um homem pode ser muito afetado pelos dois. Por combinações semelhantes de suas perspectivas e idéias, o homem pode adquirir uma tendência ou hábito para se comportar de uma maneira similar em circunstâncias semelhantes no futuro. Por isso, escreve o autor que: “Em cada mente lógica devem existir primeiramente idéias; em segundo plano, regras gerais, de acordo com uma idéia determinada por outra, ou hábitos da mente, os quais conectam idéias; e, em terceiro e último plano, os processos nos quais as conexões habituais são estabelecidas” (PEIRCE, CP 7.358, tradução nossa).

As nossas condutas, segundo Peirce (CP 5.412), podem ser alteradas somente pelas nossas experiências. A experiência é, para ele, o processo de confrontar o objeto desejado com a representação que fazemos dele, o que pode modificar ou fortalecer o hábito (SILVEIRA, 2001).

Na abordagem dos hábitos gerais adquiridos logicamente, as crenças ou opiniões, julgamentos ou expectativas que temos e alteramos no decorrer de nossa existência, constituem para Peirce, experiências que interferem em nossas ações reais. A

crença ou *opinião*, para o autor (CP 5.397), é um estado da ação mental ou um hábito formado somente na imaginação e que influenciará nossa ação real em uma determinada circunstância: a crença permanecerá inalterada até encontrar alguma surpresa que provoque dúvidas, colocando-a em questão. Porém, segundo nosso autor (CP 1.50), a crença em idéias morais pode envolver um elemento ruim, visto que a moralidade é conservativa e de difícil alteração: mesmo com muitas pessoas acreditando que conduta boa e conduta moral são únicas e mesmas, Peirce discorda e considera a moralidade necessária, mas não co-extensiva da conduta boa. Para ele, a moralidade é um folclore da conduta certa, um hábito cujas leis tenderão a espalhar-se. Sabemos que, quando uma pessoa foi educada para comportar-se de uma maneira que disseram ser a correta (moral), se ela se comporta de outra forma, poderá ser vítima de sua própria cólera, sentindo-se com remorso e em desconforto. Portanto, a moralidade, para Peirce, dificulta a mudança que em determinadas situações podem contribuir para melhorar nossa qualidade de vida.

A representação de que temos uma crença é chamada por Peirce (CP 1.107) de julgamento. Os julgamentos, dentro da concepção peirciana, (CP 2.435), são atos dos quais estamos conscientes, isto é, num determinado momento, somos capazes de reconhecer uma crença ou opinião, podendo inclusive modificá-la ou fortalecê-la. Peirce cita que, quando um julgamento é formado com a influência da crença ou regra ativa em nós, poderá dar lugar a um novo julgamento. O julgamento (ou julgamentos) antecedente é chamado por ele (CP 2.773) de premissa e o julgamento conseqüente de conclusão. O pensamento é que determina a passagem de um para o outro. Para que a conclusão, também chamada por Peirce (CP 3.164) de *hábito da inferência*, seja considerada boa, ela nunca deve partir de premissas verdadeiras para alguma conclusão falsa (PEIRCE, CP 3.163). Ao partir de alguma premissa verdadeira, sua conclusão deve sempre ser



verdadeira, para assim, ser um processo chamado por Peirce (CP 3.164), de *princípio de aprendizagem do raciocínio*.

Outra experiência que pode modificar nossa conduta é a expectativa que, para Peirce (CP 2.148), consiste em um hábito do imaginar. Sendo o hábito “[...] uma lei geral da ação que torna o homem apto a agir de uma certa maneira em uma dada ocasião [...]” (PEIRCE, CP 2.148, tradução nossa), uma imaginação pode afetá-lo, discordando dele ou concordando com ele. Peirce escreve: “A minha expectativa consiste em um hábito de que, quando penso na ação, imagino o resultado dela na visão” (PEIRCE, CP 5.415, tradução nossa). Como exemplo da expectativa, Peirce (CP 2.148), cita a ação de colocar um centavo em uma máquina e esperar para ver, com o puxão da alavanca, um bolo de chocolate aparecer. “Quando a percepção do bolo de chocolate vem à minha visão, minha imaginação é um sentimento tal, que pode ser comparado com o bolo de chocolate real pelo tamanho, forma, cor, sabor, aroma, etc” (PEIRCE, CP 2.148). Peirce, mostra, com este exemplo, que cada expectativa é um processo inferencial, o qual envolve a formação de um hábito geral, pois gera uma crença ou opinião, e, como vimos anteriormente, uma crença ou opinião prepara o homem para agir no futuro.

Sabe-se que a crença ou opinião, o julgamento e a expectativa são inferências lógicas que, ao serem experienciadas, podem alterar nossas condutas reais e, conseqüentemente, nossos hábitos. Na teoria peirciana, existem três classes de inferências principais: a **dedução**, a **indução** e a **hipótese**, **inferência hipotética** ou **abdução**. Segundo Peirce, elas “[...] correspondem aos três modos das ações mentais humanas” (PEIRCE, CP 6.144).

A dedução, para Peirce, é o resultado conseqüente (e ativo na mente) de um hábito já adquirido e acompanhado por uma sensação que o originou. Salientamos que, para o autor, a mente não é uma exclusividade dos seres humanos, ou de qualquer classe



especial de seres: é uma função lógica (SILVEIRA, 2001). Como exemplo, Peirce cita a perna de uma rã que, mesmo separada do resto do seu corpo, se move para livrar-se de uma eventual agressão. Como escreve Peirce:

Na dedução, a mente está sob o domínio de um hábito ou associação, por virtude do qual uma idéia geral sugere em cada caso uma reação correspondente. Mas, vê-se que uma certa sensação envolve aquela idéia. Consequentemente, a esta sensação, segue-se aquela reação (PEIRCE, CP 6.144).

A indução, por sua vez, é definida por Peirce (CP 6.145) como um processo pelo qual um hábito geral é estabelecido. Neste processo várias sensações seguidas da mesma reação são associadas, constituindo uma idéia geral que segue a mesma reação. Um exemplo dado por Santaella (1995, p.6), é entrar em um navio carregado de café e escolher uma amostra do café. Ao retirar alguns grãos da parte superior, do meio e da parte inferior de sacas colocadas nos quatro cantos do porão do navio, concluo, por indução, que a carga toda tem o mesmo valor, por grãos, que os grãos de minha amostra.

Podemos citar vários exemplos de indução ao observarmos nossas atividades diárias. Por exemplo, quando vamos ao supermercado, experimentamos uma uva para concluirmos se devemos ou não comprar um caixa ou uma porção daquele lote de uvas disponível, ou quando cozinhamos temos que provar um pouco do tempero para concluirmos se o prato que estamos preparando está com a quantidade adequada de sal, etc.

Já a inferência hipotética, segundo Peirce, “[...] é uma indução a partir de qualidades [...]” (PEIRCE, CP 6.145). Também é um processo de associação, porém, neste processo, várias reações produzidas em uma determinada ocasião são associadas, constituindo uma idéia geral, que ocorrerá na mesma ocasião (PEIRCE, CP 6.146). Um exemplo pode ser, segundo Peirce, a coordenação dos nossos movimentos, pois associamos as várias ações necessárias para realizar um movimento, formando na mente uma idéia geral do movimento, antes de executá-lo. Tal processo consciente tenderá gradativamente

para a espontaneidade de uma ação. Os aprendizados de línguas ou qualquer outra habilidade, para Peirce, também podem ser enquadrados aqui.

Com estes três conceitos, fica claro que, para Peirce, a formação de um hábito constituído logicamente tem a tendência crescente de generalizar certas idéias, por intermédio de associação. Isto confirma, para Peirce, o fato de que, na maioria das vezes, as idéias e os raciocínios têm muita boa influência na conduta humana. E que a frase: “...tanto a verdade quanto a justiça são forças boas no mundo” (PEIRCE, CP 3.348, tradução nossa), não é uma figura de linguagem, mas é fator relevante para que teorias possam se harmonizar.

Um hábito geral, para Peirce (CP 2.417), é completamente previsível até encontrar alguma surpresa, que traga dúvidas, podendo iniciar desta forma, sua dissolução. Portanto, para Peirce, a dúvida é a privação de um hábito, ou seja, é uma atividade irregular que, em algum momento, no futuro, poderá ser substituída por um hábito. Em nossas vidas, adquirimos hábitos os quais, com o passar do tempo, podem ser alterados em determinadas situações. Esta quebra ou mudança de hábito, consiste, para Peirce (CP 2.418), na elevação ou diminuição da resistência da força de um hábito, que pode variar de completa separação à inseparável associação. Os efeitos da mudança de um hábito podem produzir novas mudanças, pois é natural que certas repetições de ações que causaram a mudança aumentem. Com isso, segundo Peirce (CP 2.418), a afirmação de que a repetição da ação é indispensável para a formação de um hábito é dubitável em certas situações.

Quando Peirce fala sobre mudança de hábito, deixa claro que uma mudança pode não ser ato somente da mente que a provocou, mas também de experiências forçadas. Logo, por um lado temos a surpresa, que para Peirce (CP 5.417), é muito eficiente na quebra de associações de idéias; e por outro, temos o instante novo que é

trazido pela experiência, em apoio à indução e fortalecimento à associação de idéias, que, no hábito geral peirciano, consiste em uma tendência para acreditar na conclusão indutiva.

Passando para a abordagem do hábito geral constituído fisicamente por seres dotados de sistema nervoso, a aquisição de hábito geral, para Peirce (CP 1.390), depende dos cinco princípios descritos a seguir.

1º Princípio: quando um estímulo ou irritação permanece por algum tempo, a excitação das células diretamente afetadas estende-se para aquelas que estão associadas com elas, e dessas para outras, e assim sucessivamente, aumentando ao mesmo tempo a intensidade.

2º Princípio: depois de algum tempo, começa a fadiga. Além da completa fadiga, que consiste em células perdendo toda a excitabilidade e o sistema nervoso recusando-se a reagir a qualquer estímulo, existe também uma fadiga suave, que afeta uma parte muito importante do cérebro, servindo como um órgão da razão. Esta fadiga suave implica cessar o reflexo da ação ou descarga da célula nervosa e ir para outro caminho, começando em um caminho quando não tiver havido descarga, ou aumentar a intensidade da descarga ao longo do caminho, caso tenha havido previamente uma descarga insignificante.

3º Princípio: quando a causa do estímulo é removida da célula nervosa, a excitação rapidamente diminui. Isto não é sentido instantaneamente, pois todo sentimento perceptível diminui na fração de segundos, mas um vestígio muito pequeno continua por um tempo maior. Este fenômeno é conhecido entre os físicos pelo nome de “*sensação de persistência*”.

4º Princípio: se a mesma célula que foi uma vez excitada e que, nesta excitação, teve sua descarga ao longo de certo caminho ou caminhos, vier a adquirir uma segunda excitação, é mais comum que nesta segunda vez, sua descarga se dê ao longo do

mesmo caminho ou caminhos da primeira excitação, em caso contrário não poderia ter sido antes, desse modo, a sua própria descarga. Este é o princípio central do hábito.

5º Princípio: depois de um tempo considerável sem que o nervo tenha reagido em algum caminho particular, surge o princípio de desatento ou hábito negativo (esquecimento seletivo), que não permite que a célula reaja de outra maneira.

Combinando estes cinco princípios, Peirce (CP 1.390) relata que, quando um nervo é estimulado, se a ação reflexiva não remover a irritação, a ação será alterada até que a causa da irritação seja removida. Quando o nervo for estimulado pela segunda vez, da mesma maneira que a anterior, é provável que as ações realizadas na primeira ocasião se repitam (pelo menos as últimas), e a irritação permanecerá, até que a ação que removeu a irritação anterior seja realizada. Na terceira vez que a irritação ocorrer, o processo de esquecimento da tendência em repetir algumas ações que não foram repetidas na segunda vez, será iniciado. E das ações que se repetiram na segunda vez, algumas serão novamente repetidas nesta terceira vez e outras não. Conforme as mesmas estimulações do nervo forem se repetindo, a ação que realmente remove a origem da irritação vai sendo fortalecida e as outras ações vão sendo mais e mais esquecidas. O resultado desses cinco princípios, para Peirce, é a formação de um hábito geral constituído fisicamente, o qual remove a origem da irritação. E para Peirce (CP 1.392), a fórmula geral de todos os nossos desejos, pode ser justamente esta, remover um estímulo.

Segundo Peirce (CP 3.159), muitas vezes não é a reação externa, mas apenas uma idéia que inicia uma sucessão de pensamentos; noutros termos, a irritação, em vez de ser uma ação, é uma idéia. Mesmo a imaginação de um caminho particular, para Peirce (CP 5.538), é possível após várias repetições desta irritação, por saber o tipo imaginado de reação que a eliminará, devendo acontecer em ocorrências semelhantes posteriores. Na formação dos hábitos constituídos fisicamente, segundo Peirce (CP 5.538),



podemos *a priori* imaginar as ocorrências dos estímulos e pensar que existirão vários resultados de ações diferentes, bem como decidir qual desses resultados parece ser mais satisfatório. Assim, para Peirce, quando um estímulo ou irritação real e similar ocorrer, uma linha de conduta que leve a formação do hábito geral já estará definida, encontrando a reação correta para remover a origem da irritação mais rapidamente.

Todavia, o aprender, para Peirce (CP 1.385-394), resultaria da capacidade das células nervosas em formar redes ou hábitos adquiridos e agir no futuro, por meio delas. Esta capacidade, segundo ele, permite concluir que sistemas formados por células nervosas podem superar o princípio da ação e reação mecânica e sustentar uma conduta racional (SILVEIRA, 1998, p. 128).

Peirce (CP 2.66) exclui a necessidade da consciência para a aquisição de hábitos. No entanto, não a despreza, pois entende que a consciência colabora na interação do mundo exterior e interior do homem. E sendo a consciência como uma sensação, fornecerá o substrato de sentir nas ocasiões em que os hábitos de conduta devem atuar; mas, quando temos uma experiência, nem sempre estamos conscientes, nem um hábito exigirá tal consciência na ação que seguirá dele.

Resumindo, de um ponto de vista peirciano, hábitos são regularidades e mudanças de hábito são divergências da regularidade. Na abrangência do conceito de hábito peirciano, qualquer sistema (vivo ou não) deve possuir uma tendência a adquirir hábitos, mas alguns desses sistemas podem estar paralisados por hábitos fixos e rígidos e, em outros sistemas, existe a possibilidade de mudanças de hábito em um nível e em outro não.

Portanto, fica claro que, para Peirce, um sistema que disponha exclusiva e simplesmente da lei mecânica, não aprende. Para ser capaz de aprender e conseqüentemente, adquirir hábitos, o sistema deve ter alguma coisa, além da lei mecânica

(SILVEIRA, 1998, p. 120). Assim, vale questionar se a RNA A-O de Kohonen é um sistema puramente mecânico. Ou será que essa rede é capaz de aprender e generalizar um comportamento a partir de exemplos (instâncias) processados? Para a obtenção de uma conclusão satisfatória, importa conhecer melhor este tipo de rede. É o que faremos no próximo capítulo.



CAPÍTULO 5 – AQUISIÇÃO DE HÁBITOS NA REDE DE KOHONEN

5.1 Apresentação

Chegamos ao ponto central deste trabalho. Após havermos adquirido os conceitos necessários, este capítulo tem finalmente o objetivo de encontrar uma resposta satisfatória para nossa questão: Uma RNA do tipo Kohonen adquire hábito geral tal como proposto por Peirce?

Para tanto, faremos uma continuação da seção 2.4.3 do capítulo 2, abordando mais detalhadamente, na seção 5.2, os mapas auto-organizáveis de Kohonen (SOM) e os seus algoritmos. Na seção 5.3, será analisado o ajuste fino que pode ser feito nas redes de Kohonen, que são métodos usados para aumentar a eficiência da rede neural em reconhecer os padrões para a qual foi treinada. Na seção 5.4, será verificado o processo de aprendizagem de uma rede de Kohonen treinada para fazer o reconhecimento de padrão, por intermédio do *software Kohonen Network Simulator*, versão 1.1, o qual acompanha o livro *Understanding neural networks: computer explorations*, dos autores Caudill e Butler (1992). Na última seção (5.5), faremos uma comparação entre a rede de Kohonen e o hábito geral peirciano, com o intuito de descobrir se este modelo de rede pode ser considerada como uma máquina não-determinística, e consequentemente, poder ser capaz de adquirir tal hábito.

5.2 Os mapas auto-organizáveis de Kohonen

Complementando o que já foi visto na seção 2.4.3 do capítulo 2 do presente trabalho, o modelo de Kohonen é uma rede neural que usa o tipo de alimentação



feedforward entre suas camadas e a alimentação *feedback* restritamente entre as conexões laterais das UNS's da camada de Kohonen. Sua técnica de aprendizagem é a não supervisionada ou por A-O, o que permite à rede classificar e atuar por si própria, sem a intervenção de um agente externo, que indica quando as respostas da rede estão certas ou erradas (BEALE; JACKSON, 1994, p. 109). Este modelo de rede produz, durante sua execução, os chamados Mapas Auto-Organizáveis de Kohonen ou, simplesmente, Mapas Auto-Organizáveis (SOM). Um exemplo da rede de Kohonen é mostrado na figura 14.




Figura 14: Exemplo de um mapa de Kohonen com neurônios de saída usados de forma bidimensional. Neste exemplo todas as entradas $X_0...X_N$ estão conectadas com as saídas (KOHONEN, 1987, p 128).

Conforme Kohonen (1987, p. 122 e 123), o esquema básico de seu modelo é fazer com que as UNS's da camada de Kohonen disputem entre si, por meio de conexões laterais, a representação do padrão de *input* fornecido a elas. Encontrando a UNS vencedora, ou seja, a UNS mais próxima ao padrão de *input*, esta é reajustada para responder ainda melhor ao estímulo recebido. Dentro desse modelo não supervisionado, não apenas a UNS vencedora, mas também as suas vizinhas (dentro de um limite físico que pode ser definido pela função do Chapéu Mexicano, citado na seção 2.4.3) são ajustadas.

Tal “comportamento” tem por objetivo fazer com que a rede simule uma atividade da região do córtex cerebral. Para Beale e Jackson (1994, p.112), esta idéia de Kohonen é baseada na teoria de que as células nervosas corticais são arranjadas em mapas topológicos no cérebro de acordo com os estímulos (excitatórios ou inibitórios) que recebem dos sensores aos quais estão ligadas. Como lemos em Beale e Jackson:

[...] a ativação da célula nervosa é propagada para outras células via ligações dos axônios (a qual pode ter efeito excitatório ou inibitório no *input* de outra célula). [...] Podemos ver que essas células, fisicamente próximas da célula ativa, têm as ligações mais fortes. E aquelas a uma certa distância dessas realmente alternam para ligações inibitórias. Tal fenômeno, Kohonen atribuiu ao desenvolvimento (pelo menos em parte) dos mapas topológicos localizados no cérebro. Como temos visto, ele (Kohonen) tem modelado esse efeito usando somente rede interconectada localmente e restringindo a adaptação dos valores dos pesos para “vizinhanças” localizadas (BEALE; JACKSON, 1994, p.112, tradução nossa).

O algoritmo de aprendizagem não supervisionado é que possibilita a criação dos mapas topológicos na rede de Kohonen. Ao organizar as UNS's da camada de Kohonen através de ciclos de processos de comparações entre padrões de *inputs* e os vetores armazenados em cada UNS, o algoritmo atua como classificador do dado de *input*, sem que nenhuma resposta seja especificada. Essa comparação é possível devido às conexões laterais entre as UNS's da camada de Kohonen e determina a UNS vencedora, sem precisar de um agente externo. Diferentemente das outras redes neurais vistas neste trabalho, na rede de Kohonen, somente a UNS vencedora e sua vizinhança (dentro da distância especificada da vencedora) é que modificam os pesos das suas conexões. O restante das UNS's não experenciam a aprendizagem (não serão alteradas). Como Beale e Jackson escrevem:

O algoritmo de aprendizagem organiza os nós na grade do local de vizinhança, o qual atua como classificador da característica do dado de *input*. O mapa topológico é organizado autonomamente por ciclos de processos de comparações entre os padrões de *inputs* e os vetores armazenados em cada nó. Nenhuma resposta de treinamento é especificada por algum *input* de treinamento, em que os *inputs* se igualam aos vetores dos nós; essa área do mapa é seletivamente otimizada para representar uma média do dado de treinamento daquela classe (BEALE; JACKSON, 1994, p. 110, tradução nossa).

Os passos do algoritmo de aprendizagem da rede de Kohonen são os seguintes (BEALE; JACKSON, 1994, p. 111):

01. inicializar os pesos dos n *inputs* das UNS's com valores aleatórios baixos (baixos em relação aos valores de entrada), com $w_{ij}(t)$ ($0 \leq i \leq n-1$) o peso (w) do input (i) da UNS (j) no tempo (t);
02. definir o raio de vizinhança V_j de cada UNS (inicialmente recomenda-se que V_j seja igual ao tamanho da rede);
03. apresentar as entradas $x_0(t)$, $x_1(t)$, $x_2(t)$, ..., $x_{n-1}(t)$ à rede, em que $x_j(t)$ é a entrada da UNS (j) no tempo (t);
04. calcular para a UNS $_j$, a distância euclidiana entre as entradas e os pesos para cada UNS $_j$ da camada de Kohonen:

$$d_j(t) = \sum_{i=0}^{n-1} (x_i(t) - w_{ij}(t))^2 \quad (5.1)$$

05. selecionar a UNS vencedora, ou seja, a UNS que apresenta a menor distância (o menor $d_j(t)$);
06. os pesos (w_{ij}) da UNS $_j$ selecionada são atualizados juntamente com todas as UNS's que estão dentro da vizinhança definida por $V_j(t)$:

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t) (x_i(t) - w_{ij}(t)), \quad (5.2)$$

em que:

O tempo (t) deve ficar entre 0 e 1. Recomenda-se iniciar com um valor alto e baixá-lo com o decorrer do tempo;

η é o coeficiente ou taxa de aprendizagem com $0 < \eta(t) < 1$;

07. se necessário, modificar o raio de vizinhança de todas as UNS's. Esta modificação deverá implicar um decréscimo do raio de $V_j(t)$, localizando, desse modo, a área de máxima atividade;
08. se existir, ainda, alguma informação que faça parte do conjunto de treinamento e que não foi apresentada à rede, voltar ao passo 03;
09. se o número de iterações realizadas até o momento atingiu a quantidade especificada no início, encerrar essa fase do treinamento. Em caso contrário, realizar nova iteração do conjunto de treinamento retornando ao passo 03.

Analisando os passos citados acima, vemos que, sinteticamente, o mecanismo de Kohonen (1987) funciona da seguinte forma: os pesos iniciam contendo valores aleatórios baixos, e um sinal de entrada X (com valores que representam um padrão de *input* qualquer) é provido para a rede, sem que se especifique a saída desejada (característica da rede não supervisionada). O sinal de entrada X é descrito como segue: $X = (x_0, x_1, x_2, \dots, x_{n-1})$.

Conforme o sinal de entrada, uma UNS de saída (j) deverá responder melhor para a entrada respectiva, e, então, será a vencedora. Isto faz com que essa UNS seja disparada sempre que essa entrada específica for apresentada à rede neural. A UNS vencedora (j) e suas vizinhas (V_j) terão seus pesos ajustados para responder melhor do que antes à entrada X apresentada. A rede é considerada treinada depois de todo o conjunto de treinamento ter sido apresentado a ela e os critérios de treinamento, satisfeitos.

Uma medida que tem sido adotada por Kohonen na fase de treinamento é a de 10 a 100 passos para cada UNS na camada de Kohonen (KOHONEN, 1987, p. 133). Isso significa que, havendo 10 UNS's na camada de Kohonen, deverá haver mais de 100 iterações para que o mapa esteja ordenado adequadamente. Entretanto, Kohonen (1987) ressalta que esses parâmetros não são regras; são recomendações resultantes da observação

de determinados pesquisadores. Nada impede que se obtenha sucesso com menos ou mais iterações.

Seguindo a fase de treinamento, temos a fase de teste da rede neural. Esta é semelhante à fase de treinamento, só que não serão mais alterados os pesos das UNS's. Para que o teste seja mais apurado, a rede poderá receber, como entrada, além dos fatos que foram apresentados, outros que não fizeram parte do conjunto de treinamento. Reconhecendo as entradas do teste de forma adequada, a rede é considerada treinada com sucesso.

Para Beale e Jackson (1994, p. 113), este algoritmo é fácil de entender, pois nos mostra que:

- durante a fase de aprendizagem, um conjunto de padrões de treinamento é apresentado à rede. A ação da rede com o estímulo desses *inputs* de treinamento é comparar cada padrão de entrada com os vetores peso, até encontrar a UNS vencedora. A UNS vencedora é caracterizada como a UNS que tem vetor peso para competir com o vetor de *input*, e fornecerá uma resposta máxima à rede se for novamente usada depois de o ciclo de treinamento haver sido completado;
- as UNS's da vizinhança da UNS vencedora são modificadas. Terminado o ciclo de treinamento, essas vizinhas determinarão uma média de representação da classe padrão;
- a mudança no vetor peso é proporcional à diferença entre o vetor de *input* e o vetor peso: $w_{ij}(t+1) = w_{ij}(t) + \eta(t) (x_i(t) - w_{ij}(t))$, em que w_{ij} é o componente do vetor peso da UNS j , para j na vizinhança $V_j(t)$ ($0 \leq i \leq n-1$). A unidade de proporcionalidade é $\eta(t)$, o coeficiente de aprendizagem. Cada vez que um novo *input* de treinamento é aplicado à rede, a UNS vencedora deve ser primeiramente localizada, identificando-se, assim, a região do mapa característico que terá os valores dos seus pesos atualizados.

Com essa análise sintética do algoritmo de Kohonen, fica claro que ele possui duas finalidades principais: encontrar a unidade mais próxima do *input* de treinamento (a UNS vencedora) e aumentar a similaridade dessa UNS e de sua vizinhança com o *input* de treinamento. Para conseguir isso, o algoritmo de aprendizagem de Kohonen precisa trabalhar com: “o processo de adaptação dos pesos e o conceito de vizinhança topológica de nós” (BEALE; JACKSON, 1994, p. 113, tradução nossa).

O processo de adaptação dos pesos das UNS's (ajuste dos pesos) é crucial para a formação ordenada do mapa topológico, pois, apesar de uma UNS ser afetada independentemente da outra, é o conjunto inteiro que representa a informação. Segundo Beale e Jackson (1994, p. 115), a especificação inicial dos valores (pequenos) dos pesos inspiram muitos cuidados, pois podem levar a rede a não convergir para nenhuma resposta ou ter o ciclo de treinamento extremamente lento. Isso ocorre porque a vizinhança do mapa característico será conseqüentemente muito pequena, não possuindo UNS's suficientes para desenvolver a classificação correta dos *inputs*.

A fim de que isso não ocorra, existem métodos que orientam a distribuição dos pesos iniciais. Um método, citado por Beale e Jackson (1994, p. 116), consiste em inicializar todos os pesos no ciclo de treinamento somente quando eles tiverem os mesmos valores, permitindo que todos os nós do mapa característico tenham a mesma probabilidade de serem o mais próximo do vetor de *input* e assim serem incluídos na representação do mapa. Outras técnicas similares acrescentam ruídos aleatórios pelos *inputs* na fase de treinamento, na tentativa de distribuir os vetores num espaço padrão maior e, dessa maneira, utilizar mais UNS's. Entretanto, segundo Beale e Jackson (1994, p. 116), a técnica mais usada na rede de Kohonen, consiste em aumentar o tamanho da vizinhança local no início do treinamento, buscando utilizar todos os nós da rede e promover a convergência dela para alguma forma, por meio do agrupamento topológico

das UNS's. Com o decorrer do treinamento, o tamanho da vizinhança vai diminuindo. A figura 15 mostra a formação da vizinhança da UNS destacada (mais escura).




Figura 15: Definição do raio de vizinhança em diferentes tempos em que os mapas de medidas são formados (BEALE; JACKSON, 1994, p. 118).

Como é mostrado na figura 15, no quadro A, a vizinhança da rede ao redor de cada UNS, está na fase inicial do treinamento. No quadro B, vemos que, após alguns ciclos de treinamento, o tamanho da vizinhança, ou seja, das UNS's que serão alteradas, diminui e se concentra ao redor da UNS vencedora (destacada). No quadro C, vemos a rede treinada e com a vizinhança menor, representando a média dos valores dos dados de treinamento. Para diminuir e encontrar o tamanho ideal da vizinhança e cessar o treinamento, Kohonen (1987, p. 132) sugere que a taxa de adaptação seja uma função que diminua linearmente à medida que aumenta a quantidade de ciclos de treinamento. Porém, o treinamento não define somente a adaptação dos pesos e a redução da vizinhança, mas

também define a forma topológica, que pode ser não apenas quadrada, como mostrada na figura 15, mas também hexagonal, retangular, triangular, etc. Na figura 16, mostramos a forma hexagonal da rede.




Figura 16: Exemplo dos modelos quadrado e hexagonal (KOHONEN, 1987, p.132).

Na próxima seção, analisaremos uma técnica conhecida como ajuste fino, que é aplicada à rede de Kohonen após a mesma ter sido treinada.

5.3 O ajuste fino da rede

A rede de Kohonen pode, após ter sido treinada, apresentar ainda certas áreas identificadoras dos padrões de entrada com limites muito próximos, coincidentes, ou até sobrepostos. Para resolver este tipo de problema, a rede deve ser passada por um ajuste fino da camada de UNS's. Este método é usado para aumentar a eficiência da rede neural em reconhecer os padrões para os quais foi treinada (KOHONEN, 1987, p. 199). Kohonen apresentou alguns tipos de ajustes ou algoritmos, tais como: LVQ1, LVQ2 e LVQ3, sendo que um dos ajustes mais utilizado na prática computacional é o ajuste tipo LVQ1 (*Learning Vector Quantization* tipo 1).

Para Kohonen (1987, p. 199), esses métodos de aprendizagem (LVQ's) permitem que, por intermédio de processos iterativos, os pesos de determinadas UNS's da rede sejam reforçados ou inibidos, caso elas proporcionem uma resposta correta ou incorreta, respectivamente, a um padrão de entrada. Dessa forma, procura-se eliminar distorções na interpretação espacial da rede, criando regiões bem definidas que melhor classificam os padrões de entrada.

Esse ajuste deve ser aplicado à rede somente depois de ela ter sido treinada. Para tanto, segundo Kohonen (1987), é necessário que se prepare um novo conjunto de treinamento, que contenha entradas já conhecidas pela rede. Todos os passos do ajuste devem proceder da mesma forma feita para o treinamento inicial, porém com algumas pequenas diferenças, tais como as que seguem.

Procura-se fazer com que o número de iterações do ajuste seja menor que o número de iterações do treinamento da rede neural (fase anterior). O tempo (t) deve iniciar com um valor baixo visto que a iteração não é mais um grande treinamento das UNS's, mas apenas um pequeno ajuste de certos neurônios ou UNS's da rede. A taxa de redução de (t), durante as iterações do ajuste, deve ser bastante pequena. A vizinhança deve ser ignorada, permanecendo o resto das UNS's inalteradas.

O processo de ajuste fino, segundo Beale e Jackson (1994, p.122), é o seguinte:

- apresenta-se um fato do conjunto de *inputs*;
- calcula-se a distância para todas as UNS's;
- seleciona-se a UNS com a menor distância;
- compara-se o padrão informacional da UNS selecionada s adquirido no treinamento com o padrão informacional da entrada x apresentada:

Se a entrada x estiver classificada corretamente, então:

$$w_s(t+1) = w_s(t) + \eta(t) [x(t) - w_s(t)], \text{ em que} \quad (5.3)$$

$w_s(t+1)$ = novos pesos da UNS selecionada s ;

$w_s(t)$ = pesos da UNS selecionada s ;

$x(t)$ = entrada apresentada a rede.

Se a entrada x estiver classificada incorretamente, então:

$$w_s(t+1) = w_s(t) - \eta(t) [x(t) - w_s(t)] \text{ em que} \quad (5.4)$$

$w_s(t+1)$ = novos pesos da UNS selecionada s ;

$w_s(t)$ = pesos da UNS selecionada s ;

$x(t)$ = entrada apresentada a rede.

- os outros neurônios i não são afetados:

$w_i(t+1) = w_i(t)$, em que

$w_i(t+1)$ = novos pesos da UNS i ;

$w_i(t)$ = pesos do neurônio i .

- voltar para o passo 1 e continuar o processo de ajuste com as apresentações dos outros *inputs*.

Como exemplo de aplicação prática desse modelo, podemos citar a máquina de escrever fonética, ou *Phonetic Typewriter* (BEALE; JACKSON, 1994, p. 123-124). O objetivo dessa rede é, ao ser pronunciada uma palavra, no caso em idioma finlandês, informar os prováveis fonemas constituintes daquela palavra. Para tanto, a rede é treinada com os fonemas do idioma, os quais, dependendo de suas características, são agrupados com outros que possuem características similares. Assim, a cada fonema pronunciado será ativado um determinado neurônio de saída correspondente.

As redes neurais artificiais auto-organizadas estão longe de resolver todos os problemas que lhe forem propostos. No entanto, o sistema de Kohonen mostra

como as forças das técnicas neurais (paralelismo, tolerância a ruídos, generalização) podem ser usadas em conjunto com técnicas convencionais, para criar um computador mais poderoso, capaz de resolver problemas antes impossíveis.

5.4. Treinamento de uma rede de Kohonen para reconhecimento de padrões informacionais

Nesta seção, apresentaremos o resultado do treinamento de um simulador da rede de Kohonen (SOM), que faz o reconhecimento de padrões de *inputs* informacionais, isto é, que gera um padrão de saída o mais próximo possível do padrão de *input* que lhe foi provido. O *software* utilizado foi o *Kohonen Network Simulator*, versão 1.1, o qual acompanha o livro *Understanding neural networks: computer explorations*, dos autores Caudill e Butler (1992).

A rede SOM possui uma camada de *input* e outra camada de Kohonen, a qual o programa permite ter de 1 a 10 UNS's em cada um dos seus dois lados (x e y). Nossa rede terá o tamanho de 5x7 na camada de *input* e 10x10 na camada de Kohonen. Terminada a definição da quantidade de UNS's das camadas, o programa permite escolher como será a camada de Kohonen, entre as opções: *linear*, *grid* ou *hexagonal*. Escolhemos a forma *grid*, pois a visualização da resposta é melhor. Outros parâmetros que o programa nos permite alterar são os seguintes:

- a taxa de aprendizagem, que pode variar de 0.00 a 0.99. É importante citar que, quanto menor for a taxa de aprendizagem, mais demorado será o treinamento. A resposta obtida será, no entanto, mais próxima do padrão de *input*. Optamos por uma taxa de

aprendizagem de 0.6, pois a partir dessa taxa já podemos obter uma resposta aceitável, sem prolongar muito o treinamento;

- o tamanho da vizinhança inicial, que pode variar de 0 a 5. Vale lembrar que quanto maior o raio de vizinhança melhor será o resultado obtido, pois uma maior quantidade de UNS's estará participando da competição, e terão igual probabilidade de serem ou a UNS vencedora ou, pelo menos, a vizinhança dela. Nesse treinamento adotamos o valor 4, pois somente a partir desse valor o resultado será o melhor possível;
- o critério de treinamento, ou seja, o valor mínimo aceitável para encerrar o treinamento, da diferença entre a UNS vencedora e o padrão de *input*. O programa nos oferece os valores entre 0.0 a 10.0 e optamos pelo valor 0.5, pois a partir desse valor já obtemos um mínimo aceitável;
- os padrões de *input* podem ser, de acordo com o software, arquivos (.dat) binários, dos quais podemos escolher entre: o *alphabet.dat*, o *volwers.dat*, e o *volwels2.dat*. Escolhemos o arquivo *alphabet.dat*, o qual possui todas as letras do alfabeto como padrões de *input*, por ser dos três, o arquivo cujos dados são visualmente mais legíveis. Cada uma das letras do arquivo *alphabet.dat* são dispostas em uma grade matricial 5x7 (motivo pelo qual escolhemos no início o tamanho 5x7 para a camada de *input*), em que a distribuição do elemento binário 1.0 representa o símbolo da respectiva letra. A tabela 2, exemplifica as letras A, B, C, D e E desse arquivo, sendo que o mesmo contém 26 letras.

Letra do Alfabeto	Representação binária
A	0.0 0.0 1.0 0.0 0.0
	0.0 1.0 0.0 1.0 0.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 1.0 1.0 1.0 1.0
	1.0 0.0 0.0 0.0 1.0
B	1.0 1.0 1.0 1.0 0.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 1.0 1.0 1.0 0.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 1.0 1.0 1.0 0.0
C	0.0 1.0 1.0 1.0 0.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 0.0
	1.0 0.0 0.0 0.0 0.0
	1.0 0.0 0.0 0.0 0.0
	1.0 0.0 0.0 0.0 1.0
	0.0 1.0 1.0 1.0 0.0
D	1.0 1.0 1.0 1.0 0.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 0.0 0.0 0.0 1.0
	1.0 1.0 1.0 1.0 0.0
E	1.0 1.0 1.0 1.0 1.0
	1.0 0.0 0.0 0.0 0.0
	1.0 0.0 0.0 0.0 0.0
	1.0 1.0 1.0 0.0 0.0
	1.0 0.0 0.0 0.0 0.0
	1.0 0.0 0.0 0.0 0.0
	1.0 1.0 1.0 1.0 1.0

Tabela 2: Exemplos das representações das letras do alfabeto no arquivo de input (Alphabet.dat). Destacamos em negrito e itálico os valores 1.0 na tabela para facilitar a visualização das letras.

Resumidamente, a rede por nós constituída apresenta os seguintes parâmetros: 35 UNS's na camada de *input*, 100 UNS's na camada de Kohonen, taxa de aprendizagem de 0.6, tamanho da vizinhança inicial de 4, critério de treinamento de 0.5 e

os padrões de *input* contidos no arquivo ALPHABET.DAT. A figura 17 mostra como a rede está na tela do monitor, antes de iniciarmos o treinamento.




Figura 17: Definição da rede de Kohonen antes de inicializar o treinamento, extraído da tela do software de simulação utilizado.

Durante o treinamento, os padrões de *input* foram apresentados ao SOM, de forma iterativa, em subconjuntos ou passagens de 26 em 26 ciclos de treinamento, até chegar ao total de iterações desejada. O programa permite fazer quantas iterações desejarmos. Nesse treinamento, escolhemos 104, 520, 1560, 3016 e 10036 iterações, a fim de acompanhar o aprendizado da rede desde o início - quando o reconhecimento do padrão de *input* não tem um valor aceitável, até a rede apresentar o padrão de resposta aceitável e se estabilizar daí em diante. Na tela do micro, a janela do programa é dividida em três partes, como mostra a figura 17. Na parte superior da janela, visualizamos o padrão da camada de *input* sendo apresentado à camada de Kohonen e o nó vencedor do referido *input* sendo encontrado na mesma. Ao lado, paralelo ao processo, o programa nos permite

acompanhar como está a aprendizagem da rede de cada ciclo da passagem, mostrando como estão as conexões dos pesos vencedores, o que é possível identificar devido à intensidade da cor das UNS's, conforme a escala de cores à esquerda da janela. Já na parte inferior esquerda da janela, podemos visualizar o resumo de alguns parâmetros da rede, escolhidos para o treinamento; e na parte inferior direita, encontramos dois gráficos: o primeiro é o da média da distância das UNS's vencedoras e dos padrões de *input* no final de cada passagem de treinamento e o outro, referente à distância entre cada UNS vencedora e cada padrão de *input* apresentado em cada ciclo da passagem de treinamento.

No final de 104 iterações, a rede parou na tela, como mostra a figura 18:




Figura 18: Tela extraída do software SOM, no final de 104 iterações.

Optaremos por mostrar a tela somente com o resultado do padrão (ou letra) Z. Sabe-se que o mesmo tipo de resultado apresentado para a letra Z ocorre também com as outras 26 letras apresentadas à rede. Internamente, sem que possamos visualizar na tela do micro, o programa SOM nos permite escolher se queremos ou não gerar um arquivo

de relatório (*.rpt) durante o treinamento, contendo informações, tais como, os padrões apresentados em um ciclo do treinamento, a posição na grade da UNS vencedora de cada padrão do ciclo e seu respectivo conteúdo. No final de uma passagem, ou seja, de 26 ciclos apresentados à rede, o arquivo também mostra a média da distância dos ciclos da passagem de treinamento e a pior diferença do padrão do ciclo de passagem e do peso da UNS vencedora em valores. Optamos por gerar um arquivo de relatório e demos o nome de alfa.rpt. Com 104 iterações, o seguinte resultado foi apresentado no arquivo, na última passagem (26 ciclos das 104 iterações):

UNS's vencedoras (linha, coluna)	Distancia do padrão de <i>Input</i> respectivo
6,0	2.7125
3,7	1.9637
6,7	2.1387
3,4	1.8045
0,7	2.5362
0,3	1.5789
3,4	1.9878
5,1	1.3652
1,6	0.3217
2,8	0.2995
7,6	2.6584
4,7	0.7665
5,1	2.1290
5,1	1.3809
3,4	1.4055
2,3	1.8161
3,4	1.6794
2,3	1.7604
3,4	2.7784
1,6	0.3029
8,4	1.4932
4,2	0.3376
8,4	1.4300
9,5	2.0201
5,9	0.2426
9,5	2.0204

Tabela 3: Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 104. A linha com preenchimento contém a UNS's com a diferença maior em relação ao padrão de input.

- Distância média da passagem (26 ciclos) 1.574235.



- A pior distância dessa passagem: 2.7784 na sequência de número 19 da tabela.

Na primeira coluna da tabela, mostramos a posição das UNS's vencedoras, cada uma representando um padrão informacional, dos 26 que foram apresentados. Na segunda coluna, mostramos como está a diferença entre a UNS vencedora e o referente padrão de *input*. Como podemos ver nessas 26 últimas iterações das 104 feitas, o padrão de resposta apresentado pela rede ainda está muito distante do ideal. Continuando o treinamento, após 520 iterações entre as UNS's de processamento, envolvidas na primeira simulação, a rede nos apresentou na tela (ver figura 19) e no programa interno alfa.rpt (ver tabela 4), o seguinte resultado:

Na tela:




Figura 19: Tela extraída do software SOM, no final de 520 iterações.

No arquivo alfa.rpt, as 26 últimas iterações estavam com as seguintes configurações:

UNS's vencedoras (linha, coluna)	Distancia do padrão de <i>Input</i> respectivo
6,0	0.0000
1,5	1.4286
0,5	0.0000
1,5	1.4286
0,4	0.1585
0,2	0.0000
8,3	0.0000
7,1	0.0000
1,6	0.0000
2,8	0.0000
7,6	0.0000
1,3	0.1568
1,1	0.0000
3,1	0.0000
9,0	0.0000
0,0	0.0000
9,1	0.0000
2,0	0.0000
3,5	0.0000
1,7	0.0000
8,0	0.0000
4,2	0.0000
6,8	0.0000
9,5	0.0000
5,9	0.0000
9,9	0.0000

Tabela4: Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 520.

- Distância média da passagem (últimos 26 ciclos) 0.122014.
- A pior distância dessa passagem: 1.428571 na sequência de número 02 da tabela.

Como podemos constatar pelo gráfico da figura 19 e pela tabela 4, os valores das distancias das UNS's vencedoras estão estabilizando-se, mas ainda podem ser melhorados. Então, continuamos o treinamento, aplicando agora 1560 iterações entre as unidades de processamento envolvidas no treinamento, cujo resultado obtido na tela (ver figura 20) e no arquivo Alfa.rpt (ver tabela 5), foi o seguinte:

Na tela:




Figura 20: Tela extraída do software SOM, no final de 1560 iterações.

No arquivo alfa.rpt, as 26 últimas iterações estavam com as seguintes configurações:

UNS's vencedoras (linha, coluna)	Distancia do padrão de <i>Input</i> respectivo
6,0	0.0000
1,5	1.4286
0,5	0.0000
1,5	1.4286
0,4	0.0634
0,2	0.0000
8,3	0.0000
7,1	0.0000
1,6	0.0000
2,8	0.0000
7,6	0.0000
1,3	0.0627
1,1	0.0000
3,1	0.0000
9,0	0.0000
0,0	0.0000

9,1	0.0000
2,0	0.0000
3,5	0.0000
1,7	0.0000
8,8	0.0000
4,2	0.0000
6,8	0.0000
9,5	0.0000
5,9	0.0000
9,9	0.0000

Tabela 5: Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 1560.

- Distância média da passagem (últimos 26 ciclos) 0.114740.
- A pior distância dessa passagem: 1.428571 na sequência de número 02 da tabela.

A partir de 2000 iterações, a rede se estabilizou, ou seja, sua resposta continua a mesma, independentemente de quantas iterações sejam feitas a mais. A diferença entre suas respostas e os padrões de *inputs* fica em um valor mínimo aceitável e não diminui mais. Pelo gráfico da tela ou pelo arquivo de dados internamente gerado, tudo permanece sem alteração: os vencedores continuam na mesma posição na grade da rede e com os mesmos valores. A figura 21 mostra a tela do monitor e a tabela 6 mostra o arquivo interno gerado (alfa.rpt) com os resultados finais obtidos em 3016 iterações.




Figura 21: Tela extraída do software SOM, no final de 3016 iterações.

No arquivo alfa.rpt, as 26 últimas iterações das 3016 estavam com as seguintes configurações:

UNS's vencedoras (linha, coluna)	Distancia do padrão de <i>Input</i> respectivo
6,0	0.0000
1,5	1.4286
0,5	0.0000
1,5	1.4286
0,7	0.0000
0,2	0.0000
8,3	0.0000
7,1	0.0000
1,6	0.0000
2,8	0.0000
7,6	0.0000
0,4	0.0000
1,1	0.0000
3,1	0.0000
9,0	0.0000
0,0	0.0000
9,1	0.0000
2,0	0.0000
3,5	0.0000
1,7	0.0000

8,8	0.0000
4,2	0.0000
6,8	0.0000
9,5	0.0000
5,9	0.0000
9,9	0.0000

Tabela 6: Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 3016.

- Distância média da passagem (últimos 26 ciclos) 0.109890
- A pior distância dessa passagem: 1.428571 na sequência de número 02 da tabela.

Finalizando o treinamento, mostramos na figura 22 a tela do monitor e a tabela 7 com o resultado do arquivo Alfa.rpt, após 10036 iterações consecutivas, para confirmar que a partir de 2000 iterações, nada mais será alterado.

Na tela:




Figura 22: Tela extraída do software SOM, no final de 10036 iterações.

No arquivo alfa.rpt , as 26 últimas iterações das 10036 estavam com as seguintes configurações:

UNS's vencedoras (linha, coluna)	Distancia do padrão de <i>Input</i> respectivo
6,0	0.0000
1,5	1.4286
0,5	0.0000
1,5	1.4286
0,7	0.0000
0,2	0.0000
8,3	0.0000
7,1	0.0000
1,6	0.0000
2,8	0.0000
7,6	0.0000
0,4	0.0000
1,1	0.0000
3,1	0.0000
9,0	0.0000
0,0	0.0000
9,1	0.0000
2,0	0.0000
3,5	0.0000
1,7	0.0000
8,8	0.0000
4,2	0.0000
6,8	0.0000
9,5	0.0000
5,9	0.0000
9,9	0.0000

Tabela 7: Resumo do resultado obtido do arquivo Alfa.rpt, nas últimas 26 iterações de um total de 10036.

- Distância média da passagem (últimos 26 ciclos) 0.109890
- A pior distância dessa passagem: 1.428571 na sequência de número 02 da tabela.

Com esse treinamento foi possível verificar que a rede, ao encontrar o valor mínimo aceitável para o erro, estabiliza e apresenta sempre o mesmo resultado, independentemente de quantas iterações forem feitas. Os padrões corretos de saída encontrados pela rede não foram dados de antemão, e não houve a necessidade de nenhum agente externo para auxiliá-la a encontrá-los. Com o decorrer do treinamento, a rede foi-se corrigindo até desenvolver padrões informacionais mais próximos dos padrões de *input* que foram apresentados.

Na próxima seção, faremos uma comparação do comportamento desta rede, verificado neste treinamento, com o hábito geral peirciano para descobrirmos se esta rede de Kohonen pode adquirir hábitos gerais.

5.5 Rede de Kohonen versus Hábito geral peirciano

Como pudemos observar na seção anterior, o treinamento que fizemos com o simulador da rede de Kohonen, cujo nome é *Kohonen Network Simulator*, versão 1.1 (CAUDILL; BUTLER, 1992), foi muito satisfatório.

Antes de iniciarmos o treinamento, definimos alguns parâmetros ajustáveis que o programa nos permite alterar, tais como, a quantidade de UNS's da camada de *input* e da camada de Kohonen, a taxa de aprendizagem, o tamanho inicial da vizinhança, o critério de treinamento e os padrões de *inputs* que inserimos na rede. Conforme as iterações dos padrões de *inputs* foram ocorrendo durante o treinamento, a rede de Kohonen sozinha, sem nenhuma intervenção nossa e sem que os padrões de saída corretos fossem dados de antemão, foi gradativamente aprendendo a representar os padrões de *inputs*, por meio do reconhecimento das regularidades de tais padrões, até que a diferença entre os padrões de *inputs* apresentados à rede e a resposta (*output*) a esta diferença fossem um valor baixíssimo (nesse treinamento igual a 0.109890) e, conseqüentemente, aceitável. Após 2000 iterações, a rede de Kohonen aprendeu a generalizar, estabilizou-se e sua resposta continuou a mesma, independentemente de quantas iterações a mais fossem feitas.

Com esse treinamento, pudemos verificar que o padrão de saída correto, apresentado pela rede de Kohonen, pode ser considerado um conhecimento adquirido, de



acordo com o conceito de Peirce, visto que para esse autor (CP 2.335), como já citado na seção 4.2, do capítulo 4, o conhecimento é uma forma de representar o real, o qual é adquirido cometendo-se erros, corrigindo-os, até obter-se um aperfeiçoamento a fim de representar o real o melhor possível.

Como a característica mais interessante da rede de Kohonen é errar e corrigir seus erros até conseguir apresentar um padrão de saída o mais próximo do padrão de *input*, podemos dizer que ela aprende a generalizar certos comportamentos, a partir dos exemplos (*inputs*) processados, isto é, do reconhecimento das regularidades dos padrões de *inputs* apresentados.

Assim, ao compararmos a rede de Kohonen por nós testada com a abordagem do hábito geral constituído logicamente por idéias, pudemos verificar que a rede de Kohonen é capaz de realizar as três principais classes de raciocínio, as quais, segundo Peirce, podem interferir na formação do hábito geral: a indução, a inferência hipotética e a dedução (PEIRCE, CP 6.144-145).

Como citado na seção 4.2, do capítulo 4, deste trabalho, para Peirce (CP 6.145), a indução é o processo efetivo pelo qual um hábito geral é estabelecido ou alterado. Este processo consiste em fazer associações de várias sensações que seguem a mesma reação, formando uma idéia geral que seguirá a mesma reação. No treinamento da rede de Kohonen, apresentamos à rede os padrões de *inputs* e a rede (sozinha) foi associando estes *inputs*, reconhecendo suas regularidades, até constituir uma idéia geral, ou seja, até aprender a generalizar, representando um comportamento geral ou padrão de saída correto.

Para conseguir realizar a indução e generalizar corretamente seu comportamento, primeiro a rede de Kohonen cometeu erros. Ou seja, com as repetições dos padrões de *inputs*, a rede testou várias hipóteses provisórias, criando a cada instante, padrões ou formas destes *inputs*. Quando a rede encontrou o padrão ou forma corretos, isto



é, mais próximo dos padrões de *inputs*, a rede não testou mais hipóteses, pois sua conduta correta foi estabelecida. Com isso, acreditamos que a rede de Kohonen realizou um certo tipo de inferência hipotética, tal como apresentada por Peirce (CP 6.145), fazendo associações destas hipóteses (formas) produzidas, e constituindo uma idéia geral destas, a qual ocorrerá sempre que o mesmo *input* for apresentado à rede.

Ao aprender a apresentar uma resposta geral correta de um padrão de *input*, sempre que o mesmo for inserido na rede de Kohonen, automaticamente esta apresentará o padrão de saída correto aprendido com o primeiro padrão de *input*. Assim, a rede produz o que Peirce (CP 6.144) chama de dedução, repetindo reações conseqüentes de hábitos já adquiridos em uma determinada ocasião.

Já na abordagem do hábito geral, fisicamente constituído, a formação do hábito geral nas células nervosas, segundo Peirce (CP 1.390), depende de cinco princípios, citados na seção 4.2 do capítulo 4. Comparando o resultado da rede treinada na seção anterior com estes princípios, observamos que o primeiro princípio pode ser realizado pela rede de Kohonen, se o estímulo ou a irritação que chega na célula nervosa for visto como o padrão de *input* que é inserido nas UNS's da camada de *input* da rede de Kohonen. Estas UNS's, diretamente afetadas, passam tais *inputs* para as UNS's conectadas a elas, aumentando também a intensidade.

O segundo e terceiro princípios podem ser realizados pela rede de Kohonen, se a fadiga que começa após algum tempo (segundo princípio), fazendo a célula vir a alterar o caminho (ou caminhos) de sua descarga até encontrar o caminho que remova a origem da irritação (terceiro princípio), sejam interpretados como sendo os erros da rede. Isto é, as respostas incorretas apresentadas pela rede e as quais a rede vai alterando (corrigindo), enquanto a resposta correta não for encontrada. Ao apresentar a resposta correta, a rede se estabiliza e nenhuma outra alteração é feita.



O quarto princípio pode ser realizado pela rede de Kohonen, se a mesma célula que foi excitada uma primeira vez, vier a ter uma segunda excitação (igual à primeira), tendo sua descarga ao longo do mesmo caminho (ou caminhos) da primeira vez, e for entendida como sendo um segundo padrão de *input* (igual ao primeiro), chegando à rede e seguindo um caminho similar ao primeiro. Tal fato se deve a que as conexões laterais da UNS vencedora e das suas vizinhas, na rede de Kohonen, tenderão a ficar cada vez mais fortes e a serem mais alteradas, definindo o caminho pelo qual o segundo *input* ou outros posteriores a ele, passarão.

Finalmente, o quinto princípio poderá ser realizado pela rede de Kohonen, se o princípio de desatento ou hábito negativo, o qual não permite que a célula nervosa reaja de outra maneira, for pensado como sendo as conexões laterais inibitórias das UNS's que estão mais distantes da UNS vencedora e que ficarão cada vez mais fracas, não sendo alteradas e não havendo a possibilidade de experenciação da aprendizagem.

Ao verificarmos que a rede de Kohonen é capaz de realizar as três classes principais de raciocínio (abordagem do hábito geral constituído logicamente) como também de simular os cinco princípios citados acima (abordagem do hábito geral constituído fisicamente por seres dotados de sistema nervoso), concluímos que a mesma, ao apresentar um padrão de saída correto, pode ter adquirido um hábito geral, visto que as classes de raciocínio e os cinco princípios, segundo Peirce, permitem formar hábitos genuinamente gerais.

O hábito geral adquirido é previsível, segundo Peirce (CP 2.417), até encontrar alguma surpresa que traga dúvidas e incertezas, desestabilizando a sua regularidade. De forma similar, a rede de Kohonen, ao apresentar um padrão de resposta correto, tenderá para a regularidade constante, permanecendo organizada e não sofrendo alterações. E, se por meio de um sensor eletrônico ou de um arquivo, apresentarmos algum

ruído ou informação nova à rede, ela se desestabilizará e poderá se reorganizar de outra maneira, buscando encontrar a regularidade da nova realidade, na tentativa de se tornar mais forte e adaptável ao seu meio ambiente. Logo, a rede de Kohonen pode não apenas adquirir hábitos gerais, como pode também alterá-los em alguns casos.

Dessa forma, analisando o hábito geral de acordo com o conceito de Peirce, chegamos a mais uma conclusão: o caráter determinístico e o conceito de máquina puramente mecânica, tais como definidos por Peirce, não são encontrados na rede de Kohonen. Para Peirce, uma máquina que seja falível em seu comportamento e que, após algum tempo, aprenda a determinar uma conduta futura correta, sendo assim capaz de generalizar, é uma máquina não determinística e não puramente mecânica (SILVEIRA, 1998, p. 120). Ao proceder desta forma, a rede de Kohonen contradiz o caráter determinístico das máquinas puramente mecânicas, sendo capaz de aprender e de generalizar (sem uma intervenção externa) com seus erros. Conseqüentemente, o seu resultado correto apresentado no final do treinamento, pode ser considerado um hábito geral de conduta, de acordo com o conceito de hábito geral proposto por Peirce.

Por outro lado, verificamos que se fecharmos o programa de simulação da rede de Kohonen que treinamos, e novamente submetermos à rede ao mesmo processo de treinamento, com os mesmos parâmetros e padrões de *inputs*, a rede perde o aprendizado adquirido e recomeça a aprendizagem do zero. Isto ocorre porque a rede de Kohonen não tem uma função-memória para recuperar as informações adquiridas do treinamento anterior. Mas, independentemente deste problema, constatamos do ponto de vista formal, com nosso treinamento, que a rede de Kohonen procede como uma máquina que aprende, fazendo o que se espera que ela faça nos três raciocínios citados (dedução, indução e inferência hipotética). Se esse processo é feito até um determinado momento e

depois cessa, tal fato é irrelevante, passando a ser um problema puramente tecnológico e não conceitual.



6. CONSIDERAÇÕES FINAIS

Este trabalho se propôs a investigar se a rede neural de Kohonen, ao apresentar uma resposta correta, pode ter adquirido um hábito. Como o conceito de hábito é muito amplo e estudado por diversos pesquisadores, restringiu-se a abordar o conceito de hábito geral da teoria peirciana.

No início, procurou-se enfocar esta pesquisa pela abordagem da Ciência Cognitiva, sua história e suas principais vertentes. Assim, verificou-se que a Ciência Cognitiva é uma ciência interdisciplinar, já que leva à interação áreas como a filosofia, a psicologia, a inteligência artificial, a lingüística, a antropologia e a neurociência. Essa ciência possui suas raízes no movimento cibernético, herdando deste sua preocupação com o entendimento do comportamento dos organismos e das máquinas, apoiando-se na construção de modelos computacionais para explicar a natureza da inteligência. Tais modelos computacionais caracterizam as suas duas principais vertentes: Inteligência Artificial (IA) ou Cognitivismo Ortodoxo e Redes Neurais Artificiais (RNA) ou Conexionismo.

No modelo computacional da IA, a mente cognitiva é entendida como um programa de manipulação de símbolos, com as regras algorítmicas seguindo um procedimento serial, sem importar o seu suporte físico (*hardware*).

Em oposição aos modelos propostos na IA, nos modelos da RNA ou Conexionismo, a atividade cognitiva é uma propriedade emergente da interação entre seus elementos, interconectados em rede. O processamento destes modelos é paralelo e distribuído, e o seu suporte físico (*hardware*) é muito importante. Tais modelos são estruturados em redes de neurônios simples (UNS's), cuja aprendizagem é regida por leis físicas.



Após esclarecer que este trabalho é desenvolvido na vertente conexionista da Ciência Cognitiva, partiu-se para as abordagens dos conceitos necessários a fim de sustentar a investigação pretendida. Como o objetivo deste trabalho é investigar se a rede de Kohonen adquire o hábito geral peirciano, fez-se necessário, primeiramente, saber o que é a RNA, como funciona a rede neural de Kohonen, o que é hábito geral peirciano, e com base nestes conceitos, concluir tal investigação.

O primeiro conceito abordado foi o de RNA. Em tal abordagem, enfatizou-se que os modelos computacionais desta área são desenvolvidos a partir do entendimento do funcionamento do cérebro. Para entender este funcionamento, analisaram-se as funções básicas dos neurônios naturais, pois os mesmos inspiram o funcionamento dos neurônios artificiais ou UNS's, com as quais a rede neural trabalha.

Ressaltou-se que as UNS's, conectadas e organizadas em camadas, formam a estrutura das RNA's. Associado a cada par de UNS's conectadas, existe um valor ajustável, chamado de peso, que pode ser alterado durante a execução da rede, de forma a melhorar seu desempenho. Verificou-se também que, de acordo com a aplicação, os modelos de RNA's podem diferir uns dos outros, quanto à quantidade de camadas e de UNS's, aos mecanismos de aprendizagem, ao esquema de alimentação, etc. Desses diferentes modelos, analisou-se o Perceptron de camada simples e de várias camadas, o Backpropagation e, com mais detalhes a rede de Kohonen, pela qual se tem um maior interesse neste trabalho.

Viu-se que o modelo de Kohonen possui uma peculiaridade em sua camada de *output*: as conexões ou inibições laterais entre as UNS's daquela camada. Esta característica permite que, a partir das UNS's interconectadas, a rede consiga encontrar a resposta correta, sem que esta tenha sido dada de antemão e sem ajuda externa, motivo pelo qual o treinamento desta rede é considerado não supervisionado ou auto-organizado.

Durante o treinamento não supervisionado ou auto-organizado, os pesos das conexões das UNS's da rede são modificados, apoiando-se apenas na detecção de regularidades presentes nos padrões de *inputs* recebidos do exterior. O ajuste dos pesos das conexões das UNS's provoca a formação de mapas de característica auto-organizadoras.

No decorrer do trabalho, para entender como é o treinamento não supervisionado ou auto-organizado da rede de Kohonen, passou-se a abordar o conceito de auto-organização e suas modalidades, observando-se as noções de organização, máquinas em geral, condições de partida, elementos distintos e forma ou organização final. Verificou-se que o conceito de A-O procura compreender o processo de surgimento espontâneo de padrões, formas ou organização (tanto nos sistemas biológicos e físicos, quanto nos sistemas artificiais), a partir das interações entre elementos, sem a necessidade de um supervisor externo, ou de um centro organizador. Tais surgimentos espontâneos de padrões, formas ou organizações, podem ocorrer em duas modalidades: na A-O primária e na A-O secundária.

Constatou-se que a primeira A-O ocorre quando elementos desorganizados e independentes passam, com o tempo, para organizados, constituindo uma forma ou organização. A segunda A-O ocorre quando a organização adquirida, altera-se para uma organização melhor.

Com esta abordagem da A-O, verificou-se a presença de propriedades dos processos de A-O na rede de Kohonen, tais como: a dinâmica de cooperação e competição que se estabelece entre seus elementos, bem como a ausência de um elemento supervisor externo, no ajuste de parâmetros internos.

Em seqüência às abordagens dos conceitos essenciais para sustentar esta investigação, analisou-se o que é hábito geral para Peirce. Assim, observou-se que o conceito de hábito geral peirciano possui duas abordagens: a abordagem dos hábitos gerais

constituídos logicamente e a abordagem dos hábitos gerais constituídos fisicamente em seres dotados de sistema nervoso.

Na primeira abordagem, o hábito geral é estabelecido e alterado por idéias e raciocínios. Enquanto que, na segunda abordagem citada acima, o hábito geral é estabelecido e alterado por atos de reações nas células do sistema nervoso. Independentemente das duas abordagens, verificou-se que o hábito geral peirciano é uma lei, a qual pode ser alterada por seu próprio controle. Como, para Peirce, o hábito geral não é um privilégio somente dos seres humanos, constatou-se que tudo no universo tem uma tendência à aquisição de hábitos, isto é, uma tendência a obedecer a leis, a generalizar certas regularidades, formando um conhecimento que pode ser modificado por seu próprio controle. Porém, um sistema que disponha exclusivamente da lei mecânica, segundo Peirce, não aprende, pois está paralisado por hábitos fixos e rígidos. Mas algo que disponha de alguma coisa a mais, além do meramente mecânico, pode aprender e, por conseguinte, adquirir hábitos gerais.

Com estes conceitos fundamentais analisados, partiu-se para a etapa mais esperada deste trabalho: a comparação da rede de Kohonen com o conceito de hábito geral peirciano, com vista a verificar se esta rede pode adquirir tal hábito.

Para tanto, analisou-se, com mais detalhes, a rede de Kohonen: seu algoritmo de aprendizagem, bem como o método de ajuste fino, que consiste em uma técnica para aumentar a eficiência desta rede no reconhecimento de padrões para a qual foi treinada. Na seqüência, efetuou-se o treinamento de um simulador da rede de Kohonen, que faz o reconhecimento de padrões de *inputs* informacionais, utilizando o *software Kohonen Network Simulator*, versão 1.1.

Com esta análise, observou-se que, conforme as iterações dos padrões de *inputs* foram ocorrendo no treinamento, a rede de Kohonen sozinha, sem nenhuma



intervenção externa e sem que os padrões de saída corretos fossem dados de antemão, foi gradativamente aprendendo a representar os padrões de *inputs* de forma correta, errando no reconhecimento das regularidades dos padrões de *inputs* e corrigindo seus erros, até que a diferença entre os padrões de *inputs* apresentados à rede e a sua resposta fosse um valor muito baixo, e assim, aceitável. A partir desse momento, a rede se estabiliza, nenhuma outra alteração é realizada e sua resposta permanece a mesma, sejam quantas forem as iterações a mais.

Ao comparar este seu resultado apresentado com o hábito geral peirciano, concluiu-se que, como a rede de Kohonen no desenvolvimento do treinamento é capaz de generalizar por meio do reconhecimento das regularidades dos padrões de *inputs* e da correção dos seus erros (isto é, é capaz de aprender a reconhecer padrões de *inputs* apenas com a interação dos seus elementos internos interconectados, sem interferência externa), então, seu resultado apresentado no final do treinamento pode ser considerado uma aprendizagem, e conseqüentemente, um hábito geral de conduta. Ao proceder esta forma, a rede de Kohonen contradiz o caráter determinístico das máquinas puramente mecânicas, possuindo algo mais; além do mecânico.

Entretanto, constatou-se também, que existem algumas limitações na rede de Kohonen, como por exemplo, a falta de uma função-memória que, ao encerrar a rede, venha a impedir que esta perca suas informações adquiridas com o treinamento. Este é um problema de ordem tecnológica e questionamo-nos se o mesmo terá solução.

Também surgiu com esta investigação uma dúvida muito pertinente e intrigante. Investigou-se, neste trabalho, se a rede de Kohonen pode adquirir hábito geral peirciano e constatou-se que sim. Mas, e as outras classes de hábitos peircianos mais particulares, podem ser adquiridas por tais redes?



Estas perguntas abrem caminho para o desenvolvimento de novas e futuras pesquisas, objeto de outro trabalho.



REFERÊNCIAS

ASHBY, W.R. Principles of the Self-Organizing System. In: VON FOERSTER, H. ; ZOPF, Jr. G.W. (Org.). *Principles of self-organization*. Oxford: Pergamon, 1962, p. 255-278.

BEALE, R. ; JACKSON, T. *Neural computing: an introduction*. Bristol: Institute of Physics Publishing, 1994.p.107-131.

CAUDILL, M.; BUTLER, C. *Understanding neural networks: Computer Explorations*. Boston: Massachusetts Institute of Techonology, 1992.v.1.

DEBRUN, M. A idéia de auto-organização. IN: DEBRUN, M; GONZALES, M.E.Q; PESSOA, O.J. *Auto-organização: estudos interdisciplinares em Filosofia, Ciências Naturais e Humanas, e Arte*. Coleção CLE; v.18. Campinas: Unicamp – Centro de Lógica, Epistemologia e História da Ciência, 1996a.

DEBRUN, M. A dinâmica da auto-organização primária. IN: DEBRUN, M; GONZALES, M.E.Q; PESSOA, O.J. *Auto-organização: estudos interdisciplinares em Filosofia, Ciências Naturais e Humanas, e Arte*. Coleção CLE; v.18. Campinas: Unicamp – Centro de Lógica, Epistemologia e História da Ciência, 1996b.

DEBRUN, M. ; GONZALES, M.E.Q. ; PESSOA, O.J. *Auto-organização: estudos interdisciplinares em Filosofia, Ciências Naturais e Humanas, e Artes*. Coleção CLE; v.18. Campinas: Unicamp – Centro de Lógica, Epistemologia e História da Ciência, 1996.

D'OTTAVIANO, I.M.L.; GONZALES, M.E.Q. *Auto-organização: estudos interdisciplinares*. Campinas:Unicamp – Centro de Lógica, Epistemologia e História da Ciência, 2000.

DREYFUS, H.L. *O que os computadores não podem fazer: crítica da razão artificial*. Rio de Janeiro: Casa do Livro Eldorado, 1975.

DUPUY, J.P. *Nas origens das ciências cognitivas*. São Paulo: Editora Afiliada, 1996.

GARDNER, H.A. *The mind's new science: a history of cognitive revolution*. New York: Basic Books, 1985.

GARDNER, D. *The neurobiology of neural networks*. Boston: Massachusetts Institute of Techonology, 1993.



GARDNER, H.A. *A nova ciência da mente*. 2.ed. São Paulo: Edusp, 1996.

GONZALES, M.E.Q. Um estudo cognitivo-informacional das representações mentais. In Arantes P. (Org.). *Epistemologia e cognição*. Brasília: Universidade de Brasília, 1994.

GONZALES, M.E.Q. Ação, Causalidade e Ruído nas Redes Neurais Auto-Organizadas. IN: DEBRUN, M; GONZALES, M.E.Q; PESSOA, O.J. *Auto-organização: Estudos Interdisciplinares em Filosofia, Ciências Naturais e Humanas, e Arte*. Coleção CLE; v.18. Campinas: Unicamp – Centro de Lógica, Epistemologia e História da Ciência, 1996.

GONZALES, M.E.Q ; LUNGARZO, C.A. ; MILIDONI, C.B. ; PEREIRA, A. J. ; WRIGLEY, M.B. *Encontro com as ciências cognitivas*. 2.ed. Marília: Editora Unesp, 1997.

GONZALES, M.E.Q.; BROENS, M.C.; SERZEDELLO, J. Auto-organização, autonomia e identidade pessoal. In: D'OTTAVIANO, I.M.L.; GONZALES, M.E.Q. (Org.). *Auto-organização: estudos interdisciplinares*. Campinas: CLE/UNICAMP, 2000. v.30, p. 69-81.

HANSON, S.J.; OLSON, C.R. *Connectionist modeling and brain function: The Developing Interface*. Boston: The Massachusetts Institute of Technology, 1990.

HOPFIELD, J. *Neural networks and physical systems with emergent collective computational abilities*. USA, v.79, p. 2554-2558, 1982.

KOHONEN, T. *Self-organization and associative memory*. Berlin: Springer, 1987.

KOVÁCS, Z. L. *Redes neurais artificiais: Fundamentos e Aplicações*. Um texto básico – 2ª Edição. São Paulo: Edição Acadêmica, 1996.

KOVÁCS, Z.L. *O cérebro e a sua mente: uma introdução à neurociência computacional*. São Paulo: Edição Acadêmica, 1997.

LIPPMANN, R. An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine*, 1987, p.4-23.

RUMELHART, D. E; McCLELLAND, J. L. *Parallel distributed processing: Explorations in the Microstructure of Cognition*. Cambridge: The MIT Press, 3.ed., 1986.

McCULLOCH, W. S. ; PITTS, W. A logical Calculus of the ideas imminent in Nervous Activity. *Bulletin of mathematical biophysics*. New York: Oxford University Press, v. 5, 1943. p. 115-133.



MINSKY, L.M.; PAPERT, A.S. *Perceptrons: an introduction to computational geometry*. Massachussetts: MIT Press, 1969.

PEIRCE, C. S. *Collectec papers of Charles S. Peirce*. Cambridge: Harvard University Press, v. 1-6 edited by C. Hartshorne & P. Weiss; v.7-8 editado por A. W. Burks, 1934/1974.

SANTAELLA, L. *A teoria geral dos signos: semiose e autogeração*. São Paulo: Ática, 1995.

SEARLE, J.R. *A redescoberta da mente*. 1.ed., São Paulo: Ed. Martins Fontes, 1997.

SILVEIRA, L. F. B. Algumas considerações sobre máquinas semióticas do ponto de vista da Filosofia de Charles Sanders Peirce. In GONZALES, M.E.Q. (Org.); BROENS, M.C. (Org.) – *Encontro com as ciências cognitivas*. Marília: Unesp-Marília-Publicações, v. 2, 1998.

SILVEIRA, L. F. B. Diagramas e hábitos: interação entre diagrama e hábito na concepção peirciana de conhecimento. In GONZALES, M.E.Q.; et al. (orgs). *Encontro com as Ciências Cognitivas*. Marília: Marília/Unesp publicações/São Paulo, v.3, 2001. p.249-277.

SIMPSON, P. K. *Artificial neural systems: Foundations, Paradigms, Applications and Implementations*. San Diego:Pergamon Press, 1990.

WASSERMAN, P.D. *Neural computing: theory and practice*. New York: Van Nostrand Reinhold, 1989.

WIDROW, B. ; LEHR, M. 30 years of adaptative Neural Networks: Perceptron, Madaline, and Back-Propagation. *Proceedings of the IEEE*. New York: v.78, n.9, 1990. p.1415-1441.



BIBLIOGRAFIA CONSULTADA

ATLAN, H. *Entre o cristal e a fumaça*. Rio de Janeiro: Zahar, 1992.

BENNATON, J. *O que é cibernética*. São Paulo: Editora Brasiliense, 1986.

BUTTON, G.; COULTER, J.; LEE, J.R.R.; SHARROCK, W. *Computadores, mentes e conduta*. São Paulo: Editora Unesp, 1995.

DENNETT, D.C. *Tipos de mentes*. Rio de Janeiro: Ed. Rocco Ltda., 1996.

ÉVORA, F.R.R.(Ed.). *Espaço e tempo*. Campinas: Unicamp, Centro de Lógica, Epistemologia e História da Ciência, 1995.

KHALFA, J. et al. *A natureza da inteligência: uma visão interdisciplinar*. Tradução Luiz Paulo Rouanet. São Paulo: Fundação Editora da UNESP, 1996.

KOHONEN, T. The Neural Phonetic Typewriter. *IEEE Computer*. New York: v.21, n.3, 1988a. p.11-22.

KOHONEN, T. *An introduction to neural computing: Neural networks*. New York: Elmsford, v.1.1988b. p.3-16.

PESSIS-PASTERNAK, G. *Do caos à inteligência artificial: quando os cientistas se interrogam*. Tradução Luiz Paulo Rouanet. São Paulo: Editora da Universidade Estadual Paulista, 1993.

ROMESÍN, H.M. ; GARCIA, F.J.V. *De máquinas e seres vivos: autopoiese – a organização do vivo*. 3.ed. Porto Alegre: Artes Médicas, 1997.

SOARES, A.B. *O que são ciências cognitivas*. São Paulo: Brasiliense, 1993.



