



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

UM MODELO CONEXIONISTA PARA A GERAÇÃO DE MOVIMENTOS VOLUNTÁRIOS EM AMBIENTE DESESTRUTURADO

Autor: **André Mendeleck**

Orientador: **Prof. Dr. Douglas E. Zampieri**

ESTE EXEMPLAR CORRESPONDE A REDAÇÃO FINAL DA
TESE DEFENDIDA POR ANDRÉ MENDELECK
E APROVADA PELA
COMISSÃO JULGADORA EM 26 / 10 / 95.

Douglas E. Zampieri
ORIENTADOR

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

M522m Mendeleck, André
Um modelo conexionista para a geração de movimentos voluntários em ambiente desestruturado / André Mendeleck.--Campinas, SP: [s.n.], 1995.

Orientador: Douglas Eduardo Zampieri.
Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Redes neurais (Computação). 2. Aprendizado do computador. 3. Robótica.. 4. Robôs. 5. Inteligência artificial. 6. Hipocampo (Cérebro). I. Zampieri, Douglas Eduardo. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

202/05580198



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
DEPARTAMENTO DE MECÂNICA COMPUTACIONAL

UM MODELO CONEXIONISTA PARA A GERAÇÃO DE MOVIMENTOS VOLUNTÁRIOS EM AMBIENTE DESESTRUTURADO

Autor: **André Mendeleck**

Orientador: **Prof. Dr. Douglas E. Zampieri**

Curso: Engenharia Mecânica

Área de Concentração: Mecânica dos Sólidos

Tese de doutorado apresentada à comissão de Pós Graduação da Faculdade de Engenharia Mecânica, como requisito para a obtenção do título de Doutor em Engenharia Mecânica.

Campinas, 1995
S.P. - Brasil



UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
DEPARTAMENTO DE MECÂNICA COMPUTACIONAL

TESE DE DOUTORADO

**UM MODELO CONEXIONISTA PARA A
GERAÇÃO DE MOVIMENTOS VOLUNTÁRIOS
EM AMBIENTE DESESTRUTURADO**

Autor: **André Mendeleck**

Orientador: **Prof. Dr. Douglas E. Zampieri**

**Prof. Dr. Douglas Eduardo Zampieri, Presidente
UNICAMP - Universidade Estadual de Campinas**

**Prof. Dr. Marcio Luiz Andrade Neto
UNICAMP - Universidade Estadual de Campinas**

**Prof. Dr. Eurípedes E. G. Oliveira Nóbrega
UNICAMP - Universidade Estadual de Campinas**

**Prof. Dr. Paulo Eigi Miyagi
USP - Universidade de São Paulo**

**Prof. Dr. Atair Rios Neto
INPE - Instituto Nacional de Pesquisas Espaciais**

Campinas, 26 de outubro de 1995

**ESTA TESE CONTOU COM O APOIO FINANCEIRO DA
FAPESP - Fundação de Amparo À Pesquisa do Estado de São Paulo**

Dedicatória:

Dedico esta tese aos meus pais.

Agradecimentos

Durante os meses que passei trabalhando nesta tese contei, com o apoio de várias pessoas, das quais gostaria de destacar:

A Kátia Maria pelo incentivo e apoio em todos os momentos.

Ao meu orientador, Prof. Dr. Douglas Eduardo Zampieri, que me mostrou os caminhos a serem seguidos, pela seriedade na orientação, pelo apoio e confiança nas horas difíceis.

A vocês, obrigado pela ajuda.

Resumo

Mendeleck, André, *Um Modelo Conexionista para a Geração de movimentos voluntários em ambiente desestruturado*, Campinas,: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1995. 180 p. Tese (Doutorado)

Neste trabalho apresentamos uma estrutura neuronal artificial com auto-aprendizado para o auxílio à geração de trajetórias em um ambiente desestruturado,

O objetivo é formar uma sequência de valores de referência que podem auxiliar a definição de um caminho ou uma trajetória. A estrutura que estamos propondo foi inspirada no sistema neural biológico (principalmente a região hipocampal e cerebelar), redes neurais (principalmente rede tipo perceptron com treinamento pelo método de backpropagation) e nas teorias de aprendizado (principalmente a proposta por R. M. Gagnè).

Palavras Chave

1. Redes neurais (Computação), 2. Aprendizado do computador, 3. Robótica., 4. Robôs, 5. Inteligência artificial e 6. Hipocampo (Cérebro).

Abstract

Mendeleck, André, *A Connectionistic Model to Generate Voluntary Movement in Unknown Place*, Campinas,: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1995. 180 p. Tese (Master Degree)

In this paper we present a model using a connectionistic neural artificial net, operating in real time, to generate voluntary movement, with self learning, in unknown place. The model can help a robot to define a trajectory and to go round impediments. The neuronal structure is based in hippocampal theory and R. M. Gagnè learning theory.

Key Words

1. Neural net (Computation), 2. Learning, 3. Robotic., 4. Robot, 5. Artificial Intelligence e 6. Hippocampal (Brain).

ÍNDICE

INTRODUÇÃO 1

I REDES NEURAIS

(REDE NEURAL ARTIFICIAL)

1. Introdução 1
2. Rede Perceptron multi-camada 9
3. Rede Hopfield 15
4. Rede Bidirectional associative memory 19

II SISTEMAS BIOLÓGICOS

(SISTEMAS BIOLÓGICOS)

1. Introdução 1
2. O Neurônio 6
3. O Cerebelo 9
4. O Hipocampo 19

III APRENDIZADO

(APRENDIZADO)

1. Introdução 1
2. J. B. Watson 4
3. Ivan P. Pavlov 5
4. E. R. Guthrie 7
5. W. K. Estes 9
6. E. L. Thorndike 11
7. N. Miller 16
8. C. L. Hull 16
9. B. F. Skinner 23
10. Gestalt 25
11. E. C. Tolman 29
12. J. Piaget 32
13. R. M. Gagnè 35
14. Aprendizado de máquina 40

IV O SISTEMA

(SISTEMA)

1. Introdução	1
2. O mecanismo sensor	2
2.1 A estrutura do mecanismo sensor	2
2.2 Movimento do cursor durante o aprendizado	7
2.3 Mudança de direção do cursor durante o aprendizado	9
2.4 Seleção de uma nova direção de movimento durante o aprendizado	11
3. A estrutura neural para o aprendizado	14
4. A estrutura neuronal	22

V SIMULAÇÕES

(SIMULAÇÃO)

1. Introdução	1
2. Simulações	2

VI CONCLUSÃO

VII BIBLIOGRAFIA

LISTA DE FIGURAS

INTRODUÇÃO

FIGURA II. Layout de uma sistema para geração de trajetória.

I REDES NEURAIS

- FIGURA RNA1. Estímulos externos aplicados no córtex cerebral (principalmente nas áreas motoras) produz movimentos dos membros.
- FIGURA RNA2. (A) Neurônio artificial. (B) Liberação de neuro-transmissores na conexão sináptica.
- FIGURA RNA3. Uma rede formada por um único neurônio permite selecionar dois estados.
- FIGURA RNA4. Rede com duas camadas permite isolar uma faixa de valores
- FIGURA RNA5. Rede com 3 camadas permite isolar áreas de conhecimento.
- FIGURA RNA6. Layout de uma rede Perceptron com 3 camadas.
- FIGURA RNA7. Mínimos locais obtidos durante o treinamento da rede..
- FIGURA RNA8. Layout da rede de Hopfield.
- FIGURA RNA9. Layout de uma rede BAM.

II SISTEMAS BIOLÓGICOS

- FIGURA B1. Estímulos externos e internos fornecem informações para o sistema nervoso ativa uma ação muscular ou troca o seu estado.
- FIGURA B2. Cérebro.
- FIGURA B3. Sistema nervoso, coluna vertebral e medula.
- FIGURA B4. Hemisfério esquerdo e hemisfério direito do cérebro e suas subdivisões em lobos.
- FIGURA B5. Layout de um neurônio e terminação sináptica.
- FIGURA B6. Variação de tensão no *soma* indicando um potencial de ação.
- FIGURA B7. Detalhe da variação de potencial no dendrito.
- FIGURA B8. Localização do cerebelo no sistema nervoso.
- FIGURA B9. Layout de algumas vias de comunicação entre o cerebelo e outros núcleos no sistema nervoso (não representamos todas as conexões). A via que liga o córtex motor aos músculos passa por neurônios internunciais, neurônios motor gama e nerônio motor alfa [MAC-80].
- FIGURA B10. Layout do segmento de uma folha cerebelar [MAC-80].
- FIGURA B11. Um dos principais circuitos cerebelar.
- FIGURA B12. Circuitos no cerebelo [ECC-67].

- FIGURA B13. Vias de comunicação cérebro-cerebelar unindo o córtex motor e de associação ao cerebelo [ALLE-74].
- FIGURA B14. Layout do principal circuito cerebelar implementado no sistema.
- FIGURA B15. Localização do hipocampo.
- FIGURA B16. Layout da estrutura hipocampal [BROD-84] [O'MAR-95] de um roedor. FMX: fórmix; SO: stratum oriens; CA1, CA2, CA3 e CA4: subdivisões do Ammon's horn; HGD: hilus do giro denteado; GD: giro denteado; S: subiculum; PRES: pré-subiculum; PARS: Para-subiculum; CE: córtex entorrinal; CP: córtex perirrinal
- FIGURA B17. Estrutura lamelar [LOTH-91].
- FIGURA B18. Principais vias de comunicação no hipocampo.
- FIGURA B19. (A)Principal via de comunicação no hipocampo [WEST-90]. (B) Principal via de comunicação no hipocampo e tipos de células.[AMARA-90a].
- FIGURA B20. Layout da área de trabalho utilizada por Barnes [BARN-90]
- FIGURA B21. Layout da área de trabalho utilizada por [O' MAR-94].
- FIGURA B22. Resposta de um neurônio e função do tipo de movimento e da orientação da cabeça de um macaco [O'MAR-94].
- FIGURA B23. Detalhe da rede neural proposta por Zipser [ZIPS-85] [ZIPS-88].
- FIGURA B24. Layout geral da rede neural proposta por Zipser [ZIPS-85] [ZIPS-88].
- FIGURA B25. Região da área de trabalho mapeada por um neurônio.
- FIGURA B26. Região circular da área de trabalho mapeada por um neurônio.

III APRENDIZADO

- FIGURA A1. Conjunto de estímulos que provocam respostas diferentes.
- FIGURA A2. Curva de tempo de aprendizado x número de tentativas para "insight" e aprendizado incremental.
- FIGURA A3. Alguma similaridade entre estímulos diferentes é capaz de desencadear a resposta desejada.
- FIGURA A4. Variância (ruído) de um mesmo estímulo produz a mesma resposta.
- FIGURA A5. Integração de estímulos.
- FIGURA A6. Estímulo discriminativo produz resposta secundária que desencadeia estímulos secundários que reforçam a resposta principal.
- FIGURA A7. Cadeia de estímulos-respostas.
- FIGURA A8. Diagrama relacionando as variáveis propostas por Hull.
- FIGURA A9. Layout da área de treinamento.
- FIGURA A10. Caminho de treinamento é obstruído e caminhos secundários são liberados.
- FIGURA A11. Sequenciamento de estágios de aprendizado.
- FIGURA A12. Tipos de aprendizado.

- FIGURA A13. (A) Antes do treinamento, estímulo produz a resposta. (B) Antes do treinamento, estímulo condicionador não produz a resposta. (C) Durante o treinamento, estímulo e estímulo condicionador produzem a resposta. (D) Após o treinamento, estímulo condicionador induz a resposta.
- FIGURA A14. Aprendizado do tipo estímulo-resposta (TIPO 2)
- FIGURA A15. Aprendizado de cadeias (TIPO 3)
- FIGURA A16. Algumas etapas que envolvem o aprendizado de máquina.

IV O SISTEMA

- FIGURA SS1. Sistema de coordenadas.
- FIGURA SS2. Cursor e a leitura dos sensores.
- FIGURA SS3. Posição dos sensores no *cursor*.
- FIGURA SS4. Estrutura da rede ponderadora de direção.
- FIGURA SS5. Posições do *cursor* utilizada para o treinamento preliminar da rede.
- FIGURA SS6. Centralização do *cursor*.
- FIGURA SS7. Cursor centralizado obedecendo o limite máximo dos sensores.
- FIGURA SS8. Rede utilizada para centralizar o *cursor*.
- FIGURA SS9. Exemplo de situações que conduzem ao ajuste de posição do *cursor*.
- FIGURA SS10. Sequência para a mudança de direção e reposicionamento do *cursor*.
- FIGURA SS11. Rede para seleção de direção.
- FIGURA SS12. Rede seletora com *threshold*.
- FIGURA SS13. Estrutura de aprendizado.
- FIGURA SS14. Diâmetro da área mapeada é o menor valor ponderado pelos sensores.
- FIGURA SS15. Região mapeada.
- FIGURA SS16. Regiões que podem induzir a erros de mapeamento.
- FIGURA SS17. Sequenciamento de uma rota.
- FIGURA SS18. Movimento do *cursor* seguindo uma rota mapeada.
- FIGURA SS19. Exemplo de rotas encadeadas.
- FIGURA SS20. (A) ROTAS APRENDIDAS . (B) INÍCIO DO PROCESSO DE BUSCA. (C) PONTO FINAL ATINGINDO. (D) GRUPO DE NEURÔNIOS "CONGELADOS". (E) NEURÔNIOS SÃO RESETADOS PARA REINICIALIZAR O PROCESSO DE BUSCA. (F) PROCESSO DE CONGELAMENTO CONTINUA. (G) ENCADEAMENTO COMPLETO.
- FIGURA SS21. Neurônio artificial.
- FIGURA SS22. Efeito da inércia.
- FIGURA SS23. Estrutura principal (estrutura neuronal).

- FIGURA SS24. Primeira camada. Três neurônios. A primeira camada recebe estímulos externos por duas vias: X e Y, correspondendo ao valor (V) da posição do *cursor* no sistema cartesiano. Os neurônios (2 neurônios) desta camada tem função potenciadora. Se o estímulo de entrada tem valor V, na placa sináptica do axônio, o valor de saída terá valor $V*V$.
- FIGURA SS25. Neurônio da primeira camada.
- FIGURA SS26. Contribuição dos neurônios da primeira camada no valor do *soma* do neurônio seletor.
- FIGURA SS27. V_x e V_y são os valores dos estímulos externos. I_x e I_y são os pesos sinápticos
- FIGURA SS28. Linhas de "inibição" e "reset".
- FIGURA SS29. Botão sináptico e as duas ramificações do axônio
- FIGURA SS30. Estrutura do grupo neuronal
- FIGURA SS31. Estrutura para o sequenciamento de rotas (formação de macro rotas).
- FIGURA SS32. Função de ativação.
- FIGURA SS33. Estrutura geral do sistema
- FIGURA SS34. Estrutura seccionadora de atividades
- FIGURA SS35. Seleção de caminhos para retreinamento.

V SIMULAÇÕES

- FIGURA S1. *Layout* da área de trabalho que utilizaremos nas simulações.
- FIGURA S2. Processo de aprendizado. O ponto (P_i) indica o início e o ponto (P_f) indica o fim de uma trajetória. Uma linha liga estes pontos indicando o menor caminho e a direção preferencial de movimento. Os círculos indicam as áreas mapeadas pelo sistema. As linhas ligando as regiões circulares indicam os caminhos percorridos pelo *cursor* durante o processo de aprendizado.
- FIGURA S3. Simulação da geração de uma trajetória. Os círculos representam as áreas mapeadas. O caminho mais claro é a trajetória gerada, ligando os pontos P_i e P_f .
- FIGURA S4. Simulação utilizando pontos intermediários de uma macro-rota conhecida.
- FIGURA S5. Simulação invertendo a direção do movimento.
- FIGURA S6. Simulação com obstáculos.
- FIGURA S7. Simulação com obstáculo.
- FIGURA S8. Re-treinamento.
- FIGURA S9. Simulação ligando duas áreas pré-treinadas.
- FIGURA S10. Simulação a partir de um ponto não mapeado pelo sistema. Ao atingir uma macro-rota conhecida, o *cursor* passa a seguir as rotas que fazem parte da sua cadeia.
- FIGURA S11. Simulação a partir de um ponto não mapeado pelo sistema.

VI CONCLUSÃO

FIGURA C1.

Estrutura geral do sistema.

INTRODUÇÃO

O planejamento de trajetória [HOU-94] [KUPE-89] [KUPE-90] [SHIO-91] [WU-94] é uma importante área de estudo em robótica, envolvendo um grande número de etapas. Planejar significa organizar as informações disponíveis e previstas, de tal forma a conduzir um objeto de um estado a outro, de preferência com segurança e estabilidade. Como o ambiente de trabalho geralmente não é estático, o planejamento das ações torna-se uma tarefa dinâmica e o sistema deve ter a capacidade de realizar as adaptações e a tomada de decisões diferentes (ajustes) da planejada, ou seja, um replanejamento. E mais, no planejamento deve-se prever o aprendizado de fatos e ações não previstas, para futura utilização.

Normalmente, o planejamento [MEN-90] [MEN-91a] [NORE-95] [SARI-83] envolve a sub-divisão da tarefa a ser realizada em várias sub-tarefas, hierarquicamente estruturadas e/ou inter-relacionadas, independentes ou não. Esta sub-divisão estende-se até o nível que a sub-tarefa restringe-se a uma ação elementar (menor ação que um mecanismo pode executar) e que não deve atuar isolada do meio ou sistema, pois, são necessárias observações (monitoramento) constantes e a execução de correções (decorrentes das aleatoriedades que possam ocorrer).

A figura II mostra o organograma de um sistema de planejamento de trajetória. Trata-se de uma representação simplificada. Neste sistema, o "sistema de planejamento" recebe informações externas de três canais: o meio ambiente, a tarefa a ser realizada e o estado do mecanismo, permitindo as tomadas de decisões.

O meio fornece informações que permitem a localização e orientação do mecanismo, interação com seus elementos (objetos e obstáculos) e conhecimento topográfico. A tarefa pode ser fornecida pelo usuário ou pelo estado do próprio sistema (por exemplo, uma ação de proteção) [MEN-91b].

Em um nível hierarquicamente inferior, o "planejador" coordena as atividades de três módulos: decisão, geração de sub-tarefas e execução. O módulo de decisão é o responsável pela tomada de decisão do sistema ativando ou não, procedimentos ou estados. As informações a que está submetido dizem respeito ao reconhecimento da área de trabalho, detecção de caminhos, escolha de ações, validação de estados do sistema, controle de procedimentos críticos (condições de erro, proteção e segurança de operações), sequenciamento, aprendizado e retenção de ações e controle preditivo através de modelos (cinemático, dinâmico e estado).

Além disso, o módulo de decisão deve trocar informações com os outros dois módulos.

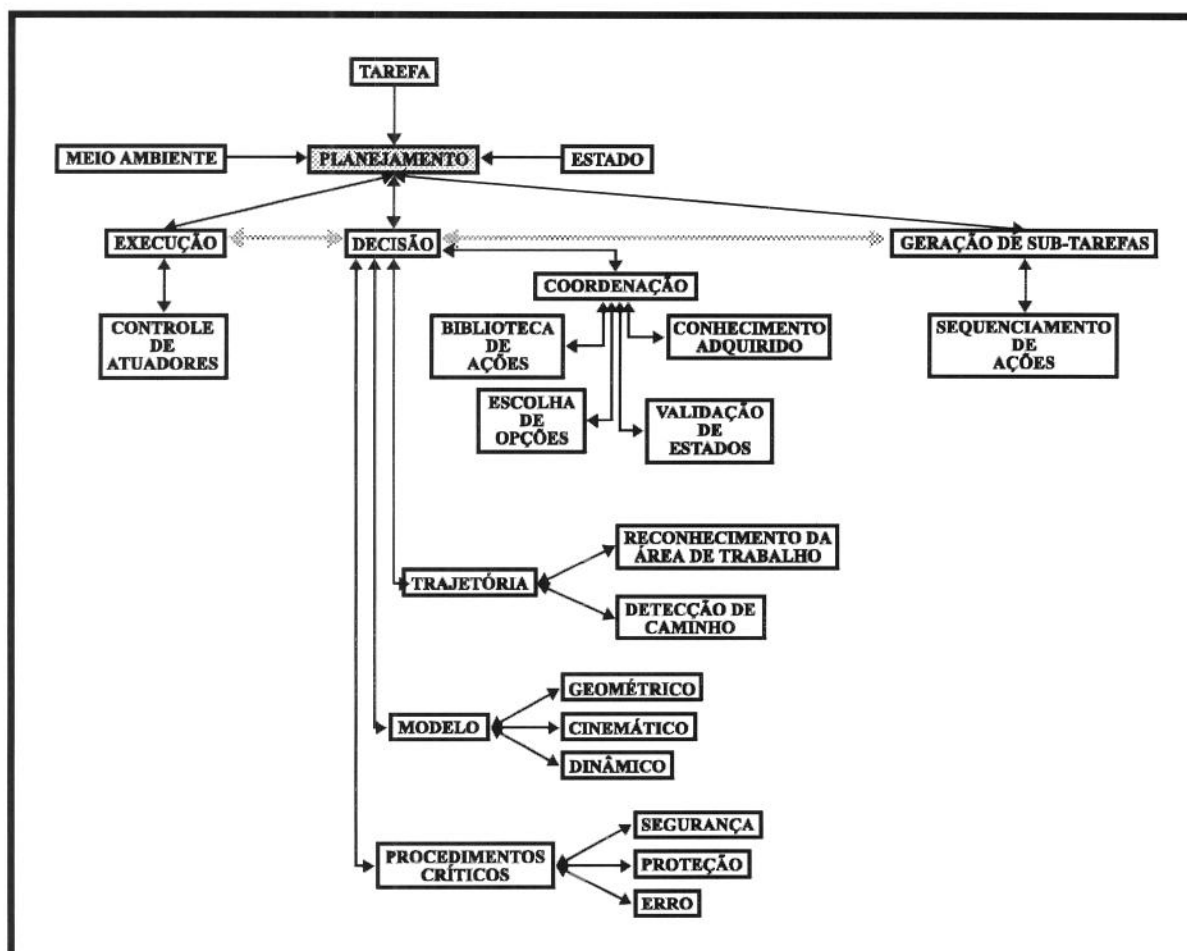


FIGURA 11. Layout de uma sistema para geração de trajetória.

Enquanto, o módulo de execução é o responsável pelo controle dos atuadores e observação do estado do mecanismo, o gerador de sub-tarefas executa a quebra da mesma até o seu nível mais elementar.

A implementação de cada um destes níveis envolve um volume grande de técnicas, algoritmos, processadores, atuadores, sensores, informações sobre o ambiente, os elementos manipulados, modelos, etc..., que não serão abordados neste trabalho. É importante ressaltar que a grande maioria dos algoritmos utiliza,

de alguma forma, técnicas de inteligência artificial: representação do conhecimento, memória e aprendizado, pesquisas, lógica e abstração, planejamento, visão e redes neurais, cada qual aplicada a um tipo de atividade. Essas técnicas tem algumas características comuns: tanto o consumo de memória, como o processamento e também o tempo de treinamento são altos. Por exemplo, uma pesquisa em base de dados pode ser tão "demorada" quanto o reconhecimento de uma imagem ou o treinamento de uma rede neural. Contudo, na grande maioria das atividades, espera-se que um robô (por exemplo) execute suas tarefas o mais rápido e da melhor forma possível, ou seja, o sistema de planejamento de trajetória deve operar "em tempo real", ou pelo menos, planejar em *off line* e efetuar as correções (adaptações) em tempo real.

No caso de robôs móveis [IYEN-85] [KAWA-87] [KAWA-88] [KAWA-90] [LIU-89] [LUH-84] [SANN-90] [SCHIZ-90] [SPON-86] [RAM-90], o problema é agravado, pois as informações sobre o meio podem ser incompletas, apresentar grandes variações e serem desconhecidas, dificultando ou até impossibilitando o processamento dos dados e da navegação.

Com esses dados, o sistema de planejamento deve ser projetado para manipular informações incompletas. Para isso, faz-se necessária a utilização de um sistema que seja auto-compensativo e preditivo, capaz de absorver ruídos e falhas de dados, erros de planejamento e execução.

A implementação de um gerador de trajetória pode ser abordada de várias maneiras [ANDE-88] [EYSE-82] [FOUX-93] [HAYE-89] [IYEN-85] [MICH-83] [NAGA-90] [NEWE-72] [NGUY-90] [ROTH-90] [UNO-87], mas geralmente consiste em encontrar um caminho que realiza a conexão entre uma configuração (posição e orientação) inicial e uma final [ECKM-89] [FU-87] [HOU-94] [RICH-88]. Se a planta do ambiente é conhecida e pode ser considerada como estática, o problema restringe-se à implementação de um algoritmo de busca [LEVI-88] [RICH-88]. Se o ambiente é desconhecido, então, o mecanismo em movimento [ZELI-92] deve possuir sensores [CURR-95] [SHIO-91] que lhe permita a identificação da área de trabalho. A estrutura desse mapeamento forma a base de conhecimento para que um planejador [SHAR-89] gere a trajetória a ser seguida. Normalmente, a área de trabalho é demarcada [HAN-94] [SUTH-94] com faixas, sinalizadores ou pontos de referência que auxiliam a navegação, e seus elementos são considerados (representados) como polígonos [FOUX-93] [HOU-94] [LIU-83]. Com essas informações, o caminho pode ser gerado.

Sharir [SHAR-89] faz uma revisão sobre alguns algoritmos para o planejamento e geração de trajetória. Em resumo, esses algoritmos podem ser classificados em 3 categorias [HU-93] [SUTH-94] [ZELI-92] :

- pesquisa em grafos/network,
- potencial de campo e
- redes neurais.

A pesquisa em grafos/network consiste em um processo de busca por configurações (C-space - Configuration Space) [HOU-94] [PERE-83] representadas em grafos ou diagramas. O método do potencial de campo [AMAR-83] consiste em equacionar funções de potencial que atraia o mecanismo para posições (ou configurações) específicas, ou então, repellido quando estiver próximo de obstáculos [GULD-95] (ou configurações indesejadas). Outra forma para a geração de trajetória é utilizar o potencial das redes neurais artificiais [MASS-89] [KUNG-89]. Um conjunto de configurações na área de trabalho é utilizado para o treinamento de uma rede neural, que então, passa a gerar valores de referência que serão seguidos pelo mecanismo. Além das informações do ambiente, alguns algoritmos utilizam informações sobre a geometria, cinemática e dinâmica do mecanismo [MEN-87] [MEN-89] [ZAPA-94] [WU-94].

Esses métodos são geralmente muito lentos [HEUB-90] [HEUB-91] para implementação em micro computadores, dificultando sua utilização em tarefas que necessite de processamento em "tempo real". A busca em grafos ou em árvores, dependendo do número de combinações de caminhos e de níveis da árvore, pode gerar uma quantidade muito grande de caminhos. No sistema que estamos propondo, o processamento é distribuído pelos neurônios e suas macro-estruturas reduzindo o tempo de busca, pois essa ocorrerá por vários caminhos simultaneamente.

As redes neurais tradicionais também apresentam algumas limitações, por exemplo, o treinamento de uma rede tipo Perceptron pelo método de Backpropagation geralmente demanda um grande número de iterações, ou então, uma rede de Hopfield que pode exigir o uso de muitos neurônios. A estrutura que estamos propondo incorpora as características de alta conectividade e massivo paralelismo das redes neurais artificiais através de elementos com processamento relativamente simples: o neurônio artificial, para mapear e seqüenciar regiões na

área de trabalho com um número reduzido de neurônios, pois um único neurônio pode mapear uma região relativamente grande, e a estrutura neuronal permite uma busca distribuída por rotas (caminhos) mais rápida que os tradicionais métodos de busca em grafos e árvores.

Com relação a identificação da área de trabalho, optamos por uma representação interna (estrutural) sem a necessidade de elementos externos como as faixas, sinalizadores e pontos de referência, pois em um ambiente desestruturado e desconhecido o uso destes elementos pode ser inviável.

Por outro lado, os animais (e os seres humanos) são dotados de um sistema neural e de efetadores que os capacitam a adaptar-se às mais diferentes situações, mesmo em ambientes desconhecidos, cada qual com o grau de destreza que o hardware e base de conhecimento lhe propicia.

O ser humano, em particular, possui um sistema neural muito elaborado, capacitando-o a identificar, analisar, propor soluções, atuar e aprender com os problemas que lhes são apresentados. Falhas neste sistema, propiciam a ativação automática de um mecanismo de compensação, permitindo ao ser adaptar-se às novas características do seu hardware. Por exemplo, um ser humano cujo sistema neural não recebe informações visuais pode suprir essa falta de informação com o auxílio de sinais de outros sensores (audição, tato, ...), adaptando o seu processamento neural.

As redes neurais artificiais [FUHR-85], inspiradas em estruturas biológicas, "tentam" incorporar algumas destas características: capacidade de auto-compensação e predição, massivo paralelismo para o processamento e capacidade de "aprendizado"; apesar de consumirem muito tempo de processamento durante o aprendizado.

Neste trabalho abordamos o problema da geração de trajetória em ambiente desestruturado através de uma estrutura neuronal artificial com auto-aprendizado. O objetivo é formar uma sequência de valores de referência que podem auxiliar a definição de um caminho ou uma trajetória.

Um mecanismo fictício, que chamaremos de *cursor*, dotado de sensores e com a capacidade de deslocar-se pela área de trabalho, realizará movimentos reconhecendo regiões "livres de obstáculos" e caminhos que poderão ser utilizados por um mecanismo físico (o *cursor* pode estar localizado no próprio mecanismo físico). As regiões reconhecidas são encadeadas formando pequenas rotas, que por sua vez, encadeadas formam macro-rotas. Assim, dado um ponto inicial e um final (conhecidos) na área de trabalho mapeada, o sistema fornece uma "previsão" do

caminho a ser seguido (pontos de referência). As características físicas (dimensões, orientações, efetuadores, ...) do "robô" [AMIR-92] [LIN-92] [ZAPA-94] [WU-94] (elemento físico a ser auxiliado pelo sistema) não são consideradas, cabendo a outro sistema, hierarquicamente superior, definir a trajetória efetiva a ser realizada em função dos pontos de referência fornecidos pelo nosso sistema.

Estamos propondo um novo método para abordar o problema da geração de trajetória inspirado em sistemas biológicos (principalmente a região cerebelar [BLON-91] e hipocampal [AMARA-90a]), redes neurais (principalmente rede tipo perceptron com treinamento pelo método de backpropagation) e nas teorias de aprendizado (principalmente a proposta por R. M. Gagnè [GAGN-65]). Podemos classificá-lo como um sistema neural artificial com aprendizado misto: acumulativo e por "insight" [KOFF-35], onde os pesos sinápticos nas principais estruturas são ajustados uma única vez, sem a necessidade da utilização de métodos iterativos. Contudo, para a formação de rotas (caminhos) um procedimento de busca, não algoritmizado foi implementado.

Dividimos o texto desta tese em 7 capítulos, obedecendo um caráter didático e refletindo a mesma ordem adotada durante a realização das atividades:

I-Estudo de redes neurais artificiais;

II-Estudo de sistemas biológicos
(aspectos neuro-físio-anatômicos);

III-Estudo de teorias sobre o aprendizado de seres vivos;

IV-Sistema proposto: aprendizado e estrutura;

V-Simulações,

VI-Conclusões e

VII-Bibliografia.

O estudo de algumas redes neurais artificiais, sistemas biológicos e teorias sobre o aprendizado em seres vivos tiveram como objetivos a capacitação do doutorando nestas áreas e serviram de fontes de inspiração para novos sistemas.

Nos três primeiros capítulos apresentamos as principais características dos respectivos temas (redes neurais, sistemas biológicos e aprendizado), que de forma direta ou não, contribuíram para a elaboração do sistema proposto. No primeiro

capítulo apresentamos um resumo teórico sobre três redes neurais: Perceptron multicamada, Hopfield e Bidirectional Associative Memory; às quais dedicamos maior tempo de estudo.

No segundo capítulo apresentamos um estudo sobre alguns elementos e circuitos neurológicos, principalmente aos relacionados com o controle motor e ao posicionamento e orientação espacial: cerebelo e hipocampo.

No terceiro capítulo estudamos as características das principais correntes teóricas do aprendizado, enfatizando os estudos de B. F. Skinner, Edward C. Tolman e Robert M. Gagnè. A intersecção destas teorias com os modelos biológicos que apresentaremos no capítulo II, formam a base do sistema que estamos propondo no capítulo IV. No capítulo V mostramos as simulações que realizamos utilizando uma área de trabalho com regiões livres, convexas e formando um labirinto. No capítulo VI comentamos os resultados e fazemos algumas sugestões. Por fim, no capítulo VII apresentamos os artigos e livros que serviram de base para a elaboração desta tese.

CAPÍTULO I

REDES NEURAIS ARTIFICIAIS

1. INTRODUÇÃO

O homem ainda não consegue compreender o mecanismo de funcionamento e processamento de informações no cérebro. Na ânsia de obter algum êxito, tem-se idealizado modelos teóricos baseados, em grande parte, nas observações neuro-anatômicas do sistema nervoso (SN) e no comportamento (resposta) funcional (atividade) de neurônios, grupos neuronais e músculos a estímulos conhecidos.

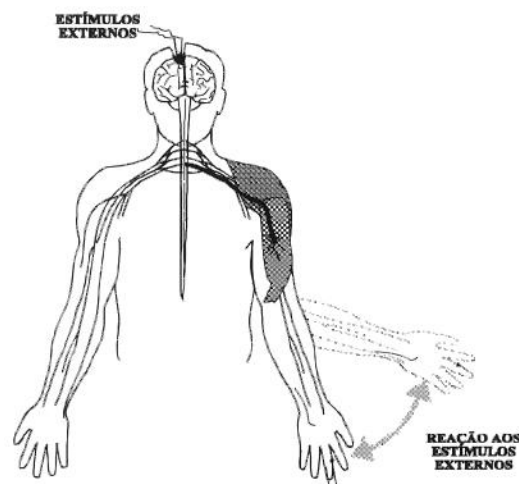


FIGURA RNA1. Estímulos externos aplicados no córtex cerebral (principalmente nas áreas motoras) produz movimentos dos membros.

Existe um grande número de modelos e simulações da estrutura do sistema nervoso utilizando conceitos e ferramentas de inspiração biológica (principalmente nas áreas de neuro-anatomia e neuro-fisiologia), matemática, eletrônica e computação [ANDE-83] [AMAR-83] [ANTS-90] [BAVA-88] [BEER-91] [BRUW-90] [CHU-90] [COHE-83] [EBER-90] [GUEZ-88a] [GUEZ-88b] [HAND-90] [HANE-92], destacando-se os trabalhos de W. C. McCulloch e W. Pitts [RUME-89] que demonstram a capacidade dos modelos neurais artificiais em processarem

dados, D. O. Hebb [HEBB-49] que desenvolveu o primeiro algoritmo de aprendizado para um modelo neuronal artificial e F. Rosenblatt [ROSE-59] que apresentou um modelo neuronal (rede neural tipo Perceptron [MINS-69]) capaz de realizar o reconhecimento de padrões de caracteres. Desde então, surgiram outros modelos neuronais com grande aplicabilidade [BHAT-90] [KALV-91] [KAUF-90] [KOHO-84] [KRAF-90] [LIPPM-87] [MIC-90] [MICH-90] [NIELS-87a] [NIELS-87b] [NIELS-88] [RAUC-88] [SOUC-89] [SPECH-90] [STEVE-90] [WASS-87] [WASS-89] [WIDR-90], podendo ser destacados os seguintes: Perceptron, Madaline, Avalanche, Cerebellatron, Perceptron com treinamento pelo método de Backpropagation, Brain State in a Box, Neocognitron, Adaptive Resonance Theory, Self Organizing Map, Hopfield, Bidirecional Associative Memory, Boltzmann Machines, Cauchy Machines e Counterpropagation.

Estes modelos apresentam algumas características que lhes conferem grande aplicabilidade:

- Processamento: massivo paralelismo não algoritmizado, o que proporciona grande velocidade de execução;
- Aprendizado: Capacidade de serem "treinadas para aprender" com a experiência;
- Plasticidade: capacidade de se "moldar", reaprendendo com novas situações;
- Representatividade: capacidade de representar comportamentos de sistemas lineares e não lineares e
- Adaptabilidade: capacidade de adaptar-se a situações aleatórias que surgem em operação.

As redes neurais artificiais [BAILE-90] [COIT-91] [HEND-90] [HOLD-83] [PSALT-88] podem ser consideradas como analogias do sistema nervoso de seres vivos, sendo constituídas por pequenas unidades "autônomas" de processamento, chamadas de neurônios artificiais, altamente distribuídos e inter-conectados. Cada modelo tem um *layout* próprio para a estrutura e funcionalidade dos neurônios, suas conexões e localização na rede. Geralmente o neurônio atua como um ponderador. Um conjunto de valores de entrada (E) são enviados ao neurônio que realiza a

ponderação desses dados em função da força (peso) das conexões sinápticas¹ (ω) produzindo um único valor de saída (S), como mostrado na figura RNA2.



FIGURA RNA2. (A) Neurônio artificial. (B) Liberação de neuro-transmissores na conexão sináptica.

A ponderação [HINTO-89] [LIPPM-87] [PASSI-89] [PSALT-88] é realizada pela soma das entradas (S_i) multiplicadas pelos pesos (ω_i) correspondentes:

$$SOMA = \sum_{i=1}^n s_i * \omega_i \tag{R1}$$

onde n é o número total de entradas, S_i é o valor da entrada e ω_i é o peso sináptico.

O valor do soma passa por uma função de ativação (FA) que dispara o valor de saída (potencial de ação do neurônio biológico) do neurônio. Essa função limita e normaliza o valor da saída evitando a saturação da rede. A função de ativação pode assumir as mais variadas formas (rampa, sigmoide, *threshold* ou tangente hiperbólica), mas geralmente utiliza-se uma função sigmoide:


$$S(soma) = \frac{1}{1 + e^{-\frac{soma}{\gamma}}} \tag{R2}$$

onde γ o parâmetro de forma.

¹ No neurônio biológico, o sinal de saída é conduzido através do axônio até as posições terminais. A presença de um pulso elétrico nas terminações provoca a liberação de substâncias neuro-transmissoras no meio extra-celular. Os neuro-transmissores (sob a influência das substâncias presentes no meio externo) alteram a permeabilidade da membrana plasmática do neurônio receptor, produzindo alterações no potencial elétrico dos dendritos e soma. A influência dos neuro-transmissores no potencial elétrico é chamada de força sináptica.

A estrutura da rede também pode ter vários *layouts*. Geralmente os neurônios são organizados em camadas e inter-conectados com os neurônios da camada seguinte.

Na organização em camadas, o número de neurônios e a estrutura da rede podem ampliar o espectro de ação dos neurônios. Um único neurônio tem um campo de atuação muito limitado, por exemplo, um neurônio com duas entradas, uma saída e uma função de ativação do tipo *threshold* binário tem a capacidade de selecionar somente dois estados, como mostrado na figura RNA3. É importante salientar que o perfil da região mapeada, e apresentada abaixo, depende do tipo de função de ativação utilizada.



Representação do valor da saída em função das entradas. A linha *s* é definida pela função de ativação.

Representação do valor da saída em função das entradas no espaço tridimensional.




FIGURA RNA3. Uma rede formada por um único neurônio permite selecionar dois estados.

Já uma rede formada por duas camadas, tem a capacidade de isolar uma única região, como mostrado na figura RNA4. Os neurônios da primeira camada definem uma das linhas S1 ou S2 (assumindo função de ativação *threshold* binário) e respectivas regiões de ativação. O neurônio da segunda camada realiza a intersecção das regiões de ativação, definindo uma "faixa comum".




FIGURA RNA4. Rede com duas camadas permite isolar uma faixa de valores

Para uma rede com três [LIPPM-87] ou mais camadas é possível definir regiões de ativação (seleção) convexas, como mostrado na figura RNA5. O perfil da região de ativação é definido pela função de ativação. Para o *threshold* binário, tem-se a forma de um triângulo, para uma função sigmoide, tem-se um contorno "mais contínuo".

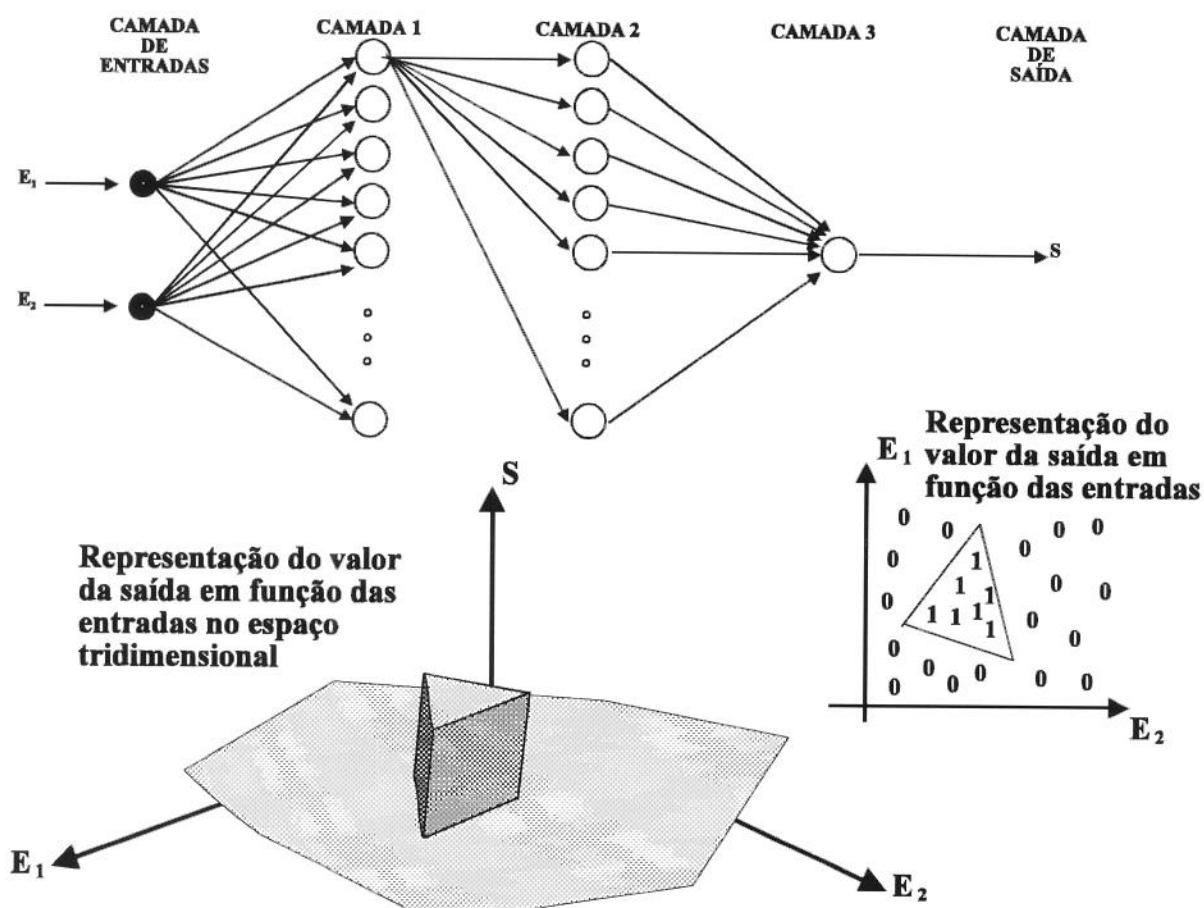


FIGURA RNA5. Rede com 3 camadas permite isolar áreas de conhecimento.

Dentre o grande número de tipos de redes e suas variadas configurações, escolhemos aquelas que apresentassem algumas características básicas, tais como:

- capacidade de mapeamento de regiões de uma área de trabalho,
- aprendizado em tempo real,
- sequenciamento de valores,
- capacidade de busca,
- capacidade de interpolação,
- processamento distribuído e
- baixo consumo de memória.

Assim, estudamos várias redes, mas com maior intensidade, três tipos: **Perceptron** com treinamento pelo método de **backpropagation**, **Hopfield** e **Memória Associativa Bidirecional (BAM)**.

Os nossos estudos consistiram em implementar essas redes utilizando um ambiente de processamento seqüencial (emulando dessincronizadamente o processamento distribuído), treiná-las com dados de uma área de trabalho pré-definida e avaliarmos o desempenho.

A primeira rede estudada foi a Perceptron multi-camada. Sabíamos que o tempo de treinamento seria relativamente grande, mesmo para um número reduzido de padrões (mínimo 12 padrões). Como o nosso objetivo era o sequenciamento de regiões de referência para a formação de uma trajetória (e não um ponto pré-definido na área de trabalho) e o treinamento em tempo real, procuramos minimizar o tamanho da rede (conseqüentemente o tempo de treinamento por iteração). Inicialmente adotamos uma rede com 3 camadas, 2 neurônios por camada, 2 entradas e 2 saídas, e aumentamos a dispersão (aumentando o erro aceitável) no treinamento. Os resultados não foram satisfatórios, independentemente do número de neurônios por camada, pois o número médio de iterações foi aproximadamente 1500, aumentando com a dispersão entre os padrões, ou seja, maior a área a ser mapeada, e quanto mais próximos (menor a área mapeada) os pontos de referência, maior o erro na direção do movimento a ser seguido, ou então, os valores de saída convergiam para um valor comum (como um mínimo local) e não para o sequenciamento desejado, instabilizando o processo de encadeamento. No entanto, a rede Perceptron apresentou um comportamento inercial (gerado pelo método de treinamento: backpropagation) que nos será útil. Durante o aprendizado, apresentamos padrões que indicavam uma direção (Norte, Sul, Leste e Oeste) preferencial de movimento. Quando o padrão *seta* outra direção, a rede, por algumas iterações, preservava a tendência para a direção anterior até assumir a nova. Utilizamos este comportamento na seleção da direção a ser determinada pelo sistema.

No sistema que estamos propondo, a "reconstrução" e o sequenciamento de padrões são atividades fundamentais para o reconhecimento e formação das rotas a serem seguidas. Assim, continuamos nossos estudos com as redes de Hopfield e Bidirectional Associative Memory, pois, apresentam algumas dessas características. As suas principais diferenças, comparadas com a rede Perceptron multi-camada, são a inter-conexão entre as entradas e saídas formando uma malha fechada e os pesos sinápticos são pré-definidos em função dos padrões adotados. A implementação que

realizamos foi binária, com as direções de movimentos sendo compostas por uma sequência binária. As duas redes apresentaram resultados satisfatórios, produzindo as sequências de movimentos desejadas, mas com um número muito grande de neurônios por camada (no mínimo 100 neurônios para 12 padrões).

Na sequência, apresentamos um resumo teórico das 3 citadas redes que foram utilizadas explícitas ou implicitamente.

2. REDE PERCEPTRON MULTI-CAMADA

A rede Perceptron [GASP-91] [HUAN-90] [WASS-89] é a denominação para uma rede neural multi camadas com vários neurônios por camada, múltiplas entradas e saídas. Essa rede atua como um classificador ou mapeador de dados digitais ou analógicos. O *layout* da rede é mostrado na figura RNA6. Os neurônios estão dispostos em camadas e altamente conectados com os da camada subsequente. O número de entradas e saídas podem ser diferentes, bem como, o número de neurônios nas camadas intermediárias.

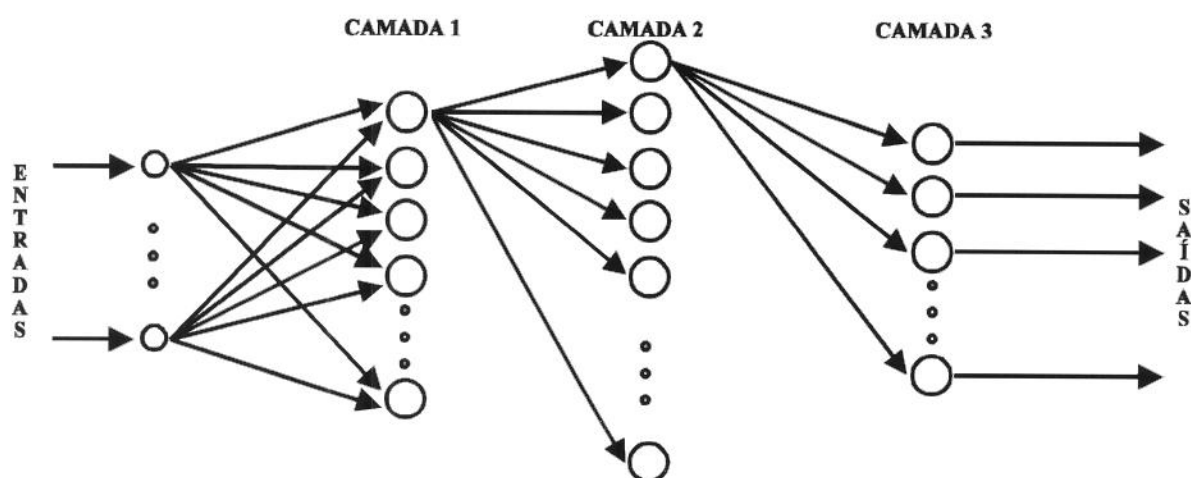


FIGURA RNA6. Layout de uma rede Perceptron com 3 camadas.

Normalmente, as conexões entre neurônios ocorre em camadas consecutivas, no entanto, nada impede que um neurônio de uma camada k faça conexão direta com algum neurônio da camada $k+3$. A estrutura desse tipo de rede não é rígida, o projetista tem a liberdade para elaborar a estrutura mais adequada à aplicação, contudo, deve-se tomar o cuidado nas adaptações no algoritmo de treinamento e atenção para a estabilidade e convergência do processo, pois, pode-se atingir um mínimo local e "bloquear" o treinamento.

Nesta caso, os neurônios atuam como ponderadores, onde o valor de ativação é calculado pela equação:

$$SOMA_{k,j} = \left(\sum_{i=1}^{N_{k-1}} V_{k-1,i} * \omega_{k-1,i,j} \right) - \omega_{0,k,j} \quad (R3)$$

onde $SOMA_{k,j}$ indica o valor de ativação do j-ésimo neurônio da k-ésima camada;

$\omega_{k,i,j}$ indica o peso da conexão sináptica entre o i-ésimo neurônio de entrada ou da k-1 ésima camada com o j-ésimo neurônio da k-ésima camada;

$V_{k-1,i}$ indica uma saída do i-ésimo neurônio da k-1 ésima camada;

ω_{0kj} é o *threshold*.

A função de ativação ($f()$) deve ser não linear, evitando a "degeneração" da rede, pois, se $f(SOMA)$ é linear, uma rede multi camadas pode ser reduzida a uma rede perceptron com uma única camada. Normalmente utiliza-se uma função de ativação do tipo sigmoide, cujas características evitam a saturação da rede para valores de ativação muito altos.

O ajuste dos pesos das conexões é efetuado pelo método de backpropagation, podendo ser implementado pela seguinte equação:

$$\omega_{k,i,j}(t+1) = \omega_{k,i,j}(t) + \eta * \delta(t)_{k,j} * V(t)_{k-1,i} \quad (R4)$$

onde $\omega_{k,i,j}(t+1)$ é o peso da conexão sináptica do i-ésimo neurônio da k-1 ésima camada ou da i-ésima entrada com o j-ésimo neurônio da k-ésima camada;

η é o coeficiente de aprendizado;

$\delta_{k,j}$ coeficiente de erro do j-ésimo neurônio da k-ésima camada;

$V_{k-1,i}$ indica a saída do i-ésimo neurônio da k-1 ésima camada ou i-ésima entrada.

O coeficiente de erro $\delta_{k,i}$ é um parâmetro característico do método backpropagation de treinamento [BRAD-89] [CHEN-90] [LIPPM87] [VOGL-88] [WASS-89]. Sua função é permitir a correção dos pesos sinápticos a partir da propagação dos erros nos valores da saída de cada neurônio das sucessivas camadas, iniciando o processo da última para a primeira.

O cálculo de δ é definido para duas situações:

-camada de saída:

$$\delta_{k,j} = f'_{k,j}(SOMA_{k,j}) * (S_j - s_{k,j}) \quad (R5)$$

onde $f_{k,j}()$ é a derivada da função de ativação do j-ésimo neurônio da k-ésima camada;

S_j é o valor desejado para o neurônio da j-ésima saída e

$s_{k,j}$ é o valor calculado para o j-ésimo neurônio da k-ésima camada (no caso, a última camada).

-para a camada de entradas e intermediárias:

$$\delta_{k,j} = f'_{k,j}(SOMA_{k,j}) * \sum_{p=1}^{N_{k+1}} \delta_{k+1,p} * \omega_{k+1,j,p} \quad (R6)$$

onde $f_{k,j}()$ é a derivada da função de ativação do j-ésimo neurônio da k-ésima camada;

$\omega_{k+1,j,p}$ é o peso da conexão sináptica do j-ésimo neurônio da k-ésima camada com o p-ésimo neurônio da k+1-ésima camada e

$\delta_{k,i}$ coeficiente de erro do p-ésimo neurônio da k+1-ésima camada.

O método de treinamento que implementamos, como o proposto por Rumelhart, Hinton e Williams [RUME-89], é uma variação da versão *standard* do método de backpropagation:

$$\omega_{k,i,j}(t+1) = \omega_{k,i,j}(t) + \eta * \delta_{k,j} * V_{k-1,i} + \alpha * [\omega_{k,i,j}(t) - \omega_{k,i,j}(t-1)] \quad (R7)$$

onde α : é o coeficiente de *momentun*. A correção dos pesos sinápticos é efetuada levando-se em conta a variação dos pesos sinápticos nos instantes t e $t-1$, e α atua como um fator de escala.

O processo de treinamento é executado até que seja atingido um valor mínimo desejado para uma função que minimize o erro quadrático das saídas da rede:

$$J = \sqrt{\sum_{i=1}^N (S_i - s_i)^2} \quad (R8)$$

onde J: é a função de minimização e
N: é o número de saídas.

O algoritmo de treinamento é apresentado a seguir:

- 1-inicializar os pesos $\omega_{k,i,j}$ com valores randômicos e pequenos ($\cong 0$)
- 2-especificar a função de ativação dos neurônios
- 3-especificar o valor inicial do coeficiente de aprendizado e *momentum*
- 4-apresentar um vetor de entradas (E) à rede
- 5-calcular o valor de ativação e de saída dos neurônios:

$$S(soma) = \frac{1}{1 + e^{-\frac{soma}{\gamma}}}$$

- 6-corrigir os pesos das conexões sinápticas $w_{i,j}$:

$$\omega_{k,i,j}(t+1) = \omega_{k,i,j}(t) + \eta * \delta_{k,j} * V_{k-1,i} + \alpha * [\omega_{k,i,j}(t) - \omega_{k,i,j}(t-1)]$$

- 7-se ainda existir algum vetor de entradas retornar ao passo 4
- 8-verificar se o valor da função de minimização atingiu o valor esperado, se não, corrigir o coeficiente de aprendizado η e retornar ao passo 4 reinicializando o processo de aprendizado.

A principal característica do método de backpropagation é o processo de treinamento. Para o ajuste dos pesos, leva-se em consideração a variação da função de ativação do neurônio ($f()$). Assim, se durante o treinamento, a função de ativação

apresentar grandes variações, a correção dos pesos das conexões será maior. Para as camadas intermediárias, o coeficiente de erro é calculado considerando o seu valor para os neurônios das camadas subseqüentes, ou seja, para o cálculo do coeficiente de erro ($\delta_{k,i}$) do i -ésimo neurônio da k -ésima camada, utilizando-se o valor do coeficiente de erro dos neurônios da $k+1$ -ésima camada, ponderado pelo peso das conexões sinápticas. Com isso, existe a propagação do erro da última para a primeira camada (backpropagation) corrigindo sucessivamente os pesos.

Deve-se treinar a rede com o maior número possível e variado de relações ENTRADA-SAÍDA, abrangendo toda a região do espaço a ser representada.

O uso da derivada primeira como fator de correção dos pesos pode provocar a "paralisia" do processo de treinamento. Tomemos como exemplo a derivada primeira da função de ativação sigmoide:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (R9)$$

$$f'(x) = \frac{e^{-x}}{e^x + e^{-x} + 2} \quad (R10)$$

se o valor de ativação for muito grande: $SOMA \rightarrow \pm\infty$, então $f'()$ terá um valor muito pequeno,

$$\lim_{x \rightarrow \pm\infty} f'(x) = \frac{e^{-x}}{e^x + e^{-x} + 2} = 0 \quad (R11)$$

não contribuindo decisivamente para a correção dos pesos sinápticos, ou seja, o treinamento fica paralisado. Uma alternativa para se evitar a paralisia é limitar o valor de ativação do neurônio, fazendo com que a correção seja realizada de forma controlada.

Um dos grandes problemas do método de backpropagation é a convergência. O método garante (salvo algumas restrições quanto aos parâmetros utilizados) a convergência para um valor de erro entre as saídas calculadas e as desejadas, mas não garante que esse erro seja um valor mínimo absoluto. Por exemplo, dependendo da variação do coeficiente de aprendizado, o processo pode convergir para um valor fora dos limites tolerados, ou então, ficar alternando entre valores mínimos. Esses pontos de convergência são chamados de mínimos locais.




FIGURA RNA7. Mínimos locais obtidos durante o treinamento da rede..

A figura RNA7 mostra uma série de mínimos locais. Os valores com que são inicializados os pesos sinápticos e o perfil de variação do coeficiente de aprendizado (η) durante o processo definem o ponto de convergência para o erro de cálculo das saídas da rede e a direção de convergência. Se η for muito pequeno, os pesos sinápticos convergem para um nível que o processo de aprendizado "não tem força" para ultrapassar, por exemplo, os pontos de mínimo local. Se η for muito grande, os pesos sinápticos sofrem alterações muito bruscas fazendo com que o erro fique oscilando, não convergindo. O valor de η também pode influir de forma decisiva no tempo de treinamento. Um valor pequeno pode tornar o processo muito lento.

É importante salientar que deve haver uma relação de compromisso entre o tempo de treinamento e o grau de estabilidade da rede. Pode ocorrer que o ponto de mínimo de erro atingido pela rede seja insuficiente para a sua estabilidade e a rede pode estar "treinada" para reconhecer um conjunto de padrões, mas, ao ser treinada com um novo padrão, esquece os anteriores ou torna-se muito sensível a ruído de entrada.

3. REDE DE HOPFIELD

Enquanto a rede Perceptron não incorpora nenhum tipo de *feedback* e apresenta comportamento estático, ou seja, para um conjunto de valores das entradas aplicados à rede, um conjunto de valores das saídas são produzidos, a rede Hopfield [HOLP-85] [LIPPM-87] [WASS-89] é do tipo recorrente, incorporando malhas de *feedback* e apresentando comportamento dinâmico. Um conjunto de entradas é aplicado à rede, os valores das saídas dos neurônios são calculados e apresentados às entradas da rede, reiniciando o processo, que continua até atingir um estado de estabilidade, ou seja, os valores das saídas da rede "não são alterados".

A rede de Hopfield e suas variações foram desenvolvidas inicialmente para manipular informações binárias, podendo também, manipular dados analógicos. A figura RNA8 mostra a estrutura de uma rede de Hopfield com duas camadas, três neurônios, três entradas e três saídas. Os neurônios da camada zero atuam como um elo de ligação entre as saídas e as entradas dos neurônios da camada 1, não realizando nenhum processamento.

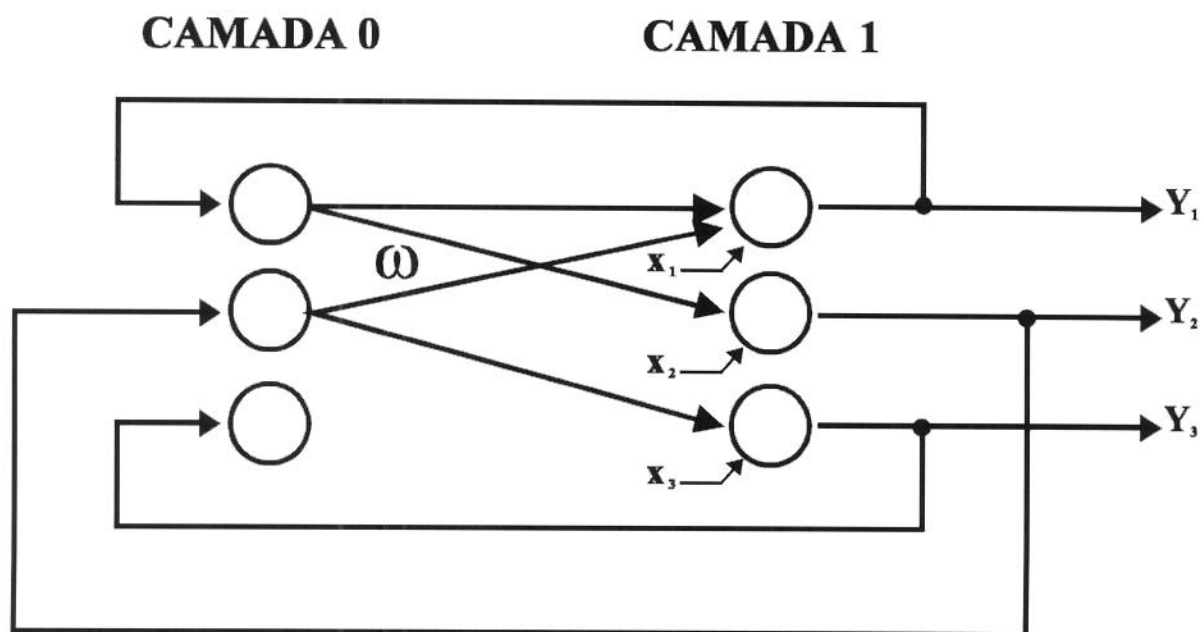


FIGURA RNA8. Layout da rede de Hopfield.

Os neurônios da camada 1 realizam os seguintes processamentos (para uma rede binária):

- valor de ativação:

$$SOMA_j = \sum_{i \neq j}^N \omega_{i,j} * S_i + x_j \quad (R12)$$

onde x_j : entrada externa para o neurônio j
 S_i : saída do neurônio i atuando como entrada
 N : número de neurônios
 $\omega_{i,j}$: peso da conexão sináptica

- função de ativação:

$$\begin{aligned} S_j &= 1 && \text{se } SOMA_j > T_j \\ S_j &= 0 && \text{se } SOMA_j < T_j \\ S_j &= \text{inalterado} && \text{se } SOMA_j = T_j \end{aligned} \quad (R13)$$

onde T_j é um *threshold*.

O processo de treinamento consiste em determinar os pesos das conexões sinápticas através da fórmula:

$$\omega_{i,j} = \sum_{p=1}^P (2 * x_i^p - 1) * (2 * x_j^p - 1) \quad (R14)$$

onde P : número total de padrões a serem ensinados.

O processo de treinamento consiste em definir a priori o valor dos pesos das conexões sinápticas. Para que a rede seja estável é necessário que $\omega_{i,j}=0$ para $i=j$ e que $\omega_{i,j}=\omega_{j,i}$. Este critério de simetria dos pesos é suficiente mas não necessário para definir a estabilidade da rede, pois, existem sistemas estáveis com matriz de pesos $[\omega]$ não simétricas. Também pode ser mostrado (através de exemplos) que a

introdução de ruído na matriz $[\omega]$, alterando sua simetria, pode provocar oscilações nos valores de saída da rede.

A prova de estabilidade da rede é dada a partir da função de energia de Liapunov que deve decrescer a cada troca assíncrona de estado da rede, atingindo um mínimo e parando. A função de energia é dada por [WASS-89]:

$$E = -\frac{1}{2} * \sum_i \sum_j \omega_{i,j} * S_i * S_j - \sum_j S_j * x_j + \sum_j T_j * S_j \quad (R15)$$

A variação de energia devido a troca de estado do neurônio j é dada por:

$$\begin{aligned} \Delta E &= \left[\sum_{i \neq j} (\omega_{i,j} * S_i * S_j) + x_j - T_j \right] * [S_j(t) - S_j(t-1)] = \\ &= -[SOMA_j - T_j] * [S_j(t) - S_j(t-1)] \end{aligned} \quad (R16)$$

Analisando a equação de variação de energia, pode-se concluir:

- se o valor de ativação do neurônio j ($SOMA_j$) for maior que o *threshold* T_j , então, $S_j(t) > S_j(t-1)$ e ΔE será negativo,
- se o valor de ativação do neurônio j ($SOMA_j$) for menor que o *threshold* T_j , então, $S_j(t) < S_j(t-1)$ e ΔE será negativo,
- se o valor de ativação do neurônio j ($SOMA_j$) for igual ao *threshold* T_j , então, $S_j(t) = S_j(t-1)$ e $\Delta E = 0$.

Com isso, tem-se que a troca de estado do neurônio j irá reduzir ou manter a energia da rede, eventualmente encontrar um mínimo e parar. Conclui-se que a rede é estável para mudanças assíncronas de estados.

A rede de Hopfield tem duas grandes limitações [LIPPM-87]:

- o número de padrões que pode reconhecer (armazenar) acuradamente é da ordem de 15% do número de entradas ou neurônios da rede,

- se os padrões utilizados no treinamento forem semelhantes, a rede pode tornar-se instável, de tal forma que durante o processo de reconhecimento, padrões incorretos serão classificados ou identificados. Para dois padrões semelhantes: P_1 e P_2 , o valor de ativação dos neurônios serão numericamente próximos, mascarando o valor de ativação na saída dos neurônios. Quando as diferenças entre dois padrões é pequena, a rede considera o segundo padrão idêntico ao primeiro com algum ruído. Assim, a rede atua como um filtro e os dois padrões são considerados únicos.

A rede de Hopfield pode ser utilizada para valores contínuos de entradas e saídas, bastando trocar a função de ativação. Normalmente é utilizada a função sigmoide do tipo:

$$S(t+1) = f(SOMA(t), SOMA(t-1)) = \frac{1}{1 + e^{\frac{-(K_1 * SOMA(t) + K_2 * SOMA(t-1))}{\mu_0}}} \quad (R17)$$

onde K_1 e K_2 são constantes e μ_0 o coeficiente de forma.

Como para a rede binária, a estabilidade é garantida se a matriz de pesos for simétrica e $\omega_{ij}=0$ para $i=j$. A função de energia pode ser definida de forma semelhante a desenvolvida para o caso binário.

4. BIDIRECTIONAL ASSOCIATIVE MEMORY (BAM)

O acesso a qualquer informação armazenada na memória de um computador é realizada através da leitura ou escrita a um endereço específico. Diferentemente, a memória humana é do tipo associativa, bastando "alguma parte da informação" para acessar ("relembrar") todo o conteúdo. A BAM [NIELS-87c] [WASS-90] é um tipo de rede neural que "tenta simular" essa característica. A figura RNA9 mostra a estrutura desta rede. A rede é composta por duas camadas de neurônios (a camada 0 é uma camada de transferência - um *buffer*) e um conjunto de entradas e saídas interconectadas em *loop*.




FIGURA RNA9. Layout de uma rede BAM.

O processamento da rede BAM é simples. Inicialmente, um vetor de entradas é apresentado à rede como valor de saída dos neurônios da camada 1. Calcula-se o valor de ativação e de saída dos neurônios da camada 2, sendo apresentado aos neurônios da camada 0, que não executam nenhum processamento, simplesmente efetua a transferência para os neurônios da camada 1. Os dados ficam "girando" pela rede até que as saídas dos neurônios das camadas 1 e 2 estabilizem em um valor aceitável: $|_1Y - _2Y| < \text{ERRO_MÍNIMO}$ ($_1Y$ é o vetor de saída dos neurônios da camada 1, $_2Y$ idem para a camada 2). Esse processo é chamado de ressonância, pois, os valores circulam entre as camadas reforçando as saídas de forma a convergir para um valor estável, na direção que minimiza uma função de energia de Liapunov,

semelhante ao processo utilizado para a rede de Hopfield. Assim, cada "loop" provoca uma diminuição de energia da rede.

Outra característica importante da rede BAM é a sua capacidade de generalização e recomposição, pois, dado um vetor de entradas incompleto, a rede convergirá para o padrão mais próximo para o qual tenha sido "treinada". O processo de treinamento consiste em pré-definir os pesos sinápticos e mantê-los constantes quando em operação.

A matriz de pesos entre a camada 0 e a camada 1: ω^t , é a matriz transposta da matriz de pesos entre a camada 1 e a camada 2.

O processamento para as duas camadas é dados por:

CAMADA 2. O valor de ativação é calculado por:

$$SOMA_j = \sum_{i=1}^N a_i * \omega_{i,j} \quad (R18)$$

onde a_i : valor da saída do neurônio i da camada 1,
 $SOMA_j$: valor de ativação do neurônio j da camada 2 e
 N : número de neurônios da camada 2.

Utilizando-se a notação matricial: $[SOMA] = [A]*[\omega]$, onde $[A]$ é o vetor de entradas, $[\omega]$ é a matriz de pesos e $[SOMA]$ o vetor com os valores de ativação dos neurônios.

O valor de saída dos neurônios é calculado utilizando-se uma função sigmoide:

$$f(SOMA) = \frac{1}{1 + e^{-\lambda * SOMA}} \quad (R19)$$

Se a rede for binária, deve-se utilizar uma função de ativação do tipo *threshold*. Assim, utilizando a notação matricial, o valor de saída dos neurônios da camada 2 é dado por:

$$[B] = f([A]*[\omega]) \quad (R20)$$

onde $[B]$ é o vetor com o valor das saídas.

CAMADA 1. O valor de ativação é calculado por:

$$SOMA_j = \sum_{i=1}^N b_i * \omega_{ji} \quad (R21)$$

onde b_i : valor da saída do neurônio i da camada 0,
 $SOMA_j$: valor de ativação do neurônio j da camada 1 e
 N : número de neurônios da camada 1.

Utilizando-se a notação matricial: $[SOMA] = [B]*[\omega]^t$, onde $[B]$ é o vetor de entradas, $[\omega]$ é a matriz de pesos e $[SOMA]$ o vetor com os valores de ativação dos neurônios.

O valor de saída dos neurônios é calculado utilizando-se uma função sigmoide. Se a rede for binária, deve-se utilizar uma função de ativação do tipo *threshold*. Assim, utilizando a notação matricial, o valor de saída dos neurônios da camada 1 é dado por:

$$[A] = f([B]*[\omega]^t) \quad (R22)$$

onde $[A]$ é o vetor com o valor das saídas.

O processamento, nos neurônios de cada camada, é realizado sincronizadamente, ou seja, calcula-se o valor de saída de todos os neurônios simultaneamente e então, tornando-os disponíveis para a camada subsequente.

A inicialização da matriz $[\omega]$ é dada por:

$$[\omega] = \sum_{i=0}^M [{}_iA]^t * [{}_iB] \quad (R23)$$

onde M : número de vetores apresentados à rede,
 ${}_iA$: vetor de entradas,
 ${}_iB$: vetor associado ao vetor de entradas,

permanecendo constante durante a operação. Os pesos das conexões sinápticas são ajustados pela seguinte equação:

$$\Delta\omega_{i,j} = \eta * (a_i * b_j) \quad (R24)$$

onde η : coeficiente de aprendizado. Assumir um valor menor que 0.1 ,
 a_i : valor de saída do neurônio i da camada 1 e
 b_j : valor de saída do neurônio j da camada 2.

Com relação à estabilidade, a rede MAB tem a característica de que qualquer associação pode ser aprendida sem o risco de instabilidade [WASS-89], contudo, existe um restrição crítica quanto ao número de associações que podem ser incorporadas (aprendidas). Pode-se mostrar que a capacidade de recuperação da rede é dada por:

$$L \leq \frac{N}{4 * \text{Log}(N)} \quad (R25)$$

onde N é o número de neurônios da menor camada e L é o número de padrões reconhecidos. Conclui-se que esse tipo de rede pode realizar um número muito pequeno de associações. Uma rede com 256 neurônios na menor camada poderá realizar somente 8 associações. Um estudo mais detalhado sobre a capacidade da rede MAB binária pode ser encontrado em [NIELS-87c].

CAPÍTULO II

SISTEMAS BIOLÓGICOS

1. INTRODUÇÃO

Neste capítulo apresentamos o resumo dos elementos e estruturas biológicas [ANDR-88] [GUYT-76] do sistema nervoso humano e de outros animais que forneceram os princípios (similaridade) para o desenvolvimento das estruturas do sistema artificial que estamos propondo. Estudamos duas regiões do sistema biológico: o cerebelo e o hipocampo. O cerebelo é uma estrutura que atua principalmente em atividades relacionadas com o movimento muscular. Os seus circuitos neuronais serviram de inspiração para a elaboração da estrutura neuronal artificial responsável pela formação de rotas de movimento. Essa estrutura é formada por uma célula principal de processamento (como a célula de Purkinje) que realiza o mapeamento da área de trabalho. Várias dessas células são agrupadas e interligadas por vias diretas (como as fibras paralelas) que atuam junto ao *soma* e indiretas (como as fibras musgosas e trepadeiras), geralmente de caráter inibitório, tendo como objetivo realizar o sequenciamento das áreas mapeadas. A formação hipocampal, atuando diretamente sobre a localização espacial do ser, nos forneceu os elementos necessários para o desenvolvimento de uma estrutura capaz de mapear regiões em uma área de trabalho. Algumas células do hipocampo respondem à posição, orientação e direção do movimento realizado pelo ser. A resposta é específica. Utilizamos esse comportamento para implementar um neurônio artificial que assuma o estado de ativação quando os sinais de sensores indicarem uma região específica da área de trabalho. Esse neurônio artificial é o elemento principal da estrutura de mapeamento que apresentamos no capítulo IV.

O sistema nervoso humano [AGNA-92] [CARE-85] [CARE-91] é altamente complexo, sendo formado por um número muito grande de núcleos de processamento "aparentemente especializados, independentes e inter-conectados", o que dificulta o estudo do processo de aprendizado e tomada de decisão (entre outros). Do ponto de vista fisiológico, estrutural, anatômico e químico existe muito conhecimento adquirido, mas quanto aos processos neurológicos: forma de

armazenamento, processamento e recuperação das informações, temos somente "suposições".

A grosso modo, o sistema nervoso [ARBIB-81] [BEAR-91] [HEBB-49] recebe informações através de sensores e vias neuronais internas. Esses dados são processados pelos elementos do sistema nervoso que geram novas informações modificando o estado do sistema ou a base de informações. Pode ainda, gerar ações através das interações com o sistema esqueleto-muscular.

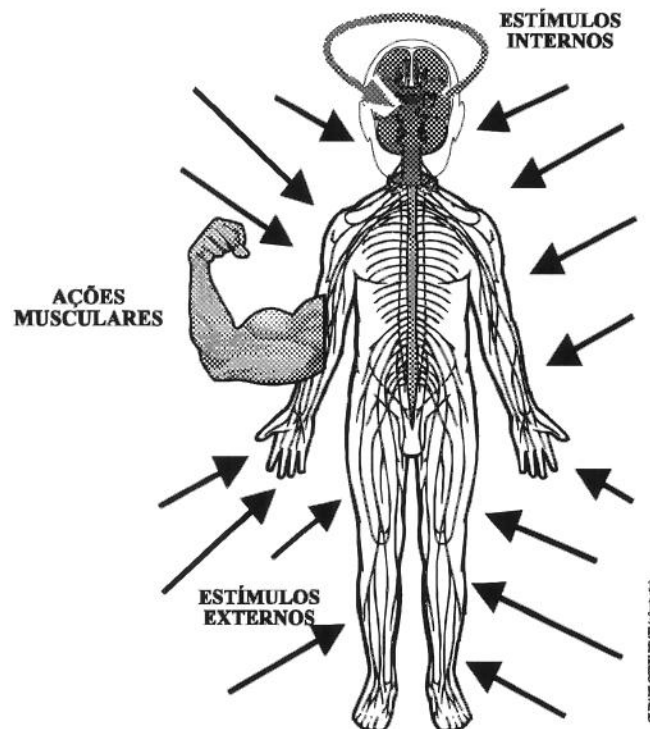


FIGURA B1. Estímulos externos e internos fornecem informações para o sistema nervoso que ativa uma ação muscular ou troca o seu estado.

Para facilitar o nosso estudo sobre o sistema nervoso, resolvemos dividi-lo em 4 partes (do ponto de vista anatômico):

- cérebro
- medula
- sensores receptores
- efetores

O cérebro (formado por dois hemisférios) é a principal macro-estrutura localizada na cabeça dos seres humanos e principal responsável pelo processamento das informações. A medula é o "tubo" condutor de sinais para o cérebro, do cérebro para os efetadores (músculos) e realiza algum tipo de processamento (principalmente a nível de reflexo). Os receptores coletam informações (força, pressão, deslocamento, temperatura, dor, olfato, paladar, imagem, som, ...) do meio externo e dos órgãos internos, enviando-as para o cérebro e medula. Os efetores são terminações nervosas conectadas aos músculos e glândulas, sendo responsáveis pela geração de alguma ação.



FIGURA B2. Cérebro.

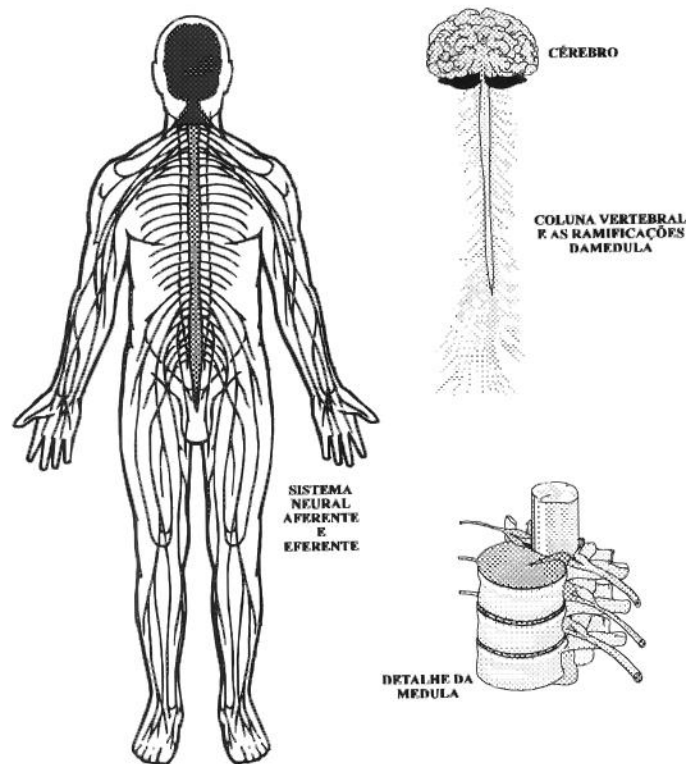


FIGURA B3. Sistema nervoso, coluna vertebral e medula.

O cérebro é a parte de maior interesse neste trabalho, merecendo alguns comentários objetivando a localização anatômica das regiões que abordaremos a seguir. O córtex cerebral [CARPE-90] pode ser dividido em dois hemisférios separados por uma grande fissura cruzada por uma comissura branca chamada corpo

caloso. A superfície dos hemisférios apresenta grandes depressões chamadas cisuras ou sulcos, que permitem a sua sub-divisão como indicado na figura B4. Essas subdivisões obedecem a critérios anatômicos e funcionais, por exemplo:

- lobo frontal: principalmente relacionado com o movimento dos olhos e pupilas,
- lobo parietal: principalmente relacionado como área sensorial e associativa,
- lobo temporal: principalmente relacionado como área associativa e com a audição e
- lobo occipital: área relacionada principalmente com a visão.

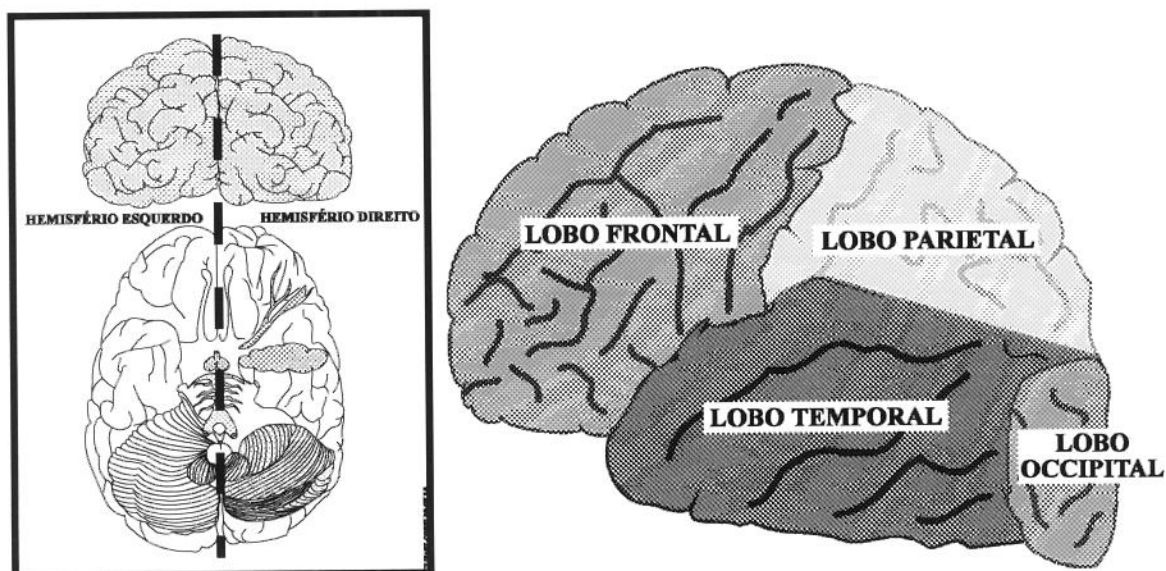


FIGURA B4. Hemisfério esquerdo e hemisfério direito do cérebro e suas subdivisões em lobos.

Essas regiões do córtex foram mapeadas quanto a sua funcionalidade e associatividade, principalmente do ponto de vista do controle motor e comportamental. No entanto, as "fronteiras não são bem definidas, devido principalmente ao alto grau de inter-conectividade e distribuição funcional do processamento das informações. Nota-se que existe uma "predominância geográfica" nas áreas do córtex atuando no controle específico de certas áreas motoras e associativas, mas que podem ser "substituídas" por outras.

Cada uma destas partes é formada por um grande número de núcleos específicos de processamento, de vias de inter-conexões, de vias aferentes e

eferentes. Para o nosso trabalho, estamos interessados nos circuitos relacionados com o processamento cognitivo (em especial a formação de mapas cognitivos), relacionados com a localização e navegação espacial e circuitos de controle de movimentos. Existem vários núcleos relacionados com o controle motor [EVAR-81] (principalmente no córtex cerebral), mas alguns circuitos cerebelares (cerebelo está localizado na região do metencéfalo) serviram de inspiração para o nosso modelo, principalmente do ponto de vista estrutural. Com relação à representação espacial, encontramos estudos que revelam a importância do hipocampo (localizado no telencéfalo) neste tipo de processamento. Assim, a seguir, apresentamos um breve resumo, do ponto de vista biológico, sobre essas áreas citadas.

2. O NEURÔNIO

A unidade principal de processamento e formadora dos núcleos especializados no sistema nervoso é chamada de neurônio (de certa forma, as reações químicas, ações genéticas, ... , podem também revelar algum tipo de "processamento"). O neurônio biológico [BROB-76] [GANO-83] [JACO-91] pode ser dividido, estruturalmente, em três partes principais: soma, dendritos e axônio.

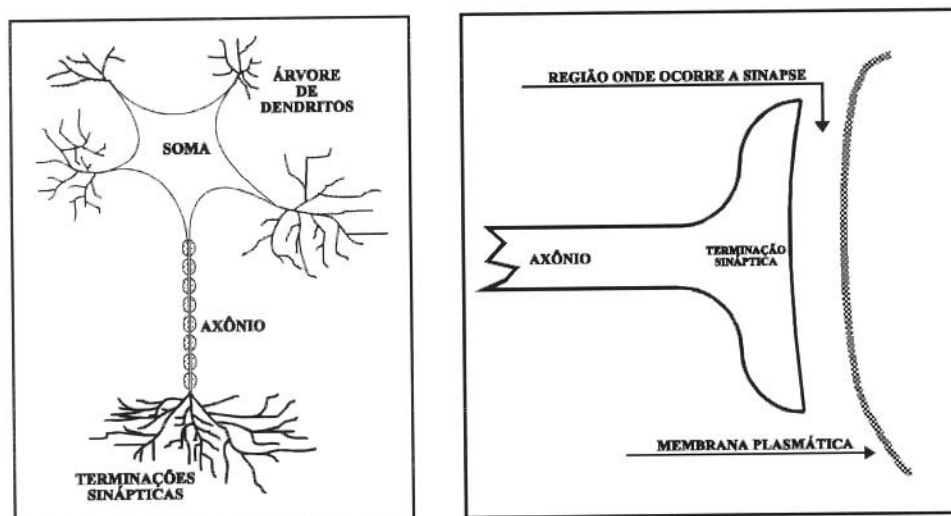


FIGURA B5. Layout de um neurônio e terminação sináptica.

O soma é o corpo principal do neurônio, responsável pelo "processamento" das informações. Os dendritos são as projeções do soma, atuando como canal de entrada de dados. O axônio é o prolongamento do soma, responsável pela transmissão do sinal de saída para outros neurônios ou para os efetadores (músculos). Junto a superfície dos dendritos (principalmente), por todo o soma e próximo ao início do axônio (junto ao soma) existem um grande número de botões sinápticos que são nodos de forma arredondada atuando como "porta de entrada" de dados, ou seja, é o local onde ocorre a sinapse (junção de dois neurônios ou entre um neurônio e uma placa motora). A parte terminal de um axônio, terminal pré-sináptico, faz conexão com outro neurônio no botão sináptico, liberando substâncias excitadoras, ou inibidoras, de forma a contribuir positivamente ou negativamente para a alteração do potencial elétrico do neurônio receptor.

O soma recebe os sinais de vários dendritos, executando uma ponderação e se o valor obtido for superior a um limiar mínimo, ocorre o disparo de um sinal de

saída, chamado de potencial de ação, que é transmitido pelo axônio. A ponderação ocorre de forma analógica, atuando como um somador (integrador). O sinal de um único dendrito não provoca a liberação de um potencial de ação, e sim, são necessários centenas de sinais, que geralmente ocorrem de forma dessincronizada.

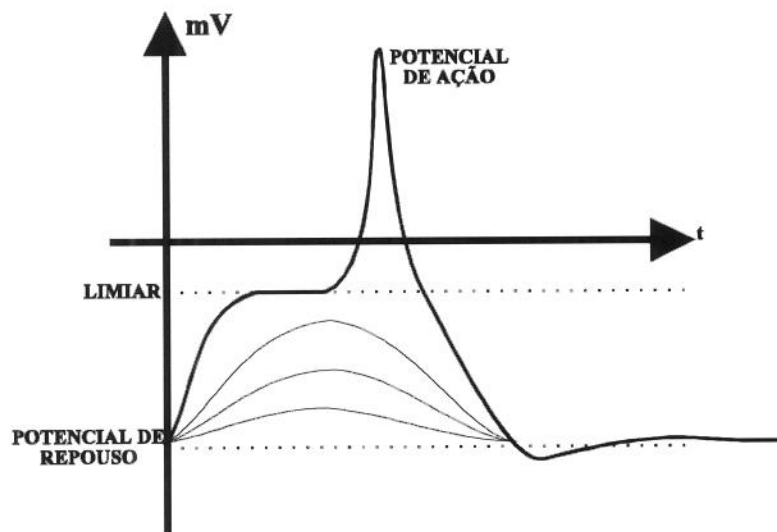


FIGURA B6. Variação de tensão no *soma* indicando um potencial de ação.

A figura B6 mostra uma série de sinais sendo ponderados no soma e um potencial de ação disparado. O soma tem um valor de tensão de repouso, chamado potencial de repouso que é mantido "constante" por processos fisio-físico-químicos. Com o recebimento de sinais nos botões sinápticos, esse potencial aumenta (se o sinal for excitatório) provocando a despolarização do soma, ou então, pode diminuir (se o sinal for inibitório) provocando uma hiperpolarização. Quando o potencial do soma atinge um limiar mínimo, ocorre o disparo de um potencial de ação que será conduzido aos neurônios subsequentes ou a uma placa motora através do axônio. A contribuição de cada sinal de entrada para o disparo do potencial de ação é função do seu "peso sináptico". Uma série de fatores físicos e químicos exercem influência na formação do "peso sináptico". Por exemplo, a contribuição do sinal coletado por um dendrito muito afastado do soma será menor que o sinal injetado diretamente na base do axônio junto ao soma, pois, existem perdas e interferências de outros sinais. A figura B7 mostra a interferência de um sinal inibitório atenuando um sinal excitatório. Nota-se que o sinal excitatório que despolariza o dendrito elevando o

potencial para -25 mV sofre a interferência de terminações sinápticas inibitórias repolarizando-o.

O potencial de ação é um pico de tensão "propagando" pelo axônio. Após o disparo, o potencial do soma volta ao estado de repouso. Um novo potencial de ação poderá ser gerado somente se o potencial do soma estiver abaixo do

limiar de ativação. O "processamento" dos sinais ocorre no soma, mas o potencial de ação tem origem na região de junção entre o soma e o axônio. O sinal no axônio é uni direcional, propagando-se somente para os neurônios conectados ao axônio condutor.

Devido ao grande número de terminais receptores [AGNA-92] no neurônio e a natureza assíncrona dos sinais de entrada, o potencial de repouso do soma pode aumentar, aproximando-se do limiar de disparo, de tal forma que o recebimento de mais alguns poucos sinais de entrada, dispare novos potenciais de ação. Esse estado de sub-ativação é chamado de *facilitação*. Sinais difusos no sistema nervoso muitas vezes *facilitam* grupos de neurônios, possibilitando um resposta rápida a estímulos de menor intensidade, criando-se assim, um estado de vigília e atenção. O axônio comporta-se como um cabo condutor do potencial de ação, transportando sinais excitatórios ou inibitórios. O sinal é transmitido de forma binária: ou existe um potencial de ação (nível lógico 1) ou existe um potencial de repouso (nível lógico 0), ou seja, a informação transmitida não é analógica.

Outras informações sobre a anato-fisiologia do neurônio e formas de transmissão de sinais nas sinapses podem ser encontradas em [BROB-76] e [GANO-83]. Fizemos aqui referências somente às características que nos serão úteis na definição da unidade básica de processamento do sistema a ser proposto.




FIGURA B7. Detalhe da variação de potencial no dendrito.

3. O CEREBELO

O cerebelo [ALB-71] [CHAU-86] faz parte do sistema nervoso supra-segmentar, apresentando um córtex externo e substância branca ao centro. Sua principal função é a de supervisão de atividades motoras [BROB-76] (a nível de inconsciente e movimentos involuntários) relacionadas com o controle de movimentos finos, suaves, seguros e com a coordenação do movimento de múltiplas juntas (decomposição e sincronismo de movimentos). As tarefas realizadas pelo cerebelo têm caráter preditivo, baseadas no aprendizado por experiências, e também, em informações altamente facilitadas transferidas de áreas do córtex associativo. Assim, o cerebelo [ITO-70] [ITO-84] atua como um supervisor, corrigindo e ajustando os movimentos. Esse processamento é realizado comparando o estado atual das partes do corpo envolvidas com o padrão desejado (esperado) de movimento e interferindo no nível da ativação muscular. Para tanto, recebe informações de todo o corpo, o que lhe permite determinar a posição, orientação, velocidade, força e outros parâmetros necessários para a realização do movimento [LALO-86] [LALO-90]. Esse processamento, a princípio, deveria ser rápido, acompanhando os movimentos, no entanto, geralmente isso não ocorre. Além disso, o cerebelo também está relacionado com funções associadas à localização espacial, pois, faz conexão com o sistema límbico e córtex fronto-parietal.

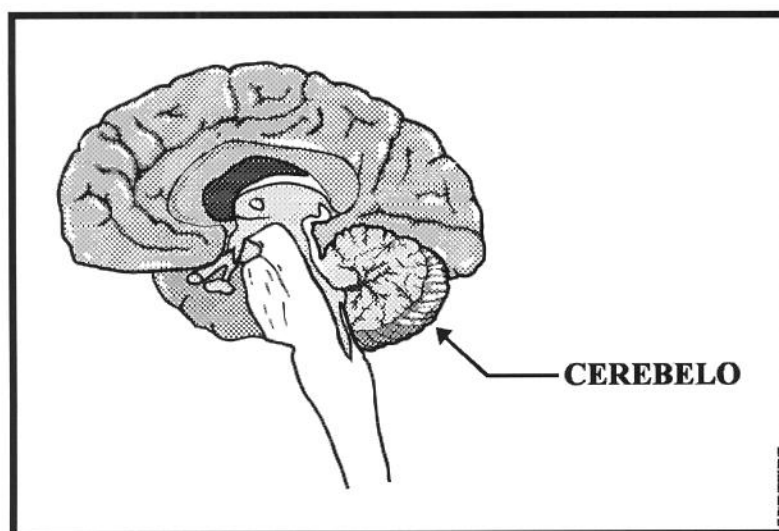


FIGURA B8. Localização do cerebelo no sistema nervoso.

Nota-se que a estimulação elétrica no cerebelo raramente provoca uma contração muscular. O cerebelo [MARR-69] não gera nenhum tipo de movimento, e sim, atua sobre movimentos iniciados por outras partes do sistema nervoso, como por exemplo, a medula espinhal, formação reticular, núcleos da base, córtex motor e somato-sensorial. Outros experimentos permitem concluir que o cerebelo atua como um controlador do amortecimento muscular. Quase todos os movimentos de membros são pendulares e normalmente ocorrem em posições instáveis, como um pêndulo invertido. Para que o deslocamento do membro ocorra com o mínimo de oscilação, é necessário introduzir um mecanismo amortecedor (seja físico ou de controle). O cerebelo atua neste sentido. Outra função do cerebelo é atuar como compensador de inércia. Quando se está movimentando continuamente uma grande massa, geralmente o ponto final da trajetória não é atingido na primeira tentativa. Embora o córtex motor atue vigorosamente na correção do movimento, é o cerebelo quem modula os excessos de atividade, uma vez que suas malhas de *feedback* são muitas vezes mais rápidas que as do córtex. No início de um movimento, a quantidade de estímulos sobre os músculos agonistas é grande, contudo, pouco antes do ponto final da trajetória ele é inibido e o antagonista ativado, e quanto mais rápido o movimento e maior a massa manipulada, mais cedo o controle cerebelar é ativado (inconscientemente). Deve-se ressaltar que o cerebelo não atua sozinho neste processo, pois o reflexo medular de estiramento tem grande influência no controle da ação de amortecimento. O cerebelo atua sustentando ou inibindo os estímulos, e assim, tornando a ação adaptável às situações aleatórias que surgem durante o movimento. As vias de *feedback* proprioceptivo ao córtex motor são muito lentas, introduzindo um grande atraso entre o instante que um evento ocorreu, o processamento, e a resposta motora (principalmente em movimentos rápidos).

O cerebelo [ALB-75a] [ALB-75b] [CHAU-86] possui vias de *feedback* muito rápidas, interferindo neste mecanismo através da filtragem de sinais proprioceptivos, realimentando o sistema nervoso central com uma previsão dos estados futuros dos membros em movimento. A figura B9 mostra esquematicamente algumas vias para fluxo de sinais entre os "atuadores musculares" e o "controlador neuronal".

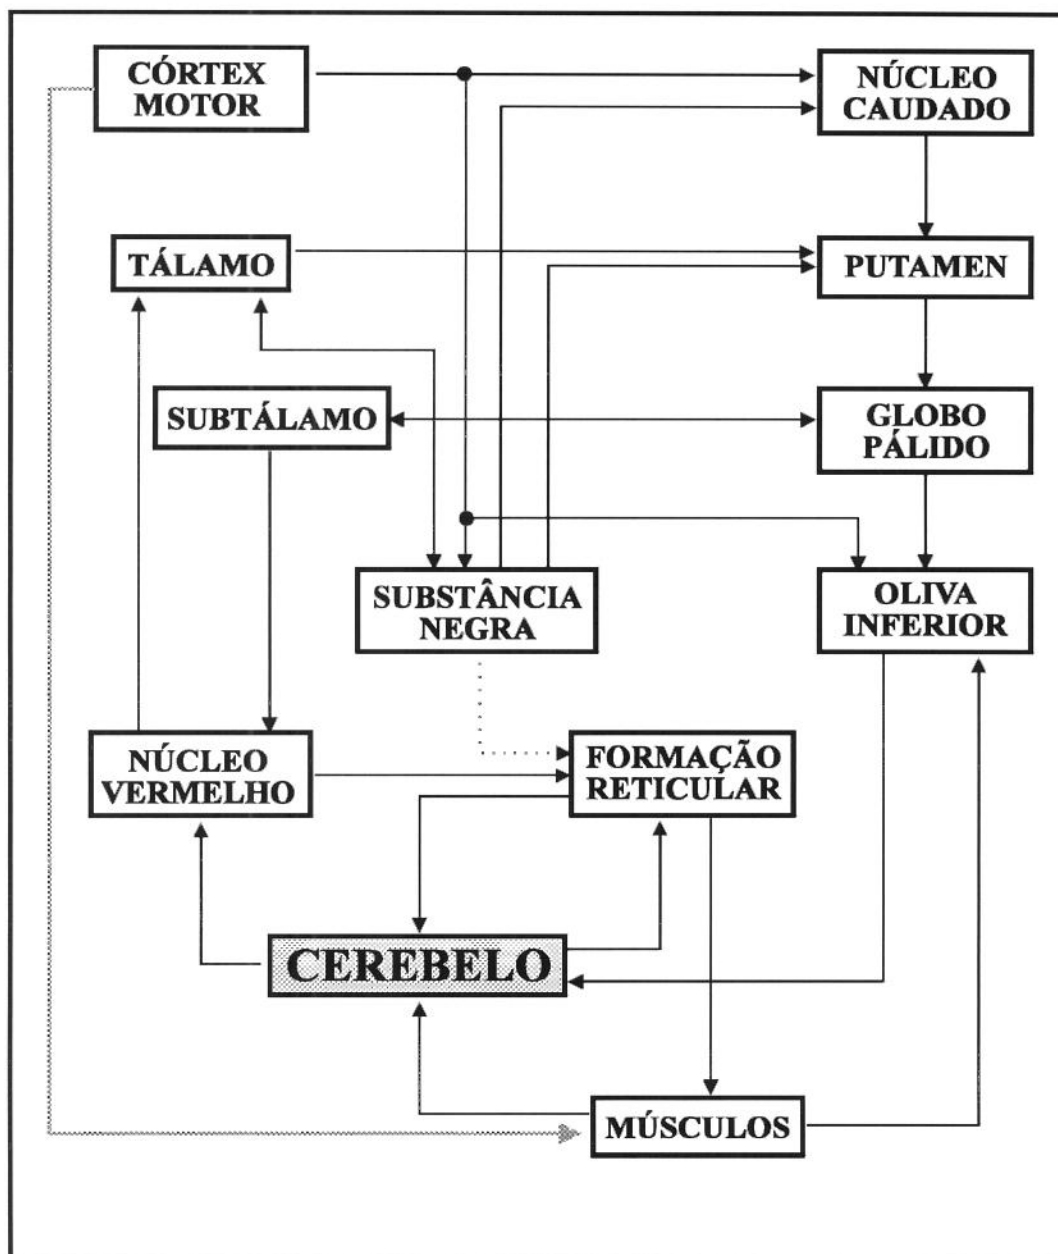


FIGURA B9. Layout de algumas vias de comunicação entre o cerebelo e outros núcleos no sistema nervoso (não representamos todas as conexões). A via que liga o córtex motor aos músculos passa por neurônios internunciais, neurônios motor gama e neurônio motor alfa [MAC-80].

A participação do cerebelo no controle de movimentos "subconscientes" e postural é semelhante a exercida durante os movimentos voluntários, diferindo pelas vias de controle. Todo o sinal aferente aos músculos partem da formação reticular, que recebe sinais do cerebelo e núcleo vermelho; "não existe" uma via direta entre o

córtex motor e os músculos, e sim, passando pela oliva inferior, cerebelo e formação reticular, ou então, provavelmente pela substância negra e formação reticular. Pode-se notar a presença de longos e curtos loops de *feedback*, por exemplo:

- cerebelo, núcleo vermelho, tálamo, núcleo caudado, putamen, globo pálido, oliva inferior e cerebelo;
- cerebelo, núcleo vermelho, formação reticular e cerebelo;
- cerebelo, tálamo, córtex motor, oliva inferior e cerebelo.

Não entraremos em detalhes neste assunto, pois, o nosso interesse é a estrutura anatômica do cerebelo. A estrutura cerebelar é surpreendentemente uniforme, sendo composta pela união de milhões de unidades funcionais praticamente idênticas, cujo cerne são as células de Purkinje. O conjunto destas unidades funcionais permite dividir o córtex cerebelar em 3 camadas (vide figura B10) :

- camada molecular,
- camada de células de Purkinje e
- camada granular.

As células de Purkinje são piriformes e grandes, apresentando muitos dendritos que vão se alojar na camada molecular (mais externa) e um axônio que se estende até os núcleos centrais do cerebelo.

Na camada molecular existem poucos neurônios, sendo as células em cesto as mais importantes, cuja função é unir várias células de Purkinje através do seu axônio.

A camada granular é composta principalmente por um grande número de células granulares. Essas células apresentam vários dendritos e um axônio que cruza a camada de células de Purkinje alcançando a camada molecular onde bifurca-se em forma de um 'T' formando um conjunto de fibras paralelas, estabelecendo sinapses com os dendritos das células de Purkinje e com as células em cesto. Nesta camada existem ainda outros tipos de neurônios, como por exemplo, as células de Golgi cujos dendritos estabelecem sinapses com a camada de Purkinje e molecular.

Observa-se nas figuras B11 e B12 que as células de Golgi são excitadas pelas fibras paralelas e também pelas fibras musgosas. Seu axônio faz sinapse inibitória

sobre as células granulares completando uma das alças de retro-alimentação negativa do circuito cerebelar.

O cerebelo [CHAU-86] [GHEZ-85] [MAC80] recebe informações de várias partes do corpo através de várias vias, entre elas:

- via córtico-cerebelar que liga o córtex motor ao córtex do cerebelo passando pelos núcleos da ponte e tratos ponto-cerebelares;
- trato olivo-cerebelar que liga a oliva inferior com o cerebelo;
- fibras vestibulo-cerebelar;
- fibras retículo-cerebelares e
- tratos espino-cerebelares ventrais e dorsais que enviam informações sobre o estado do corpo. Estes sinais têm origens nos fusos neuro-musculares, órgão tendinoso de Golgi, receptores táteis da pele e articulações, permitindo monitorar a força muscular, posição e tensões externas ao membro. É importante salientar que essas vias sensoriais são extremamente rápidas.

As vias aferentes terminam principalmente no córtex cerebelar, projetando os respectivos pontos de estimulação no corpo, ou seja, cada músculo e articulação é projetado em uma área específica no córtex cerebelar. Os sinais aferentes penetram no córtex cerebelar através de dois tipos de fibras:

- fibras musgosas e
- fibras trepadeiras.

As fibras musgosas cruzam o corpo medular do cerebelo ramificando-se próximo à camada granular onde fazem sinapses com as células granulares, e assim, os sinais aferentes atingem o córtex através das fibras paralelas, fazendo sinapse excitatória com as células de Purkinje através das conexões com os seus dendritos (fibras paralelas - dendrito da célula de Purkinje) e as células em cesto, cujo axônio faz sinapse inibidora com o corpo da célula de Purkinje. A célula em cesto envolve o soma da célula de Purkinje formando uma estrutura semelhante a um cesto.

Os sinais das fibras musgosas são muito fracos, necessitando que inúmeras fibras enviem sinais para que uma célula de Purkinje dispare um potencial de ação. Em geral, essas fibras atuam como *facilitadoras*, elevando o potencial médio das células de Purkinje.

As fibras trepadeiras tem esse nome porque enrolam-se em torno dos dendritos da célula de Purkinje exercendo forte ação excitadora.

As portas de saída do cerebelo são os núcleos centrais que recebem os estímulos inibitórios das células de Purkinje e excitatórios das fibras trepadeiras e musgosas.

Os núcleos centrais podem ser divididos em 4 grupos:

- núcleo dentado,
- núcleo emboliforme,
- núcleo globoso e
- núcleo fastigial.

Os sinais aferentes são enviados para o córtex cerebelar e núcleos profundos. O córtex cerebelar processa essas informações enviando o sinal resposta para os núcleos profundos que os envia para o exterior. Nenhuma via eferente parte do córtex cerebelar, as principais estão conectadas ao córtex motor, núcleos da base, núcleo vermelho, formação reticular do tronco cerebral e núcleos vestibulares.




FIGURA B10. Layout do segmento de uma folha cerebelar [MAC-80].




FIGURA B11. Um dos principais circuitos cerebelar.




FIGURA B12. Circuitos no cerebelo [ECC-67].

Em resumo, as células do córtex cerebelar são inibidoras, exceto as células granulares. Este tipo de estrutura não é observada em nenhuma outra região do sistema nervoso. A título de curiosidade, lesões nos núcleos da base (porta de saída dos sinais) resultam em Parkinsonismo e lesões no córtex cerebelar provoca ataxia e tremor.

O cerebelo está ligado ao córtex cerebral (associativo e motor) por uma série de vias (vias cérebro-cerebelares), sendo que as principais são mostradas na figura B13. Uma destas grandes vias tem origem nas células Piramidais (L.PYR.C) fazendo conexão com moto-neurônios alfa e gama, ativando as fibras musculares. As L.PYR.C também ramificam-se fazendo sinapses nos núcleos da ponte (NP) e no núcleo reticular lateral (LRN), fornecendo sinais para as fibras musgosas (MF). Desta forma, os sinais de início do movimento são enviados simultaneamente para o lado oposto do córtex cerebelar (situado no mesmo lado do movimento). Assim, existe uma via rápida entre o córtex motor e o cerebelo, ou seja, o cérebro ao iniciar um movimento "ativa" simultaneamente o cerebelo. Uma das vias de retorno de sinais do córtex cerebelar ao córtex motor é através do núcleo interpositus (IP) que é estimulado por sinais provenientes das fibras musgosas, fibras trepadeiras e inibido pelos sinais das células de Purkinje. Essa via é muito rápida, havendo uma única estação sináptica no tálamo ventro lateral (VL). Um outro caminho de ação sobre os moto-neurônios da medula espinhal é o que conduz os sinais do IP passando pelo núcleo rubro (RN) e atingindo o moto-neurônio via trato rubro-espinhal (RST). Deve-se salientar que o sinal de retorno proveniente do córtex cerebelar retorna à mesma área do córtex motor onde teve início o sinal de "start" do movimento.

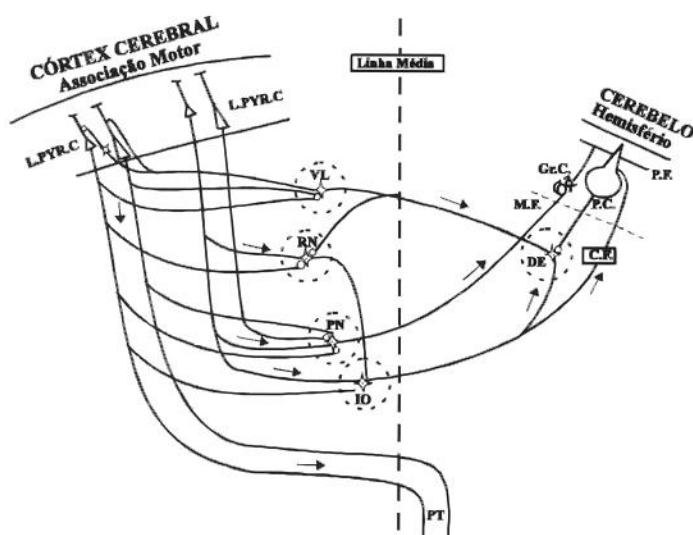


FIGURA B13. Vias de comunicação cérebro-cerebelar unindo o córtex motor e de associação ao cerebelo [ALLE-74].

Os sinais do córtex associativo cruzam o hemisfério cerebelar contra lateral através de conexões nos núcleos da ponte (PN) e oliva inferior (IO). Após a computação no cerebelo, a via de retorno que conduz sinais ao córtex motor passa pelo núcleo VL do tálamo. E então, do córtex motor, via trato piramidal (PT) para os moto-neurônios que ativam os movimentos. Anatomicamente as células piramidais do córtex motor têm interface com células granulares do córtex sensitivo-somático, e vice-versa. Muitas fibras desse córtex também terminam no córtex motor, tanto é que alguns movimentos têm origem no córtex sensitivo, ou são alterados por este. Pelas vias sensitivas, o sistema nervoso central (SNC) monitora os efeitos dos movimentos realizados, "aprendendo" os padrões que "de alguma forma" lhe são úteis. Quando necessário, o SNC lança mão destes padrões armazenados para a realização dos movimentos, por exemplo, padrões cíclicos como o andar, pular, cortar e pedalar. Nota-se que deve haver um encadeamento temporal e espacial das ações que são disparadas pelos estímulos proprioceptivos, e o córtex motor atua como um servo controlador. Experiências utilizando macacos treinados para a realização de tarefas complexas demonstram a influência dos dois córtex (motor e sensorial). Removendo parte do córtex motor e deixando intacto o córtex sensitivo, o macaco ainda consegue realizar as tarefas utilizando os músculos que permanecem controláveis. Mas o contrário não é observado, removendo parte do córtex sensitivo-somático e deixando intacto o córtex motor, o macaco perde a coordenação motora ou não consegue realizar o movimento.

Pouco se sabe a respeito de qual a participação do cerebelo no aprendizado e execução de um comando motor. No entanto, observa-se que primeiro um movimento é executado muito lentamente com a intensa atuação cerebral. Com a prática, esse movimento torna-se "automatizado" (pré-programado) podendo ser executado mais rapidamente. O cerebelo atua na pré-programação ("talvez predição") e execução (a nível de modulação) dos movimentos. Se o cerebelo for removido, os movimentos ainda poderão ser realizados mas com tremor e intensa atuação do cérebro.

Na figura B14 esquematizamos o principal circuito cerebelar (ver figuras B11 e B12) através de 2 módulos que se repetem por todo órgão. Utilizamos esta estrutura para implementar o processo de mapeamento da área de trabalho e formação de rotas. A funcionalidade dos seus elementos não será a mesma observada no sistema biológico. O módulo de processamento (representado pelas células de Purkinje) é o responsável pelo mapeamento da área de trabalho. Sinais externos, contendo valores de posição, e sinais internos de caráter inibitório

fornecem informações ao processador que produzirá os sinais de saída correspondentes às novas posições (coordenadas) as serem seguidas. Essa estrutura bi-modular é agrupada e interconectada (semelhante às fibras paralelas) com outras idênticas formando um núcleo básico para o aprendizado (formação) de rotas.

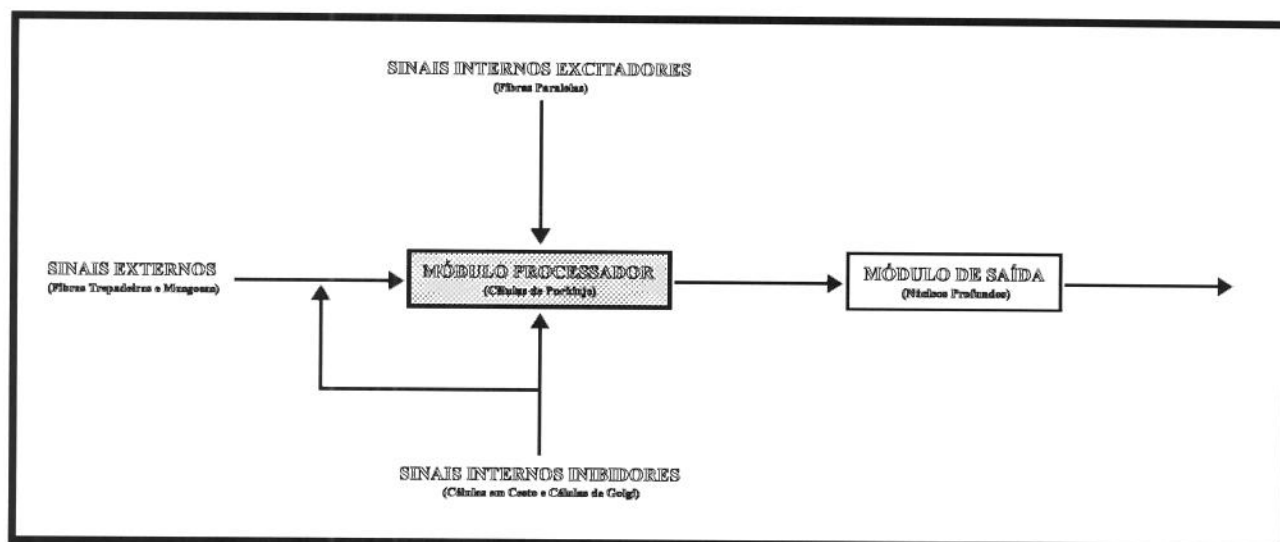


FIGURA B14. Layout do principal circuito cerebelar implementado no sistema.

A principal célula do cerebelo, a célula de Purkinje (módulo processador), tem caráter inibitório sobre a via de saída (célula nuclear profunda). No sistema proposto, adotamos um procedimento inverso, o módulo processador terá influência excitatória sobre o módulo de saída. Utilizamos esse procedimento procurando facilitar a implementação computacional do sistema, pois se todos os módulos de processamento estiverem ativos simultaneamente, o custo computacional seria muito grande uma vez que a implementação (simulação) foi realizada em uma CPU com processamento sequencial.

As vias inibitórias têm por objetivo interconectar as estruturas desse núcleo, atuando como um selecionador. Por exemplo, se uma estrutura é ativada, as outras do mesmo núcleo serão inibidas, permitindo que somente uma resposta seja válida.

No item a seguir, região hipocampal, descrevemos o processamento funcional do módulo processador, mostrando como as regiões da área de trabalho serão mapeadas.

4. O HIPOCAMPO

Estudos [AMARA-89] [AMARA-90a] [AMARA-90b] [BUZS-90] [DIST-91] [EICH-91] [LOTH-91] [McNA-91] [MULL-94] [O'MAR-94] revelam que a região hipocampal está, de alguma forma, associada (ou participa) ao aprendizado de posição e orientação de seres vivos (experimentos com ratos, macacos e humanos permitem esta conclusão) no espaço.

A região hipocampal [EICH-92] está localizada no assoalho do lobo temporal apresentando a forma de um 'C' (com grande variação de tamanho entre os mamíferos [WEST-90] [LORE-33] [LORE-34]. É uma estrutura bastante organizada e seus circuitos propiciam algum controle em malha fechada, pois possuem vias para *feedback* [BUZS-90]. A região hipocampal pode ser dividida em 4 núcleos:

- giro denteado,
- hipocampo propriamente dito (regiões CA1, CA2, CA3 e CA4),
- complexo subicular (subiculum, pré-subiculum e para subiculum) e
- córtex entorrinal (medial e lateral).

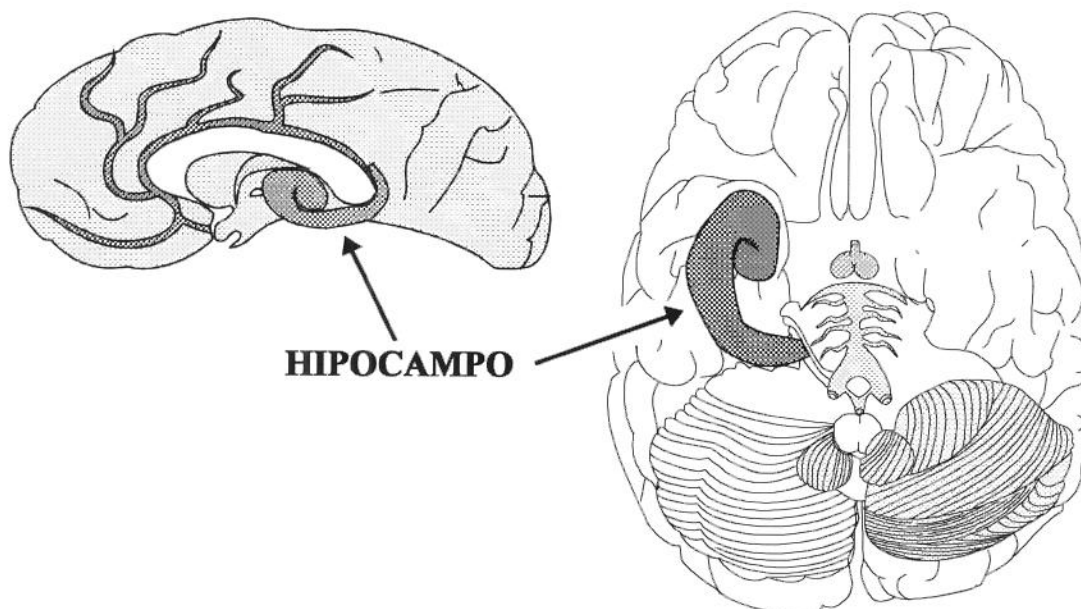


FIGURA B15. Localização do hipocampo.

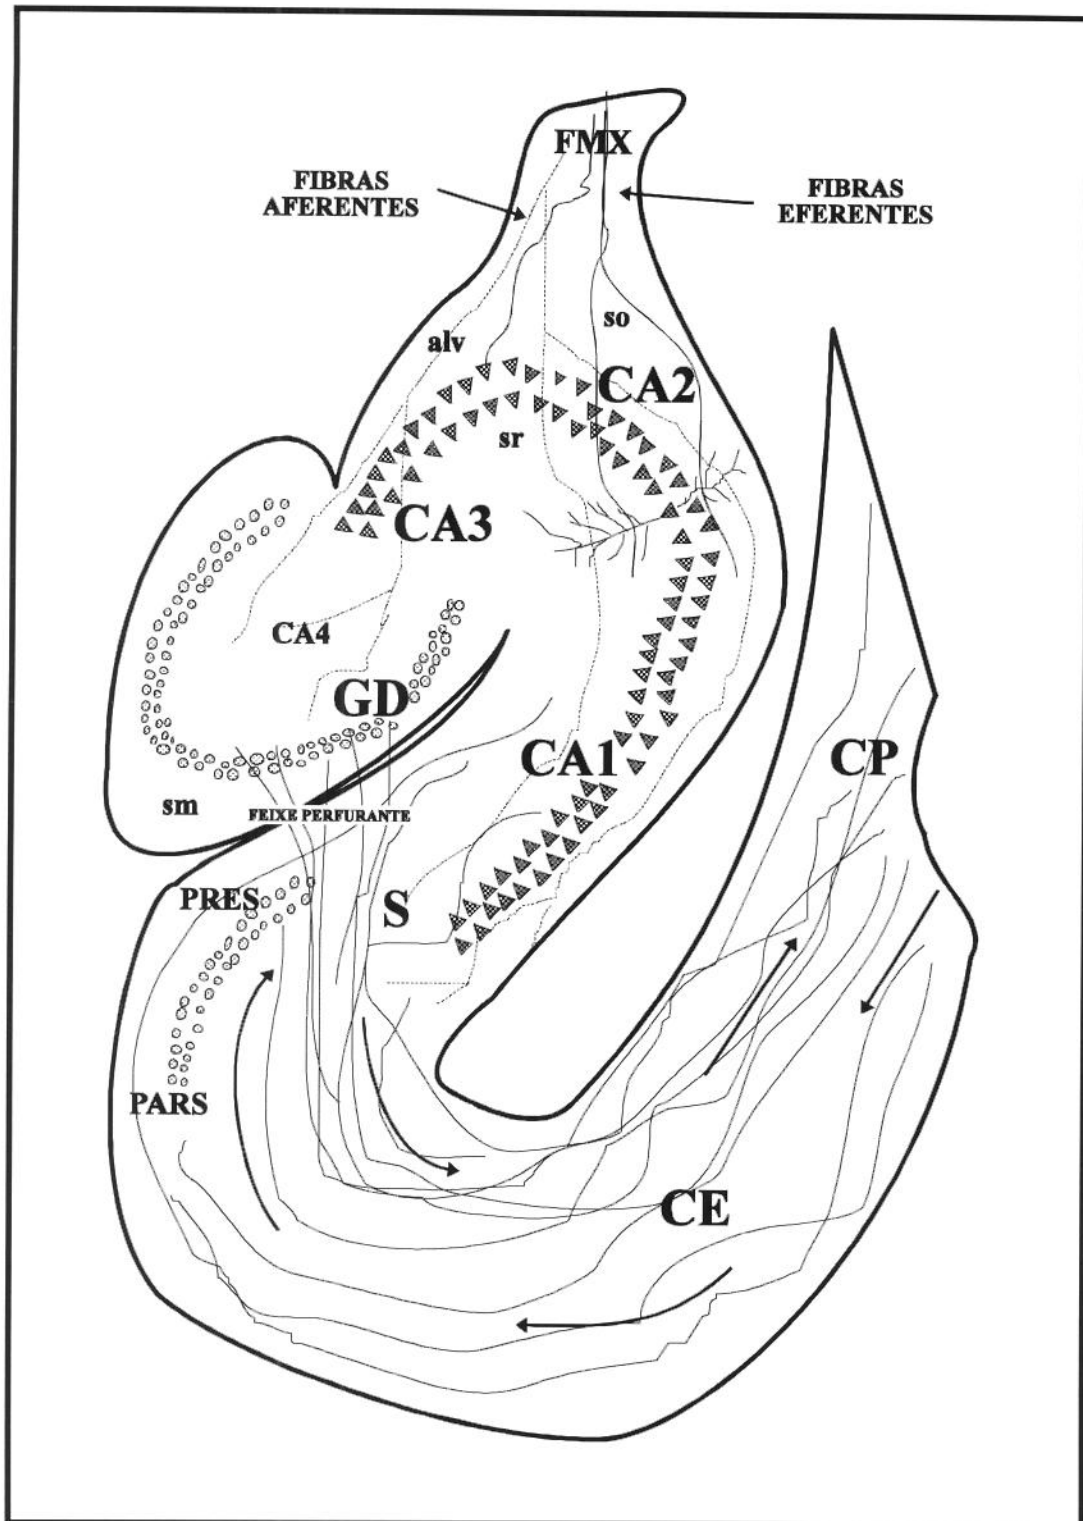


FIGURA B16. Layout da estrutura hipocampal [BROD-84] [O'MAR-95] de um roedor. FMX: fórmix; SO: stratum oriens; CA1, CA2, CA3 e CA4: subdivisões do Ammon's horn; HGD: hilus do giro denteado; GD: giro denteado; S: subiculum; PRES: pré-subiculum; PARS: Para-subiculum; CE: córtex entorrinal; CP: córtex perirrinal.

Com relação a estrutura anatômica da região hipocampal, existem duas teorias principais. Uma teoria, proposta por Andersen [AND-71] que sugere uma organização lamelar [RAW-77] [LOTH-91] (camadas de lamelas) operando independentemente e inter-conectadas (conexões excitatórias e inibitórias) lateralmente, onde o principal processamento ocorre nas lamelas independentemente.

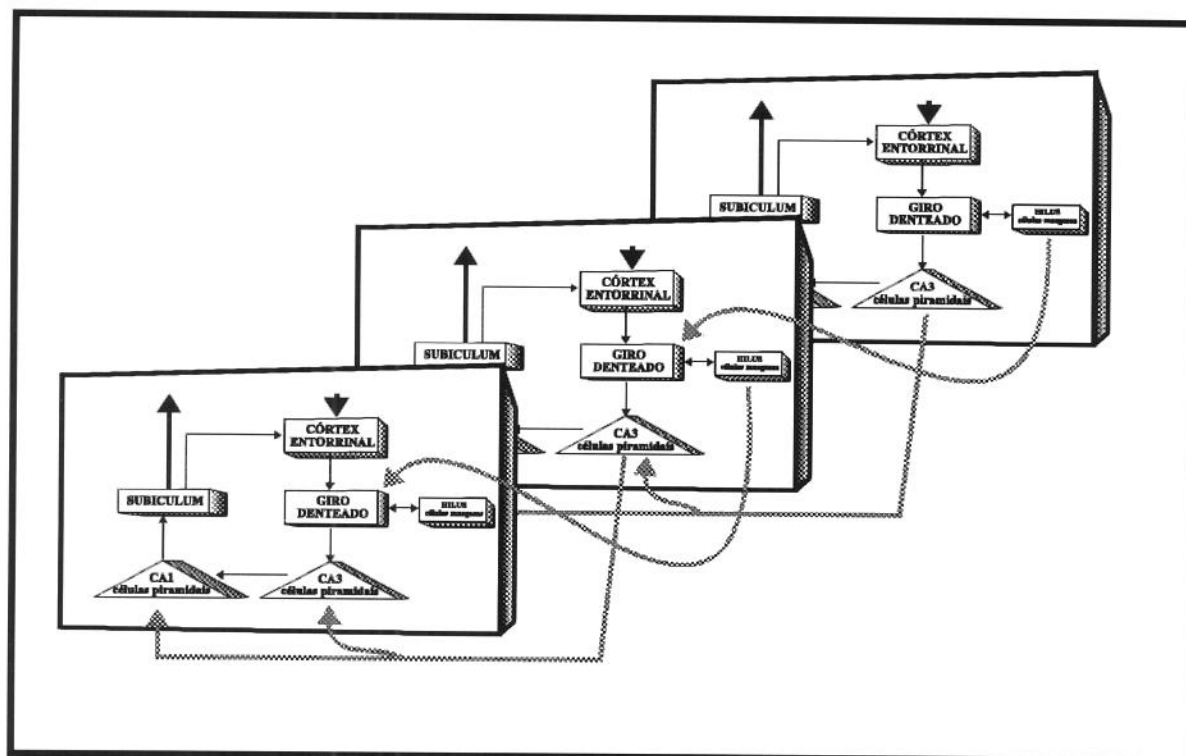


FIGURA B17. Estrutura lamelar [LOTH-91].

Estudos mais recentes contestam esta teoria (ou parte dela). Amaral [AMARA-90a] afirma que além da organização das fibras musgosas nenhuma outra conexão na formação hipocampal apresenta uma estrutura lamelar, pois, os circuitos e conexões são amplamente divergentes. Por exemplo, as conexões das áreas CA3 para a área CA1 [AND-90] apresentam uma estrutura que permite a dispersão de sinal de uma região específica para áreas muito maiores que a de uma lamela (figura B17). Amaral acredita que a estrutura hipocampal pode ser vista como uma série de regiões corticais e que as informações são processadas simultaneamente por várias regiões e não em uma lamela isolada.

Não temos recursos, experiência e interesse em validar esta ou aquela teoria, no entanto, as observações de ambas podem fornecer o embasamento necessário para a consolidação do modelo que estamos propondo.

A figura B16 mostra o *layout* da região hipocampal e as figuras B18 e B19 mostram suas principais conexões e o fluxo de dados entre os núcleos.

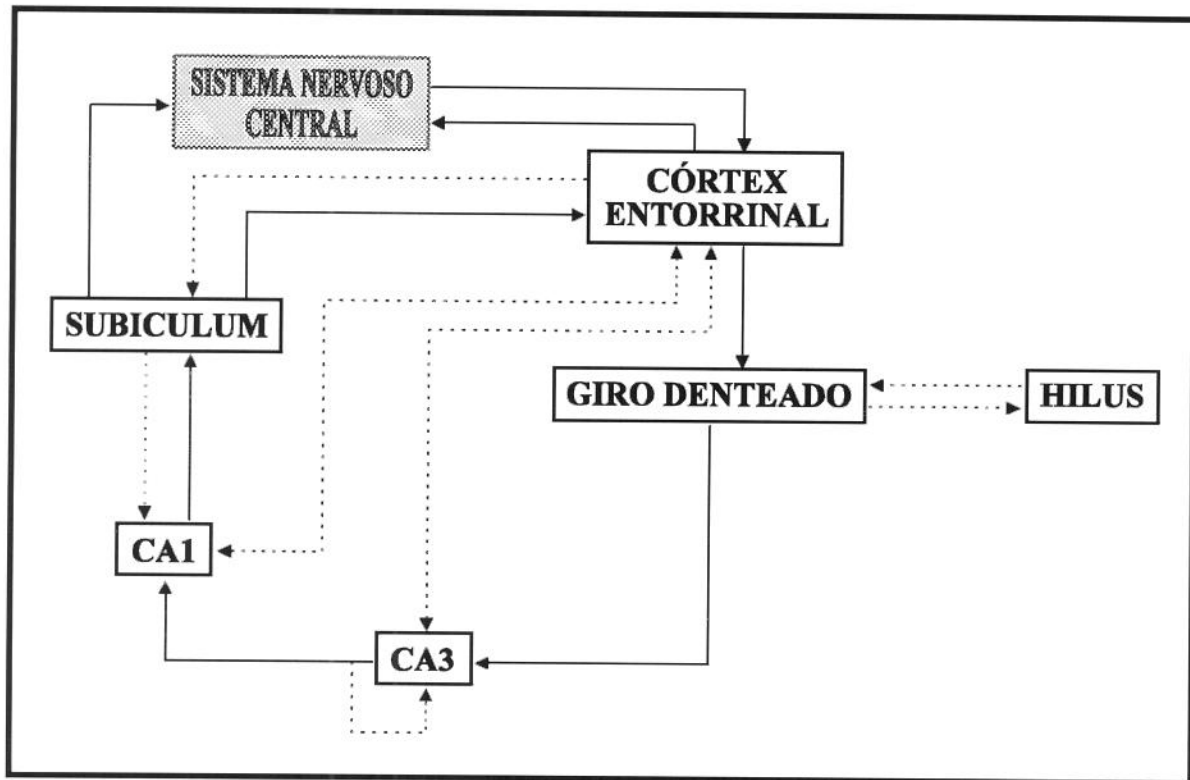


FIGURA B18. Principais vias de comunicação no hipocampo.

Os circuitos indicados na figura B18 não são os únicos, mas são os mais importantes e revelam uma grande integração entre os núcleos, que não operam como unidades funcionais isoladas. A principal via (uni-direcional [WEST-90]) é formada pelo córtex entorrinal, giro denteado, região CA3, região CA1, subiculum e retornando ao córtex entorrinal.

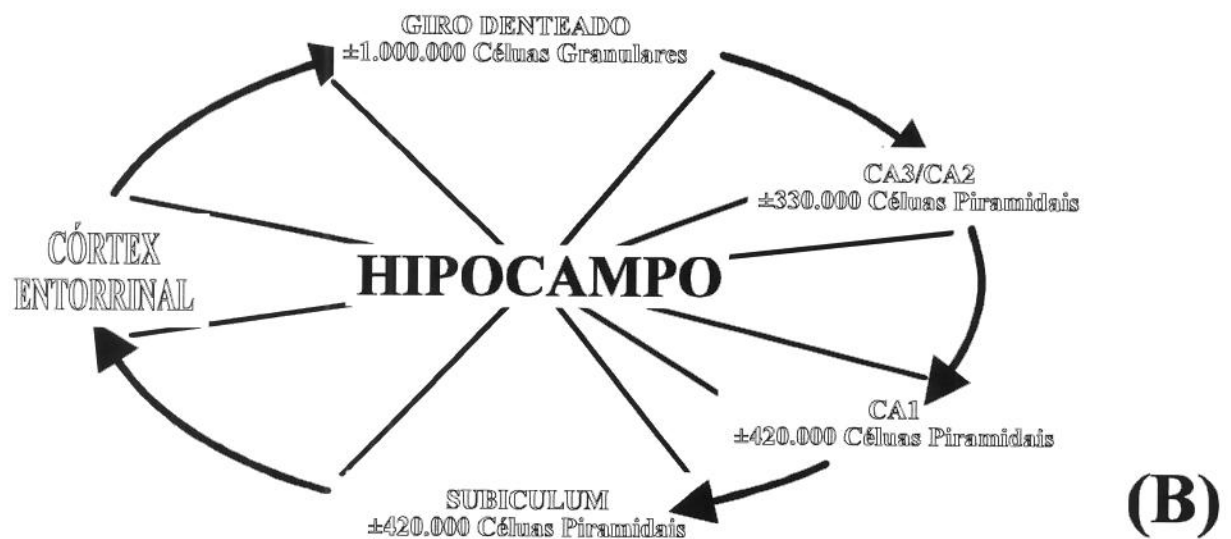
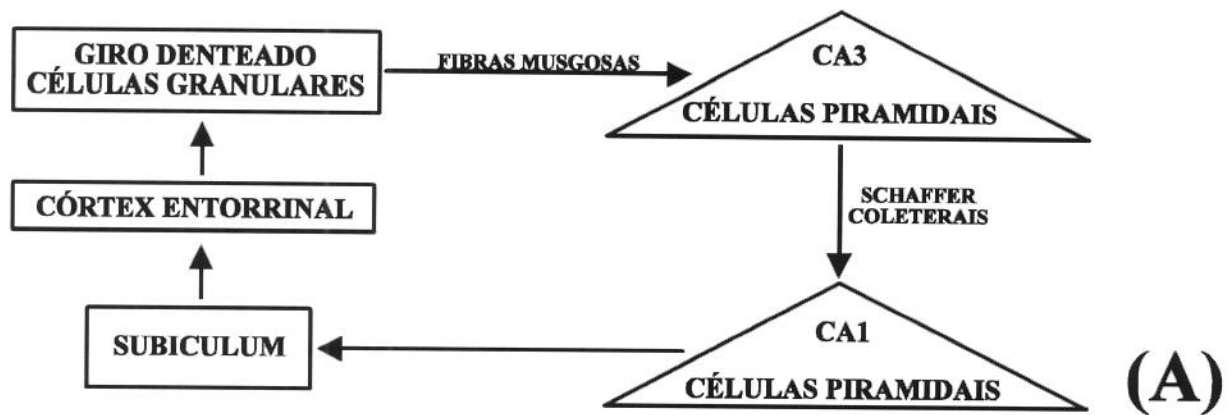


FIGURA B19. (A) Principal via de comunicação no hipocampo [WEST-90]. (B) Principal via de comunicação no hipocampo e tipos de células. [AMARA-90a].

Em função do alto número de conexões aferentes e eferentes, e também devido às observações, sugere-se que o hipocampo exerça influência em um grande número de áreas do sistema nervoso. Existem vários estudos sobre a função do hipocampo no SNC (orientação, discriminação espacial, atenção, memória, ..) mas o que mais nos interessa são os que revelam sua relação com a orientação e localização espacial [O'KEE-71] [OLTO-91]. As linhas cheias indicam intenso fluxo de dados. Pode-se notar que existe um fluxo anelar (e seqüencial) entre o subiculum, córtex entorrinal, fascia denteada, região CA3 e CA1.

O córtex entorrinal faz conexão com uma vasta área do hipocampo (CA3 e CA1 principalmente) exercendo acentuada influência no processamento. Essas

conexões obedecem certos padrões, sendo distribuídas em camadas (teoria da estrutura lamelar do hipocampo).

A área entorrinal pode ser dividida em duas regiões: lateral e medial. A área lateral recebe sinal de vários núcleos externos: bulbo oftalmológico, córtex periforme e periamigdalóide, áreas temporais, córtex granular pré-frontal e amígdala entre outros. A área medial recebe sinais de núcleos internos: área CA3 e pré-subiculum e de áreas externas: as mesmas áreas que formassem sinal aferente para a região lateral, área septal e tálamo entre outras.

As principais conexões aferentes com o giro denteado provem do córtex entorrinal e do hilus. As conexões eferentes são com o hilus e região CA3. O giro denteado pode ser dividido em 3 camadas:

- molecular: onde as fibras perfurantes [LOMO-71] provenientes do córtex entorrinal fazem conexão (terminam);
- de células granulares: formada principalmente por células piramidais. O axônio destas células forma as fibras musgosas que fazem sinapse com a região CA3 e
- polimórfica: formada por uma grande variedade de tipos de células. Supõem-se que essas células tem caráter associativo apesar de não atingirem outras áreas hipocampais.

O giro denteado envia sinais para uma região chamada Ammon's horn, que é dividida em 3 regiões (alguns autores citam uma quarta região CA4 localizada próxima ao hilus): CA3, CA2 e CA1. Essa região é formada por uma única camada de células. A principal célula é a célula piramidal que apresenta um corpo celular de médio para grande, duas regiões de dendritos e um axônio. Na região apical existe uma grande árvore de dendritos e no polo oposto, uma pequena árvore de dendritos proximais. As células piramidais se distribuem de forma diferenciada pelas regiões. As células do núcleo CA3 recebem sinal do córtex entorrinal através das fibras musgosas, e seu axônio faz conexão recorrente com as células do próprio núcleo e com o núcleo CA1 (conexões de caráter excitatório). Através de conexões secundárias, o núcleo CA3 recebe sinais do córtex entorrinal. O núcleo CA1 também recebe sinais do subiculum [KOHL-90] [WITT-90] e córtex entorrinal e faz conexão

eferente com o subiculum que faz conexão eferente com o córtex entorrinal e através do fórmix com outros núcleos do sistema nervoso. Os sinais externos também atingem o hipocampo pelas vias aferentes através do fórmix.

A região subicular está localizada na porção terminal da região CA1, sendo composta pelo subiculum e por duas outras sub-regiões: pré-subiculum e para-subiculum. A região subicular possui um número grande de tipos de células (mais que na região CA1), incluindo as células piramidais, altamente inter-conectadas (principalmente a nível da camada polimórfica) com ramificações de outras regiões do hipocampo.

As principais células que formam a região hipocampal são: células piramidais, células em cesto e células granulares. Andersen [AND-90] sugere que estas células atuam como centro integrador de sinais. As células piramidais são as mais importantes na estrutura hipocampal. Seus dendritos compõem as extremidades da pirâmide. Na região basal (estrato de oriens) encontram-se os dendritos basais e na outra extremidade encontram-se os dendritos apicais (região denominada de estrato radiado). Os dendritos apicais ramificam-se até as camadas mais internas no estrato lacunoso molecular. Os dendritos apresentam uma distribuição heterogênea de comprimento e forma [AMARA-90a]. O axônio das células piramidais ramifica-se principalmente até o estrato radiado, estrato de oriens e forma as principais vias eferentes pelo fórmix. O axônio das células piramidais na região CA3 faz conexão colateral recorrente com a própria região (CA3) e com a região CA1. Na região CA1 as células piramidais são menores e a densidade de células é maior que nas outras regiões. Nas outras regiões, as células são maiores e mais espaçadas. As células piramidais na região CA1 apresentam a árvore de dendritos mais homogênea no comprimento [AMARA-90a].

As células em cesto são encontradas no estrato de oriens. Seu axônio ramifica-se pelas células Piramidais atingindo o corpo celular. Acredita-se que a célula em cesto tem caráter inibitório.

As células granulares são encontradas principalmente no giro denteado. Seus dendritos fazem conexão com feixes aferentes e perfurantes. Seus axônios formam as fibras musgosas que fazem conexão com os dendritos apicais das células piramidais, em botões gigantes, principalmente no núcleo CA3. As fibras musgosas atuam como canais de caráter excitatório.

Além destes tipos de células, principalmente nas regiões CA3, CA1 e giro denteado, existem os inter-neurônios [SCHW-90] (localizados em grande parte junto ou próximo a células piramidais). Os principais inter-neurônios são: *basket cells*,

O/A inter-neurônio (Oriens/Alveus) e L/M inter-neurônio (Lacunosum/Moleculare). O inter-neurônio "mais importante" são as "basket cells", que apresentam caráter inibitório sobre as células piramidais e células granulares, e também, recebem conexão excitatória das células piramidais criando uma malha de re-alimentação. Essas células apresentam um potencial de ação de curta duração com hiperpolarização após disparo e a grande atividade espontânea (comparado com as células piramidais), pois, possuem um limiar relativamente baixo. Localizados em uma camada bem definida na região CA1, os inter-neurônios L/M também apresentam caráter inibitório sobre as células piramidais, seus dendritos se estendem pelas regiões CA1 e giro denteado e apresentam pouca ativação espontânea (auto-ativação). Os inter-neurônios O/A também formam uma malha de re-alimentação com as células piramidais, recebendo sinal excitatório direto e tendo atividade inibitória.

Os principais módulos relacionados com a localização do animal no espaço são: CA3 e CA1 [MORR-82]. A maioria das células destes núcleos são chamadas de "place cells", pois apresentam um conjunto complexo de disparos de sinais indicando uma posição ou orientação do corpo (nem todas as células respondem a esses elementos - algumas células respondem mais rapidamente com movimentos em uma direção específica do que em outras). Assim, a atuação das "place cells" sugere que o hipocampo atue como memória de informação espacial.

Teoricamente, uma "place cells" será ativada (ou terá a sua taxa de disparo alterada) quando um ambiente (posição ou orientação), previamente aprendido, for identificado ou um movimento for realizado. No entanto, na prática, o volume de parâmetros que interferem neste processo de reconhecimento é muito grande, por exemplo, a velocidade de deslocamento e orientação do animal, a variação (ruído) no ambiente e o estado (neuro-fisiológico) do hipocampo. Estudos indicam que a taxa de disparo da "place cells" seja modulada pela direção e orientação da cabeça do animal. McNaughton [McNA-83] [McNA-89] [McNA-91] propõe que as "place cells" disparam quando recebem um certo conjunto de estímulos (sinais externos ou não à região hipocampal) específicos amostrados do ambiente e da direção da cabeça do animal. As "place cells" não são as únicas que respondem à direção da cabeça ou do corpo. Têm-se identificado outras células nas partes anterior e lateral do núcleo dorsal do tálamo.

Em seus estudos, Muller [MULL-94] propõe que a taxa de disparos de uma região (campo) do hipocampo é função do ângulo da cabeça e pode ser quantificada por uma fórmula do tipo:

$$R(\varphi) = \frac{R_{\text{max}} \cos(\varphi - \varphi_0) + R_{\text{min}}}{2} \quad (B1)$$

onde φ é o ângulo de rotação da cabeça, R a taxa de disparo amostrada na região (campo) e $T(\varphi)$ o tempo que a cabeça permaneceu com um ângulo φ . Muller apresenta uma série de gráficos mostrando a correlação entre os sinais amostrados diretamente na região hipocampal e o valor esperado (equação anterior).

Para mostrar a atividade das células piramidais das regiões CA3 e CA1, como "elementos de localização espacial", Barnes [BARN-90] monitorou o comportamento de algumas destas células utilizando ratos em movimento em um labirinto com 8 braços. A figura B20 mostra o labirinto e o layout do comportamento da taxa de disparo de células piramidais das regiões CA3 e CA1. A curva não achurada indica a taxa de disparo quando o rato está se movendo para fora do labirinto e a curva achurada quando o rato está se movendo para dentro do labirinto. Observa-se que as células respondem somente quando o rato está sobre braços específicos. Barnes mostra que algumas células do subiculum também apresentam as características de uma "place cells".

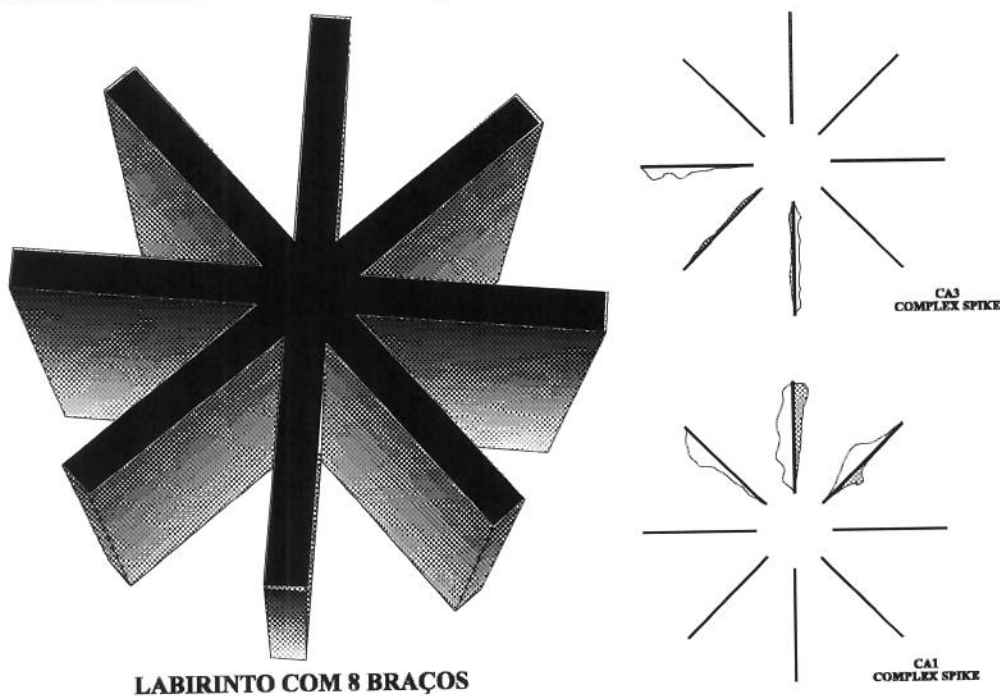


FIGURA B20. Layout da área de trabalho utilizada por Barnes [BARN-90]

Algumas células do hipocampo respondem quando um movimento já realizado é executado novamente sem a atuação do sistema de visão. O'Mara sugere que estas células recebem informações do sistema vestibular. Outras células respondem aos sinais proeminentes do sistema visual ("*view cells*"). Outras respondem a combinação de sinais provenientes do movimento do corpo como um todo e do sistema visual. Essas células são chamadas de "*whole-body motion cells*", pois respondem ao movimento de translação e rotação do corpo como um todo. Algumas células respondem ao movimento de translação, ou somente para frente, ou somente para trás, ou somente para os lados e não respondem a movimentos axiais. Outras que respondem a movimentos de translação, necessitam de sinais visuais, mesmo assim, algumas respondem somente se o campo de visão estiver livre. Outras respondem à rotação do corpo ou então detectam a rotação de objetos no ambiente. O'Mara, em um de seus experimentos, posicionou um macaco no centro de um quarto e orientou o corpo do animal em direção a uma porta, na direção oposta, para a esquerda e para a direita como mostrado na figura B21 e observou que a frequência de disparo de uma célula sensível a orientação muda com a rotação do corpo.




FIGURA B21. Layout da área de trabalho utilizada por [O' MAR-94].

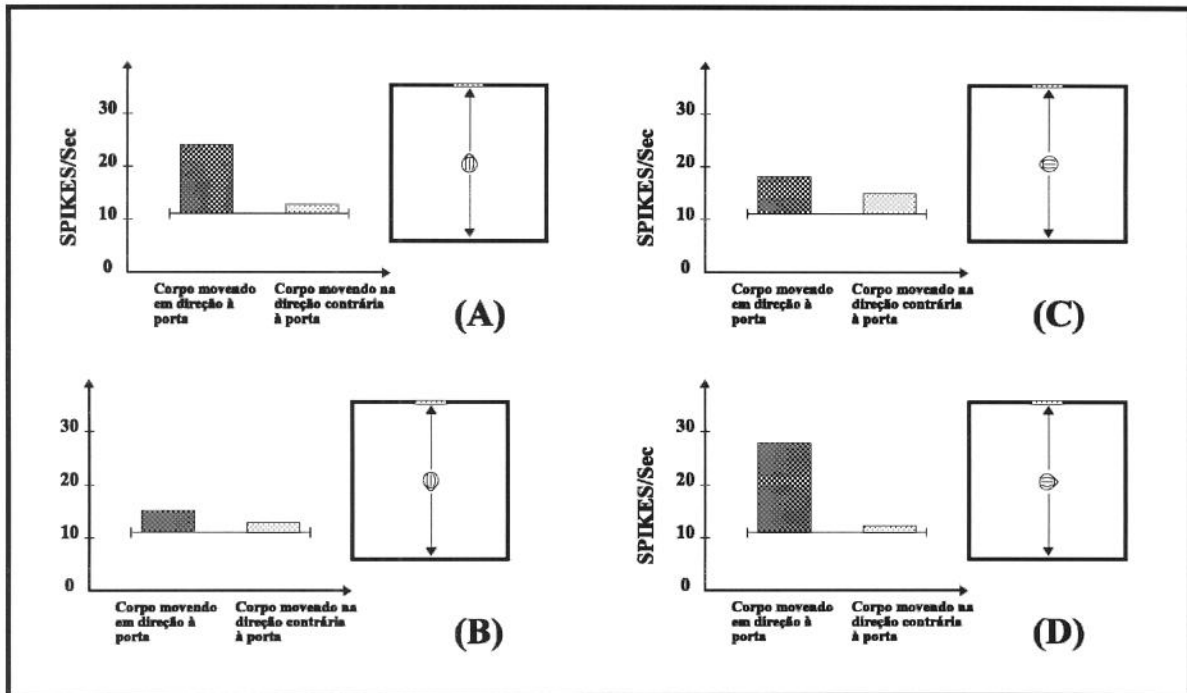


FIGURA B22. Resposta de um um neurônio e função do tipo de movimento e da orientação da cabeça de um macaco [O'MAR-94].

Na literatura podemos encontrar vários modelos matemáticos e computacionais para simular o comportamento das células e estruturas do hipocampo. Citaremos três modelos, propostos por autores relacionados com a área biológica, cuja forma ou estrutura mais se aproximam do modelo que estamos propondo.

O modelo hipocampal proposto por McNaughton [McNA-89] utiliza uma matriz para representar a posição corrente do animal e uma matriz associada representando o movimento que pode executar (assumindo que a "place cell" responda a uma dada direção ou atitude). A união destas matrizes produz uma outra representando a direção a seguir ou "aprendida". Trata-se de um modelo muito simples que pode consumir muita memória em função da área a ser mapeada e da resolução adotada e que apresenta um baixo grau de tomada de decisão.

O'Keefe [O'KEE-90] propõe um modelo matemático para o funcionamento do hipocampo baseado em matrizes e no comportamento neuro-fisiológico das regiões CA3 e CA1, na taxa de disparo das células piramidais, no fenômeno das ondas θ . O ritmo θ^1 é apresentado por estas células durante o processo de identificação de odores e quando animais (ratos) estão explorando novos ambientes [LYNC-90]

O ritmo θ - *teta* [BARN-90]: inter-neurônios na camada de células piramidais apresentam um padrão muito semelhante ao ritmo θ do EEG-Eletroencefalograma (4-7Hz).

[LYNC-91] e comportamento dos inter-neurônios: "basket cells". Um sistema de coordenadas é posicionado na cabeça do animal. Através de sensores, o ângulo de rotação é medido. A distância entre os objetos é calculada. Através de matrizes de transformação (rotação e translação) e matrizes formadas a partir da taxa de disparo das células piramidais das regiões CA3 e inter-neurônios, é possível prever o movimento a ser seguido.

Em seus estudos de neuro-fisiologia da região hipocampal, Zipser [ZIPS-85] [ZIPS-88] revela a existência de células que atingem altas taxas de disparo quando um animal está em um ambiente previamente conhecido (a localização ocorre a partir do reconhecimento de marcas). Baseado nestes estudos Zipser propõe um modelo neuronal artificial para simular o comportamento da região hipocampal no processo de localização espacial e tomada de decisão em relação ao movimento a ser seguido. Utilizando marcas identificadoras no meio ambiente e da distância do observador a elas, um sistema neuronal de duas camadas efetua a correlação destas informações com as previamente aprendidas (não só a distância pode ser utilizada, mas qualquer outra informação mensurável: formas, cores, sons, ...).

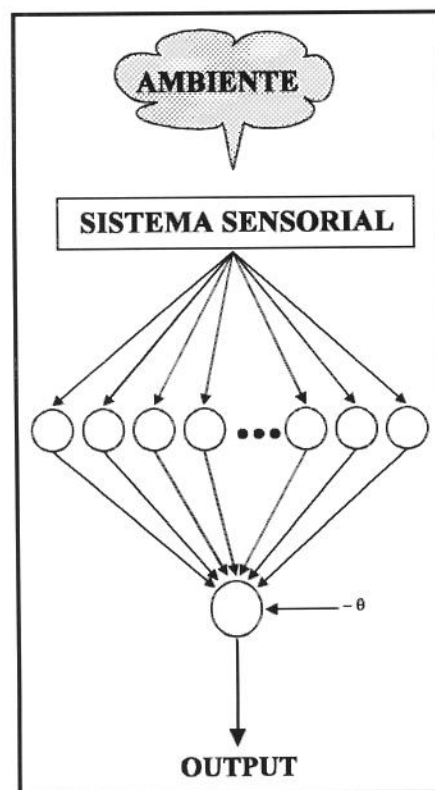


FIGURA B23. Detalhe da rede neural proposta por Zipser [ZIPS-85] [ZIPS-88].

Os neurônios da primeira camada processam as informações sensoriais através da seguinte equação:

$$S_i = \sum_j w_{ij} |d_j - d^*| \quad (B2)$$

onde d é o valor da distância do observador até as marcas identificadas e d^* o valor, destas distâncias, previamente "aprendido". No *soma*, os valores são ponderados pela diferença. A função de ativação deste neurônio é do tipo *threshold*:

$$S_i = \begin{cases} 1 & \text{se } S_i \geq \sigma \\ 0 & \text{caso contrário} \end{cases} \quad (B3)$$

onde S_i é o valor de saída do i -ésimo neurônio da primeira camada e σ é o limite para disparo. Quanto maior a correlação entre as distâncias, menor o valor do *soma*, maior a probabilidade de disparo do neurônio.

Na segunda camada, um neurônio efetua a soma dos valores de saída dos neurônios da camada anterior:

$$S = \sum_i w_i S_i \quad (B4)$$

A função de ativação também é do tipo *threshold*:

$$S = \begin{cases} 1 & \text{se } S \geq \gamma \\ 0 & \text{caso contrário} \end{cases} \quad (B5)$$

onde S é o valor de saída da rede e γ é o *offset*.

Sabendo-se que certas células do hipocampo respondem (são ativadas) quando o observador está orientado para uma direção específica, Zipser propõe outro modelo neuronal artificial para "calcular" a direção do movimento. A figura B24 mostra o layout da estrutura da rede. O sistema visual fornece informações de três campos: à esquerda, no centro e à direita. Esses dados são enviados à primeira

camada cujo processamento é semelhante ao apresentado na rede anterior (equação B3), ou seja, é efetuado o reconhecimento do padrão apresentado.

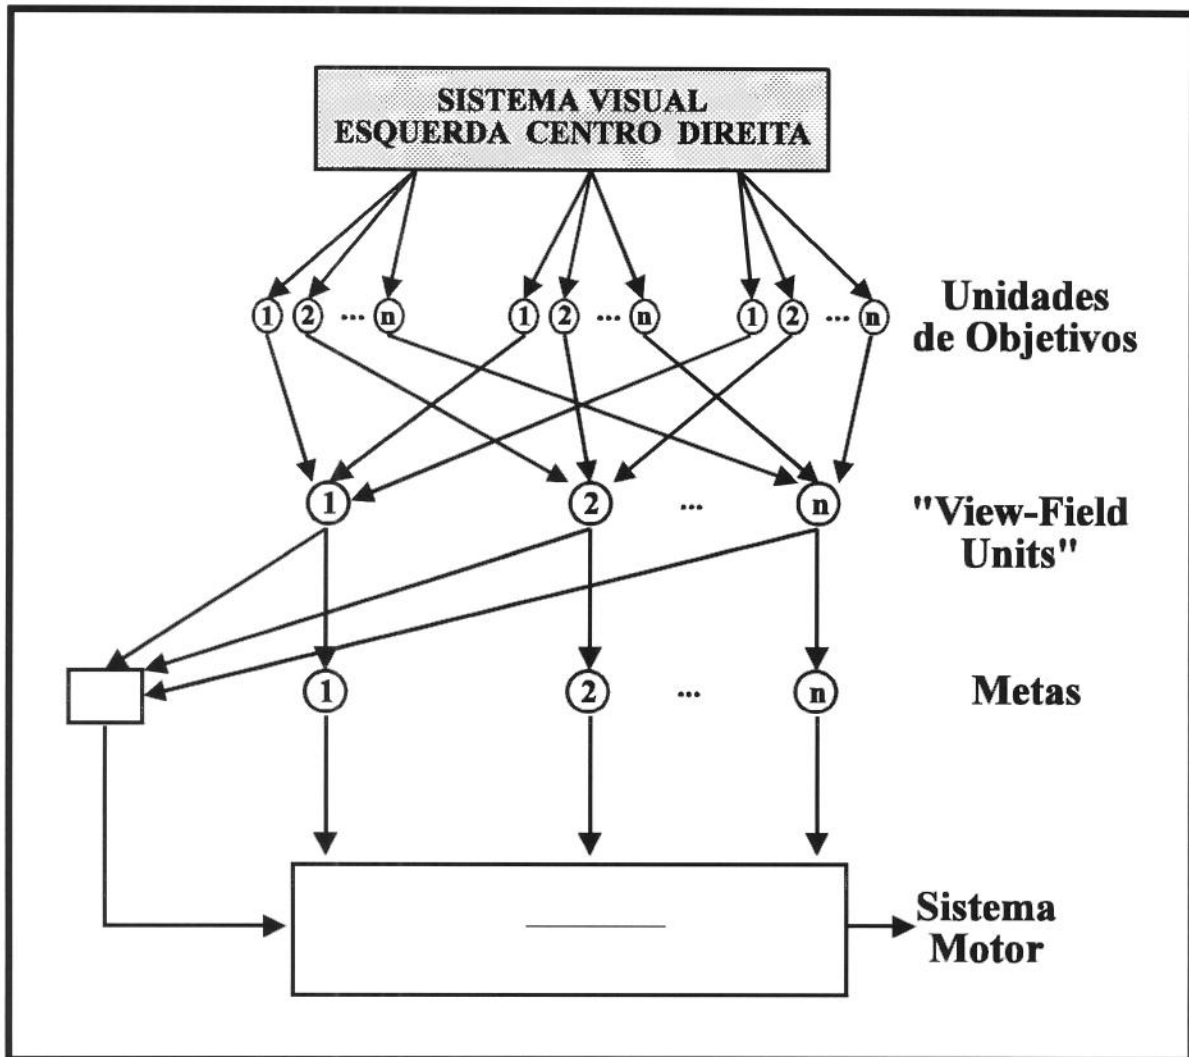



FIGURA B24. Layout geral da rede neural proposta por Zipser [ZIPS-85] [ZIPS-88].

Se ocorrer o "match" dos dados com algum padrão previamente aprendido, então, o neurônio dispara, caso contrário permanece em zero. Na segunda camada ("view-field units") um grupo de neurônios efetua a totalização do valor de disparo de cada unidade de reconhecimento (cada unidade "reconhece" um determinado padrão nos três campos visuais). O processamento nos neurônios desta camada é idêntico ao implementado nos da segunda camada da rede anterior. O valor de saída dos neurônios da segunda camada é ponderado com pesos sinápticos relativos a cada

ponto (meta-objetivo) que pode ser atingido (identificado) pelo sistema, e então, ponderado:



(B6)

onde g indica a direção a ser seguida pelo sistema motor. A rede proposta por Zipser apresenta uma série de problemas, por exemplo, o número de combinações que devem ser mapeadas é muito grande, mesmo com somente duas marcas a serem reconhecidas. No entanto, permite algum tipo de navegação.

Em resumo, algumas células da região hipocampal respondem a estímulos de determinadas áreas do ambiente e a movimentos em direções e com orientações bem definidas. Inspirados nestas observações propomos um modelo onde células artificiais respondem a estímulos externos relacionados com a posição absoluta de um mecanismo em movimento. Assim, dado um posição (X, Y) , uma (ou um grupo) célula artificial efetuará o mapeamento de uma região em torno deste ponto.

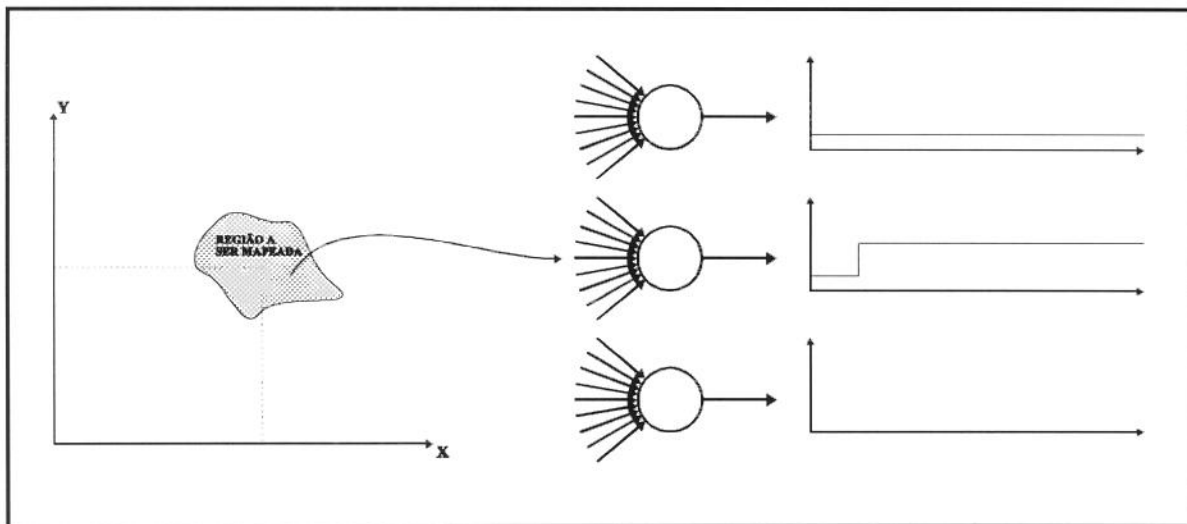


FIGURA B25. Região da área de trabalho mapeada por um neurônio.

A área mapeada pode assumir as mais variadas formas, mas vamos restringí-la visando facilitar a implementação computacional. O *soma* neuronal (biológico) atua como um totalizador de sinais, assim, assumiremos que o neurônio artificial a

ser implementado realizará um processamento (no *soma* neuronal) baseado em uma equação do tipo:

$$C(x,y) = \omega_0 + \omega_1 x + \omega_2 y + \omega_3 (x^2 + y^2 - r^2) \quad (B7)$$

onde ω_0 , ω_1 , ω_2 e ω_3 representam os pesos sinápticos e x e y são os valores das coordenadas no plano cartesiano.

Se restringirmos os pesos sinápticos aos valores a seguir:

$$\begin{aligned} \omega_0 &= 1 \\ \omega_1 &= -2 * X_0 \\ \omega_2 &= -2 * Y_0 \\ \omega_3 &= X_0^2 + Y_0^2 - r^2 \end{aligned}$$

a equação $C(x,y)$ corresponde à equação do círculo onde X_0 e Y_0 são as coordenadas do centro.

Se adotarmos uma função de ativação do tipo:

$$f(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases}$$

ou seja, se um ponto $P()$ estiver no interior da região circular, um (ou um grupo) neurônio será ativado disparando um potencial de ação que pode estar associado a uma nova coordenada (X,Y) a ser seguida formando uma rota. Esse modelo foi implementado no módulo de processamento apresentado na figura B14.




FIGURA B26. Região circular da área de trabalho mapeada por um neurônio.

CAPÍTULO III

APRENDIZADO

1. INTRODUÇÃO

O ser humano tem uma grande capacidade de operar em ambientes desconhecidos, devido às suas "habilidades" de adaptar-se a novas situações e propor soluções [WERT-45]. Isso é possível graças à estrutura do seu sistema nervoso que consegue obter, reter e manipular informações e gerar ações.

Neste capítulo apresentamos uma compilação dos estudos que realizamos sobre o "aprendizado" [GALL-76] [GUTH-52] [HERG-88] [HILL-77] [ROUA-67] [SKINN-53] visando a compreensão do processo e aplicação no sistema que estamos propondo. A bibliografia é vasta, mas identificamos duas linhas teóricas que agrupam grande parte dos trabalhos: as teorias conexionistas e as teorias cognitivistas.

Os conexionistas consideram a aprendizagem como uma relação entre estímulos e respostas produzidas pelos seres vivos. Os estímulos podem ser qualquer "input" (externo ou interno) recebido pelo ser e a resposta pode ser física (acionando algum músculo) ou mudança de estado do sistema neural.

Na interpretação cognitiva, o aprendizado é considerado como a união de padrões do comportamento, eventos e crenças que o organismo "manifesta" interagindo com o meio ou com as mudanças de estado do seu sistema nervoso.

Em muitas teorias estas duas classes teóricas sofrem intersecções gerando teorias intermediárias.

A estrutura básica do sistema neuronal artificial que estamos propondo (apresentada no capítulo II), de inspiração biológica, contém os elementos para o mapeamento das regiões da área de trabalho e o seqüenciamento de atividades, cabendo ao aprendizado organizar as informações coletadas e disponibilizá-las de forma produtiva na resolução de problemas. A linha básica que adotamos tem como cerne a teoria proposta por Robert M. Gagnè [GAGN-65] que estrutura o aprendizado em 8 tipos hierarquicamente organizados. Trata-se de uma teoria ampla, abordando desde o aprendizado de ações primárias (elementares) até a resolução de

problemas. Contudo, utilizamos elementos de outras teorias [EYSE-82] [GAGN-65] [GALL-76] [GUTH-52] [HEND-90] [HERG-88] [HILL-77] [HULL-52] [KOFF-35] [ROUA-67] [SKINN-53] para fundamentar e complementar a que estamos propondo:

-Watson afirma em sua teoria que as atitudes que tomamos estão relacionadas com reflexos condicionados (relação estímulo-resposta) que podem ser alterados com a interação com o meio. Aplicamos esse comportamento reflexo no processo de fuga de obstáculos seguindo os sinais enviados pelos sensores.

-Pavlov mostra que os animais tem a capacidade de formar novas relações estímulo-resposta a partir de relações previamente conhecidas através de um procedimento de condicionamento. Utilizamos a idéia do condicionamento para orientar a seleção das direções dos movimentos a serem realizados durante o mapeamento da área de trabalho, geração de rotas e em operação. O procedimento de condicionamento implementado consiste em treinar uma rede neural artificial tipo Perceptron com a direção a ser seguida naquele determinado instante, ou seja, a direção do movimento. A cada interação do processo de treinamento, a direção corrente corresponderá ao padrão a ser aprendido.

-Guthrie propõe um método para que um hábito seja fixado ou modelado. Por exemplo, para fixar um hábito, ele propõe que o espectro de estímulos que produzem uma resposta específica seja gradativamente aumentado, de tal forma que pequenas variações nos estímulos produzam a mesma resposta. No nosso sistema, utilizamos uma abordagem semelhante para a implementação do mapeamento da área de trabalho. Como estamos buscando a redução do número de neurônios utilizados, não poderíamos efetuar o mapeamento ponto a ponto. Implementamos uma estrutura que é capaz de identificar estímulos de uma região próxima a um ponto específico e produzir a mesma resposta, ou seja, temos uma redundância de estímulos.

-Estes propõe em sua teoria que somente um subconjunto de estímulos é suficiente para ativar uma resposta. Em um ambiente desestruturado esta característica fez-se necessária, pois, podem haver variações entre os estímulos utilizados no treinamento das redes neurais artificiais e os amostrados. A estrutura de mapeamento apresenta essa característica.

-Thorndike afirma que o método mais simples de aprendizado é o da tentativa e erro. Interagindo com o meio, o ser seleciona e processa as informações e as ações (estados) permitindo que relações entre estímulos-respostas sejam reforçadas por alguma "satisfação ou compensação". Para o sistema que estamos propondo, onde o

ambiente é desconhecido e está desestruturado, o aprendizado por tentativa e erro é utilizado no mapeamento da área de trabalho, mas de forma restrita, pois existe a interferência dos valores dos sensores, da direção preferencial de movimento e estado do sistema neuronal artificial.

-Hull relata em sua teoria que quando uma relação estímulo-resposta é ativada, outras relações estímulo-resposta, de caráter secundário, são desencadeadas. Utilizamos este esquema de cadeias secundárias para implementar o procedimento de aprendizado de rotas e macro-rotas de movimento. Contribuição semelhante retiramos da teoria de Skinner.

-Thorndike afirma em sua teoria que o aprendizado ocorre de forma gradual (incremental), no entanto, a escola Gestaltista afirma que a solução de problemas ocorre de uma só vez, de súbito, através de um processo chamado de "*insight*". No sistema proposto, utilizamos os dois processos: o "*insight*" ocorre durante o mapeamento da área de trabalho e o incremental durante a formação de macro-rotas de movimentos.

-Tolman, Piaget e Gagnè propõem em suas teorias que o aprendizado ocorre em etapas bem definidas, hierarquicamente estruturadas. No sistema que estamos propondo, utilizamos algumas destas etapas, principalmente as propostas por Gagnè: aquisição de habilidades primárias (relacionadas com o mapeamento da área de trabalho) e seu encadeamento (formação de rotas), e discriminação de ações (formação de macro-rotas)

-Outro aspecto que utilizamos da teoria de Tolman, que associamos com o mapeamento da área de trabalho e formação de rotas, é o fato de o aprendizado ocorrer em função do local onde o ser "pensa estar" ("*place learning*") e não em função de relações do tipo estímulo-resposta. Ou seja, o ser aprende relações de posição e orientação. O que o ser aprende é o que ele observa, independente do reforço, formando um mapa cognitivo ("*cognitive map*").

No contexto deste trabalho, restringimos o escopo das teorias do aprendizado que estudamos, buscando unicamente o aprendizado de rotas de movimento em ambientes inicialmente desestruturados. Baseado nos conceitos de aprendizagem de ações elementares que encadeadas permitem a discriminação de múltiplas situações, implementamos o processo de aprendizado no sistema que estamos propondo no capítulo IV. O principal processo para a navegação consiste em formar (aprender) rotas através do encadeamento de regiões previamente mapeadas.

A seguir, apresentamos uma série de teorias sobre o processo de aprendizado que utilizamos para complementar (do nosso ponto de vista) a teoria de Gagnè. Não estamos afirmando que a teoria de Gagnè seja incompleta do ponto de vista pedagógico ou observado experimentalmente, mas sim, que existem elementos em outras teorias que podem fornecer subsídios para uma implementação computacional. Nosso interesse não é analisar as teorias do ponto de vista pedagógico ou psicológico, e sim, estruturar alguns pontos que utilizaremos no sistema neural que estamos propondo. Também não estaremos questionando esses trabalhos, mas compilando as características que julgamos interessantes. A seqüência de teorias que abordamos segue um caráter didático, culminando com a teoria de Gagnè.

2. J. B. WATSON

O fundador do Behaviorismo, J. B. Watson, realizou uma série de estudos sobre o aprendizado de ratos em labirintos, visando a análise comportamental (behavior) dos roedores. Ele afirma que as atitudes que os ratos apresentam são uma questão de reflexos condicionados. Herdamos "a casca" (o corpo) e alguns reflexos de nossos pais, mas, o comportamento aprendemos interagindo com o meio ambiente. Dessa interação, faz-se surgir novas conexões do tipo estímulo-resposta (ou seja, novos reflexos), cuja combinação (sequenciamento) pode gerar ações complexas. Outras afirmações são que quanto mais for estimulada (maior frequência) uma relação estímulo-resposta, maior a probabilidade de sua ocorrência, definindo as características básicas do comportamento e quanto mais recente for a ocorrência de uma relação, maior a probabilidade de ser repetida. Durante o aprendizado, o ser produz uma série de respostas ao estímulo. Aquela que gerar a resposta esperada (obtendo êxito - o alvo - os objetivos) torna-se a "preferida". Pode-se notar grande influência dos trabalhos de Pavlov na teoria de Watson, contudo, sua teoria não explica uma série de questões que são fundamentais, como por exemplo, qual a influência do estado do sistema nervoso no condicionamento, como o "hardware" (estrutura neuronal) interfere no processo de aprendizado

(condicionamento) ou, como explicar o fato de que o ser pode manifestar tentativas erradas com maior frequência do que a desejada.

Aplicamos o comportamento reflexo proposto por Watson no processo de fuga (ou contorno) de obstáculos. Monitorando constantemente a área próxima do mecanismo em movimento e confrontando esses dados com as informações previamente armazenadas, é possível identificar alterações e tomar decisões. Neste caso, as primeiras atitudes executadas pelo sistema consistem em atos reflexos (respostas pré-aprendidas). Por exemplo, ativar outra direção de movimento e contornar os obstáculos.

3. IVAN P. PAVLOV

As atitudes tomadas pelo sistema que estamos propondo são função de um conjunto de estímulos coletados, principalmente, do meio externo. Assim, a cada conjunto de estímulos, cabe uma atitude do sistema. Ivan Petrovich Pavlov formulou uma teoria sobre o aprendizado baseada neste tipo de relação: estímulo-resposta (E-R). Pavlov assume que o ser já possui a capacidade de responder a um determinado estímulo, de forma incondicionada. Se um estímulo específico é apresentado ao ser, uma resposta (natural) específica será produzida. Chamamos esse estímulo de estímulo não condicionado (ENC) e a resposta de resposta não condicionada (RNC):

ESTÍMULO NÃO CONDICIONADO (ENC)  RESPOSTA NÃO CONDICIONADA (RNC)

O trabalho de Pavlov consistiu em usar um outro estímulo (estímulo condicionado - EC) para produzir a mesma resposta. O treinamento consiste em apresentar o estímulo condicionado ao ser, logo a seguir o estímulo não condicionado (ENC) que irá produzir a resposta não condicionada (RNC) correspondente.



ANTES DO TREINAMENTO




APÓS O TREINAMENTO

Se após uma série de repetições, somente o estímulo condicionado (EC) é apresentado e uma resposta semelhante à resposta não condicionada é produzida, então dizemos que ocorreu uma resposta condicionada (RC). Uma vez aprendida a nova relação, EC desencadeará uma resposta RC.

Pavlov realizou uma série de experimentos procurando identificar os parâmetros neuro-fisiológicos e de aprendizado para que ocorra o condicionamento de forma eficiente mas não são relevantes para este trabalho.

Utilizamos as relações E-R para gerar as rotas dos movimentos. A posição cartesiana do mecanismo serve de estímulo para a geração de uma nova coordenada a ser atingida. No processo de aprendizado, o reforço mencionado por Pavlov, que tem a função de validar uma resposta e intensificar uma relação E-R, no nosso sistema simplesmente consiste na certeza (fornecida pelos valores dos sensores) de que na área mapeada não existem obstáculos. Assim, basta que uma relação E-R ocorra uma única vez e seja validada, que o sistema irá aprendê-la.

Existe uma série muito grande de estudos sobre o condicionamento, mas gostaríamos de ressaltar a teoria de Thorndike (como veremos a seguir) que aborda um tipo especial de condicionamento: o condicionamento instrumental. Neste tipo de condicionamento, somente as respostas válidas (ou desejadas) são reforçadas, ou seja, existe uma dependência a ser adquirida entre o estímulo e a resposta. O reforço é apresentado ao ser (animal) após ter ocorrido a resposta.



4. E. R. GUTHRIE

Com uma linha de pesquisa fundamentada no princípio do condicionamento, o Prof. E. R. Guthrie formulou uma teoria sobre o aprendizado a partir de um princípio básico mais geral e simples que o proposto por Watson: *"Uma combinação de estímulos seguida de um movimento, tenderá a ser repetida quando essa combinação ocorrer novamente"* [HERG-88]. Essa combinação é do tipo "tudo ou nada", ou ocorre ou não, sem variação de intensidade. Com relação ao movimento, Guthrie refere-se aos movimentos específicos de cada músculo. Assim, o encadeamento de várias combinações de estímulos-respostas produz um movimento complexo, cujo refinamento (aquisição e domínio de habilidades) ocorre a nível da ativação ou não, de determinadas unidades musculares.

Essa teoria não faz referência aos estímulos condicionados, não condicionados, condições de aprendizado, reforço ou qualidade da resposta (se é ou não desejada, "certa" ou "errada" ou "aceitável"), e sim, que o aprendizado ocorrerá se estímulo e resposta ocorrerem juntos. Interagindo com o meio, o ser recebe um número muito grande de estímulos. Então, qual conjunto será considerado pelo sistema neural para que ocorra o aprendizado? Guthrie afirma que será a última sequência executada, e essa, com maior probabilidade, quer a ação seja a desejada ou não.

Guthrie raramente faz referência à questão do reforço, como também não "se preocupou" com o êxito ou fracasso das ações, o importante é a contigüidade dos eventos. Da mesma forma, a extinção (ou aprendizado) de um hábito (resposta) é consequência da substituição de uma resposta por outra e não do desuso. O esquecimento gradual ocorre devido ao grande número de conexões E-R que compõem o hábito e são alteradas gradativamente. Um método proposto por Guthrie para fixar um hábito é aumentar o espectro dos estímulos que produzem a mesma resposta, gerando um número variado de situações diferentes tornando as respostas redundantes. Pequenas variações nos estímulos tendem a manter a mesma resposta.

No sistema proposto, uma mesma região pode ser mapeada por vários neurônios, tornando a base de conhecimento altamente redundante, e um conjunto difuso de estímulos pode ativar respostas semelhantes. A redundância permite ainda, a contigüidade das regiões mapeadas, facilitando a formação de rotas de movimentos.

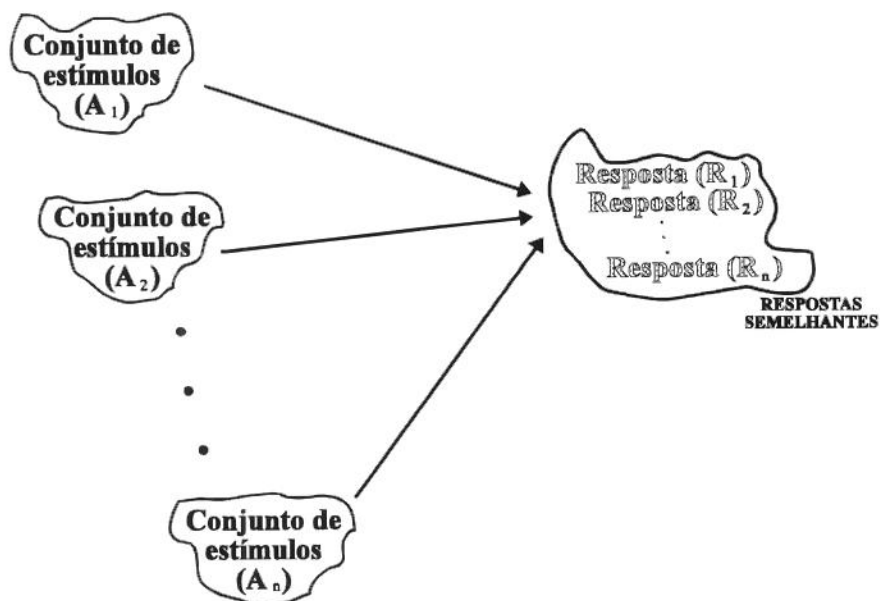


FIGURA A1. Conjunto de estímulos que provocam respostas diferentes.

Guthrie também faz referência a 4 estímulos que "gerenciam" algumas ações básicas do ser:

- ESTÍMULOS MANTENEDORES: aqueles que mantêm o ser ativo;
- ESTÍMULOS BLOQUEADORES: bloqueiam qualquer "tentativa" de remoção completa dos estímulos mantenedores;
- ESTÍMULOS DE PRONTIDÃO: aqueles que prontamente executam ações musculares e
- ESTÍMULOS DE PRONTIDÃO ÀS CONSEQUÊNCIAS: são estímulos que garantem a sobrevivência e a regulação do organismo através de uma sequência de ações elementares.

Em um ambiente desestruturado, as informações podem ser muito vagas e o mecanismo em movimento pode ser conduzido a situações que inviabilize o seu deslocamento, principalmente em regiões fechadas. Por exemplo, o mecanismo pode não conseguir encontrar a saída de uma região em forma de uma espiral. Para minimizar o problema, implementamos alguns sinais que ativam procedimentos específicos (ações básicas):

- se o mecanismo está em uma região não mapeada, automaticamente o processo de aprendizado é ativado e

- se uma região é atingida muitas vezes em um curto intervalo de tempo, significa que o mecanismo não consegue sair, e um procedimento de fuga é ativado.

5. W. K. ESTES

W. K. Estes é outro teórico do comportamento (behaviorista) que se preocupou em gerar sistemas capazes de modelar alguns comportamentos de seres. A teoria de Estes tem como base alguns princípios:


- o número de estímulos (E) envolvidos no aprendizado é muito grande e finito;

- todas as respostas produzidas por um conjunto de estímulos são classificadas em duas categorias:

R_1 - resposta esperada (certa)

R_2 - resposta não esperada (errada)

ou seja, existe alguma relação entre estímulo (E) e resposta (R):



- dado um conjunto de estímulos (E), somente um sub-conjunto (θ) é interpretado (aproveitado) pelo sistema nervoso;

- se uma resposta (R_1) é aprendida, o sub-conjunto (θ) de estímulos é suficiente para ativar R_1 :



- o processo de aprendizagem deve obedecer certa contigüidade;
- a probabilidade da resposta (R_1) ser *setada* é igual à quantidade de estímulos condicionados (θ) no início do aprendizado:

$$P_n = 1 - (1 - P_1) * (1 - \theta)^{n-1} \quad (A1)$$

- onde n: número da tentativa de aprendizado,
 P_n : probabilidade da resposta (R_1) ocorrer na n-ésima tentativa,
 $1-P_1$: probabilidade de R_1 não ocorrer na primeira tentativa,
 $1-\theta$: quantidade de estímulos que não são aproveitados pelo sistema nervoso;

- se parte dos estímulos (θ) que *setaram* R_1 estiverem presentes durante o aprendizado de uma outra resposta (R_3), então, existe uma alta probabilidade de R_1 ser *setado* quando R_3 também for;
- MATCHING. Se a probabilidade da resposta (R_1) ocorrer não for 100%, e sim, λ , a equação de probabilidade é escrita por:

$$P_n = \lambda - (\lambda - P_1) * (1 - \theta)^{n-1} \quad (A2)$$

- se o número de estímulos envolvidos no processo de aprendizagem for reduzido, o aprendizado ocorrerá como um *threshold* (tudo ou nada), ou seja, o aprendizado ocorrerá de uma única vez, e não incrementalmente. O mais importante é que cada indivíduo necessita de uma número diferente de tentativas para realizar o aprendizado. Por outro lado, quando o número

de estímulos é muito grande, a probabilidade de aprendizado é muito pequena.

Adotamos alguns dos princípios utilizados nos trabalhos de Estes. Todo estímulo produzirá uma resposta do sistema, quer seja válida ou não. A contigüidade na formação de rotas de movimentos permite a estruturação (representação interna) da área de trabalho e facilita a navegação.

Estes apresenta uma equação (A2) que permite estimar a probabilidade de ocorrência de uma resposta. No nosso sistema, se o estímulo de posição pertencer a uma região mapeada, pelo menos um neurônio irá responder e a probabilidade de uma resposta é de 100%. Esse tipo de comportamento deve-se ao fato de adotarmos uma função de ativação, cuja fronteira de ativação é do tipo degrau (tudo ou nada). A nossa opção por esse tipo de função deve-se ao fato do ambiente ser desestruturado e desejarmos restringir as aleatoriedades que por ventura possam surgir. Se adotássemos uma função contínua, faria sentido calcular a probabilidade de uma resposta.

6. E. L. THORNDIKE

Edward L. Thorndike (1874-1949) acrescentou um elemento às teorias de Watson e Guthrie, o **reforço**. Para ele, não é suficiente que o conjugado estímulo-resposta ocorra conjuntamente, é necessário um outro estímulo que "direcione" o aprendizado informando se essa relação supre ou não alguma necessidade. Em outras palavras, a relação E-R deve ser reforçada por alguma "satisfação ou compensação" para que se realize o aprendizado. A sua teoria pode ser dividida em duas fases, onde a segunda é uma revisão e correção da primeira.

PARTE 1. Para Thorndike, o método mais simples de aprendizado (solução de problemas) é a tentativa e erro. O aprendiz interage com o meio, "seleciona" e processa as informações e as ações (e estados), e o sistema nervoso realiza as "conexões" para que ocorra a aprendizagem. Avaliando o perfil das curvas de tempo para a solução de um problema em função do número de tentativas, é possível

concluir que o aprendizado ocorre de forma incremental e não por "insight" (como sugere outras teorias como a Gestaltista), pois, o tempo decrementa assintoticamente e não como um degrau.




FIGURA A2. Curva de tempo de aprendizado x número de tentativas para "insight" e aprendizado incremental.

Thorndike concluiu que os animais resolvem os problemas de forma direta (instintivamente) e não através do planejamento, análise e seleção de opções. Ele também formulou algumas leis e apresentou algumas idéias sobre o processo de aprendizado, entre elas, podemos citar:

-LEI DA PRONTIDÃO: mais conhecida como a lei da satisfação-frustração. "Se o sistema nervoso está pronto para realizar uma ação e é executada, então, o resultado é a satisfação. Se o sistema nervoso está pronto para realizar uma ação e não é executada, o resultado é a frustração. Se o sistema nervoso não está preparado para realizar uma ação e é forçado a executá-la, o resultado também é a frustração". O estado de satisfação leva a um fortalecimento da uma conexão E-R e o estado de frustração produz o enfraquecimento da relação;

-LEI DO EXERCÍCIO-USO: a conexão estímulo-resposta é fortalecida pelo uso (reforço);

-LEI DO EXERCÍCIO-DESUSO: a conexão estímulo-resposta é enfraquecida pelo desuso ou pela descontinuidade de ocorrências. Deve-se entender como fortalecimento ou enfraquecimento de uma conexão como a probabilidade de ocorrência de uma resposta na presença de um estímulo;

-LEI DO EFEITO (consequências): se uma relação estímulo-resposta conduz o ser a um estado de satisfação, a conexão é fortalecida, caso contrário é enfraquecida;

-MÚLTIPLAS RESPOSTAS: no processo de resolução de problemas utilizando o método de tentativa e erro, se o animal não obtém sucesso em uma tentativa, outra é selecionada e testada até a solução do problema;

-ATITUDE, DISPOSIÇÃO e PRÉ-JULGAMENTO: a resposta produzida é função do hardware (estrutura neuro-fisiológica do sistema nervoso e motor) e estado (emocional, fadiga, *stress*, ...) do ser, da natureza do problema e experiência (conhecimento adquirido) anterior;

-RESPOSTA POR ANALOGIA: a resposta que manifestada frente a uma nova situação é função do grau de similaridade entre a novidade e a base de conhecimento existente. Quanto maior a correlação, maior a probabilidade de uma resposta já conhecida ser ativada (ao menos como primeira resposta);

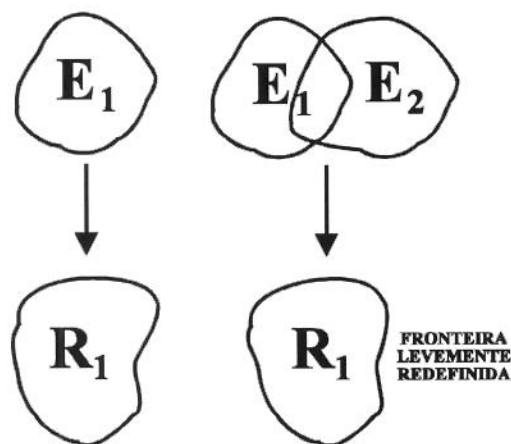


FIGURA A3. Alguma similaridade entre estímulos diferentes é capaz de desencadear a resposta desejada.

-"ASSOCIATIVE SHIFT" : uma resposta específica pode ser produzida mesmo com alguma variância (ruído) no estímulo original (a relação E-R pode ser considerada como um processo fuzzy);




FIGURA A4. Variância (ruído) de um mesmo estímulo produz a mesma resposta.

PARTE 2. Após vários estudos e experimentos, Thorndike reformulou alguns elementos da sua teoria. Ele constatou que a lei do exercício como formulada é "inadequada", pois, o desuso não enfraquece uma conexão (nós podemos relembrar de fatos ou executar ações que há muito tempo não fazemos referência). A lei do efeito foi considerada "meio válida", para Thorndike, a satisfação reforça as conexões, por outro lado, a insatisfação (frustração) nem sempre as enfraquece.

PRINCÍPIO DA POLARIDADE. Thorndike observou que existe um certo grau de orientação nas sequências de E-R, facilitando o aprendizado. Por exemplo, na língua portuguesa, aprendemos mais rapidamente uma relação entre substantivo e adjetivo, do que adjetivo e substantivo (o ser consegue, por exemplo, memorizar com maior facilidade, a primeira relação do que a segunda. A primeira relação, além de fazer parte de um conjunto de regras válidas, o ser a utiliza com maior frequência).

PRINCÍPIO DA EXTENSÃO DO EFEITO. Não somente o reforço de uma relação E-R, em termos de uma resposta específica, fortalece uma conexão, mas também em torno de uma região próxima à da resposta desejada (respostas parciais ou incompletas reforçam uma conexão).

Essas leis e princípios que relacionamos, evidentemente, não constituem nenhuma teoria geral sobre o aprendizado e comportamento, tratam-se de observações experimentais.

Em um sistema neuronal conexionista tradicional (rede Perceptron com treinamento pelo método de backpropagation por exemplo) o aprendizado ocorre de forma incremental e o tempo de aprendizagem decrementa com o aumento do número de tentativas (se o processo convergir para um mínimo local e os neurônios da rede não saturarem) como sugerido por Thorndike. No nosso sistema, o aprendizado contínuo e o "*insight*" ocorrem em situações distintas. O "*insight*" ocorre no aprendizado de regiões da área de trabalho, satisfazendo a necessidade que o sistema tem de mapear uma região desconhecida. O aprendizado incremental ocorre durante a busca e formação de rotas, manifestado no encadeamento incremental das regiões mapeadas. Esse aprendizado pode resultar em uma satisfação, gerando a rota ou em uma frustração se houver descontinuidade no mapeamento. No entanto, as conexões não são enfraquecidas, pois, ou elas existem ou não existem, contrariando as leis do exercício-uso, exercício-desuso e efeito. Essas leis se aplicam a sistemas com maior plasticidade que o proposto neste trabalho.

Thorndike acredita que o aprendizado pode ocorrer através do método da tentativa e erro, onde alternativas são selecionadas (ou geradas aleatoriamente), testadas e avaliadas, cabendo ao reforço e à satisfação de uma necessidade a alteração na força das conexões estímulo-resposta. Quando o ambiente é desestruturado e o conhecimento prévio é restrito, o aprendizado por tentativa e erro faz-se necessário, sendo utilizado no sistema, contudo de forma restrita, pois existe a interferência dos valores dos sensores, direção preferencial de movimento e estado das redes neuronais que ponderam e selecionam as direções dos movimentos.

Também encontramos plausibilidade na teoria de Thorndike quanto à redundância no mapeamento, pois, estímulos semelhantes podem ativar um ou mais neurônios, conseqüentemente, uma ou mais respostas.

7. N. MILLER

Outra teoria, proposta por Neal Miller, considera que uma parcela do aprendizado envolve a imitação, que a resolução de problemas pode envolver o encadeamento de ações "copiadas" de outros indivíduos, satisfazendo, ou compensando alguma necessidade do ser.

A imitação implica que a área de trabalho tenha sido previamente mapeada, que não é o escopo deste trabalho. Após as simulações (capítulo 6) julgamos que a presença de um instrutor é indispensável, pois, existem situações que conduzem o sistema a um estado de desequilíbrio que não consegue encontrar as rotas. Isso ocorre principalmente quando a área de trabalho contém muito ruído dificultando a navegação. A intervenção do instrutor pode ocorrer em vários níveis, por exemplo, orientando uma direção a seguir temporariamente, ou gerando uma seqüência de rotas a partir de uma "cópia" fornecida por um sistema semelhante. A "imitação" não foi implementada no sistema, pois, demandaria um estudo próprio, o desenvolvimento de estruturas capazes de reconhecer similaridades e propor as adaptações que se fizerem necessárias, o que tornaria o escopo deste trabalho muito amplo, divergindo dos objetivos iniciais.

8. C. L. HULL

Com um pouco mais de rigor, do ponto de vista matemático, Clark L. Hull (1884-1952) [HULL-52] propõe uma teoria conexionista sobre o aprendizado baseada em postulados e teoremas. A partir de 17 postulados a respeito do comportamento dos seres, ele derivou uma série de teoremas (133 teoremas) que permitem "modelar matematicamente o aprendizado e o comportamento dos seres". A seguir relacionamos os postulados que de alguma forma foram utilizados neste trabalho:

POSTULADO 1. Sentindo o ambiente externo e traço de estímulo. Hull postula a existência de um traço de estímulo (e) que permanece "latente" no sistema

nervoso, após o estímulo principal (E) ter "cessado". Esse traço de estímulo desencadeia uma reação motora (r) que desencadeia a resposta (R) efetiva. Assim, Hull escreve a tradicional relação entre estímulo (E) e resposta (R) da seguinte forma:

$$\mathbf{E} \longrightarrow \mathbf{e} \longrightarrow \mathbf{r} \longrightarrow \mathbf{R}$$

POSTULADO 2. A integração de impulsos sensoriais. O comportamento (resposta) é desencadeado por uma combinação de estímulos e com menor probabilidade por um único estímulo:




FIGURA A5. Integração de estímulos.

POSTULADO 3. Comportamento não aprendido. Hull afirma que o ser nasce com um conjunto de comportamentos previamente "aprendido" (incorporado à sua base de conhecimento e habilidades). Trata-se de respostas "padronizadas" (por exemplo, os reflexos neuro-musculares).

POSTULADO 4. Contigüidade e redução de necessidades. Se um estímulo produz uma resposta e supre alguma necessidade (biológica), então, a força dessa relação é aumentada. Hull associa a força de uma relação (E-R) com a força do hábito (${}_E H_R$):

$${}_E H_R = 1 - 10^{-0.0305 * N} \tag{A3}$$

onde ${}_E H_R$: representa a força do hábito,
 E estímulo,
 R resposta e
 N : o número total de reforços.

POSTULADO 5. Generalização do estímulo. A quantidade e qualidade do estímulo que desencadeará uma resposta dependerá do grau de similaridade (correlação - ruído) com o estímulo utilizado durante a fase de aprendizado. Esse postulado faz referência ao grau de dispersão dos estímulos associados a uma resposta específica.

POSTULADO 6. Estímulo associado com estados decisórios (D - Drive State). As necessidades biológicas ou algum tipo de carência produz um estado e um estímulo que orienta a tomada de decisão do ser. Por exemplo, um ser com muita sede, em uma sala com duas mesas, uma com um copo com água e outra com alimento sólido. O estímulo de sede, com grande probabilidade, forçará o ser a escolher a mesa com o copo com água. O potencial do estado de decisão não define um comportamento, mas, intensifica uma dada resposta, sendo utilizado como elemento desencadeador de comportamento durante a fase de aprendizagem.

POSTULADO 7: Potencial de reação. Trata-se da força com que uma resposta é ativada. O potencial de reação é função da força do hábito (${}_E H_R$) e do potencial de estado decisório (D):

$${}_E P_R = {}_E H_R * D \quad (A4)$$

onde ${}_E P_R$ representa o potencial de reação,
 ${}_E H_R$ força do hábito e
D nível total dos estímulos atuando no ser (Drive State).

POSTULADO 8. Fadiga - inibição reativa. Os circuitos neuro-musculares possuem a característica de reduzir a força e intensidade de operação quando solicitados por um longo período contínuo de tempo. Esse fenômeno é chamado fadiga. Como resultado, quando o sistema é solicitado, a resposta é manifestada com pouca intensidade ou não ocorre. Hull definiu um fator de inibição (I_f) para incorporar o efeito da fadiga no seu modelo. Esse fator aumenta de valor com a frequência e intensidade de uma resposta. Períodos de "descanso" (ausência da resposta) diminuem o valor de I_f .

POSTULADO 9. Potencial efetivo de reação. Hull definiu um potencial efetivo de reação, ou seja, a força com que uma resposta ocorrerá, como sendo função da força do hábito (${}_E H_R$), do potencial do estado decisório (D - Drive state) :

$${}_E P_R = {}_E H_R * D - (I_R + {}_E I_R) \quad (A5)$$

- onde ${}_E H_R$ força do hábito,
 E estímulo,
 R resposta;
 D nível total dos estímulos atuando no ser (Drive State);
 ${}_E P_R$ potencial efetivo de reação. É a tendência total de ativar determinada resposta na presença de determinado estímulo;
 I_R inibição reativa. Trata-se de um fator de fadiga. O valor de I_R aumenta com o número de respostas e diminui com o tempo, o que evita a saturação do potencial de reação. Hull utiliza esse fator para explicar por que um ser apresenta melhores resultados no aprendizado quando o processo ocorre com a alternância de períodos com grande esforço de aprendizado e períodos de repouso. O repouso é o tempo para reduzir o valor de I_R . Note que a inibição reativa é função somente da resposta;
 ${}_E I_R$ inibição condicionada. Trata-se da tendência (bloqueio - hábito) do ser não responder na presença de um determinado estímulo.

Os fatores I_R e ${}_E I_R$ atuam como inibidores, quanto maior os seus valores, menor a força com que uma resposta será ativada.

POSTULADO 10. Fator de Oscilação Comportamental (${}_E O_R$). Hull afirma que existe um potencial inibitório que varia a cada momento, inibindo determinadas respostas. Esse fator geralmente atua com um intervalo pré-definido, sendo assumido com uma distribuição normal. O fator de oscilação comportamental (${}_E O_R$) é função do estímulo e atua inibindo a resposta. Assim, Hull corrige o potencial efetivo de reação criando o potencial efetivo de reação instantâneo:

$${}_E\underline{P}'_R = \left[{}_E H_R * D - (I_R + {}_E I_R) \right] - {}_E O_R \quad (A6)$$

onde ${}_E\underline{P}'_R$ potencial efetivo de reação instantâneo e
 ${}_E O_R$ fator de oscilação comportamental.

POSTULADO 11. Relação entre a resposta e o potencial efetivo de reação instantâneo. Hull afirma que o valor ${}_E\underline{P}'_R$ deve estar acima de um valor mínimo (*threshold* de reação - ${}_E L_R$) para que a resposta ocorra.

POSTULADO 13. Latência (${}_E t_R$). Latência é o tempo decorrido entre a presença de um estímulo e a resposta executada. O valor de ${}_E\underline{P}'_R$ deve ser maior que o threshold. Quanto maior ${}_E\underline{P}'_R$, menor o tempo de latência. O valor de ${}_E\underline{P}'_R$ também define o grau de resistência para a excitação de uma resposta. Quanto maior esse valor, maior o número de respostas a serem produzidas. A amplitude da resposta condicionada varia diretamente com o valor de ${}_E\underline{P}'_R$. Quando várias respostas diferentes apresentam alguma probabilidade de ocorrer, aquela que apresentar o maior valor de ${}_E\underline{P}'_R$ irá ocorrer.

Após vários experimentos e estudos, Hull reavaliou sua teoria alterando e complementando alguns de seus conceitos. Por exemplo, o ser aprende mais rapidamente na presença de um incentivo, variando com o tipo e a magnitude. A intensidade de um estímulo interfere diretamente no potencial efetivo de reação instantâneo, assim, a equação para ${}_E\underline{P}'_R$ foi corrigida para:

$${}_E\underline{P}'_R = \left[{}_E H_R * D * V * K - (I_R + {}_E I_R) \right] - {}_E O_R \quad (A7)$$

onde K é um fator de motivação e V é um fator de intensidade dinâmica do estímulo (força do estímulo).

Outro ponto interessante da teoria de Hull é o fato de que um estímulo (E) desencadeia uma série de “respostas secundárias” que por sua vez, desencadeiam “estímulos secundários” que auxiliam na produção da resposta principal, ver figura A6.




FIGURA A6. Estímulo discriminativo produz resposta secundária que desencadeia estímulos secundários que reforçam a resposta principal.

A partir deste esquema, Hull desenvolve um esquema sequencial, que chamou de cadeia de respostas. As ações a que o ser está sujeito, geralmente, não são tão simples como uma relação E-R, envolve uma série de estímulos e atitudes (ações-respostas) secundárias que conduzem (ou induzem) a um procedimento mais geral. Um exemplo clássico é o da fome. Quando o ser está com fome e observa o alimento, o organismo desencadeia uma série de procedimentos com o objetivo de reduzir o estímulo inicial: a fome.




FIGURA A7. Cadeia de estímulos-respostas.

Note que as respostas (R_1 , R_2 e R) foram *setadas* com o auxílio de um estímulo (e - estímulo secundário) previamente aprendido e não diretamente relacionado com a tarefa principal.

De forma muito resumida, a teoria de Hull incorpora 3 tipos de variáveis:

- Independentes: estímulos;
- Intervenientes: relacionadas diretamente ao organismo;
- Dependentes: resultado de uma ação dependente dos outros dois tipos de variáveis.

A figura A8 relaciona os tipos de variáveis com alguns elementos dos postulados apresentados.

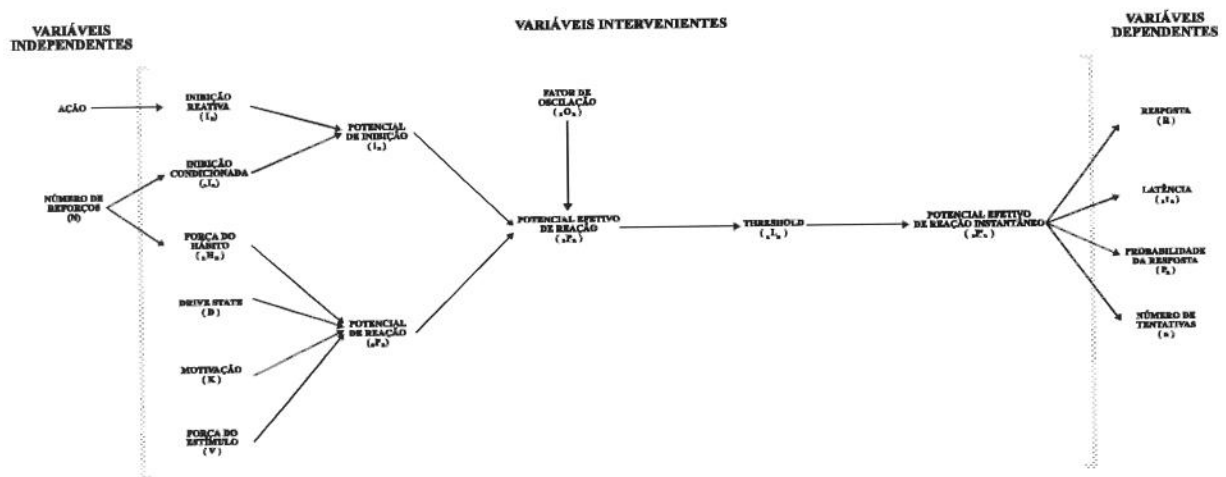


FIGURA A8. Diagrama relacionando as variáveis propostas por Hull.

Hull desenvolveu um sistema que possui 4 estágios (4 níveis) de variáveis: o primeiro estágio é composto pelas variáveis independentes, o segundo e terceiros estágios por variáveis intervenientes e o quarto estágio por variáveis dependentes. Essa foi a principal contribuição de Hull para a teoria do aprendizado, quantizá-lo através de equações matemáticas.

A partir de funções de variáveis independentes, Hull procura fazer suas previsões, pois, podem ser controladas (estimulação, quantidade de alimento, ...). As variáveis intervenientes são função das variáveis independentes. Os parâmetros da equação A7 podem ser modelados utilizando-se as mais variadas funções (resguardando-se o compromisso com o comportamento do ser).

Os aspectos da teoria de Hull que nos foram úteis na estruturação do processo de aprendizado são: o esquema de cadeias de respostas e o desencadeamento de

respostas secundárias; que utilizamos para a implementação do processo de busca e geração de macro-rotas (combinação de várias rotas). O mapeamento de regiões e a formação de rotas não significa que o sistema seja capaz de "sugerir" uma trajetória. Somente com a sequenciamento de rotas isso é possível, pois, as rotas possuem uma abrangência muito restrita. Como o mapeamento é altamente redundante, utilizamos o esquema de estímulos secundários para ativar sucessivos caminhos de busca pela base de dados do sistema. A seqüência de rotas que primeiro conectar o ponto inicial e final de uma trajetória será aprendida.

9. B. F. SKINNER

Para B. F. Skinner, o aprendizado envolve dois tipos de comportamentos distintos: comportamento respondente e comportamento operante. No comportamento respondente, dado um estímulo específico que provoca uma resposta específica, ao ser ativado simultaneamente com outro estímulo, após um certo número de tentativas, esse novo estímulo passa a produzir a mesma resposta específica (condicionamento clássico). No entanto, Skinner afirma que grande parte do comportamento é do tipo operante. Esse tipo de comportamento é explicitado (manifestado) pelo estado do próprio ser interagindo com o meio, independente da presença de um estímulo. Nem sempre será um estímulo específico, o ativador de uma resposta, e sim, de um conjunto de estímulos atuando. A união de vários conjuntos de estímulos-respostas, que satisfaçam a alguma necessidade do organismo forma uma cadeia, que passa a compor uma resposta operante. Skinner, também salienta que o reforço é fundamental no processo de aprendizado atuando como sustentáculo de um comportamento.


Dois princípios estão associados ao condicionamento operante: qualquer resposta seguida pelo reforço de um estímulo tende a ser aprendida e o reforço de um estímulo tende a aumentar a frequência de uma resposta operante. O condicionamento operante está intimamente relacionado com o comportamento do aprendiz e suas consequências individuais e coletivas (interação com a sociedade). Para que ocorra a assimilação (ou modificação) de um determinado comportamento (R), a relação estímulo(E)-resposta(R), presente no processo, deve ser repetida

várias vezes pelo reforço do estímulo desencadeador do processo. Esse estímulo pode ser externo (gerado por um professor) ou interno (auto-reforço - vontade própria para satisfazer alguma necessidade). Da mesma forma, se um comportamento deve ser eliminado, "basta remover o estímulo que o ativou". Identificar o estímulo ou o conjunto de estímulos pode não ser uma tarefa muito fácil devido a fatores conjunturais e sociais (o reforço da sociedade pode ser difuso e é muito forte).

A resposta produzida pela presença de um estímulo específico, pode desencadear um novo estímulo, que Skinner chamou de estímulo secundário de reforço:

$$E^D \rightarrow R \rightarrow E^R$$

O estímulo específico (E^D - estímulo discriminador) produz uma resposta (R) operante que "ativa" um estímulo secundário, chamado de estímulo respondente (E^R). Esse estímulo atua como reforço (ou desencadeador) para outro estímulo discriminativo, o resultado é uma cadeia de relações de estímulos-respostas:



O estímulo de reforço (E^R), atua positivamente (reforçador) ou negativamente (remover), aumentando ou diminuindo a probabilidade de ocorrência de uma resposta. O estímulo negativo não consiste necessariamente em uma punição. Para Skinner, a punição ocorre quando uma resposta (R) remove algo com caráter positivo ou adiciona algo com caráter negativo inibindo um evento, contudo, não

diminui a probabilidade de uma resposta ocorrer. Ele afirma que enquanto a punição está ativa, o comportamento inibido tem sua ação reduzida, mas ao removermos a punição, o comportamento é "*resetado*" (reativado). A punição tem caráter temporário, uma alternativa para suprimir um comportamento é substituí-lo por outro.

A teoria de Skinner sobre o sequenciamento de relações estímulo-resposta, com a ativação de estímulos respondentes vem de encontro com o processo de formação de macro-rotas que mencionamos anteriormente. Durante esse processo, regiões mapeadas redundantemente, provocam a ativação de vários grupos de neurônios e várias rotas simultaneamente (estímulos secundários). O processo continua até que uma rota intermediária ou o ponto final sejam atingidos. A primeira rota intermediária a ser *setada* será uma que contenha o ponto final da trajetória. A próxima será aquela que faz conexão com a primeira, e assim sucessivamente até que uma rota que contenha o ponto inicial faça conexão com uma rota intermediária previamente sequenciada. Se várias rotas fazem conexão, aquela que primeiro atingir uma rota já sequenciada será a escolhida. Não significa que esta escolha corresponda à trajetória mais curta.

10. GESTALT

Algumas teorias conexionistas incorporam características da abordagem cognitiva, por isso, apresentaremos algumas teorias que julgamos serem úteis em nosso estudo. Uma das mais importantes escolas cognitivistas é a Gestalt [KOFF-35]. A quantidade de estudos mais uma vez é muito grande, por isso, consideraremos somente algumas de suas características. Nessa teoria, no processo de aprendizado, deve-se considerar o ser como um todo, que possui um sistema nervoso operando dinamicamente com múltiplos processamentos interrelacionados. Assim, os estados ou respostas deste sistema devem ser analisados como um todo, em função de como ele observa, analisa e interage com o meio. Isso não significa que não exista um certo grau de interdependência nos processos e entre os elementos neuronais.

Gestalt significa configuração, organização ou estruturação (não com o mesmo significado da escola estruturalista que concentrou seus estudos nos

processos físico-químicos do cérebro). A teoria gestaltista é composta por uma série de princípios. A seguir relacionaremos alguns que julgamos interessantes para o nosso trabalho:

TEORIA DOS CAMPOS. O campo define a inter-relação entre os sistemas (que estão interrelacionados e não tem ação isolada) do ser. Os estímulos a que o ser é submetido, exercem (de alguma forma) influência sobre todo o corpo e seu comportamento. No sistema que estamos propondo, um estímulo de posição é enviado a todas as redes neuronais simultaneamente.

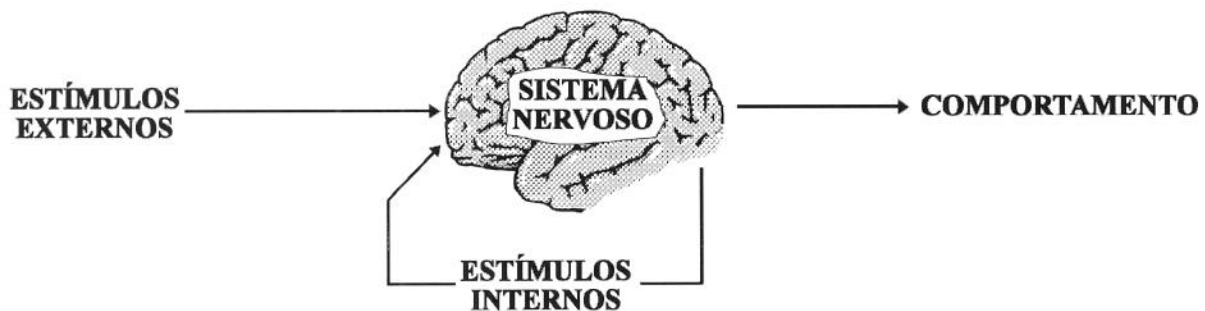
NATIVISMO. Na teoria gestaltista, o cérebro (sistema nervoso) é um elemento dinâmico, que armazena, seleciona e ativa procedimentos e que adquire (aprende) suas funções com a experiência. No entanto, a teoria gestaltista assume que muitos atributos do sistema nervoso pré-existem, independentemente da experiência (existem "procedimentos pré-definidos" que organizam as informações e o acesso ao sistema nervoso - influência da genética).

A "genética" das redes neurais artificiais são pré-concebidas pelos seus idealizadores que definem suas estruturas, dinâmicas de aprendizado e operação. A funcionalidade dependerá da aplicação, ou seja, dos padrões utilizados no treinamento. No nosso sistema, as estruturas também são previamente definidas, cabendo aos padrões (regiões mapeadas e rotas) estabelecer as relações com o meio.

CONSTÂNCIA NA IDENTIFICAÇÃO. Apesar dos objetos apresentarem formas distintas, dependendo de como são observados ou de como os estímulos são enviados e processados, o sistema nervoso consegue identificar um objeto, por exemplo. Os gestaltistas acreditam que o cérebro armazena o "significado" (as principais características) do objeto.

O mapeamento das regiões da área de trabalho é implementado através da equação da circunferência (ver capítulo IV). Detalhes dos obstáculos (pequenos ruídos, irregularidades nas paredes por exemplo) serão ignorados. Com essa restrição, o processo de mapeamento, localização, formação e busca de rotas fica simplificado e compatível com o objetivo principal do sistema que é atuar como um orientador e não como um gerador de trajetória.

RELAÇÃO ENTRE O CORPO E A MENTE. O cérebro recebe e processa (podendo interferir - transformar) as informações sensoriais; e o corpo experimenta (reage) seguindo os modelos formados e sua estrutura física (habilidades físicas).



Os estímulos externos (fora do corpo ou vontades próprias) não definem sozinhos os comportamentos, a estrutura do sistema nervoso e os estímulos internos (crenças, objetivos, necessidades, ...) atuam como filtros modulando o comportamento final.

INSIGHT. Os gestaltistas acreditam que quando o ser defronta com algum problema, o sistema nervoso entra em desequilíbrio (cognitivo) que deve ser reduzido (atingir um novo equilíbrio). Esse desequilíbrio fornece estímulos (que persistem até que o problema seja resolvido ou atenuado) ao sistema nervoso. Para a solução, são ativadas todas as estruturas neuronais, sua experiências, sua base de dados (memória, habilidades, ...), enfim, todo o corpo tenta propor soluções. Os gestaltistas acreditam que a solução ocorre de uma só vez, de súbito e não de forma incremental. Esse processo é o chamado "*insight*". O processo de "*insight*" pode sofrer a influência de uma série de fatores, por exemplo, fatos que ocorreram mais recentemente exercem maior interferência no processo.

Antes de "surgir" a solução, o ser realiza uma espécie de busca, formula hipóteses, testa pré-soluções parciais, muitas vezes utilizando o método da tentativa e erro. O conteúdo aprendido por "*insight*" tem a característica de permanecer "retido" (memorizado) por um período grande de tempo e ser ativado ("com maior frequência") para "compor" a solução de outros problemas. Quando um problema é resolvido desta forma, um "traço" (vestígio) do processo utilizado permanece ativo no sistema nervoso. Vários "vestígios" combinados, formam um "sistema de influências", com forte atuação sobre o ser.

No sistema que estamos propondo, o mapeamento das regiões na área de trabalho ocorre por aprendizado do tipo "*insight*". Quando em movimento por uma região desconhecida, o sistema entra em desequilíbrio, permanecendo até que uma região possa ser identificada, ou seja, os pesos sinápticos possam ser *setados*. Esse processo ocorre de forma súbita, é o "*insight*".

As três teorias que apresentaremos a seguir: Tolman, Piaget e Gagnè, serviram de base para o projeto da estrutura do processo de aprendizado que implementamos no nosso sistema. Essas teorias apresentam um fator em comum: a estruturação do aprendizado em etapas (tipos) hierarquicamente organizados e interdependentes. Como veremos, o aprendizado ocorre pela aquisição de habilidades primárias (básicas - elementares) e seu encadeamento, discriminação de ações, formação de conceitos, formação de princípios e resolução de problemas.

Tolman propõe 6 tipos de aprendizado, Piaget 4 estágios e Gagnè 8 tipos. Não questionaremos a validade destas teorias, as utilizaremos de forma harmônica para compor a estrutura que implementamos, pois muitas de suas características principais são comuns.

11. E. C. TOLMAN

Uma das tentativas de aproximar essas duas linhas teóricas (conexionista e gestaltista) foi a modelo proposto por Edward Chace Tolman (1886-1959). O ser não executa ações respondendo somente a estímulos, mas influenciado por uma série de fatores relacionados com a sua ética, moral, crenças, interação com o meio e objetivos. Este último fator, o objetivo, é considerado como o principal elemento que "orienta" todos os processos. Tolman propõe 6 tipos de aprendizagem:

- formação de catexias,
- crenças de equivalências,
- expectativas de campo,
- modos de cognição de campo,
- discriminação de impulsos e
- padrões motores.

A catexia é a tendência do ser buscar determinados objetivos visando satisfazer algumas de suas necessidades ou inibir (satisfazer) algum impulso. A equivalência consiste no aprendizado de razões ou estados equivalentes. Por exemplo, um adulto recebe um elogio pelo projeto arquitetônico e uma criança pelo desenho de uma choupana. As expectativas de campo consistem nas regras que conduzem o ser de um estado para outro, são os mapas cognitivos. Essas regras são formadas através da integração com o meio e do reforço que produz. Os modos cognitivos de campo são os métodos que o ser utiliza para realizar o aprendizado, são as habilidades ("algoritmos") que o ser manifesta através da facilidade com que aprende determinada tarefa. Neste caso, as características do "hardware neural" devem ser consideradas. Através da discriminação, o ser aprende a separar impulsos (estímulos), catexias e mapas cognitivos semelhantes, criando seus próprios padrões. Por fim, os padrões motores consistem nas habilidades do ser controlar seu sistema muscular, ou seja, suas habilidades motoras.

Tolman também considera que esses 6 tipos de aprendizagem manifestam-se de forma distintas nos indivíduos, sendo função de parâmetros relacionados com

fatores genéticos, idade, "condições de vida" (estado físico do ser), e treinamento (condições sociais para realizar (manifestar) o aprendizado).

Para Tolman todo comportamento (ou elemento a ser aprendido) tem como elemento terminal, alcançar algum objetivo; e é essa meta que "direciona" (na medida do possível) o comportamento do ser. Assim, interagindo com o meio (ou com a sua base de dados neurológica), o ser, através de processos exploratórios e de certificação (consistência-validação), observa e valida as relações de causa e efeitos que estão ocorrendo, bem como, o encadeamento (relação) que elas formam. Durante esse processo, o ser é levado a tomar decisões. Para tanto, ele formula hipóteses que necessitam de algum tipo de confirmação, sujeitas à validação da sua base de dados (experiências prévias - moral - fé - crenças) ou através de ensaios. Essas hipóteses podem auxiliar no processo decisório. Como resultado, as decisões escolhidas conduzem a um menor gasto de energia.

O que o ser aprende é o que ele observa, independente do reforço. A motivação serve para "orientar" (filtrar) essa observação, permitindo a gradual formação de uma "mapa" ("*cognitive map*"). Grande parte dessa base de dados permanece latente (em *stand by*); quando solicitada, as informações são "reativadas".

Outro aspecto interessante na teoria de Tolman, com relação ao aprendizado de ambientes, é o fato de afirmar que o aprendizado ocorre em função do local onde "pensa" estar ("*place learning*") e não em função de relações do tipo estímulo-resposta. Para mostrar essa teoria, foram realizados experimentos com ratos. Um grupo de ratos foi treinado para trafegar por um caminho semelhante ao mostrado na figura A9. A seguir, um ambiente semelhante, mas com múltiplas opções de caminhos, foi apresentado aos roedores, mas com a direção preferencial inicial bloqueada. Como resultado, o caminho 6 foi o mais escolhido. Tolman supunha que o animal consiga identificar uma direção preferencial (global-absoluta) de movimento.




FIGURA A9. Layout da área de treinamento.




FIGURA A10. Caminho de treinamento é obstruído e caminhos secundários são liberados.

12. J. PIAGET

Outro influente cognitivista, Jean Piaget [MUSS-83] [PIAGE-70], que realizou importantes estudos sobre o aprendizado em crianças, apresentou uma teoria que incorpora ao que chamou de esquema. Os esquemas são as formas como o ser observa, compreende, analisa e interage com o meio. Os seres possuem vários esquemas que estão em constante modificação, "acomodando-se" em níveis de relativa estabilidade. O nível de complexidade dos esquemas forma o conjunto de habilidades, "pensamentos" do ser.

Piaget classificou a evolução dos esquemas em 4 estágios operacionais:

- sensório-motor
- pré-operatório
- operações concretas
- operações formais

Durante o primeiro estágio, os esquemas formam estruturas elementares com informações do ambiente. É o estágio onde a criança começa a perceber as formas das coisas, adquire as primeiras habilidades motoras, enfim, tem-se o início da formação interna dos modelos do mundo. No segundo estágio, os esquemas já possuem a complexidade para permitir a representação das coisas e ações de forma simbólica e concreta. A criança já possui a capacidade de identificar os objetos e associar com palavras. No terceiro estágio, a complexidade dos esquemas aumenta ao ponto de permitir a hierarquização, combinação e comparação de coisas e fatos. A criança já consegue manipular símbolos e realizar operações com maior habilidade. No quarto estágio, os esquemas permitem a manipulação de eventos abstratos, no entanto, a capacidade de manipulação hierárquica e lógica já deve estar bem estruturada nos esquemas. Estes estágios são macro agrupamentos de sub-estágios, pois, todo processo é contínuo e hierarquizado.

Para Piaget, o desenvolvimento cognitivo não pode ser entendido sem uma análise com pressupostos biológicos (características do hardware biológico herdado através do código genético) e da interação do ser com o meio que lhe fornece informações (estímulos - permite realizar experiências) para a estruturação de relações cognitivas. Desta relação, o ser realiza o registro da "realidade observada". Quanto maior a capacidade do sistema neuronal coletar, selecionar, classificar e

discriminar essas informações, mais "consistentes e confiáveis" serão os modelos mentais do ambiente. Piaget salienta que não se adquire conhecimento somente através do registro de informações externas, e sim, das inter-relações entre o sujeito e os objetos (o próprio ambiente) (o ser deve ter (ou adquirir) a capacidade de coordenar suas ações). A aquisição de um novo conhecimento está fundamentada em estruturas e esquemas já incorporados pelo sistema. Neste contexto, atribuir a simples relações do tipo estímulo-resposta como sendo a única "formadora de um conhecimento" não é coerente. Contudo, Piaget afirma que o ser (sistema nervoso) já deve possuir algumas estruturas ou esquemas que "inicialize" a manifestação da resposta a um determinado estímulo (como por exemplo os reflexos neuro-musculares). Assim, deve existir alguma relação bi-unívoca entre estímulo e resposta que possa ser representada por:

$$E \Leftrightarrow R$$

ou

$$S \rightarrow (AT) \rightarrow R$$

onde **A** indica a assimilação de um estímulo a uma estrutura **T**. O processo de assimilação é o que garante a continuidade do processo de formação das estruturas quer seja biológica (transformação e formação das estruturas neuronais) ou cognitiva. A cada assimilação de novos elementos às estruturas, o sistema responde com uma atitude de "acomodação dinâmica" (como um período de latência para que o sistema "adquirir forças" e continue o processo). Esse equilíbrio entre a aquisição e a acomodação define o estado de equilíbrio do ser. Quando a acomodação prevalece sobre o processo de aquisição (auto aquisição de conhecimento) o sujeito passa simplesmente a imitar (copiar e reproduzir) os fatos (ações) observados no meio.

O processo de interação propicia a evolução gradual e constante da massa de conhecimento, ao ponto do ser não considerar-se um elemento (objeto) dissociado do meio, mas, pertencente ao ambiente. Piaget relata que o processo de aprendizado se manifesta de forma bem ordenada (bem definida e gradual) e seqüencial, em sintonia com a evolução (maturação) do sistema nervoso ou do do próprio ser. Piaget classificou esse processo evolutivo em estágios, que se manifestam seqüencialmente e interdependentes (um estágio superior depende das habilidades adquiridas nos estágios anteriores).

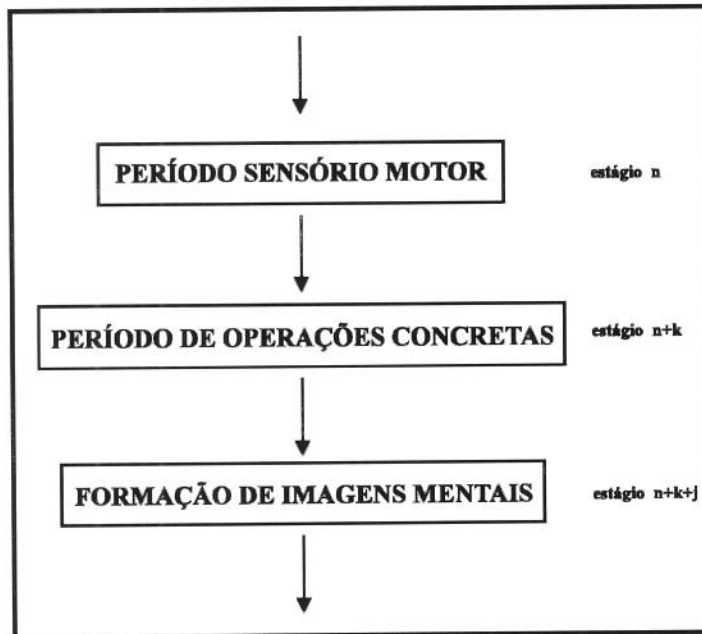


FIGURA A11. Sequenciamento de estágios de aprendizado.

A influência de agentes externos (volume de informações e estímulos, ambiente social, cultural e educacional) que atuam como "orientadores", aceleram ou retardam a passagem de um estágio para outro. Em cada estágio, o ser não acumula somente informações, ele aprende formas (métodos, algoritmos, ferramentas...) para manipular os dados.

Em resumo, se o ser recebe uma informação e não experimenta, ele geralmente torna-se um repetidor, mas se experimenta, realiza abstrações e deduções lógicas sobre os elementos envolvidos na atividade, transforma-se em um gerador de novos conhecimentos ou derivados, pois, interfere no processo contribuindo com as suas habilidades e experiências, e adquirindo novas (quer seja proveniente do meio ou construídas pelo ser). A palavra "experiência" está sendo utilizada com um sentido mais amplo, não somente no sentido de realizar uma ação física (atividade perceptiva), mas também, validar uma informação através de exercício intelectual.

13. R. M. GAGNÈ

Para finalizar, apresentamos a teoria de Robert M. Gagnè [GAGN-65] que desenvolveu uma organização para o processo de aprendizado. Gagnè propõe um processo de aprendizagem estruturado em 8 tipos hierarquicamente associados:

- 1 - Aprendizagem de sinais
- 2 - Aprendizagem tipo estímulo - resposta
- 3 - Aprendizagem de cadeias
- 4 - Associação verbal
- 5 - Aprendizagem de discriminações múltiplas
- 6 - Aprendizagem de conceitos
- 7 - Aprendizagem de princípios
- 8 - Resolução de problemas

A aprendizagem de sinais (TIPO 1) é o processo mais elementar de aprendizagem. Trata-se de um processo de resposta condicionada. A um estímulo que produz uma resposta, associa-se um segundo estímulo, chamado de condicionador, que não tem nenhuma relação com o processo bio-físico-fisiológico da resposta ao primeiro estímulo. Ou seja, o estímulo condicionador, por si só, antes do aprendizado, não produz a resposta desejada. Os dois estímulos são apresentados repetidas vezes ao aprendiz. O aprendizado termina quando o estímulo condicionador, isoladamente, induz a resposta desejada. Esse tipo de aprendizagem tem como característica principal: o fato de que as respostas são gerais e difusas, muitas vezes involuntárias.

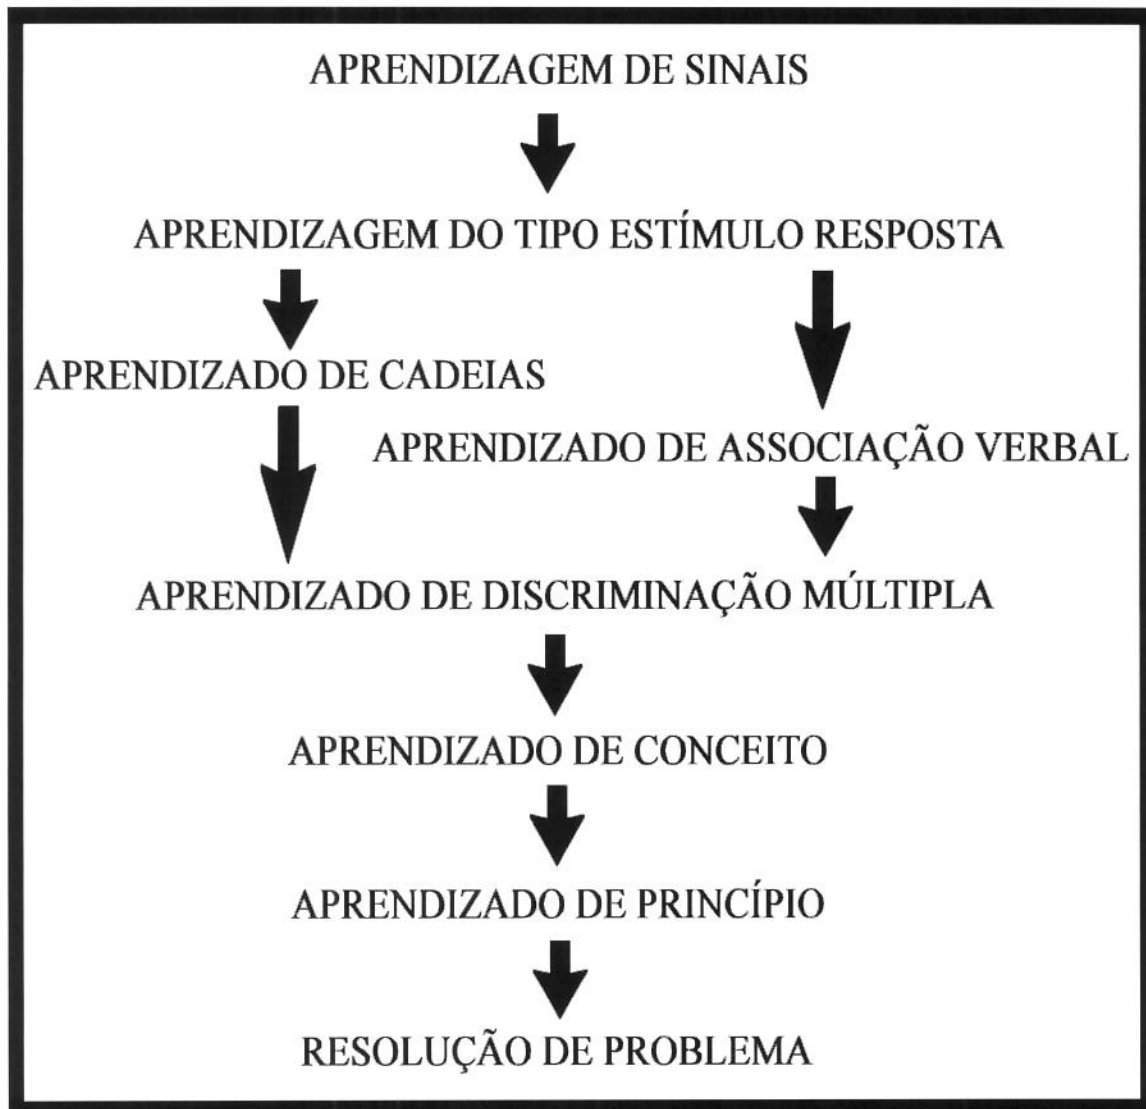


FIGURA A12. Tipos de aprendizado.

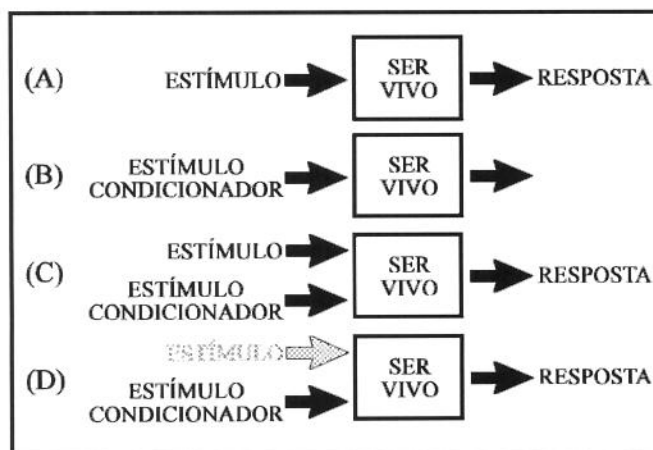


FIGURA A13. (A) Antes do treinamento, estímulo produz a resposta. (B) Antes do treinamento, estímulo condicionador não produz a resposta. (C) Durante o treinamento, estímulo e estímulo condicionador produzem a resposta. (D) Após o treinamento, estímulo condicionador induz a resposta.

A aprendizagem do tipo estímulo-resposta (TIPO 2) é uma forma mais elaborada de aprendizagem, onde associa-se, a uma resposta (R) específica, um estímulo (E) específico.




FIGURA A14. Aprendizado do tipo estímulo-resposta (TIPO 2)

O processo de aprendizagem consiste em associar um estímulo (E) específico a uma resposta (R) específica. Um estímulo (e) interno ao sistema nervoso (estímulo proprioceptivo), modula (influencia) o processo. Esse tipo de aprendizado é gradual, a resposta torna-se mais específica e exata com o número de repetições, podendo tornar-se automatizado, atuando a nível do inconsciente. Para que ocorra esse tipo de aprendizagem, é preciso levar em consideração as capacidades inerentes do aprendiz, ou seja, as habilidades que já domina. As respostas corretas devem ser "reforçadas" ou "validadas", proporcionando ao aprendiz, algum parâmetro indicativo para o fim do processo. Pouco se sabe sobre como esse processo é "implementado" à nível de sistema nervoso. No entanto, a principal diferença entre o aprendizado do tipo 1 e do tipo 2 é que no aprendizado do tipo estímulo-resposta o estímulo (E) produz uma resposta voluntária, "razoavelmente" específica e precisa.

A aprendizagem de cadeias (tipo 3) consiste em "ligar" (associar) duas (ou mais) relações de estímulo-resposta (habilidades) previamente aprendidas (aprender significa dominar suas habilidades e não somente saber repetí-las como lhes foi apresentada). O resultado é uma cadeia de habilidades.




FIGURA A15. Aprendizado de cadeias (TIPO 3)

Esse processo deve ser contínuo e coerente, verificando a validade de cada conexão. Essa avaliação é realizada com o auxílio de estímulos externos e estímulos provenientes da "realidade mapeada no sistema nervoso".

A aprendizagem (associação) de cadeia verbal (tipo 4) é um sub-tipo da aprendizagem em cadeia. Trata-se da associação de sílabas e palavras. Para ocorrer a aprendizagem do tipo 3, o aprendiz deve dominar cada elo da cadeia, ao menos, conhecer o significado das sílabas e palavras. A validação de cada conexão é realizada com o auxílio de estímulos visuais e com o grau de domínio do assunto abordado (contexto). A frase: O gato é verde, pode ser representada pela união de dois elos:

GATO → VERDE

O aprendiz deve dominar (saber identificar) e associar com a sua realidade as palavras *GATO* e *VERDE*. A conexão é estabelecida a partir do momento que a associação é validada. Por exemplo, o aprendiz observa (ou imagina) a figura de um gato verde. Como no aprendizado de estímulo-resposta e cadeia, o encadeamento de associações verbais é efetuado com elementos (elos) específicos.

A aprendizagem de discriminações múltiplas (tipo 5) consiste em capacitar o aprendiz a discriminar (identificar) cadeias semelhantes. Por exemplo, uma criança é constantemente solicitada a identificar pessoas de outros animais, quando é solicitada a distinguir entre homens e mulheres, isso é uma discriminação múltipla. A discriminação múltipla consiste em estabelecer respostas diferentes para um conjunto de estímulos semelhantes.

A aprendizagem de conceitos (tipo 6) consiste em capacitar o aprendiz a fornecer uma resposta única a um conjunto de estímulos diferentes, identificando as semelhanças entre eles. Neste tipo de aprendizagem, a verbalização por parte do agente instrutor é fundamental, conduzindo e facilitando o processo. Aprendido um conceito, o aprendiz adquire a capacidade de poder generalizar, aplicando-o a outras situações estimuladoras.

A aprendizagem de princípios (tipo 7) consiste na associação (formulação de cadeias) de dois ou mais conceitos, por exemplo, "Se A, então B", criando regras gerais. Para tanto, o aprendiz deve dominar (conhecer e saber aplicar) e saber selecionar os conceitos que serão encadeados. Cada nova conexão deve ser avaliada, tornando o princípio útil e aplicável a algumas situações. A aprendizagem de princípios é facilitada por instruções verbais. Observa-se que

os princípios podem ser associados, formando princípios de ordem superior. Essa hierarquia é a base para a formação do conhecimento sistematizado sobre um determinado tema.

A aprendizagem do tipo 8, resolução de problemas, consiste em ensinar a utilizar os princípios para obter a solução de um problema. O aprendiz pode dominar (ter as habilidades necessárias) um determinado assunto, mas, resolver um problema implica em encadear suas habilidades de forma adequada. Pode-se notar que se todas as possibilidades de combinações das suas habilidades fossem ativadas durante a solução de um problema, a resolução seria muito demorada. Os seres humanos lançam mão de alguns artifícios para obter o resultado esperado mais rapidamente: instruções verbais, observação da natureza e realização de experimentos. Na realidade, a resolução de um problema nada mais é do que a determinação de um princípio de ordem superior, pois todo o seu conhecimento é utilizado, manipulado e filtrado gerando "algo novo" que é o *princípio* de novas atividades.

No modelo de Gagnè, todos esses tipos de aprendizados estão relacionados, a resolução de problemas (tipo 8) exige como pré-requisito o conhecimento e domínio de princípios (tipo 7), que exige o conhecimento de conceitos (tipo 6) que por sua vez, exige o aprendizado de discriminações múltiplas (tipo 5) que exige como pré-requisito o aprendizado de associações verbais (tipo 4) e de cadeias (tipo 3) que é estruturada a partir de conexões do tipo estímulo-resposta (tipo 2).

O que está sendo proposto é um modelo estruturado e hierarquizado para explicar o processo de aprendizado. Mas, na realidade, observa-se que é possível identificar outros tipos, estando muito mais relacionados com as propriedades dos experimentos e com o que se deseja ensinar do que com o mecanismo neuro-fisiológico do sistema nervoso central. Por outro lado, sabe-se muito pouco sobre o processo neuro-físio-físico-cognitivo do aprendizado.

Evidentemente existem muitas outras teorias e teóricos que abordaram a questão do aprendizado, e também, muito questionamento entre eles, pois não existe uma teoria geral. Essa discussão deve-se ao fato de que as teorias ou são mal formuladas ou apresentam um caráter específico [ROUA-67], centrada principalmente na exteriorização de um estado ou ação do ser, sendo este, considerado uma "caixa preta".

No sistema que estamos propondo, o aprendizado ocorre em 4 fases:

- mapeamento do meio,
- formação de rotas,
- sequenciamento de rotas e
- formação (verificação) de "vias expressas".

O mapeamento consiste no reconhecimento de pequenas regiões na área de trabalho, trata-se de um processo semelhante à formação de mapas cognitivos, catexias, aprendizagem de sinais e relações estímulo-resposta.

A formação de rotas consiste no sequenciamento das regiões mapeadas, como o aprendizado de cadeias. As rotas permitem a geração de trajetórias muito restritas. O sequenciamento hierarquizado de rotas formam as macro-rotas, com um grau de abrangência muito maior. Definidas as macro-rotas, o sistema é capaz de auxiliar na geração de trajetórias complexas, são as "vias expressas".

14. APRENDIZADO DE MÁQUINA

O aprendizado de máquina [MONO-92] [SARI-83] também tem sido muito estudado. Os objetivos são os mais variados, mas geralmente envolve a capacitação do sistema de controle de um mecanismo para a "tomada automática de decisão" melhorando a qualidade das ações efetuadas. Quando a tarefa tem o seu escopo conhecido, então pode ser pré-programada, contudo podem surgir aleatoriedades, durante a execução, que necessitam ser controladas. Se o sistema "tem a habilidade para executar as correções necessárias", os resultados serão melhores. Por outro lado, um grande número de atividades não pode (ou se tornariam onerosas) ser completamente modelada. Dai surge o aprendizado de máquina, para suprir essa carência.

O aprendizado de máquina realiza-se através da manipulação de informações [SCHM-92] obtidas de sensores, de ordens fornecidas pelo usuário ou por um sistema gerenciador de tarefas. Esse tipo de aprendizado geralmente é implementado através de técnicas de inteligência artificial [FU-87] [LEVI-88] [RICH-88]:

reconhecimento de padrões, visão, pesquisa em árvores de possibilidades, cálculos de predicados, lógica fuzzy, técnicas heurísticas, técnicas de planejamento e redes neurais. Existem muitas outras técnicas, mas em geral, a aquisição do conhecimento ocorre principalmente por duas vias: o aprendizado indutivo e o aprendizado dedutivo.

O aprendizado por indução é o processo para aquisição de conhecimento a partir de informações fornecidas por um "instrutor", pelo ambiente ou qualquer outro agente externo. O aprendizado geralmente é realizado através de exemplos, analogias ou observações. De posse desses dados, o sistema deve ter a capacidade de retenção, recuperação, análise, transformação e generalização dessas informações, de tal forma que, quando solicitado possa auxiliá-lo na resolução de problemas. O aprendizado indutivo consiste em ajustar os parâmetros do sistema neuronal artificial em função da regularidade com que padrões são apresentados, semelhante a um processo de condicionamento (ou habituação), onde padrões válidos reforçam e padrões "espúrios" reduzem os valores dos parâmetros.

O aprendizado dedutivo é o processo onde novas informações são geradas através da consulta lógica a uma base de conhecimento. Esse tipo de aprendizado pressupõe a existência de um sistema neuronal em operação. Trata-se de um processo de observação visando a modificação (evolução) e refinamento de algum conhecimento. O aprendizado indutivo pode ser implementado através de vários métodos, os principais são os operadores lógicos, funções fuzzy e regras.

Para o ser humano, todas essas informações recolhidas pela máquina, somente terão valor se permitirem alguma tomada de decisão, solução de um problema, gerar ou melhorar algum procedimento. A figura A16 mostra o layout de um sistema que envolve o aprendizado de máquina. O sinal dos sensores são enviados a um sistema de gerência de tarefas que deve ter a capacidade de filtrá-los, armazená-los de "forma estruturada" em uma base de dados para que quando solicitado possa ser recuperado. Esse sistema também deve ter a capacidade de gerar e seqüenciar ações. Para auxiliar na solução de problemas, o sistema gerente pode contar com o auxílio de um sistema associativo, que verifica (associa) a integridade das ações com a base de dados e vice-versa. A solução de problemas é a manifestação operante do aprendizado. A eficiência com que o problema é resolvido depende da quantidade e qualidade das informações disponíveis, das habilidades "físicas" e "mentais" (cognitivas) da máquina.

Para a solução de problemas, antes de mais nada, é necessário identificar qual é a natureza do problema a ser resolvido, especificar as metas, identificar as

estratégias de soluções, e então, executar o planejamento, que deve ser constantemente avaliado.

Através dos órgãos dos sentidos, recebemos informações sobre as características dos problemas, por exemplo, lendo um texto ou escutando uma apresentação. Neste instante, geralmente (de acordo com o estado físico e mental ou interesse) já estamos pré-selecionando dados que dispomos ou que "imaginamos" serem úteis para a apresentação ou solução dos problemas. Uma vez estabelecido o problema, efetuamos a "representação mental" (representação interna), identificando os elementos em questão, suas características, relações, restrições e estados, as operações e as etapas a serem implementadas para atingir as metas, as habilidades necessárias que possuímos ou que precisamos adquirir, enfim, preparar uma representação do "cenário" e das regras para solucionar o problema.



FIGURA A16. Algumas etapas que envolvem o aprendizado de máquina.

Dependendo do grau de dificuldade, podemos utilizar uma representação externa para auxiliar na caracterização e sequenciamento das etapas. A representação externa geralmente é estruturada através de esquemas, de layouts, de story board, diagramas, algoritmos ou da palavra escrita. O objetivo é criar "imagens" e relações entre objetos, estados e ações.

As representações (internas ou externas) não são uma cópia fiel da "realidade", dependem de como as informações foram obtidas, interpretadas, armazenadas e estruturadas no sistema nervoso. Um ponto crítico é como julgamos todo processo, pois, além da habilidade física, fatores emocionais, de fé, moral, interferem na seleção, validação e estruturação das informações.

Sabemos muito pouco sobre como todo esse processo está implementado no nosso sistema nervoso. Conhecemos algumas reações dessa "caixa preta"; a sua

estrutura física: unidades de processamento (neurônios), algumas estruturas de processamento e transporte de dados (vias aferentes e eferentes e grupos neuronais responsáveis por funções bem específicas: áreas motoras, associativas, relativas à visão, "controle" de movimentos finos, fala, etc) ; mas sabemos muito pouco sobre como a informação é fisicamente armazenada e estruturada. O que conseguimos definir são modelos, representações de estruturas a partir das informações que conseguimos obter das relações do tipo estímulo-resposta de testes realizados com seres vivos. Para cada caso é possível identificar um conjunto de técnicas e dados que foram utilizados para a efetiva solução de um problema específico. O porquê um indivíduo utilizou esse ou aquele procedimento é uma questão em aberto.

CAPÍTULO IV

O SISTEMA

1. INTRODUÇÃO

Neste capítulo apresentamos as estruturas que compõem o sistema de auxílio a geração de trajetória em um ambiente desestruturado. O sistema está dividido em 3 partes:

- o mecanismo sensor,
- a estrutura do aprendizado e
- a estrutura neuronal.

O mecanismo sensor é o elemento que contém sensores de posição e de aproximação. Suas funções são fornecer a posição absoluta do mecanismo e a distância dos obstáculos. A estrutura de aprendizado consiste em um conjunto de estratégias neuronais que permitem o mapeamento e a navegação do mecanismo pela área de trabalho. E a estrutura neuronal é composta por uma série de redes neurais artificiais, cujas características permitem a implementação das estratégias de aprendizado e auxílio à geração de trajetórias.

O objetivo é fazer com que o sistema seja capaz de "sugerir" uma trajetória a ser seguida por um mecanismo em movimento em um ambiente desestruturado.

2. O MECANISMO SENSOR

2.1 A ESTRUTURA DO MECANISMO SENSOR

A área de trabalho é desconhecida do sistema, com exceção de uma posição definida como início do processo de mapeamento. Para localizarmos o mecanismo físico, adotamos um sistema de referências cartesiana ortogonal no plano. A origem do sistema de referência não necessariamente deve coincidir com a posição de início do mapeamento.

Assumiremos que o mecanismo físico pode executar movimentos somente em 4 direções que identificaremos pelos pontos cardeais: Norte, Sul, Oeste e Leste (movimentos combinados e em outras direções não serão permitidos).

Para a sua localização e mapeamento da área de trabalho utilizaremos um dispositivo composto por um conjunto de sensores de posição.




FIGURA SS1. Sistema de coordenadas.




FIGURA SS2. Cursor e a leitura dos sensores.

Considerando que as dimensões deste dispositivo seja desprezível em relação ao mecanismo físico (por exemplo um robô), concentramos todos os sensores em um ponto. Assim, sempre que fizermos referência ao dispositivo com sensores, estaremos utilizando a palavra "*cursor*". A trajetória realizada por ele não representa o caminho a ser executado pelo robô ou outro elemento, mas sim, trata-se de uma "sugestão" a ser seguida.

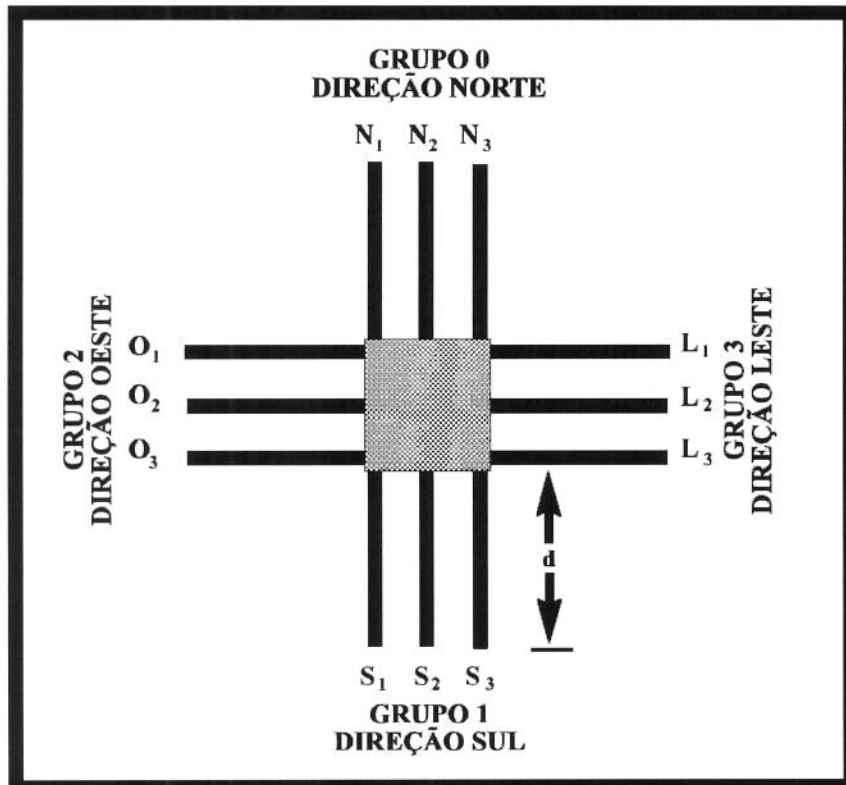


FIGURA SS3. Posição dos sensores no *cursor*.

Acoplado ao mecanismo físico, o *cursor* somente poderá executar movimentos de translação quantizados exclusivamente nas quatro direções: "norte", "sul", "leste" e "oeste", no plano cartesiano. Combinações de direções e alteração de orientação não foram implementadas (reduzindo a estrutura de dados e do software).

Acoplado ao *cursor*, fixamos 12 sensores, agrupados três a três nas direções de movimento. Sua função é fornecer a distância até a próxima colisão (obstáculo). A figura SS3 mostra o cursor, os sensores e as distâncias medidas. Os sensores monitoram a distância até um obstáculo. O *range* máximo é limitado a uma distância " d " paralela à direção do movimento correspondendo a " d " *quantuns* de movimento,

com largura de um *quantun*. A combinação do valor dos sensores fornece subsídios para o sistema que seleciona a direção do movimento. Poderíamos ter utilizado um número maior de sensores, refinando o mapeamento da área de trabalho, mas em função dos tipos de movimentos executados, três sensores por direção são suficientes para fornecer a posição dos obstáculos e orientar as mudanças de direções.

Os valores são ponderados por uma rede tipo perceptron com 12 entradas, 4 saídas e 1 camadas.

A camada de entrada recebe os valores dos sensores e a camada de saída contém os valores ponderados nas direções do movimento. A estrutura da rede é mostrada na figura SS4.




FIGURA SS4. Estrutura da rede ponderadora de direção.

O valor das saídas é calculado diretamente pela ponderação entre as entradas e os pesos sinápticos, aplicando-se uma função de ativação do tipo sigmoide:

$$S_k = f\left(\sum_{i=1}^{12} e_i * \omega_{ik}\right) \quad (S1)$$

onde $k = \{ \text{Norte, Sul, Leste, Oeste} \}$.

A rede foi treinada aplicando a correção direta sobre o erro das saídas:

$$\omega_{ik}(t+1) = \omega_{ik}(t) + \eta * (S_k(t) - S_{k-DESEJADA}) * \omega_{ik}(t) \quad (S2)$$

A escolha por uma rede com uma única camada de neurônios, com um "poder de aprendizado e reconhecimento" muito pequeno, deve-se a três fatores:

-o número de combinações possíveis entre as entradas e as saídas é muito grande, o que exigiria uma rede com um número grande de neurônios e três camadas;

-não necessitamos de uma relação "precisa" entre entradas e saídas, o importante é fornecer algum parâmetro para orientar a escolha da direção, mesmo porque o ambiente é desconhecido e outros fatores também interferem na escolha;

-e reduzir o número de conexões, conseqüentemente o tempo de treinamento.

Assim, escolhemos um conjunto de situações que consideramos limites e realizamos o pré-treinamento, buscando a "inicialização do ambiente e estabilização do valor dos pesos sinápticos" que, como esperado, apresentou um grande *range* de variação a cada treinamento, não convergindo.

A cada ciclo de treinamento verificamos o erro para todas as saídas. Adotamos como critério de parada, não o valor individual das saídas, e sim, o resultado desejado, ou seja, a saída com maior valor (correspondendo, a princípio, à

direção do movimento e que "deverá" ser reforçada). A figura SS5 mostra algumas situações que utilizamos no treinamento preliminar.

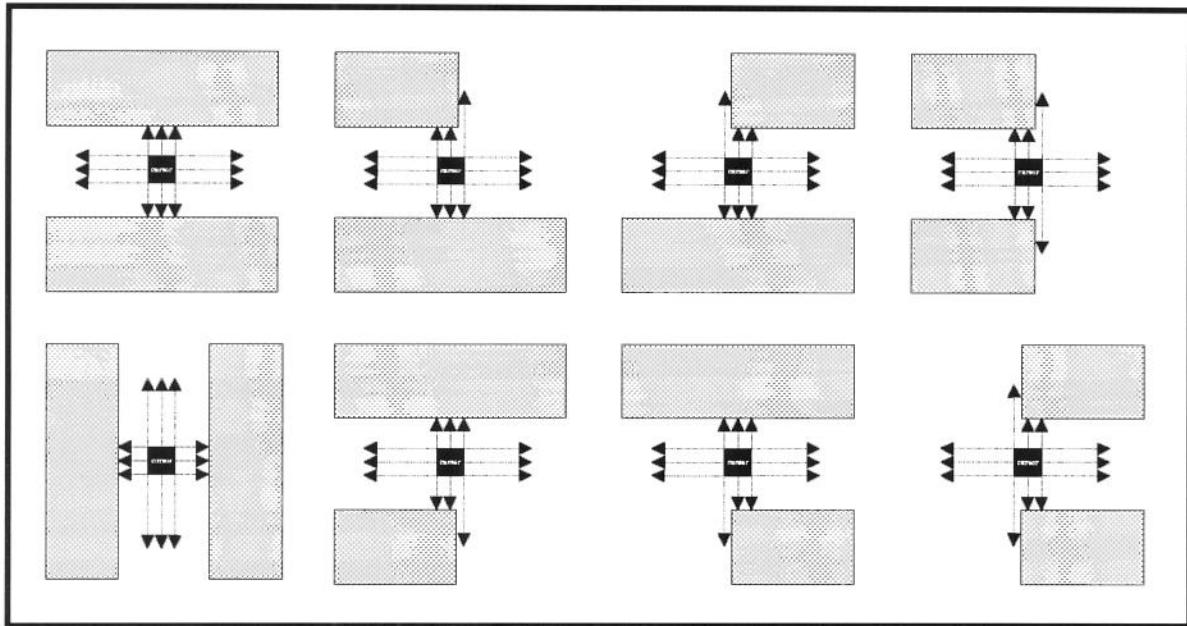


FIGURA SS5. Posições do *cursor* utilizada para o treinamento preliminar da rede.

2.2 MOVIMENTO DO *CURSOR* DURANTE O APRENDIZADO

Durante o processo de aprendizado, o *cursor* executa movimentos pela área de trabalho mantendo a equidistância (equilíbrio de valores) na direção ortogonal à do sentido do movimento. O objetivo é aumentar a área mapeada [CURR-95] [HAN-94] [SCHM-92] [ZAPA-94] pelos sensores. Se o cursor estiver muito próximo de uma das paredes (ou obstáculo) a área mapeada terá diâmetro (a representação mapeada internamente corresponde a uma região circular) da área mapeada máximo igual ao menor valor fornecido pelos sensores nesta direção.




FIGURA SS6. Centralização do *cursor*.

Se em uma das direções não houver obstáculos, a ponderação será executada com o valor máximo dos sensores.

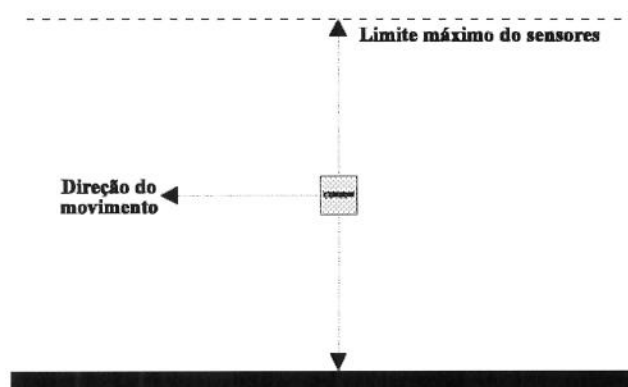


FIGURA SS7. Cursor centralizado obedecendo o limite máximo dos sensores.

O procedimento de centralização foi implementado utilizando-se dois neurônios. Os neurônios da primeira camada ponderam o valor dos sensores em cada sentido. Um sinal de sentido inibe o procedimento de cálculo, pois, o *cursor* executa os movimentos em uma única direção de cada vez. Observe (ver figura SS8) que os pesos sinápticos são fixos (-0.5 e 0.5), executando o cálculo de uma média aritmética. Na segunda camada os neurônios totalizam (*soma*) o valor de saída dos neurônios da primeira camada com o valor das coordenadas cartesianas gerando a nova posição a ser atingida. Esse procedimento é possível, pois os pesos sinápticos são normalizados e o valor dos sensores correspondem a deltas de movimentos em uma única direção.

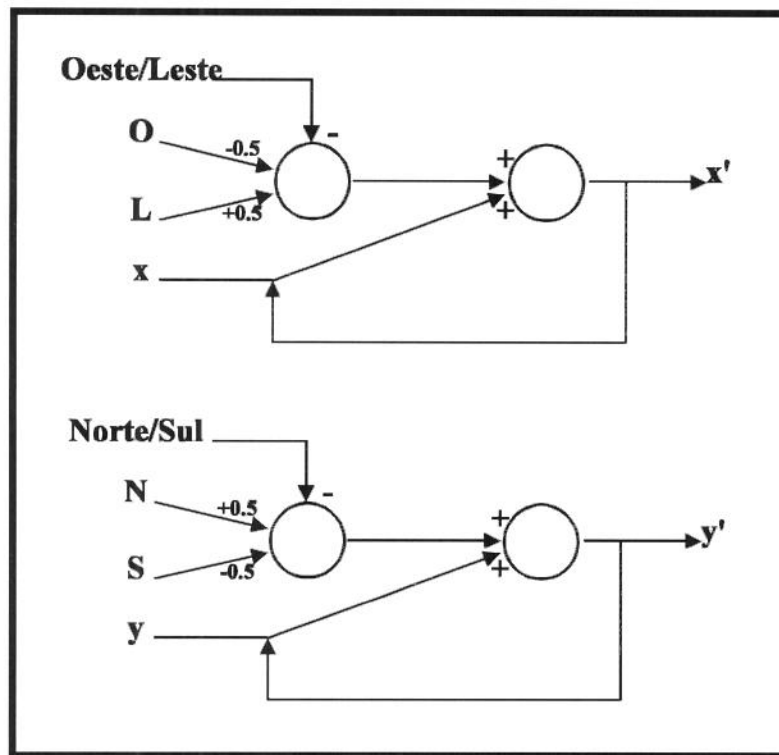


FIGURA SS8. Rede utilizada para centralizar o *cursor*.

2.3 MUDANÇA DE DIREÇÃO DO *CURSOR* DURANTE O APRENDIZADO

A mudança de direção durante o aprendizado ocorre quando ⁽¹⁾ a região a ser mapeada já foi identificada por alguma rede, ⁽²⁾ um obstáculo foi encontrado na direção do movimento ou, ⁽³⁾ os sensores, no sentido ortogonal ao do movimento, acusaram troca de valores (necessitando re-centralizar o cursor). Nesta último caso, como o *cursor* deve manter a equidistância, a alteração no valor medido pelos sensores atua como indicador de que deve-se buscar um novo ponto de equilíbrio ou verificar a necessidade de mudança de direção (por exemplo, se na direção ortogonal à do movimento existir uma abertura).

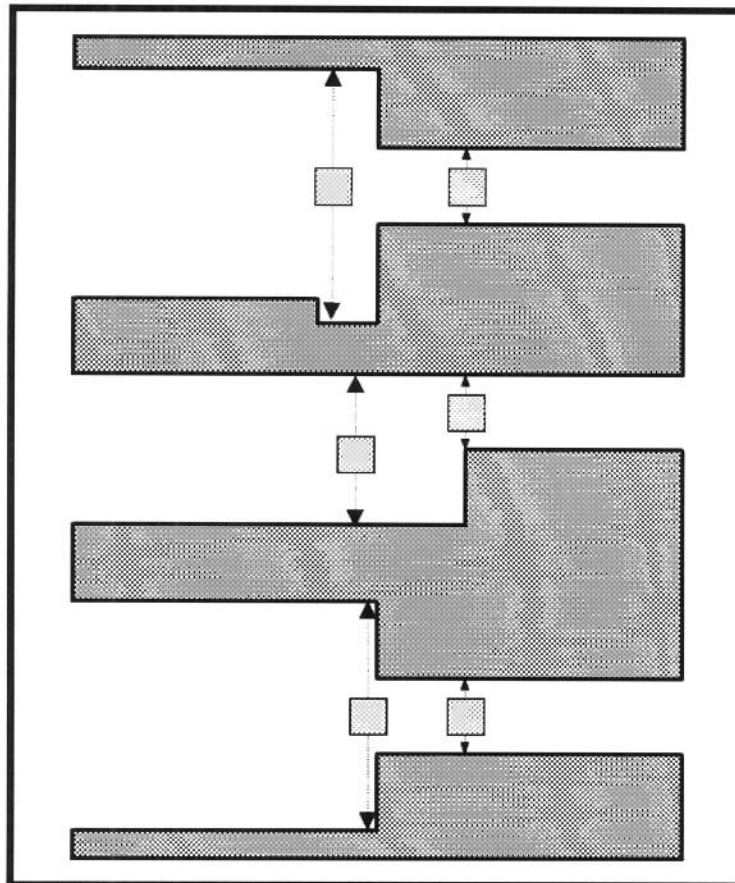


FIGURA SS9. Exemplo de situações que conduzem ao ajuste de posição do *cursor*.

Para qualquer opção, o *cursor* deve ajustar as distâncias, se o sentido do movimento não for alterado, basta equalizar os valores, caso contrário, antes de executar a equalização, o *cursor* deve deslocar-se até encontrar uma nova "referência", e então, reinicializar os procedimentos de ajuste. A busca por uma "referência" consiste em identificar as "novas bordas a serem seguidas", delimitando o novo *range* dos sensores. No exemplo da figura SS10, o *cursor* executava um movimento para o oeste, a alteração do valor dos sensores na direção ortogonal (Sul) ativou o sistema para a seleção de uma nova direção, no caso, a direção Sul, e então, deslocou-se nesta direção, equalizou as distâncias das paredes e reinicializou o movimento.




FIGURA SS10. Sequência para a mudança de direção e reposicionamento do *cursor*.

2.4 SELEÇÃO DE UMA NOVA DIREÇÃO DE MOVIMENTO DURANTE O APRENDIZADO

Durante o processo de aprendizado, a direção do movimento é selecionada por dois conjuntos de neurônios acoplados sequencialmente. Os neurônios do 1º grupo recebem sinais de outros sub-sistemas responsáveis pela seleção da direção principal do movimento, sensores e sinais de retro-alimentação das portas de saída. Os valores de entrada são ponderados com valores pré-definidos das conexões sinápticas, e então, totalizados no *soma*. A cada ciclo de cálculo, o *soma* sofre um decremento inversamente proporcional ao seu potencial de ativação:

$$SOMA(t+1)_d = \omega_{1,d} * \mu(t)_d + \omega_{2,d} * DP(t+1)_d + \omega_{3,d} * S(t+1)_d - \omega_{4,d} * SOMA(t)_d \quad (S1)$$

- onde $S(t+1)_d$: é o valor ponderado dos sensores na direção d , no instante $t+1$;
 $DP(t+1)_d$: valor da direção preferencial de movimento na direção d , no instante $t+1$;
 $\mu(t)_d$: valor de disparo da rede perceptron na direção d , no instante t ;
 $SOMA(t)_d$: valor do *soma* do neurônio da primeira camada na direção d , no instante t ;
 $\omega_{j,d}$: peso da j -ésima conexão sináptica, na direção d .

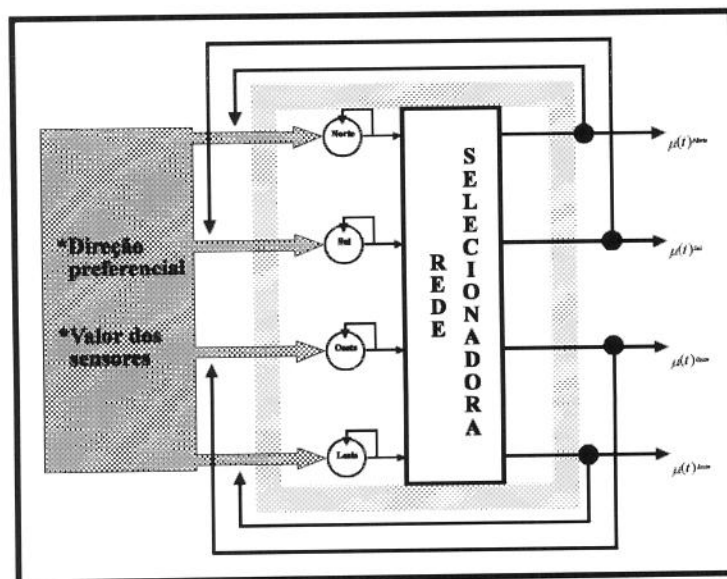


FIGURA SS11. Rede para seleção de direção.

O valor do potencial de disparo é proporcional ao valor do *soma*. Os pesos sinápticos ($\omega_{j,d}$) são previamente "calibrados" permanecendo constante durante o processo de aprendizagem. Não utilizamos nenhum critério específico para setar os pesos sinápticos, simplesmente observamos o comportamento de *cursor* em várias configurações da área de trabalho e concluímos que o fator preponderante para orientar o movimentos era o valor dos sensores (possuem pesos sinápticos maiores). No entanto, sem critérios mais consistentes de seleção, em certas situações (principalmente em áreas concavas), o *cursor* deslocava-se aleatoriamente, assim, agregamos outros dois critérios: a direção preferencial e a direção corrente de movimento, esta última com menor peso sináptico.

Para evitar a saturação do *soma*, introduzimos um fator de esquecimento proporcional ao valor do *soma*. Como resultado, o movimento do cursor não sofre mudanças bruscas de direção e quando se faz necessária, o seu comportamento é o de manter a direção corrente de movimento, como uma "inércia" impedindo a alteração.

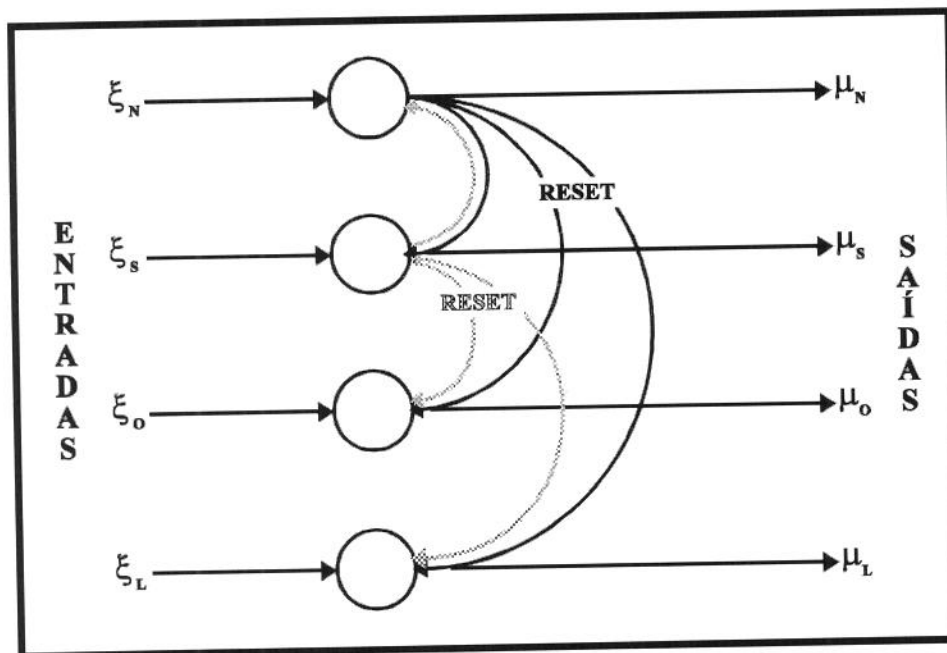


FIGURA SS12. Rede seletora com *threshold*.

Os neurônios do segundo grupo formam uma rede de uma camada. Sua função é selecionar o neurônio com o maior *soma* (ou o que disparar primeiro). Os neurônios, cada qual representando uma direção, recebem sinais do primeiro grupo e

sinais dos neurônios vizinhos. As interconexões tem caráter inibitório, *resetando* o valor do *soma* dos neurônios que não dispararam. No *soma*, a dinâmica é a seguinte:

$$SOMA(t+1)_d = SOMA(t)_d + \alpha_1 * \xi_d - \alpha_2 * \beta_d - \alpha_3 * \sum_{k=N,S,O,L(k \neq d)} RESET_k \quad (S5)$$

onde $\alpha_1, \alpha_2, \alpha_3$ são constantes atenuadoras;
 $SOMA(t)_d$ valor do *soma* neuronal no instante t para a direção d;
 ξ_d valor da entrada na direção d;
 β_d fator de esquecimento. $\beta = e^{-|+|SOMA(t)_d|}$
 $RESET_d$ sinal inibidor na direção d. Vale 0 (saída não disparada) ou 1 (saída ativada).

A função de ativação é do tipo *threshold*:

$$s(t)_d = f(SOMA(t)_d) = \begin{cases} 0 \rightarrow SOMA(t)_d \leq \mathcal{G} \\ 1 \rightarrow \text{caso contrário} \end{cases} \quad (S6)$$

O potencial mínimo de disparo é auto ajustado, pois, pode ocorrer que em algum instante a ponderação de valores nas direções não atinja o valor mínimo de disparo (\mathcal{G}), parализando o movimento do cursor e o sistema não terá parâmetro para selecionar uma direção. Então, o valor do *threshold* é ajustado segundo a equação:

$$\mathcal{G} = \begin{cases} \text{valor mínimo se disparado} \\ \mathcal{G} - \frac{1}{1 + |SOMA(t)_d|} \end{cases} \quad (S7)$$

3. A ESTRUTURA NEURAL PARA O APRENDIZADO

O aprendizado tem por objetivo permitir a "navegação" do mecanismo físico, auxiliada pelo *cursor*, em um ambiente que a princípio é desconhecido, de forma segura e "determinística". Dividimos o procedimento de aprendizado em 4 fases:

- I- identificação do meio,
- II- gerar pequenas rotas,
- III- seqüenciar essas rotas formando macro rotas e
- IV- verificar "vias expressas".

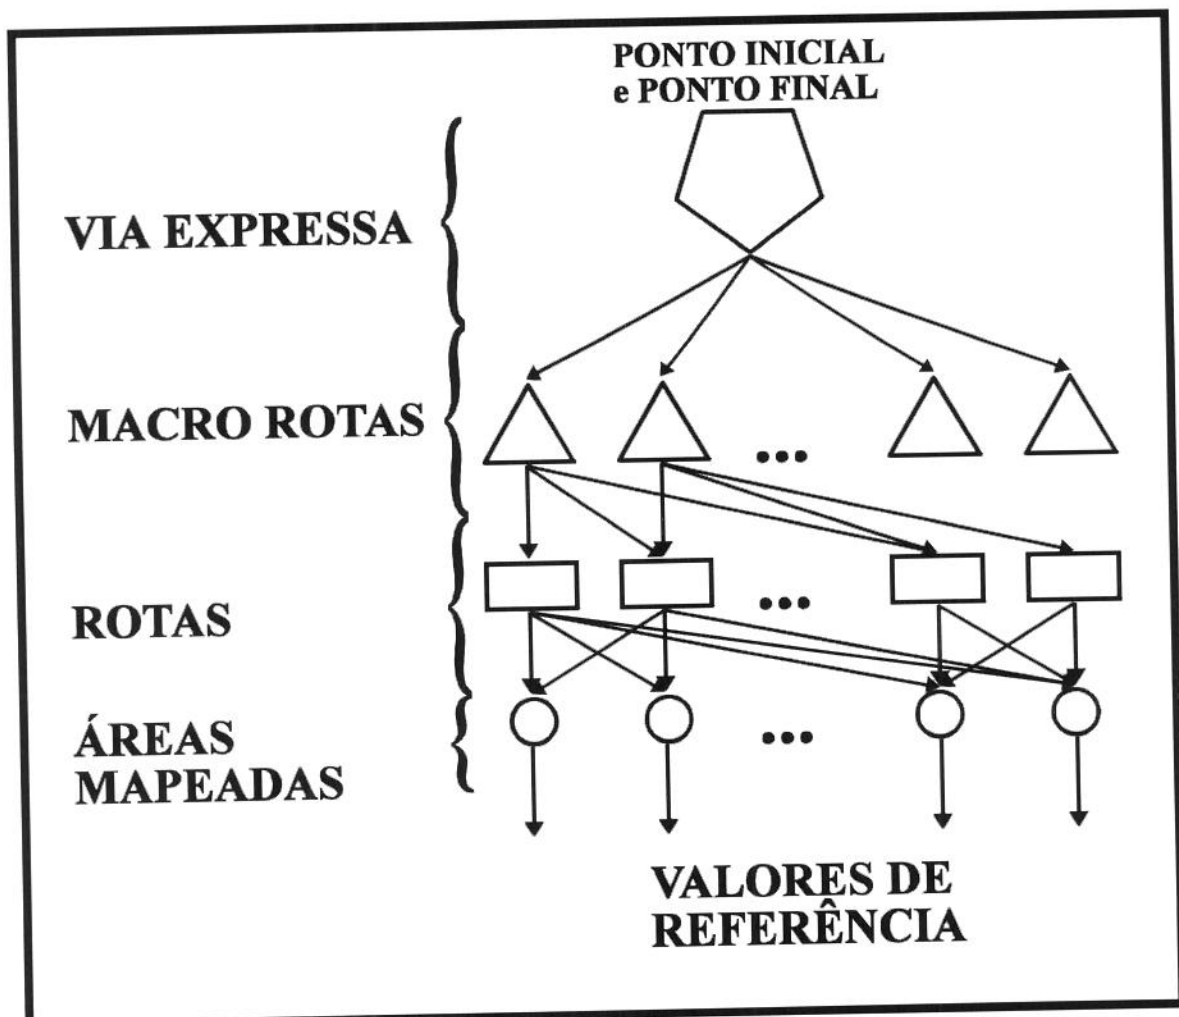


FIGURA SS13. Estrutura de aprendizado.

A primeira fase consiste na identificação dos obstáculos imediatos na vizinhança do *cursor*. O sistema utiliza as informações provenientes dos sensores para "mapear (internamente) uma região circular". O diâmetro dessa região dependerá dos valores dos sensores, sendo considerada a menor área.




FIGURA SS14. Diâmetro da área mapeada é o menor valor ponderado pelos sensores.

Como o *cursor* deve manter uma equidistância dos obstáculos no sentido ortogonal à direção do movimento, o menor valor ponderado dos sensores define o diâmetro da área. A figura SS14 mostra o *cursor*, o valor medido pelos sensores e a área mapeada pelo sistema. Assim, qualquer coordenada (X,Y), dentro da área sombreada disparará um ou um grupo de neurônios, permitindo uma tomada de decisão.

A função de ativação utiliza como base a equação do círculo:

$$(x - x_0)^2 + (y - y_0)^2 = r^2 \quad (S7)$$

A região interna ao círculo representa a área mapeada (aprendida) pelo sistema. Essa região pode ser representada pela inequação da equação anterior:

$$(x - x_0)^2 + (y - y_0)^2 \leq r^2 \quad (S8)$$

ou então:

$$x^2 + y^2 + \omega_1 * x + \omega_2 * y + \omega_3 \leq 0 \quad (S9)$$




FIGURA SS15. Região mapeada.

onde $\omega_1 = -2 * X_0$
 $\omega_2 = -2 * Y_0$
 $\omega_3 = X_0^2 + Y_0^2 - r^2$

representam os pesos sinápticos.

Mapear uma área de trabalho com regiões circulares torna a estrutura do sistema muito simples, contudo, um tanto "frágil". Uma série de obstáculos não serão mapeados ou produzirão erros de interpretação (falsos verdadeiros). Tomemos como exemplos as situações indicadas na figura SS16.




FIGURA SS16. Regiões que podem induzir a erros de mapeamento.

Na figura SS16(a), a região sombreada engloba parte do obstáculo e na figura SS16(b), uma região sem obstáculos (área sombreada) não será reconhecida pelo sistema. Estudamos outras formas para o mapeamento: retângulos, elipses e triângulos, mas cada uma possui suas particularidades. Cada uma dependendo da resolução proposta e do número de sensores.

A segunda fase do aprendizado consiste em sequenciar as regiões mapeadas, formando cadeias de rotas. A figura SS17 mostra 3 regiões com centros P_1 , P_2 e P_3 mapeadas sequencialmente pelo *cursor*. Essas regiões serão mapeadas sequencialmente formando duas cadeias:

$$P_1 \rightarrow P_2 \rightarrow P_3$$

$$P_3 \rightarrow P_2 \rightarrow P_1$$

de tal forma que, um ponto P mapeado pela região P_1 , fará com que um (ou mais) neurônios sejam ativados e disparem apontando o próximo ponto a ser atingido, no caso P_2 . Se o ponto P for mapeado pela região P_2 , então, as duas sequências serão disparadas uma apontando para a região P_3 e outra apontando para a região P_1 .




FIGURA SS17. Sequenciamento de uma rota.

Uma vez identificada a próxima região a ser atingida, o *cursor* executará o movimento tendo como atingir o ponto P que define esta região, mas, ao penetrar na região alvo, um grupo neuronal disparará setando um novo ponto objetivo, e assim por diante, até que o alvo final seja atingido. A figura SS18 contém um exemplo. O ponto P (figura SS18(a)) ativa os neurônios que mapeam a região P_1 , setando como alvo o ponto P_2 . Ao atingir a região mapeada por P_2 , o ponto objetivo muda, passando a ser o ponto P_3 .




FIGURA SS18. Movimento do *cursor* seguindo uma rota mapeada.

As cadeias são formadas durante o mapeamento das áreas circulares, sendo composta por dois grupos de neurônios, o que permite ao sistema identificar movimentos nos dois sentidos. As cadeias têm existência própria, podendo sofrer intersecções, ou seja, mapeando redundantemente uma mesma área. A área mapeada por uma cadeia é restrita, podendo atingir até 12 regiões. Poderíamos aumentar ou diminuir esse valor, no entanto, um número muito grande implicaria em desperdício quando as rotas forem curtas, pois, nem todos os elementos neuronais de

mapeamento serão utilizados e as rotas são independentes, inclusive à nível de estrutura. A formação de caminhos complexos depende de um nível superior: as macro rotas.




FIGURA SS19. Exemplo de rotas encadeadas.

A terceira fase do aprendizado é a formação de macro rotas. As cadeias formam rotas com amplitude (na área de trabalho) muito restrita e a capacidade de sequenciamento é pequena. A macro rota é uma sequência de rotas (sequência de cadeias), ou seja, é uma cadeia de cadeias com o objetivo de gerar um "caminho conhecido para o deslocamento do *cursor*."

As macro rotas são formadas a partir das necessidades do sistema, ou seja, quando o *cursor* precisa deslocar de um ponto P_i até um ponto P_f (mapeados por neurônios ou grupos de neurônios) com caminho desconhecido (as rotas já são conhecidas). O aprendizado de uma macro rota consiste em uma busca neuronal. O processo tem início com a ativação dos neurônios que mapeiam o ponto final a ser atingido: P_f . A seguir, a partir do ponto inicial, cada neurônio setado ativa o subsequente das cadeias, e assim, sucessivamente até atingir um único neurônio

setado pelo ponto P_f . Essa última rota é "congelada" e o processo de busca re-inicializado, a partir de P_i , até que um neurônio dessa rota seja atingido, re-inicializando novamente o processo. A busca termina quando uma das rotas, setadas por P_i , é "congelada". O termo "congelar" significa que a rota fará parte de uma macro rota, ou seja, será parte integrante de um caminho válido. Como resultado final, tem-se uma sequência de rotas capaz de conduzir o cursor de P_i até P_f .

Esse processo de aprendizado é semelhante a uma busca em árvore com a diferença de que todos os caminhos são processados simultaneamente a partir de uma base de informação pré-estruturada neuronalmente.


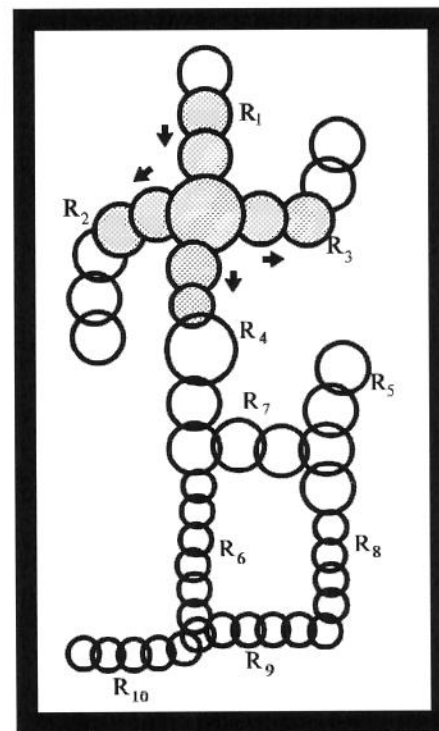
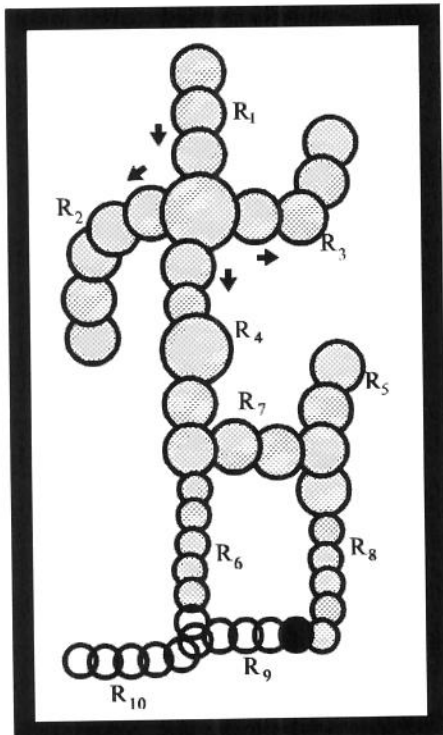


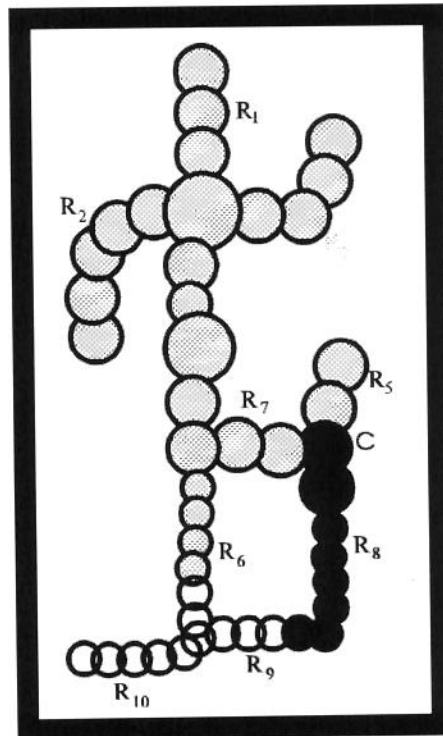
FIGURA SS20. (A) ROTAS APRENDIDAS



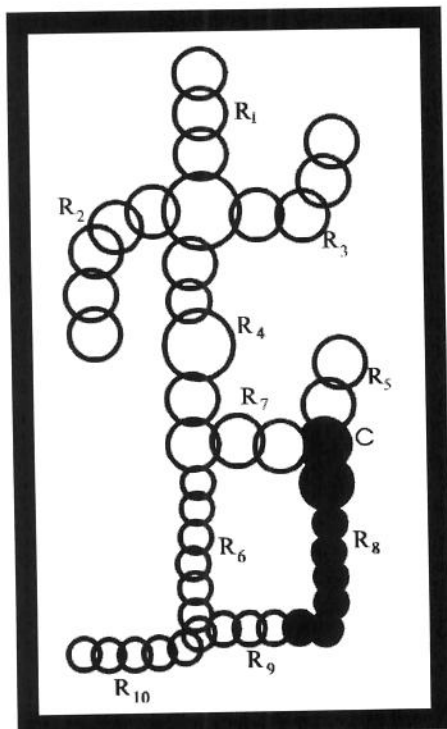
(B) INÍCIO DO PROCESSO DE BUSCA



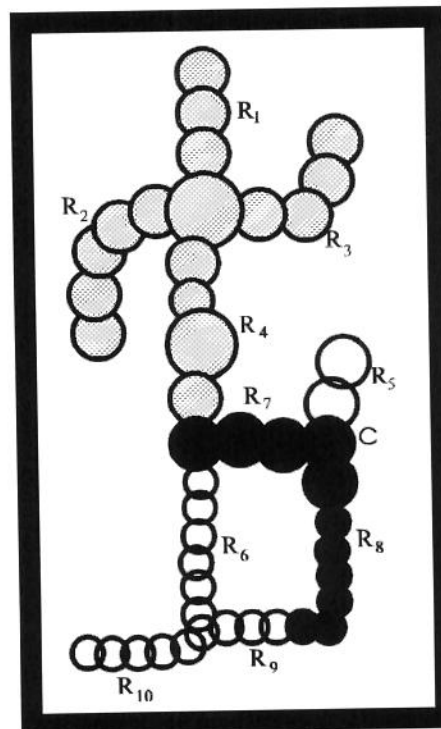
(C) PONTO FINAL ATINGINDO O NEURÔNIO "CONGELADO"




(D) GRUPO DE NEURÔNIOS "CONGELADOS"



(E) NEURÔNIOS SÃO RESETADOS PARA REINICIALIZAR O PROCESSO DE BUSCA



(F) PROCESSO DE CONGELAMENTO CONTINUA



(G) ENCADEAMENTO COMPLETO.

A figura SS20 mostra um exemplo de aprendizado de macro rota. A figura SS20(a) mostra uma sequência de áreas mapeadas e rotas aprendidas. Na figura SS20(b) o processo de busca é inicializado a partir do ponto P_i . O neurônio que mapeia P_f está em negrito indicando que está "congelado". A figura SS20(c) mostra que o neurônio "congelado" foi atingido, disparando o processo de "congelamento" dos neurônios da rota que faz conexão (figura SS20(d)). A figura SS20(e) mostra que todos os neurônios tiveram seu estado *resetado* menos os "congelados". Na figura SS20(f) o processo de busca continua até que um neurônio congelado seja atingido e na figura SS20(g) a sequência de rotas está definida estabelecendo um caminho entre P_i e P_f . Neste exemplo, a macro rota conterá a seguinte sequência de rotas: R_1, R_4, R_7 e R_8 . Durante o processo de aprendizado das

macro rotas, somente o número das rotas são sequenciadas, pois, as áreas mapeadas já estão encadeadas.

A **quarta fase** consiste na verificação das vias expressas. Não é um processo de aprendizado propriamente dito, e sim, uma validação. Dado dois pontos: P_i e P_f , indicando o início e fim de uma trajetória, neste nível, o sistema verificará a existência de uma macro rota (já aprendida) que viabilize o movimento; ou verificará a existência de uma macro rota que ligue os pontos; e ainda se os pontos foram mapeados pelo sistema. Para cada uma das possibilidades um dos "módulos do sistema" será ativado.

4. A ESTRUTURA NEURONAL

O sistema foi implantado com 4 tipos básicos de estrutura neuronal. O elemento mais elementar é o neurônio artificial (E) que agrupados formam a estrutura básica de mapeamento (EM). A união de várias EMs formam um grupo neuronal (GN), que agrupados, formam uma estrutura de macro rota (EMR). Por fim, o agrupamento de várias EMRs definem a estrutura de supervisão (ES), ver figura SS13 (estrutura geral mostrada anteriormente).

O neurônio tem a função de totalizar os valores das entradas ponderados com os respectivos pesos sinápticos e disparar (ou não) um sinal pelo seu canal de saída (axônio). Inspirado no neurônio biológico e utilizado em outras redes neuronais artificiais, o neurônio artificial que estamos adotando é dividido em três partes: dendrito, *soma* e axônio.




FIGURA SS21. Neurônio artificial.

O dendrito é a principal porta de entrada (ξ) dos sinais externos a serem processados no *soma* (em alguns casos o sinal externo é enviado diretamente ao *soma*). Cada um destes sinais sofre uma ponderação (ω) (representando a "impedância" da junção sináptica). No *soma*, o processamento é o seguinte:

$$SOMA(t) = \left(\sum_{i=0}^n \xi_i * \omega_i \right) - \omega_0 \quad (S10)$$

onde $SOMA(t)$: é o valor do *soma* no instante t ;

$\sum_{i=0}^n \xi_i * \omega_i$: é o somatório dos valores das entradas ξ_i ponderado com os pesos sinápticos ω_i .

Para alguns tipos de neurônios acrescentamos outros fatores:

$$\alpha * SOMA(t-1) + \beta * f(SOMA(t-1)) + \gamma \quad , \quad (S11)$$

com o objetivo de manter o estado anterior do neurônio por um período de tempo maior ($\alpha \neq 0$) ou então, introduzir uma fator de esquecimento ($\beta \neq 0$). Por exemplo, na escolha da direção a ser seguida adotamos o seguinte critério: a direção seguida em um instante anterior (t-1) deve ser considerada na seleção da próxima e as direções não *setadas* devem sofrer uma "penalidade" reduzindo o estado de ativação dos neurônios a elas vinculados. Com isso, o sistema torna-se menos sensível a pequenos ruídos (obstáculos pequenos por exemplo). A função f() pode apresentar os mais variados perfis, mas adotamos uma função do tipo exponencial:

$$f(x) = \begin{cases} e^{\frac{1}{|x|}} & \text{para } |x| \geq 1 \\ e^{-|x|} & \text{caso contrário} \end{cases} \quad (S12)$$

Assim, quanto maior o valor do *soma*, menor o "esquecimento" e vice-versa. O fator γ é uma constante residual, um valor "default" do neurônio.

Outra característica que esses fatores incorporam ao sistema é a inércia na mudança de direção, que quando detectada, ocorrerá somente instantes mais tarde. Na figura SS22, o caminho (1), em negrito, é o efetivamente realizado e o caminho (2), pontilhado, é o que "deveria" ser realizado se não houvesse o comportamento inercial. No primeiro caminho, o tempo entre a detecção e a atenuação do valor do *soma* na direção norte é suficiente para desviar o cursor, temporariamente, da trajetória "mais adequada".




FIGURA SS22. Efeito da inércia.

No sistema que estamos propondo, agrupamos vários neurônios em uma estrutura mínima de processamento (ET), capaz de mapear sequencialmente regiões na área de trabalho. A figura SS23 mostra o *layout* desta estrutura.

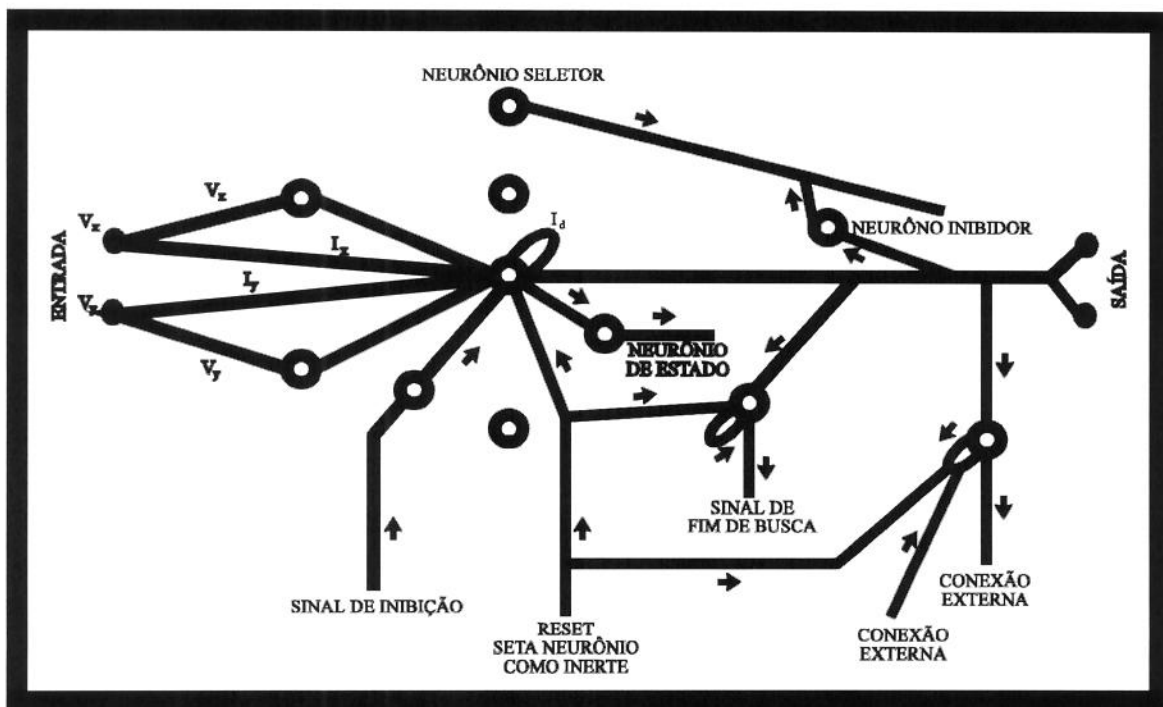


FIGURA SS23. Principal estrutura neuronal (elemento neuronal).

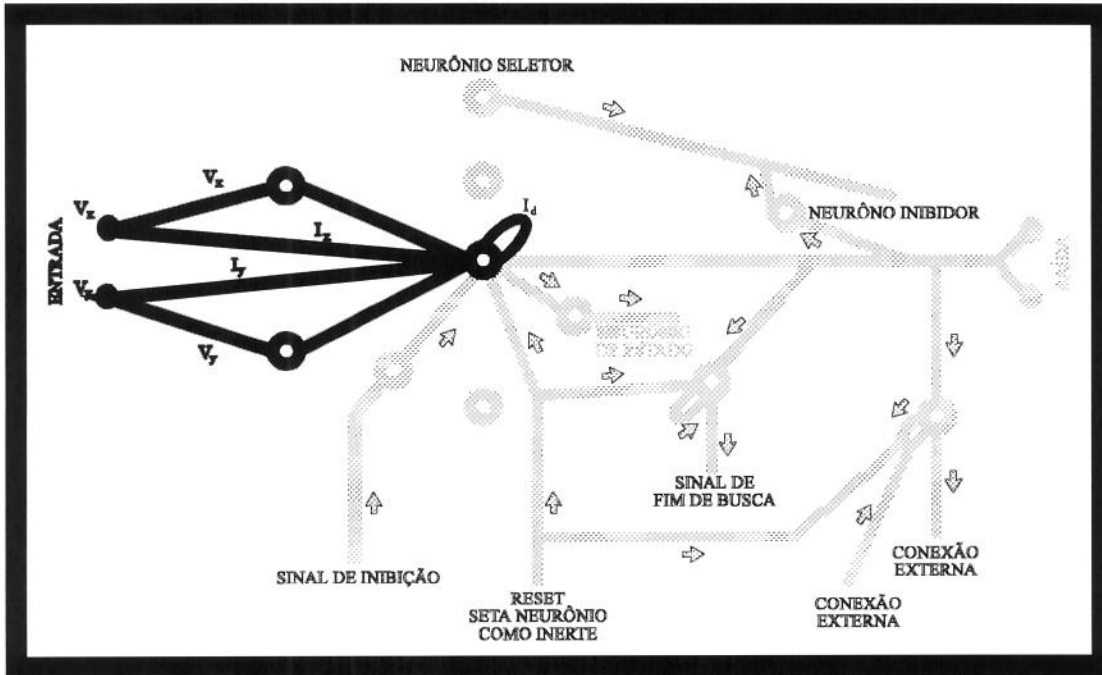


FIGURA SS24. Primeira camada. Três neurônios. A primeira camada recebe estímulos externos por duas vias: X e Y, correspondendo ao valor (V) da posição do *cursor* no sistema cartesiano. Os neurônios (2 neurônios) desta camada tem função potenciadora. Se o estímulo de entrada tem valor V, na placa sináptica do axônio, o valor de saída terá valor $V \cdot V$.

A estrutura principal é composta por 3 neurônios que efetivamente efetuam o mapeamento de uma área de trabalho. Os dois primeiros neurônios têm função potenciadora. Os sinais de entrada (V) atuam na sinapse (ω) gerando como saída o valor quadrado:




FIGURA SS25. Neurônio da primeira camada.




FIGURA SS26. Contribuição dos neurônios da primeira camada no valor do *soma* do neurônio seletor.




FIGURA SS27. V_x e V_y são os valores dos estímulos externos. I_x e I_y são os pesos sinápticos

O terceiro neurônio realiza a *soma* (totalização) dos sinais, como definido pela inequação (S9).

A *soma* ainda sofre a influência de sinais externos: um de inibição e outro de "reset". O sinal de inibição tem por objetivo bloquear o processamento impedindo que duas estruturas de um mesmo grupo efetuem o mapeamento de uma mesma área (inibição colateral) e "congelar" o neurônio durante o aprendizado (busca) de uma macro-rota. Esse sinal atua na junção entre o *soma* e o axônio. O sinal de "reset" força o *soma* a assumir o seu estado "default" ($soma = I_d$), sendo utilizado durante o processo de aprendizado de uma macro-rota.

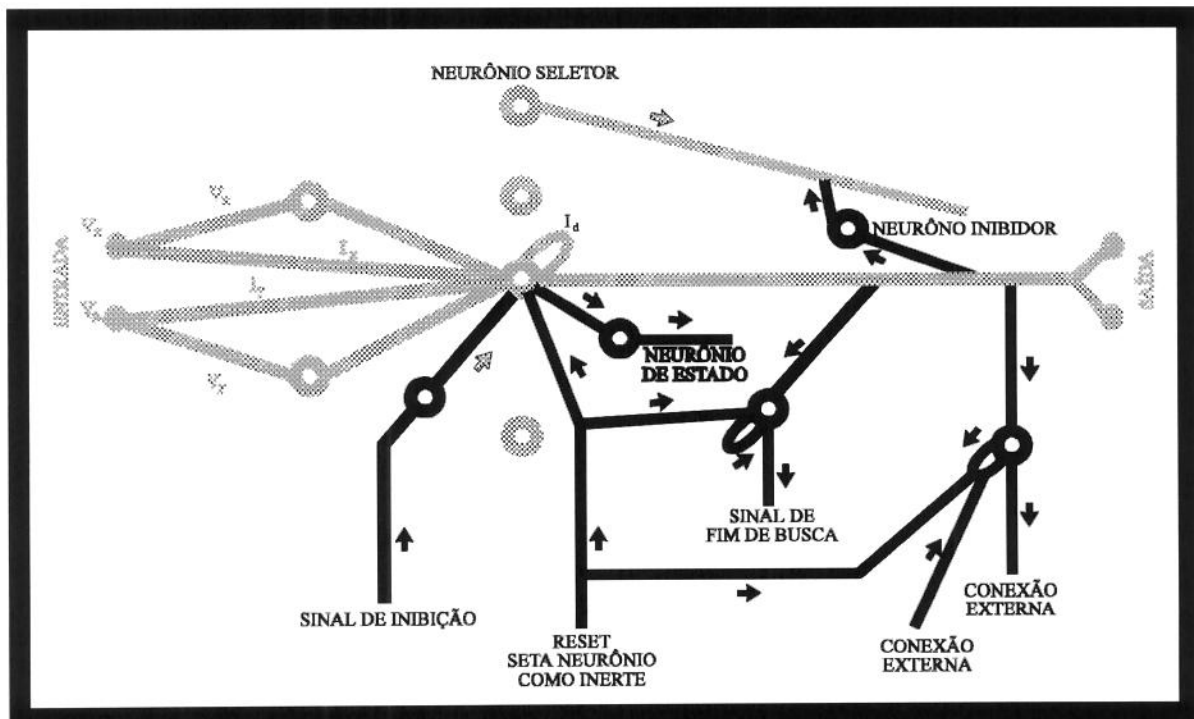


FIGURA SS28. Linhas de "inibição" e "reset".

Assim, o processamento no terceiro neurônio pode ser representado pela equação

$$SOMA = \left((V_x * V_x + V_y * V_y + V_x * I_x + V_y * I_y) * RESET + I_d \right) * INIBIDOR \quad (S13)$$

onde RESET é o valor do sinal de “reset” e INIBIDOR é o valor do sinal de “inibição”. A função de ativação do 3º neurônio é do tipo *threshold*:

$$Se \begin{cases} SOMA \leq 0 & \rightarrow SAÍDA = 1 \\ caso \text{ contrário} & \rightarrow SAÍDA = 0 \end{cases} \quad (S14)$$

ou seja, o axônio conduz um potencial de ação se o potencial do *soma* for negativo (note que se um ponto está no interior de um círculo, a inequação (S9) será negativa). Esse sinal, ao atingir as terminações dispara dois botões sinápticos cujos potenciais são proporcionais à próxima coordenada a ser seguida pelo cursor, ver figura SS29.




FIGURA SS29. Botão sináptico e as duas ramificações do axônio

O sinal do axônio é enviado a outros 4 neurônios (a figura SS28 mostra estas conexões) :

- neurônio inibidor: efetua a inibição colateral com os neurônios do próprio grupo;
- neurônio de estado: informa ao sistema que um neurônio foi *setado*;
- neurônio de fim de busca: informa que o objetivo, em uma busca, foi atingido e
- neurônio de conexão externa: informa ao sistema que esse neurônio faz parte do encadeamento de uma rota.

Os neurônios de fim de busca e conexão externa são auto re-alimentados. Uma vez ativados permanecem neste estado até que sejam *resetados*.

Com essa estrutura é possível mapear uma pequena região circular da área de trabalho.

A união de várias estruturas de mapeamento (EM) formam um grupo neuronal (GN) capaz de representar uma sequência de pontos que definem uma rota. Cada EM mapeia uma região que quando ativada gera um próximo ponto (X,Y) objetivo que é mapeado pela EM subsequente, e assim, por diante. No GN, quando uma EM é ativada, todas as outras são inibidas pelo sinal produzido pelo neurônio inibido. Cada grupo neuronal é composto por 12 estruturas de mapeamentos. O sinal de "*reset*" é comum e é enviado durante o processo de movimento, de busca por uma macro-rota e seleção de uma via expressa. O sinal de conexão externa é individual e utilizado durante o aprendizado de macro-rotas, permitindo avaliar se uma região é mapeada por vários neurônios.

O grupo neuronal recebe um sinal inibitório externo que bloqueia todo processamento.

O aprendizado de uma rota é realizado com o *cursor* em movimento, tendo um ponto de início e um ponto alvo a ser atingido. A primeira região percorrida (a ser mapeada) fornece os parâmetros (ativa um grupo neuronal) para o aprendizado da primeira estrutura de mapeamento. A cada nova região, uma nova EM é treinada (os parâmetros são *setados*), considerando os dados de saída da EM anterior. O processo termina quando 12 EM forem ativadas ou a posição corrente for mapeada por outros neurônios (interseção de rotas) ou o *cursor* entrou em colisão definitiva (ou seja, a única solução para o próximo movimento é retornar pelo caminho já percorrido).

Uma macro-rota é formada pelo encadeamento de várias rotas, ou seja, vários grupos neuronais. O *layout* desta estrutura é mostrado na figura SS30. Os grupos neuronais possuem dois vínculos: o encadeamento sequencial que define as rotas a serem seguidas e o sinal de conexão externa que define quando uma ou outra deve ser ativada.

Mesmo conectadas a outras rotas, a definição de trajetórias mais complexas deve ser realizada pelo encadeamento de rotas conhecidas, pois, existe uma "limitação" estrutural do sistema, que sequencia somente 12 valores de referência por grupo de neurônios. O sequenciamento de rotas pode ser comparado ao aprendizado de cadeias (tipo 3).

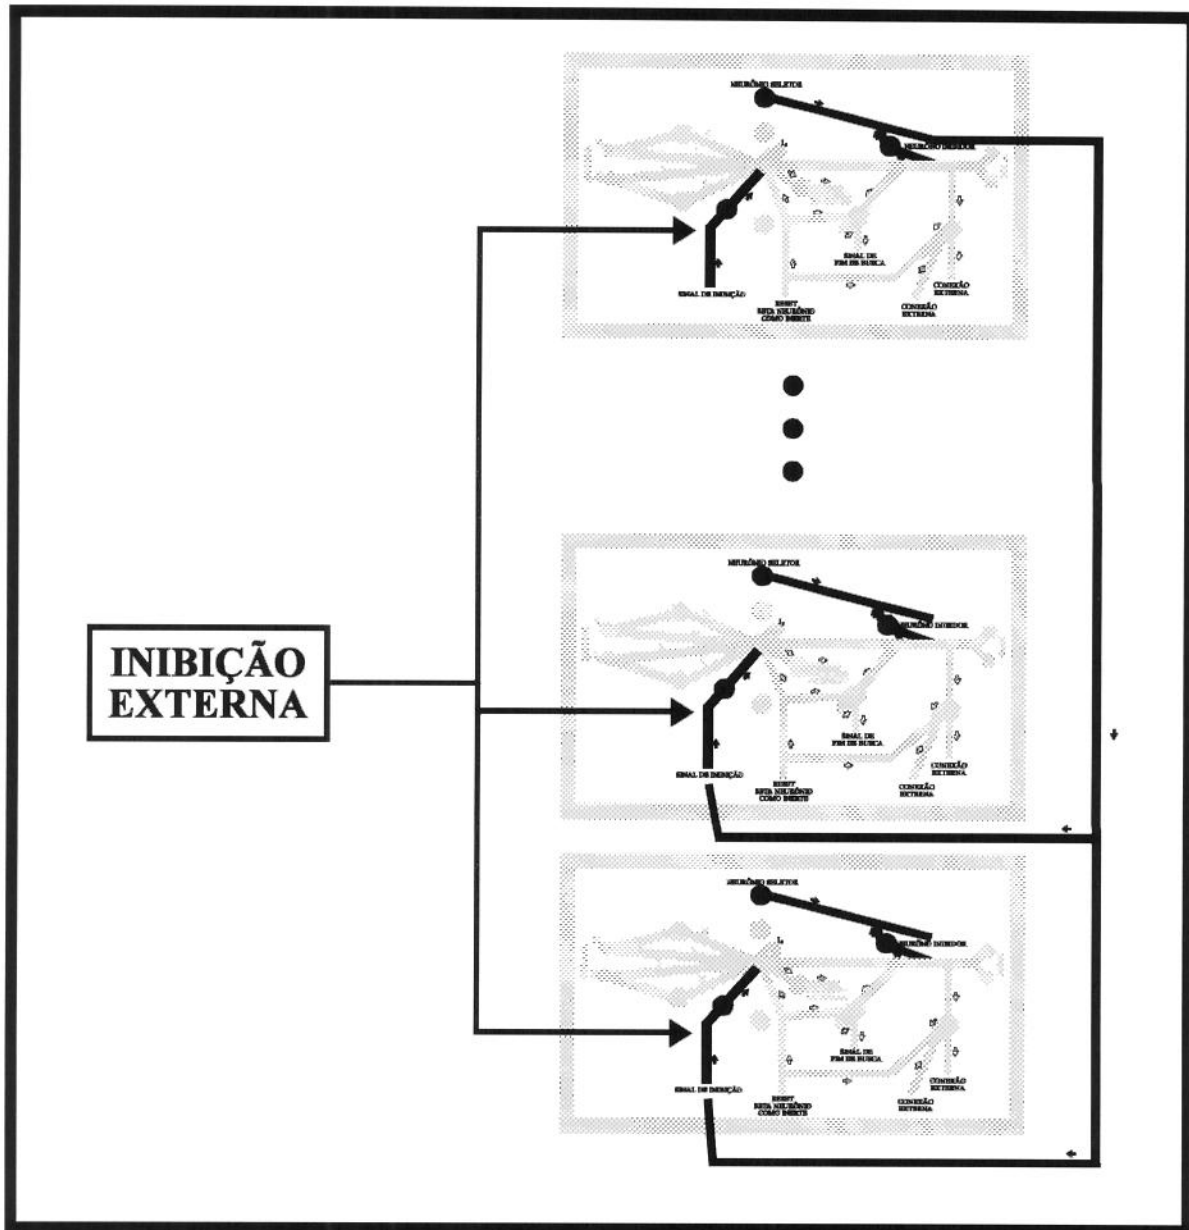


FIGURA SS30. Estrutura do grupo neuronal

O encadeamento é implementado em uma estrutura mais simples que a utilizada no aprendizado de rotas. O layout é mostrado na figura SS31. Uma única camada de neurônios é responsável por esse processo. Uma via aferente, conectada a todos os neurônios, conduz o estímulo externo (número de uma rota) aos neurônios seletores. A conexão é realizada através de uma sinapse pré-definida durante o aprendizado. O neurônio que for ativado produz, como estímulo eferente, o valor da próxima rota a ser seguida, inibindo os neurônios colaterais.

O aprendizado consiste em definir o peso da conexão sináptica aferente, eferente e o limiar de ativação do neurônio seletor. O peso sináptico da via aferente é definido a partir do valor da rota (r) a ser identificada pelo neurônio:

$$\omega_i = \frac{1}{r_i} \tag{S15}$$

onde r é o número da rota (a numeração inicia com o valor 1).

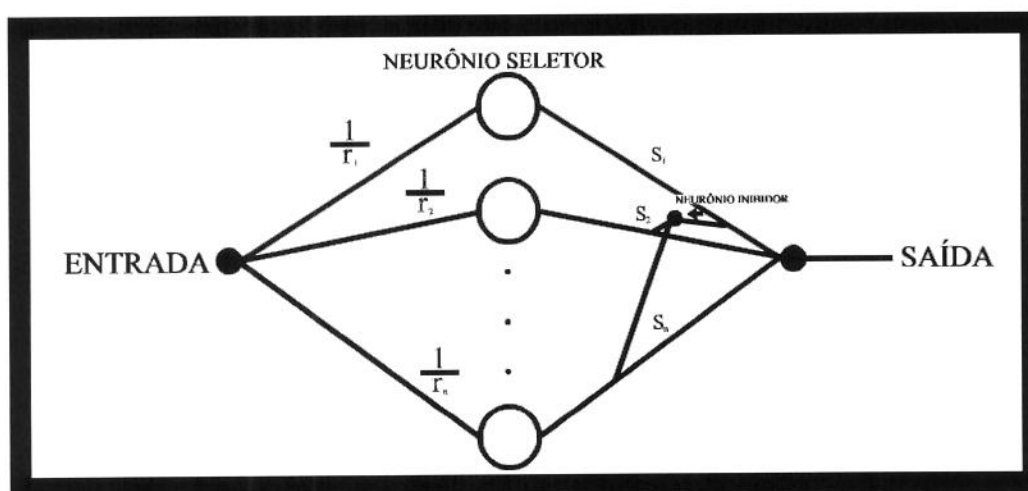


FIGURA SS31. Estrutura para o sequenciamento de rotas (formação de macro rotas).

No *soma* dos neurônios seletores, o processamento é o seguinte:

$$SOMA(t)_i = E * \frac{1}{r_i} \tag{S16}$$

onde o estímulo (E) externo (valor da rota) é aplicado a todas as conexões. Se $E = R_i$, então, o "match" é total e o neurônio pode disparar um estímulo eferente (valor 1). No entanto, o limiar de ativação permite um pequeno ruído no estímulo externo: $E \pm \Delta$ (onde Δ é o limiar). A função de ativação do neurônio é do tipo passa faixa, como indicado na figura SS32.




FIGURA SS32. Função de ativação.

O peso da conexão sináptica na saída do axônio é dada por: $S_i = r_{i+1}$, onde r_{i+1} é o valor da próxima rota a ser ativada. O axônio do neurônio seletor faz sinapse inibitória com todos os outros neurônios. Assim, somente uma única rota pode estar ativa de cada vez.

As estruturas seqüenciadoras de macro-rotas são independentes das rotas. Assim, uma rota pode pertencer a várias macro-rotas.

O último nível da hierarquia do sistema é o *supervisor*. Sua função é ativar os módulos do sistema. A figura SS33 mostra o *layout* deste nível. Como entrada, a estrutura recebe o valor das coordenadas dos pontos inicial e final da trajetória. A saída são valores binários que ativam algum dos níveis (aprendizado ou movimento) do sistema.

O processo de seleção é realizado por uma rede perceptron com 6 entradas, três camadas com 20 neurônios na segunda camada e 3 saídas, treinada pelo método de backpropagation. Essa rede recebe sinais binários de entrada das estruturas de mapeamento, grupos neuronais e macro-rotas, indicando se os pontos de início e fim são conhecidos, se existe ou não alguma rota e macro-rotas que permitam a execução dos movimentos. Dependendo da resposta dos módulos, um conjunto binário de entrada é fornecido e a rede seleciona (ou interpola) uma atitude.

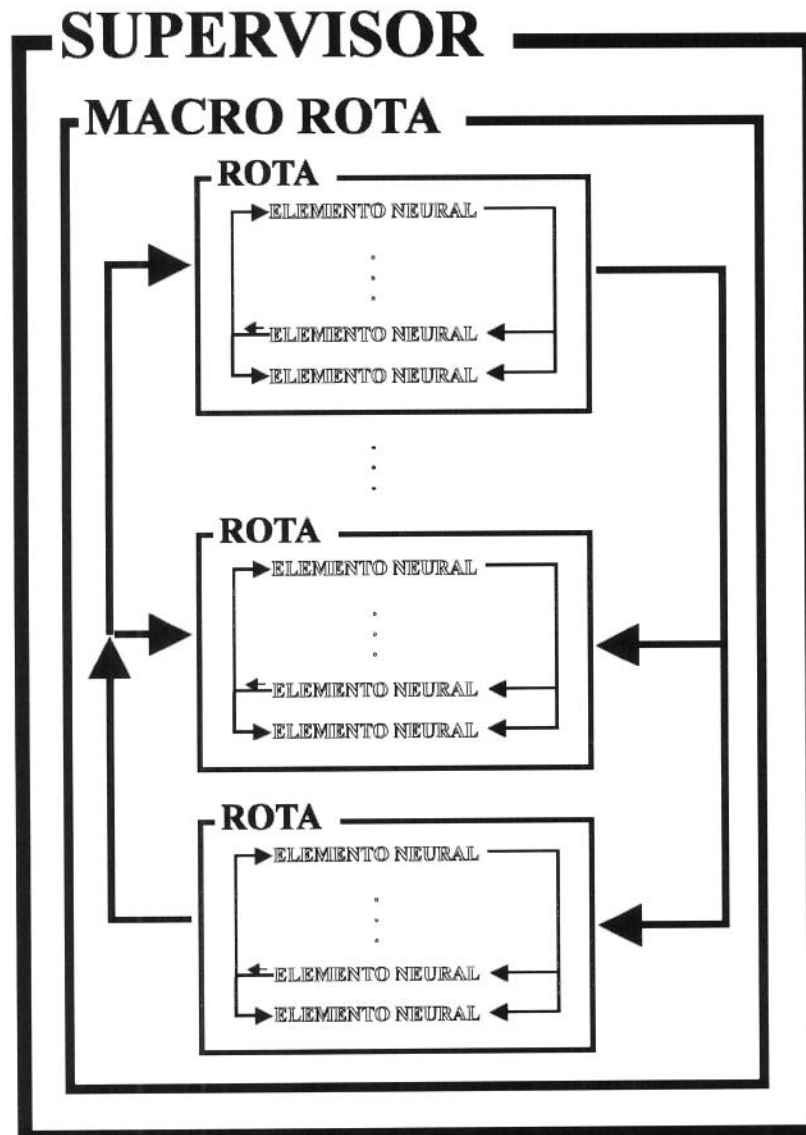


FIGURA SS33. Estrutura geral do sistema. O elemento neuronal é formado pela estrutura neuronal apresentada na figura SS23 e pelas suas interconexões.

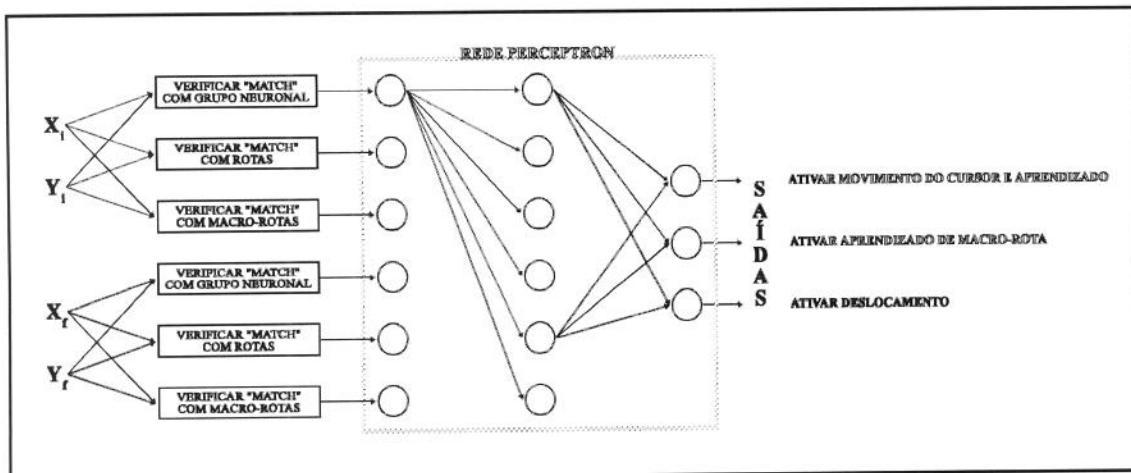


FIGURA SS34. Estrutura selecionadora de atividades

Os dados utilizados para o treinamento desta rede foram formados a partir de um conjunto de entradas válidas associados ao valor de saída desejada (associadas a uma função):

-a saída 1 (ativar movimento do cursor e aprendizado) será ativada se a entradas 1 e/ou a entrada 6 forem zero, ou seja, um dos pontos (inicial ou final) são desconhecidos, conseqüentemente as entradas 2 e 3 e/ou 4 e 5 também recebem o valor zero;

-a saída 2 (ativar o movimento de macro-rotas) será ativada se as entradas 1, 2, 5 e 6 forem *setadas* e 3 e/ou 4 forem zero, ou seja, os pontos inicial e final são mapeados e formam alguma rota. Deve-se levar em consideração que sempre deverá haver alguma conexão entre as rotas, caso contrário, o aprendizado de macro-rotas não será possível;

- e, se todas as entradas forem *setadas*, então, a saída 3 será ativada, ou seja, existe uma macro rota que une os pontos inicial e final do movimento a ser executado.

Apesar do processo de aprendizado ser ativado e executado automaticamente, existem algumas situações que conduzem o *cursor* a não executar o mapeamento e a aprendizado das macro-rotas. Por exemplo, um caminho muito estreito, próximo a outros de maior abrangência, provavelmente não será selecionado. A figura SS35 mostra essa situação. O caminho (A) será selecionado, pois, é o que apresenta a menor interferência comparado com os caminhos (B) e (C).




FIGURA SS35. Seleção de caminhos para retreinamento.

Assim, se o cursor não for conduzido novamente até o ponto (D) e o processo de aprendizado ativado, os caminhos (B) e (C) não serão mapeados. Por outro lado, sempre existe alguma localização que não será mapeada devido a resolução dos sensores.

CAPÍTULO V

SIMULAÇÕES

1. INTRODUÇÃO

Neste capítulo apresentaremos algumas simulações mostrando o comportamento do sistema na identificação do ambiente, geração de rotas, macro rotas e trafegando pela área de trabalho. O sistema foi implementado na linguagem C++ e as simulações realizadas em um computador 486DX 50MHz com 4MBytes de memória RAM e 256KBytes de cache.

Procuramos identificar algumas configurações de áreas de trabalhos. Na figura S1 apresentamos aquelas que julgamos serem as mais comuns:

- (A) região livre de obstáculos,
- (B) região com obstáculos,
- (C) região com grande entrada (saída),
- (D) região com entrada (saída) restrita,
- (E) região côncava e
- (F) região com a forma de um zigue-zague.

Certamente existem outras configurações, por exemplo, um labirinto com múltiplas entradas (saídas e forma de espiral. Por outro lado, a presença de elementos móveis pode remodelar (desestruturando a imagem mapeada pelo sistema) o ambiente, conferindo-lhe as mais variadas formas.




FIGURA S1. *Layout* da área de trabalho que utilizaremos nas simulações.

2. SIMULAÇÕES

Primeiro posicionaremos o *cursor* em uma área restrita, ponto (P_i), e ativaremos o processo de aprendizado. O ponto de fim de trajetória, que define a direção principal de movimento, é indicado pelo ponto (P_f). A primeira direção que orientará o movimento será a oeste; poderíamos adotar outra qualquer, pois a área é fechada, no entanto, o gasto neuronal será maior devido as possíveis colisões com as paredes. A figura S2 mostra as áreas mapeadas pelo *cursor* (áreas circulares). A figura também mostra detalhes de algumas regiões que não foram mapeada, apesar de serem passíveis de navegação (do ponto de vista do observador externo, mas para o sistema não). Se um ponto fora da área mapeada for *setado*, então, um processo de aprendizado será ativado até que uma "área conhecida" seja atingida.




FIGURA S2. Processo de aprendizado. O ponto (P_i) indica o início e o ponto (P_f) indica o fim de uma trajetória. Uma linha liga estes pontos indicando o menor caminho e a direção preferencial de movimento. Os círculos indicam as áreas mapeadas pelo sistema. As linhas ligando as regiões circulares indicam os caminhos percorridos pelo *cursor* durante o processo de aprendizado.

Uma vez mapeada, esta área pode ser utilizada para movimentos, ver figura S3. Neste ponto, as rotas estão formadas, mas é necessário aprender uma macro-rota, para tanto, *setamos* dois pontos (início e fim de trajetória) e ativamos o processo de aprendizado. Uma vez identificada uma macro rota, o sistema está apto para sugerir uma trajetória em qualquer ponto da área mapeada e pertencente à base de conhecimento de macro-rotas. As figura S3, S4 e S5 mostram algumas simulações. O ponto (P_i) indica início da trajetória e (P_f) indica o fim da trajetória. Observe que a trajetória inclui áreas não mapeadas e é geralmente interrompida pelas paredes da área de trabalho, isso deve-se ao efeito da "inércia" do *cursor*, contudo, sempre que possível o *cursor* desloca-se em direção à área mapeada. No final da trajetória, essas características são mais evidentes; o *cursor* não executa a trajetória mais curta, ultrapassando a linha do ponto final, "prontamente" retornando à direção desejada.




FIGURA S3. Simulação da geração de uma trajetória. Os círculos representam as áreas mapeadas. O caminho mais claro é a trajetória gerada, ligando os pontos P_i e P_f .

Na simulação anterior, uma única macro-rota é capaz de inter-conectar todas as rotas aprendidas, assim, qualquer ponto na área mapeada pode ser facilmente atingido pelo *cursor*.

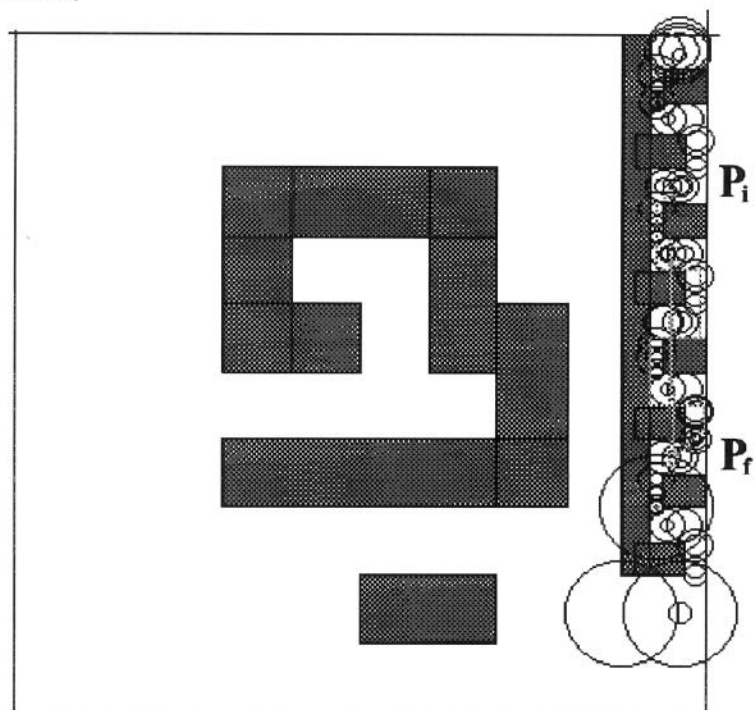


FIGURA S4. Simulação utilizando pontos intermediários de uma macro-rota conhecida.




FIGURA S5. Simulação invertendo a direção do movimento.

Na figura S5 é possível observar o *cursor* mudando de posição buscando a nova direção preferencial (A) não colidindo com a parede e no ponto (B), o *cursor* desviando da parede para atingir o ponto final.




FIGURA S6. Simulação com obstáculos.

Na simulação mostrada na figura S6, acrescentamos um obstáculo, alterando a área de trabalho previamente mapeada (ponto A), mesmo assim, o sistema foi capaz de gerar uma trajetória "contornando" o obstáculo. Na figura S7 aumentamos o obstáculo interrompendo uma área maior, e o sistema foi capaz de gerar uma trajetória.

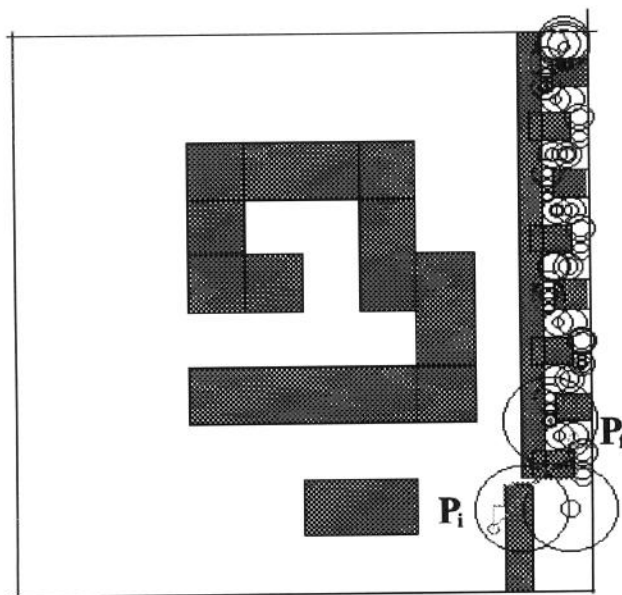


FIGURA S7. Simulação com obstáculo.

A qualquer instante é possível reinicializar o treinamento, mapeando novas áreas. A figura S8 mostra o treinamento re-inicializado. Observe o alto grau de redundância das áreas mapeadas.




FIGURA S8. Re-treinamento.

A figura S9 contém outro exemplo de navegação ligando duas áreas, côncavas, aprendidas em instantes diferentes. Note que nos pontos (A) e (B), o *cursor* desviou da rota "mais curta", no entanto o que ocorreu foi a busca por pontos intermediários da trajetória mapeada e um pouco do efeito de "inércia".




FIGURA S9. Simulação ligando duas áreas pré-treinadas.

Para finalizar, posicionamos o *cursor* em uma região não mapeada pelo sistema, mas o suficientemente perto para permitir encontrar uma macro-rota e seguir uma trajetória, ver figura S10.

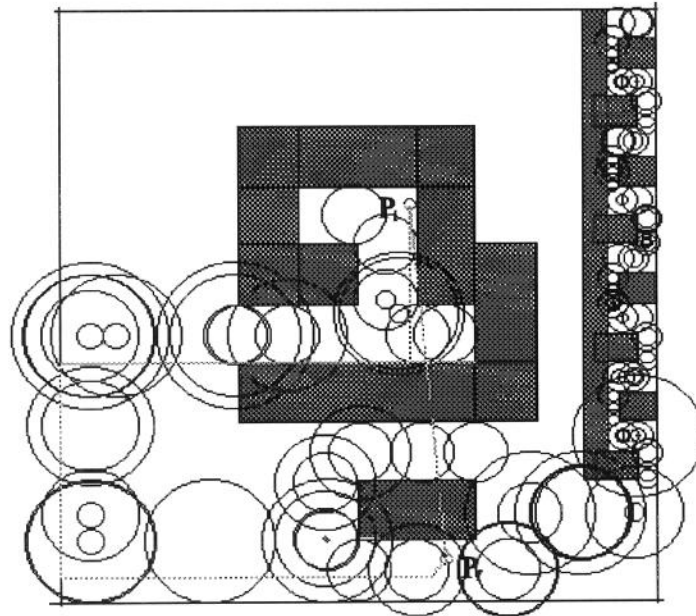


FIGURA S10. Simulação a partir de um ponto não mapeado pelo sistema. Ao atingir uma macro-rota conhecida, o *cursor* passa a seguir as rotas que fazem parte da sua cadeia.

Na figura S11 posicionamos o *cursor* em outro ponto, afastado de uma região mapeada e não ativamos o processo de treinamento, deixando que o sistema "encontre" um caminho, o que não ocorreu automaticamente.




FIGURA S11. Simulação a partir de um ponto não mapeado pelo sistema.

No ponto (A), o *cursor* identificou uma macro-rota errada, devido ao nível de redundância do mapeamento. O processo de busca foi ativado e o *cursor* conduzido para um ponto "conhecido" (B) pelo instrutor (como um ponto de referência) e então o processo de busca por uma macro-rota foi ativado, o sistema identificou uma macro-rota e executou o movimento. O ponto (C) foi atingido devido a inércia, mas prontamente corrigido.

CAPÍTULO VI

CONCLUSÃO

Planejar o deslocamento de um mecanismo por uma área de trabalho é uma tarefa que envolve um grande número de procedimentos, por exemplo gerar uma trajetória, seqüenciar as atividades a serem executadas, gerenciar os movimentos de cada um dos efetuadores e sincronizar as atividades com outros mecanismos. Esses procedimentos são implementados utilizando-se as mais variadas técnicas, geralmente pertencentes às áreas de controle, otimização e inteligência artificial.

Nesta tese abordamos o problema da geração de movimentos voluntários, a partir da trajetória a ser realizada por um mecanismo em um ambiente desestruturado. A nossa principal contribuição é um modelo conexionista, baseado em estruturas neuronais artificiais, para o mapeamento de uma área de trabalho, formação de rotas e a geração de pontos de referências que podem auxiliar na implementação de caminhos por ambientes desestruturados. Entendemos como desestruturada toda a área de trabalho cuja estrutura física e seus elementos agregados são desconhecidos do sistema que gerenciará os movimentos do mecanismo físico.

A maioria dos seres humanos, quando se encontra em um ambiente desconhecido, efetua o reconhecimento da área. Assim, a primeira atividade de um sistema que atuará neste ambiente deverá ser a de reconhecimento. E então, planejar os movimentos. Dependendo dos meios utilizados, essas atividades podem inviabilizar a execução dos movimentos, principalmente por consumirem muito tempo de processamento e geralmente serem implementadas *off-line*.

Neste trabalho propomos uma solução para auxiliar a geração de trajetória em ambientes desestruturados. Embora existam vários métodos matemáticos e numéricos eficientes para a interpolação de trajetórias a partir de pontos de referências, poucas são as citações de como gerar tais pontos para um ambiente desestruturado. Além disso, outras questões devem ser consideradas:

- como mapear a área de trabalho,
- como estruturar as informações coletadas e
- como torná-las úteis para a solução de problemas.

Buscando uma similaridade biológica, procuramos as respostas em três frentes de estudos:

- redes neurais artificiais,
- sistemas biológicos e
- teorias sobre o processo de aprendizado.

No primeiro capítulo estudamos algumas redes neurais artificiais. Concluímos que são capazes de reconhecer e aprender padrões, mas geralmente consomem muito tempo de processamento durante a fase de aprendizado. Contudo apresentam uma característica que nos será útil: processamento altamente distribuído. No segundo capítulo, estudamos os principais circuitos do cerebelo e a funcionalidade de algumas células da região hipocampal. No terceiro capítulo estudamos algumas teorias sobre o processo de aprendizado.

Como resultado destes estudos, estruturamos um sistema neural artificial capaz de auxiliar um mecanismo a navegar por um ambiente desestruturado. Os circuitos cerebelares e as redes neurais artificiais inspiraram-nos no projeto da estrutura neuronal. A funcionalidade de algumas células da região hipocampal forneceram-nos os subsídios para a implementação do mapeamento de regiões da área de trabalho.

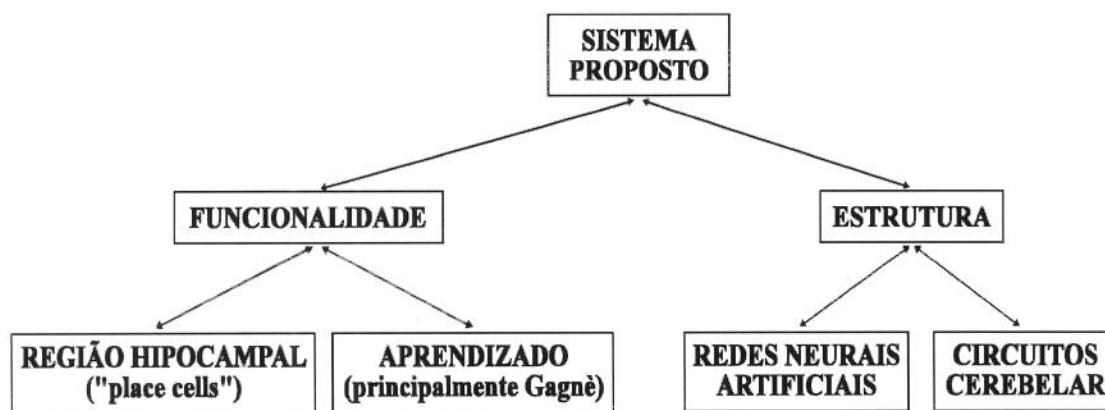


FIGURA C1. Estrutura geral do sistema.

Os estudos as teorias do aprendizado forneceram-nos os elementos necessários para a organização das informações sensoriais no sistema e a sua utilização. Enfim, é essa a nossa principal contribuição, um sistema neural artificial

conexionista capaz de auxiliar a geração de movimentos voluntários em um ambiente desestruturado, cuja estrutura está apresentada na figura C1.

As simulações que apresentamos no capítulo V mostram o desempenho satisfatório do sistema, mapeando a área de trabalho, formando rotas e auxiliando na geração de trajetória. Contudo, a não utilização de elementos externos como as faixas, sinalizadores e pontos de referência, o alto grau de redundância no mapeamento que pode induzir o sistema a tomar decisões "equivocadas", a existência de regiões desconhecidas (e sem obstáculos) nas proximidades das regiões mapeadas, às incertezas (ruídos) na área de trabalho (muitos obstáculos móveis) e a formação de macro-rotas muito extensas interceptadas por rotas não seqüenciadas pelo sistema podem desestabilizar o sistema truncando a geração dos pontos de referência. Assim, eventualmente, um "instrutor" (no caso o usuário do sistema), deve interferir no processo de aprendizado, principalmente através de sugestões de direções a serem seguidas e na ativação do processo de aprendizado em uma região de difícil mapeamento. Esses problemas podem ser contornados por sistemas de mais alto nível, supervisionando a geração das rotas e macro-rotas.

O sistema proposto tem uma grande aplicabilidade, principalmente em robótica, mas gostaríamos de ressaltar uma aplicação em bio-engenharia [CLIQ-92a] [CLIQ-92b], com grande apelo social. Como o sistema utiliza um número reduzido de sensores, de sinais de saída e fornece somente 4 direções de movimento, poderíamos aplicá-lo no auxílio ao deslocamento de deficientes visuais através de eletro-estimulação.

Além disso, a aplicação do sistema não se restringe ao auxílio na geração de trajetórias, podemos ser utilizado em outras aplicações, bastando alterar as informações utilizadas no processo de treinamento. Por exemplo, substituindo o mapa da área de trabalho por um mapa de temperatura-pressão e estado físico de uma substância, onde o sistema poderá mapear o comportamento da substância e "navegar" por um estado pré-definido.

CAPÍTULO VII

BIBLIOGRAFIA

- [AGNA-92] Agnati, L. F. ; Bjelke, B. ; Fuxe, K.
"Volume Transmission In The Brain"
American Scientist, Vol. 79, September-October, 1992,
pág. 362-373
- [ALB-71] Albus, J. S.
"A Theory of Cerebellar functions"
Math. Biosci., 10, 1971, pág. 25-61
- [ALB-75a] Albus, J. S.
"A New Approach to Manipulator Control: The Cerebellar Model
Articulation Controlled (CMAC)"
Transactions of The ASME - Journal of Dynamic Systems,
Measurement, and Control, September 1975, pág. 220-227
- [ALB-75b] Albus, J. S.
"Data Storage in The Cerebellar Model Articulation Controller
(CMAC)"
Transactions of The ASME - Journal of Dynamic Systems,
Measurement, and Control, September 1975, pág. 228-233
- [ALLE-74] Allen, G. I. ; Tsukahara, N.
"Cerebrocerebellar Communication System"
Physiol. Rev. 54:957-1006
- [AMAR-83] Amari, Shun-Ichi
"Field Theory of Self-Organizing Neural Nets"
IEEE Transactions on Systems, Man, and Cybernetics,
Vol. SMC-13, Nº 5, September/October 1983, pág. 741-748

- [AMARA-89] Amaral, D. G. ; Witter, M. P.
"The Three-Dimensional Organization of The Hippocampal Formation: A review of Anatomical Data"
Neuroscience, vol. 31, 1989, pág. 571-591
- [AMARA-90a] Amaral, D. G. ; Ishizuka, N. ; Claiborne, B.
"Neurons, Numbers and The Hippocampal Network"
Progress in Brain Research, vol. 83, 1990, pág. 1-11
- [AMARA-90b] Amaral, D. G.
"Is There 'Channelling' Of Information Through The Intrinsic Circuit Of The Rat Hippocampus"
Brain Research Reviews, 16 (1991), pág. 200-202
- [AMIR-92] Amirikian, B. R. ; Lukashin, A. V.
"A Neural Network Learns Trajectory of Motion From The Least Action Principle"
Biological Cybernetics, 66, 1992, pág. 261-264
- [AND-71] Andersen, P. ; Bliss, V. P. ; Skrede, K. K.
"Lamellar Organization of Hippocampal Excitatory Pathways"
Expl. Brain Res. 13, 1971, pág. 222-238
- [AND-90] Andersen, P.
"Synaptic Integration in Hippocampal CA1 Pyramids"
Progress in Brain Research, vol. 83, 1990, pág. 215-222
- [ANDE-89] Anderson, C. W.
"Learning to Control an Inverted Pendulum Using Neural Networks"
IEEE Contrl Systems Magazine, April 1989, pág. 31-37
- [ANDR-83] Anderson, J. A.
"Cognitive and Psychological Computation with Neural Models"
IEEE Transactions on Systems, Man, and Cybernetics,
Vol. SMC-13, Nº 5, September/October 1983, pág. 799-814

- [ANDR-88] Anderson, J. A. ; Rosenfeld, E. ; Editores
 "Neurocomputing Foundations of Research"
 Ed, MIT Press - 1988
- [ANTS-90] Antsaklis, P. J.
 "Neural Networks in Control Systems"
 IEEE Control Systems Magazine, April 1990, pág. 3-5
- [ARBIB-81] Arbib, M. A.
 "Perceptual Structures and Distributed Motor Control"
 In: V. B. Brooks, "Handbook of Physiology", Sect. 1,
 Vol. 11, part2.
 American Physiol. Soc., Bethesda, 1981, pág. 1449-1480
- [BAILE-90] Bailey, D. ; Thompson, D.
 "How to Develop Neural-Network"
 AI Expert, June 1990, pág. 38-47
- [BARN-90] Barnes, C. A. ; McNaughton, B. L. ; Mizumori, S. J. Y. ;
 Leonard, B. W. ; Lin, L. - H.
 "Comparison of Spatial and Temporal Characteristics of Neuronal
 Activity in Sequential Stage of Hippocampal Processing"
 Progress in Brain Research, vol. 83, 1990, pág. 287-300
- [BAVA-88] Bavarian, B.
 "Introduction to Neural Networks for Intelligent Control"
 IEEE Control Systems Magazine, April 1988, pág. 3-7
- [BEAR-91] Bear, M. F.
 "Use Of Developing Visual Cortex As A Model to Study The
 Mechanisms Of Experience-Dependent Synaptic Plasticity"
 Brain Research Reviews, 16 (1991), pág. 198-200

- [BEER-91] Beer, R. D. ; Chiel, H. J. ; Sterling, L. S.
"An Artificial Insect"
American Scientist, Vol. 79, September-October, 1991,
pág. 444-452
- [BHAT-90] Bhat, N. V. ; Minderman Jr., P. A. ; McAvoy, T.; Wang, N. S.
"Modeling Chemical Process Systems Via Neural Computation"
IEEE Control Systems Magazine, April 1990, pág. 24-30
- [BLON-91] Chapeau-Blondeu, F. ; Chauvet, G.
"A Neural Network Model of The Cerebellar Cortex Performing
Dynamic Associations"
Biological Cybernetics, 65, August 1991, pág. 267-279
- [BRAD-89] Brady, M. L. ; Raghavan, R. ; Slawny, J.
"Backpropagation Fails to Separate Where Perceptrons Succeed"
IEEE Transactions on Circuits and Systems, Vol. 36, Nº 5,
May 1989, pág. 665-674
- [BROB-76] Brobeck, J. R.
"As Bases Fisiológicas da Prática Médica"
Ed. Guanabara Koogan - 9ª Edição - 1976
- [BROD-84] Brodal, A.
"Neurological Anatomy In Relation To Clinical Medicine"
Ed. Oxford University Press, Inc. 1984
- [BRUW-90] Bruwer, M. ; Cruse, H.
"A Neural Model for The Control of The Movement of a
Redundant Manipulator"
Biological Cybernetics, 62, 1990, pág. 549-555
- [BUZS-90] Buzsáki, G. ; Chen, L. S. ; Gage, F. H.
"Spatial Organization of Physiological Activity in The
Hippocampal Region: Relevance to Memory Formation"
Progress in Brain Research, vol. 83, 1990, pág. 257-268

- [CARE-85] Carew, T. J.
"The Control of Reflex Action"
Principles of Neural Science 1985, pág. 457-468
Editores: E. R. Kandel ; J. H. Schwartz
- [CARE-91] Carew, T. J.
"Multiple components of Learning and Memory in Aplysia:
Excitatory and Inhibitory Information Processing in a Restricted
Neural Network"
Brain Research Reviews, 16 (1991), pág. 195-196
- [CARPE-90] Carpenter, R. H. S.
"Neurophysiology"
Ed. Edward Arnold, Segunda Edição 1990
- [CHAU-86] Chauvet, G.
"Habituation Rules For A Theory Of The Cerebellar Cortex"
Biological Cybernetics, 55, 1986, pág. 201-209
- [CHEN-90] Chen, Fu-Chuang
"Back-Propagation Neural Networks for Nonlinear Self-Tuning
Adaptative Control"
IEEE Control Systems Magazine, April 1990, pág. 44-48
- [CHU-90] Chu, S. R. ; Shoureshi, R. ; Tenorio, M.
"Neural Networks for Systems Identification"
IEEE Control Systems Magazine, April 1990, pág. 31-35
- [CLIQ-92a] Cliquet Jr., A. ; **Mendeleck, A.** et alii
"A Neural Network Voice Controlled Neuromuscular Electrical
Stimulation System for Tetraplegics"
RESNA - International '92 Conference - Toronto, Ontario - Canada
1992, pág. 29-31

- [CLIQ-92a] Cliquet Jr., A. ; **Mendeleck, A.** et alii
"Restoration of Upper Limb Function to Tetraplegics using Neural Networks and a Voice Processing System"
VI Mediterranean Conference on Medical and Biological Engineering - MEDICON '92 - Capri - Itália, 1992, pág. 553 - 556
- [COHE-83] Cohen, M. A. ; Grossberg, S.
"Absolute Stability of Global Pattern Formulation and Parallel Memory Storage by Competitive Neural Networks"
IEEE Transactions on Systems, Man, and Cybernetics,
Vol. SMC-13, Nº 5, September/October 1983, pág. 815-826
- [COIT-91] Coiton, Y. ; Gilhodes, J. C. ; Velay, J. L. ; Roll, J. P.
"A Neural Network Model for The Intersensory Coordination Involved in Goal-Directed Movement"
Biological Cybernetics, 1991, pág. 167-176
- [CURR-95] Curran, A. ; Kyriakopoulos, K. J.
"Sensor-Based Self-Localization for Wheeled Mobile Robots"
Journal of Robotic Systems, 1995, 12(3), pág. 163-176
- [DIST-91] Disterhoff, J. F. ; Black, J. ; Moyer Jr., J. R. ; Thompson, L. T.
"Calcium-Mediated Changes in Hippocampal Neurons and Learning"
Brain Research Reviews, 16 (1991), pág. 196-198
- [EBER-90] Eberhart, R. C. ; Dobbins, R. W.
"Early Neural Network Development History: The Age of Camelot"
IEEE Engineering in Medicine and Biology, September 1990,
pág. 15-18
- [ECC-67] Eccles, J. C. ; Ito, M. ; Szentagothai, J.
"The Cerebellum as a Neuronal Machine"
Ed. Springer-Verlag, 1967

- [ECKM-89] Eckmiller, R.
 "Neural Nets for Sensory and Motor Trajectories"
 IEEE Control System Magazine, April 1989, pág. 53-59
- [EICH-91] Eichenbaum, H. ; Cohen, N. J. ; Otto, T. ; Wible, C.
 "A Snapshot Without The Album"
 Brain Research Reviews, 16 (1991), pág. 209-215
- [EICH-92] Eichenbaum, H. ; Otto, T. ; Cohen, N. J.
 "The Hippocampus - What Does It Do? - Review"
 Behavioral and Neural Biology 57, 1992, pág. 2-36
- [EVAR-81] Evarts, E. V.
 "Role of Motor Cortex In Voluntary Movements In Primates"
 In: V. B. Brooks, "Handbook of Physiology", Sect. 1,
 Vol. 11, part2.
 American Physiol. Soc., Bethesda, 1981, pág. 1083-1120
- [EYSE-82] Eysenck, H. J. (editor)
 "A Model for Intelligence"
 Ed. Springer-Verlag, Berlin Heidelberg - 1982
- [FOUX-93] Foux, G. ; Heymann, M. ; Bruckstein, A.
 "Two-Dimensional Robot Navigation Among Unknown Stationary
 Polygonal Obstacles"
 IEEE Transactions on Robotics and Automation, vol. 9,
 February 1993, pág. 96-102
- [FU-87] Fu, K. S. ; Gonzalez, R. C. ; Lee, C. S. G.
 "Robotics: Control, Sensing, Vision, and Intelligence"
 Ed. McGraw-Hill Book Company, 1987
- [FUHR-85] Fuhrmann, G. Y.
 "Mathematical Approach to Integrating The 'Neuron-Module' and
 The Cell-Assembly "
 Intern. J. Neuroscience, 1985, Vol. 28, pág. 91-110

- [GAGN-65] Gagnè, R. M.
"The Conditions of Learning"
Ed. Holt, Rinehart and Winston, INC., USA, 1965
- [GALL-76] Galloway, C.
"Psychology for Learning and Teaching"
Ed. McGraw-Hill, Inc. 1976
- [GANO-83] Ganong, W. F.
"Fisiologia Médica"
Ed. Atheneu Editora São Paulo Ltda., 4ª Edição - 1983
- [GASP-91] Gaspar, E. R. ; Carvalho, L. A. V.
"Solução do Problema Cinemático Inverso de Robôs Redundantes
Via Redes Neurais"
XI Congresso Brasileiro de Engenharia Mecânica - São Paulo -
Brasil, Dezembro 1991, pág. 517-520
- [GHEZ-85] Ghez, C. ; Fahn, S.
"The Cerebellum"
in Principles of Neural Science
Ed. Elsevier Science Publishing Co., Inc 1985
- [GUEZ-88a] Guez, A. ; Elibert, J. L. ; Kam, M.
"Neural Network Architecture for Control"
IEEE Control Systems Magazine, April 1988, pág. 22-25
- [GUEZ-88b] Guez, A. ; Selinsky, J.
"A Trainable Neuromorphic Controller"
Journal of Robotic Systems, 5(4), 1988, pág. 363-388
- [GUTH-52] Guthrie, E. R.
"The Psychology of Learning"
Ed. HARPER, N.Y. 1952

- [GUYT-76] Guyton, A. C.
"Tratado de Fisiologia Médica"
1ª Edição - 1976
Ed. Interamericana Ltda.
- [HAN-94] Han, Min-Hong ; Rhee, Sang-Yong
"Navigation Control for a Mobile Robot"
Journal of Robotic Systems, 1994, 11(3), pág. 169-179
- [HAND-90] Handelman, D. A. ; Lane, S. H. ; Gelfand, J. J.
"Integrating Neural Networks and Knowledge-Based Systems for
Intelligent Robotic Control"
IEEE Control Systems Magazine, April 1990, pág. 77-87
- [HANE-92] Hanes, M. D. ; Ahalt, S. C. ; Mirza, K. ; Orin, D. E.
"Power Grasp Force Distribution Control Using Artificial Neural
Networks"
Journal of Robotic Systems, 9(5), 1992, pág. 635-661
- [HAYE-89] Hayes, J. R.
"The Complete Problem Solver"
Ed. Lawrence Erlbaum Associates, Inc., Publishers 1989
Second Edition
- [HEBB-49] Hebb, D. O.
"The Organization of Behavior; A Neuropsychological Theory"
New York, 1949
- [HEND-90] Henderson, T. C. ; Grupen, R.
"Logical Behaviors"
Journal of Robotic Systems, 7(3), 1990, pág. 309-363
- [HERG-88] Hergenhahn, B. R.
"An Introduction to Theories of Learning"
Third Edition - 1988
Ed. Prentice Hall, Englewood, New Jersey

- [HEUB-90] Heuberger, C. F. ; Zampieri, D. E.
"Determinação Automática e Simulação de Trajetória para um Manipulador Antropomórfico"
Anais do 1º SAI, Curitiba, PR, Brasil, Julho de 1990,
pág. 152-156
- [HEUB-91] Heuberger, C. F. ; Zampieri, D. E.
"Determinação Automática e Simulação de trajetórias Ótimas de um Manipulador na Presença de Obstáculos"
Anais do 4º DINAME, Pouso Alto, MG, Brasil, Março de 1991
- [HILL-77] Hill, W. F.
"LEARNING: A Survey of Psychological Interpretations"
Ed. HARPER & ROW Publishers, Inc. 1977
- [HINTO-89] Hinton, G. E.
"Connectionist Learning Procedures"
Artificial Intelligence, 40, 1989, pág. 185-234
- [HOLD-83] Holden, A. V. ; Winlow, W.
"Neuronal Activity as The Behavior of a Differential System"
IEEE Transactions on Systems, Man, and Cybernetics,
Vol. SMC-13, Nº 5, September/October 1983, pág. 711-719
- [HOLP-85] Holpfield, J. J. ; Tank, D. W.
"Neural Computation of Decisions in Optimization Problems"
Biological Cybernetics, 1985, pág. 141-145
- [HOU-94] Hou, E. S. H. ; Zheng, D.
"Mobile Robot Path Planning Based on Hierarchical Hexagonal Decomposition and Artificial Potencial Fields"
Journal of Robotic Systems, 1994, 11(7), pág. 605-614

- [HU-93] Hu, T. C. ; Kahng, A. B. ; Robins, G.
"Optimal robust Path Planning in General Environments"
IEEE Transactions on Robotics and Automation, vol. 9,
December 1993, pág. 775-784
- [HUAN-90] Huang, S. ; Huang, Y.
"Learning Algorithms for Perceptrons Using Back-Propagation
With Selective Updates"
IEEE Control Systems Magazine, April 1990, pág. 56-61
- [HULL-52] Hull, C. L.
"A Behavior System; An Introduction to Behavior Theory
Concerning The Individual Organism"
New Haven, 1952
- [ITO-70] Ito, M.
"Neurophysiological Aspects of The Cerebellar Motor Control
System"
Int. J. Neurol., 7, 1970, pág. 162-176
- [ITO-84] Ito, M.
"The Cerebellum and Neural Control"
Raven Press, New York, 1984
- [IYEN-85] Iyengar, S. S. ; Jorgensen, C. C. ; Rao, S. V. N. ; Weisbin, C. R.
"Learned Navigation Paths for a Robot in Unexplored Terrain"
IEEE CH2215-2, 1985, pág. 148-155
- [JACO-91] Jacobson, M.
"Developmental Neurobiology"
Ed. Plenum Press, New York 1991
- [KALV-91] Kalveram, K. Th.
"Controlling The Dynamics of a Two-Joined Arm by Central
Patterning and Reflex-Like Processing"
Biological Cybernetics, 65, May 1991, pág. 65-71

- [KAUF-90] Kaufman, J. J. ; Chiabrera, A. ; Hatem, M. ; Hakim, N. Z. ;
Figueiredo, M. ;
Nasser, P. ; Lattuga, S. ; Pila, A. A. ; Siffert, R. S.
"A Neural Network Approach for Bone Fracture Healing
Assessment"
IEEE Engineering in Medicine and Biology, September 1990,
pág. 23-30
- [KAWA-87] Kawato, M. ; Furukawa, K. ; Suzuki, R.
"A Hierarchical Neural-Network Model for Control and Learning
of Voluntary Movement"
Biological Cybernetics, 75, 1987, pág. 169-185
- [KAWA-88] Kawato, M. ; Uno, Y. ; Isobe, M. ; Suzuki, R.
"Hierarchical Neural Network Model for Voluntary Movement
With Application to Robotics"
IEEE Control Systems Magazine, April 1988, pág. 8-16
- [KAWA-90] Kawato, M. ; Moeda, Y. ; Uno, Y. ; Suzuki, R.
"Trajectory Formation of Arm Movement by Cascade Neural
Network Model Based on Minimum Torque-Chage Criterion"
Biological Cybernetics, 62, 1990, pág. 275-288
- [KOFF-35] Koffka, K.
"Principles of Gestalt Psychology"
Ed. Harcourt Brace Jovanovick, N.Y. 1935
- [KOHL-90] Köhler, C.
"Subicular Projections to The Hypothalamus and Brainstem:
Some Novel Aspects Revealed In The Rat by The Anterograde
Phaseolus Vulgaris Leukoagglutinin (PHA-L) Tracing Method"
Progress in Brain Research, vol. 83, 1990, pág. 59-69
- [KOHO-84] Kohonen, T.
"Self-Organization and Associative Memory"
Ed. Srpinge-Verlag, 1984

- [KRAF-90] Kraft, L. G. ; Campagna, D. P.
"A Comparison Between CMAC Neural Network Control and
Two Traditional Adaptive Control Systems"
IEEE Control Systems Magazine, April 1990, pág. 36-43
- [KUNG-89] Kung, Sun-Yuan ; Hwang, Jenq-Neng
"Neural Network Architectures for Robotic Applications"
IEEE Transactions on Robotics and Automation, vol. 5, Nº 5,
October 1989, pág. 641-657
- [KUPE-89] Kuperstein, M. ; Rubinstein, J.
"Implementation of an Adaptive Neural Controller for Sensory-
Motor Coordination"
IEEE Control Systems Magazine, April 1989, pág. 25-30
- [KUPE-90] Kuperstein, M. ; Wang, J.
"Neural Controller for Adaptive Movements With Unforeseen
Payloads"
IEEE Transactions on Neural Networks, Vol. 1, Nº 1,
March 1990, pág. 137-142
- [LALO-86] Lalonde, R. ; Botez, M. I.
"Navigational Deficits In Weaver Mutant Mice"
Brain Research 398, 1986, pág. 175-177
- [LALO-90] Lalonde, R. ; Botez, M. I.
"The Cerebellum and Learning Processes in Animals"
Brain Research Reviews 15, 1990, pág. 325-332
- [LEVI-88] Levine, R. I. ; Drang, D. E. ; Edelson, B.
"A Comprehensive Guide to AI and Expert Systems"
Ed. McGraw-Hill, 1988

- [LIN-92] Lin, P. P. ; Yang, An-Jen
"An Efficient Technique For Finding The Desired Global Optimum
of Robotic Joint Displacement"
Journal of Robotic Systems, 9(8), 1992, pág. 1043-1058
- [LIPPM-87] Lippmann, R. P.
"An Introduction to Computing With Neural Nets"
IEEE Acoustics, Speech, and Signal Processing Society,
April 1987, pág. 2-22
- [LIU-89] Liu, H. ; Iberall, T. ; Bekey, G. A.
"Neural Network Architecture for Robot Hand Control"
IEEE Control Systems Magazine, April 1989, pág. 38-43
- [LIU-94] Liu, Yun-Hui ; Arimoto, S.
"Computation of the Tangent Graph of Polygonal Obstacles by
Moving-Line Processing"
IEEE Transactions on Robotics and Automation, vol. 10,
December 1995, pág. 823-830
- [LOMO-71] Lomo, T.
"Patterns of Activation in a Monosynaptic Cortical Pathway: The
Perforant Path Input to The Dentate Area of The Hippocampal
Formation"
Expl. Brain Res. 12, 1971, pág. 18-45
- [LORE-33] Lorente de No, R.
"Studies on The Structure of The Cerebral Cortex. I. The Area
Entorhinalis"
J. Psychol. Neurol. 45, 1933, pág. 381-438
- [LORE-34] Lorente de No, R.
"Studies on The Structure of The Cerebral Cortex. II. Continuation
of The Study of The Ammonic System"
J. Psychol. Neurol. 46, 1934, pág. 113-177

- [LOTH-91] Lothman, E. W. ; Bertram III, E. H. ; Stringer, J. L.
"Functional Anatomy of Hippocampal Seizures"
Progress in Neurobiology, vol. 37, 1991, pág. 1-82
- [LUH-84] Luh, J. Y. S.
"Minimum Distance Collision-Free Path Planning for Industrial Robots With a Prismatic Join"
IEEE Transactions on Automatic Control, vol. AC-29 (8),
August 1984, pág. 675-680
- [LYNC-90] Lynch, G. ; Kessler, M. ; Arai, A. ; Larson, J.
"The Nature and Causes of Hippocampal Long-Term Potentiation"
Progress in Brain Research, vol. 83, 1990, pág. 233-250
- [LYNC-91] Lynch, G. ; Staubli, U.
"Possible Contributions Of Long-Term Potenciation To The Encoding And Organization Of Memory"
Brain Research Reviews, 16 (1991), pág. 204-206
- [MAC-80] Machado, A. B. M.
"Neuroanatomia Funcional"
Livraria Atheneu - 1980
- [MARR-69] Marr, D.
"A theory of Cerebellar Cortex"
J. Physiol. 202, 1969, pág. 437-470
- [MASS-89] Massone, L. ; Bizzi, E.
"A Neural Network Model for Limb Trajectory formation"
Biological Cybernetics, 61, 1989, pág. 417-425
- [McNA-83] McNaughton, B. L. ; Barnes, C. A. ; O'Keefe, J.
"The Contributions of Position, Direction and Velocity to Single Unit Activity in The Hippocampus of Freely Moving Rats"
Expl. Brain Res. 52, pág. 41-49

- [McNA-89] McNaughton, B. L. ; Barnes, C. A. ; Meltzer, J. ; Sutherland, R. J.
"Hippocampal Granule Cells Are Necessary For Normal Spatial Learning But Not Spatially Selective Pyramidal Cell Discharge"
Expl. Brain. Res. 76, pág. 485-496
- [McNA-91] McNaughton, B. L.
"Associative Pattern Completion In Hippocampal Circuits: New Evidence and New Questions"
Brain Research Reviews, 16 (1991), pág. 202-204
- [MEN-87] **Mendeleck, A.** ; Zampieri, D. E.
"Manipulador experimental"
VIII Seminário ADUNESP - Guaratinguetá - 1987
- [MEN-89] **Mendeleck, A.** ; Zampieri, D. E.
"Software para Equacionamento Cinemático e Dinâmico Simbólico de Robôs Manipuladores"
X COBEM - Congresso Brasileiro de Engenharia Mecânica, 1989
- [MEN-90] **Mendeleck, A.** ; Zampieri, D. E.
"Desenvolvimento de um Controle Supervisor para um Robô Manipulador com 6 Graus de Liberdade"
1º Simpósio de Automação Integrada CEFET/PR Centro Federal de Educação Tecnológica do Paraná, 1990
- [MEN-91a] **Mendeleck, A.** ; Zampieri, D. E.
"Uma Linguagem de Programação de Robôs"
Congresso de Engenharia Mecânica Norte-Nordeste, 1991
- [MEN-91b] **Mendeleck, A.** ; Zampieri, D. E.
"Ferramentas Computacionais no Auxílio ao Projeto de Robôs Manipuladores"
XIV Reunião Regional da Sociedade Brasileira de Matemática Aplicada e Computacional e I Semana de Estudos da Computação
Rio Claro - São Paulo, 1991

- [MICH-83] Michalski, R. S. ; Carbonell, J. G. ; Mitchell, T. M.
 "Machine Learning an Artificial Intelligence Approach"
 Vol. 1 e 2, Ed. Morgan Kaufmann Publishers, INC, 1983
- [MIC-90] Michel, A. N. ; Farrell, J. A.
 "Associative Memories Via Artificial Neural Networks"
 IEEE Control Systems Magazine, April 1990, pág. 6-17
- [MICH-90] Micheli-Tzanakou, E.
 "When a Feature Detector Becomes a Feature Generator"
 IEEE Engineering in Medicine and Biology, September 1990,
 pág. 19-22
- [MINS-69] Minsky, M. L. ; Papert, S.
 "Perceptrons"
 Ed. MIT Press - Cambridge, MA
- [MONO-92] Monostori, L. ; Barschdorff, D.
 "Artificial Neural Networks in Intelligent Manufacturing"
 Robotics & Computer-Integrated Manufacturing, vol. 9(6), 1992,
 pág. 421-437
- [MORR-82] Morris, R. G. M. ; Garrud, P. ; Rawlins, J. N. P. ; O'Keefe, J.
 "Place Navigation Impaired In Rats With Hippocampal Lesions"
 Nature, 292 (1982), pág. 681-683
- [MULL-94] Muller, R. U. ; Bostock, E. ; Taube, J. S. ; Kubie, J. L.
 "On The Directional Firing Properties of Hippocampal Place Cells"
 The Journal of Neuroscience, December 1994, 14(12),
 pág. 7235-7251
- [MUSS-83] Mussen, P. H. (editor)
 "Handbook of CHILD PSYCHOLOGY"
 Vols. I, II e III - Fourth Edition
 Ed. John Wiley & Sons - 1983

- [NAGA-90] Nagata, S. ; Sekiguchi, M. ; Asakawa, K.
"Mobile Robot Control by a Structured Hierarchical Neural Network"
IEEE Control Systems Magazine, April 1990, pág. 69-76
- [NEWE-72] Newell, A. ; Simon, H. A.
"Human Problem Solving"
Ed. Prentice-Hall, Inc, Englewood Cliffs, New Jersey 1972
- [NGUY-90] Nguyen, D. H. ; Widrow, B.
"Neural Networks for Self-Learning Control Systems"
IEEE Control Systems Magazine, April 1990, pág. 18-23
- [NIELS-87a] Hecht-Nielsen, R.
"Counterpropagation Networks"
Proceeding of The IEEE First International Conference on Neural
Networks"
pág. 19-32, 1987
- [NIELS-87b] Hecht-Nielsen, R.
"Counterpropagation Networks"
Applied Optics 26(33) - 1987, pág. 4979-4984
- [NIELS-87c] Hecht-Nielsen, R. ; Haines, K.
"A BAM with Increased Information Storage Capacity"
Proceeding of The IEEE First International Conference on Neural
Networks"
pág. 181-190, 1987
- [NIELS-88] Hecht-Nielsen, R.
"Neurocomputing: Picking The Human Brain"
IEEE Spectrum, March 1988, pág. 36-41

- [NORE-95] Noreils, F. R. ; Chatila, R. G.
"Plan Execution Monitoring and Control Architecture for Mobile Robots"
IEEE Transactions on Robotics and Automation, vol. 11,
April 1995, pág. 255-266
- [OLTO-91] Olton, D. S.; Golski, S. ; Mishkin, M. ; Gorman, L. K. ; Olds, J. L. ;
Alkon, D. L.
"Behaviorally Induced Changes In The Hippocampus"
Brain Research Reviews, 16 (1991), pág. 206-209
- [O'MAR-94] O'Mara, S. M.
"Neurons Responding to Whole-Body Motion in The Primate Hippocampus"
The Journal of Neuroscience, November 1994, 14(11),
pág. 6511-6523
- [O'MAR-95] O'Mara, S. M.
"Spatially Selective Firing Properties of Hippocampal Formation Neurons in Rodents and Primates"
Progress in Neurobiology, vol. 45, 1995, pág. 253-274
- [O'KEE-71] O'Keefe, J. ; Dostrovsky, J.
"The Hippocampus as a Spatial Map Preliminary Evidence From Unit Activity In The Freely-Moving Rat"
Brain Res. 34, pág. 171-175
- [O'KEE-90] O'Keefe, J.
"A Computational Theory of The Hippocampal Cognitive Map"
Progress in Brain Research, vol. 83, 1990, pág. 301-312
- [PASSI-89] Passino, K. M. ; Sartori, M. A. ; Antsaklis, P. J.
"Neural Computing for Numeric-to-Symbolic Conversion in Control Systems"
IEEE Control Systems Magazine, April 1989, pág. 44-52

- [PIAGE-70] Piaget, J.
"A Teoria de Piaget"
Do livro: "Carmichael's Manual of Child Psychology", vol. IV
Organizado por: P. H. Mussen
Editora: John Wiley&Sons,Inc - 1970
- [PSALT-88] Psaltis, D. ; Sideris, A. ; Yamamura, A. A.
"A Multilayered Neural Network Controller"
IEEE Control Systems Magazine, April 1988, pág. 17-21
- [RAUC-88] Rauch, H. E. ; Winarske, T.
"Neural Networks for Routing Communication Traffic"
IEEE Control Systems Magazine, April 1988, pág. 26-31
- [RAM-90] Ramos, C. F. ; Stark, L. W.
"Postural Maintenance During Movement: Simulations Of A Two
Joint Model"
Biological Cybernetics, 63, 1990, pág. 363-375
- [RAW-77] Rawlins, J. N. P. ; Green, K. F.
"Lamellar Organization in The Rat Hippocampus"
Expl. Brain Res. 28, 1977, pág. 335-344
- [RICH-88] Rich, E.
"Artificial Intelligence"
Ed. McGraw-Hill, 1988
- [ROSE-59] Rosenblatt, R.
"Principles of Neurodynamics"
New York, 1959
Ed. Spartan Books

- [ROTH-90] Roth, M. W.
"Survey of Neural Network Technology for Automatic Target Recognition"
IEEE Transactions on Neural Networks, Vol. 1, No 1, March 1990,
pág. 28-43
- [ROUA-67] Rouanet, H.
"Les Modèles Stochastiques d'Apprentissage"
Mouton, Paris 1967
- [RUME-89] Rumelhart, D. E. ; McClelland, J. L.
"Parallel Distributed Processing"
Vol. 1: "Explorations in The Microstructure of Cognition"
Vol. 2: "Psychological and Biological Models"
Ed. MIT Press 1989
- [SANN-90] Sanner, R. M. ; Akin, D. L.
"Neuromorphic Pitch Attitude Regulation of an Underwater Telerobot"
IEEE Control Systems Magazine, April 1990, pág. 62-68
- [SARI-83] Saridis, G. N.
"Intelligent Robotic Control"
IEEE Transactions on Automatic Control, May 1983,
pág. 547-557
- [SCHIZ-90] Schizas, C. N. ; Pattichis, C. S. ; Schofield, I. S. ; Fawcett, P. R. ;
Middleton, L. T.
"Artificial Neural Nets in Computer-Aided Macro Motor Unit
Potential Classification"
IEEE Engineering in Medicine and Biology, September 1990,
pág. 31-38

- [SCHM-92] SCHMAJUK, N. A. ; Thieme, A. D.
"Purposeful Behavior and Cognitive Mapping: A Neural Network Model"
Biological Cybernetics, 67, 1992, pág. 165-174
- [SHIO-91] Shiokawa, T.
"Navigation/Locating Control of Mobile robots for Construction"
Journal of Robotics and Mechatronics, vol. 3, 1991, pág. 387-393
- [SKINN-53] Skinner, B. F.
"Science and Human Behavior"
New York, 1953
- [SOUC-89] Soucek, B.
"Neural and Concurrent Real-Time Systems"
Ed. John Wiley & Sons - 1989
- [SPECH-90] Specht, D. F.
"Probabilistic Neural Networks and The Polynomial ADALINE as Complementary Techniques for Classification"
IEEE Transactions on Neural Networks, Vol. 1, No 1, March 1990, pág. 111-121
- [SPON-86] Spong, M. W.
"The Control of Robot Manipulators With Bounded Input"
IEEE Transactions on Automatic Control, vol. AC-31 (6), June 1986, pág. 483-490
- [SQUI-91] Squire, L. R. ;Mishkin, M.
"Introduction. The Hippocampus, synapses, circuits and cognition"
Brain Research Reviews, 16 (1991), pág. 194
- [SUTH-94] Sutherland, K. T ; Thompson, W. B.
"Localizing in Unstructured Environments: Dealing with the Errors"
IEEE Transactions on Robotics and Automation, vol. 10, December 1994, pág. 740-754

- [STEVE-90] Stevenson, M. ; Winter, R. ; Widrow, B.
"Sensitivity of Feedforward Neural Networks to Weight Errors"
IEEE Transactions on Neural Networks, Vol. 1, No 1, March 1990,
pág. 71-80
- [UNO-87] Uno, Y.; Kawato, M. ; Suzuki, R.
"Formation of Optimum Trajectory In Control of Arm Movement-
Minimum Torque-Change Model"
Japan IEICE Technical Report MBE, 1987, pág 9-16
- [VOGL-88] Vogl, T. P. ; Mangis, J. K. ; Zink, W. T. ; Alkon, D. L.
"Accelerating The Convergence of The Back-Propagation Method"
Biological Cybernetics, 59, 1988, pág. 257-263
- [ZAPA-94] Zapata, R. ; Lépinay, P. ; Thompson, P.
"Reactive Behaviors of Fast Mobile Robots"
Journal of Robotic Systems, 1994, 11(1), pág. 13-20
- [ZELI-92] Zelinsky, A.
"A Mobile Robot Exploration Algorithm"
IEEE Transactions on Robotics and Automation, vol. 8,
December 1992, pág. 707-717
- [ZIPS-85] Zipser, D.
"A Computational Model of Hippocampal Place Fields"
Behavioral Neuroscience, 99, 1985, pág. 1006-1018
- [ZIPS-88] Zipser, D.
"Biologically Plausible Models of Place Recognition and Goal
Location"
In "Parallel Distributed Processing", vol. 2, 1988, pág. 432-470
Editores: J. L. McClelland e D. E. Rumelhart
Ed. MIT Press

- [WASS-88] Wasserman, P. D.
"Combined Backpropagation/Cauchy Machine"
Proceedings of The International Neural Network Society"
Ed. Pergamon Press, New York, 1989
- [WASS-89] Wasserman, P. D.
"Neural Computing Theory and Practice"
Ed. Van Nostrand Reinhold, 1989
- [WERT-45] Wertheimer, W.
"Productive Thinking"
Ed. New York: HARPER&ROW 1945
- [WEST-90] West, M. J.
"Stereological Studies of The Hippocampus: A comparison of The
Hippocampal Subdivisions of Diverse Species Including Hedgehogs,
Laboratory Rodents, Wild Mice and Men"
Progress in Brain Research, vol. 83, 1990, pág. 13-36
- [WIDR-90] Widrow, B. ; Nguyen, D. H.
"Neural Networks For Self-Learning Control Systems"
IEEE Control System Magazine, April 1990, pág. 18-23
- [WITT-90] Witter, M. P. ; Groenewegen, H. J.
"The Subiculum: Cytoarchitectonically A Simple Structure,
But Hodologically Complex"
Progress in Brain Research, vol. 83, 1990, pág. 47-58
- [WU-94] Wu, Tzung-hsien ; Young, Kuu-young
"Path Planning in the Presence of Obstacles Based on Task
Requirements"
Journal of Robotic Systems, 1994, 11(8), pág. 703-716