

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO**

Giseli de Sousa

**SPINS – Um Simulador Neural para Visualização de
Aspectos de Aprendizado utilizando Neurônios *Spiking***

Dissertação submetida à Universidade Federal de Santa Catarina como parte dos
requisitos para a obtenção do grau de Mestre em Ciência da Computação

Mauro Roisenberg, Dr.
Orientador

Florianópolis, Dezembro de 2005.

Livros Grátis

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

Milhares de livros grátis para download.

SPINS – Um Simulador Neural para Visualização de Aspectos de Aprendizado utilizando Neurônios *Spiking*

Giseli de Sousa

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, área de concentração Sistemas de Conhecimento e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Banca Examinadora

Prof. Raul Sidnei Wazlawick, Dr.
Coordenador do Curso

Prof. Mauro Roisenberg, Dr.
Orientador

Prof. João Cândido Lima Dovicchi, Dr.

Prof. João Bosco da Mota Alves, Dr.

Profa. Mariana Graciela Terenzi, Dra.

*O aprendizado nunca termina.
Não existe parte da vida que não contenha lições.
Se você está vivo, há lições para aprender.*
(autor desconhecido)

Ofereço aos meus pais
pelo incentivo aos estudos
e ao meu namorado
pelo seu apoio, paciência e amor.

AGRADECIMENTOS

Agradeço ao meu orientador Mauro Roisenberg que aceitou esse desafio, me mostrando o caminho e não deixando desviar dele. Pelo seu apoio, seus conselhos e suas horas dedicadas a me atender e me ouvir. Agradeço ao meu “segundo” orientador João Bosco da Mota Alves que, com grande amizade e companheirismo, permitiu que eu iniciasse essa pesquisa, sempre me apoiando e sugerindo novas idéias.

Agradeço a professora Mariana por ter ajudado a decifrar os mistérios da Neurociência, que foi de grande importância para esse trabalho. E nesse sentido, ao meu colega Gibinha que esteve presente nas conversas com a professora, sempre levantando dúvidas e discutindo pontos importantes da minha pesquisa.

Agradeço aos meus amigos e colegas, em especial ao Eduardo que me ajudou na pesquisa e no desenvolvimento de todas as partes deste trabalho. Agradeço pelas horas que passou comigo, me ouvindo e debatendo nossos diferentes pontos de vista.

Agradeço aos colegas de trabalho do Labtrans, em especial aos meus chefes Armando e Amir, que me ajudaram de modo em especial, permitindo que eu “matasse” algumas horas de serviço.

Aos meus pais que sempre me incentivaram nos estudos e me apoiaram em todos os momentos, me propiciando a chegar neste ponto da minha vida.

E finalmente, mas com maior importância, agradeço meu amado Jean que sofreu junto comigo, mas sempre me dando força. Agradeço especialmente por não ter me deixado desistir.

SUMÁRIO

Sumário	vi
Lista de Figuras	viii
Lista de Tabelas	x
Lista de Siglas	xi
Lista de Símbolos.....	xii
Resumo.....	xiii
Abstract.....	xiv
1 Introdução.....	1
1.1 Motivação.....	2
1.2 Objetivos.....	3
1.2.1 Objetivo geral.....	3
1.2.2 Objetivos específicos.....	3
1.3 Justificativa.....	4
1.4 Estruturação do Texto.....	4
2 Fundamentação Biológica	6
2.1 Sistema Nervoso	7
2.2 Neurônio	10
2.2.1 Membrana neural e potencial de membrana.....	11
2.2.2 Potencial de ação	13
2.2.3 Tipos de neurônios	15
2.2.3.1 Classificação conforme o efeito do sinal transmitido.....	15
2.2.3.2 Classificação conforme o tipo de conexão neural	16
2.3 Sinapse.....	19
2.3.1 Sinapses elétricas.....	20
2.3.2 Sinapses químicas.....	21
2.3.2.1 Transmissão sináptica.....	22
2.3.2.2 Classificação conforme o efeito do neurotransmissor	23
2.3.2.3 Classificação conforme o tipo de conexão	24
2.4 Aprendizado	26
2.4.1 Formas de aprendizado.....	27
2.4.1.1 Habituação	28
2.4.1.2 Sensibilização	29
2.4.1.3 Condicionamento clássico	31
2.5 Controle Motor	34
2.5.1 Reflexos.....	34
2.5.2 Geradores centrais de padrão.....	36
3 Redes Neurais Artificiais.....	39
3.1 Neurônio Artificial	44
3.1.1 Modelos formais.....	44
3.1.1.1 Neurônio de McCulloch-Pitts.....	46
3.1.1.2 Perceptron.....	46
3.1.2 Neurônios <i>spiking</i>	47

3.1.2.1	Modelo de resposta por potencial de ação	48
3.1.2.2	Modelo de integração e disparo	51
3.1.2.3	Modelo de Hodgkin-Huxley	52
3.2	Redes Neurais Pulsadas	53
3.2.1	Hi-NOON	53
3.2.1.1	Os neurônios	54
3.2.1.2	As sinapses.....	59
3.2.1.3	O aprendizado da rede	61
3.3	Aplicabilidade em Robótica	64
4	Modelo Proposto	66
4.1	Modificações do Modelo	67
4.1.1	Função de atualização do potencial de membrana	68
4.1.2	Normalização do potencial de membrana	69
4.1.3	Cálculo do potencial sináptico.....	70
4.1.4	Constantes.....	71
4.1.5	Normalização das entradas sensoriais	71
4.2	Simulador	73
4.2.1	Funcionamento	73
4.2.2	Desenvolvimento da ferramenta.....	74
4.2.3	Interface	74
4.2.4	Objetos do Sistema	75
4.2.4.1	Os neurônios	75
4.2.4.2	As sinapses.....	76
4.2.5	Funcionalidades	77
4.2.6	Simulação	80
5	Exemplo de Aplicação.....	82
5.1	ARBIB	82
5.1.1	Gerador central de padrão.....	82
5.1.2	Reflexo	83
5.1.3	Condicionamento clássico	84
5.1.4	Condicionamento de alta-ordem.....	85
5.2	Simulação	87
6	Considerações Finais	89
6.1	Contribuições.....	89
6.2	Trabalhos Futuros.....	90
7	Referências Bibliográficas.....	91
8	Apêndices	95

LISTA DE FIGURAS

Figura 2.1 Representação esquemática da constituição morfofuncional do sistema nervoso de vertebrados.....	8
Figura 2.2 Anatomia de um neurônio típico.....	10
Figura 2.3 Potencial de repouso.....	12
Figura 2.4 Potencial de ação típico, destacando suas fases.....	13
Figura 2.5 Tipos de neurônios.....	16
Figura 2.6 Comparação entre sinapse elétrica e sinapse química.....	20
Figura 2.7 Tipos de sinapses.....	24
Figura 2.8 A <i>Aplysia</i>	27
Figura 2.9 O circuito reflexo da <i>Aplysia</i> e sua habituação.....	29
Figura 2.10 Circuito de sensibilização da <i>Aplysia</i>	30
Figura 2.11 Condicionamento clássico na <i>Aplysia</i>	32
Figura 2.12 Circuito neural de um reflexo de retirada.....	35
Figura 2.13 Circuitos geradores centrais de padrão dos invertebrados.....	38
Figura 3.1 Topologias de redes neurais artificiais.....	41
Figura 3.2 Modelo de neurônio artificial.....	45
Figura 3.3 Forma do potencial pós-sináptico excitatório (PPSE) e inibitório (PPSI)....	49
Figura 3.4 Período refratário $i(t-t_i^{(f)})$	50
Figura 3.5 Circuito “integração e disparo” de um neurônio.....	51
Figura 3.6 Diagrama esquemático do modelo de Hodgkin-Huxley.....	52
Figura 3.7 Potencial de ação (<i>spike</i>) de um neurônio, destacando os estados.....	56
Figura 3.8 Representação gráfica da sinapse básica.....	60
Figura 3.9 Sinapse axo-axônica sensibilizada (a) e condicionada (b).....	62
Figura 3.10 Aumento do peso sináptico durante o aprendizado condicionado.....	63
Figura 4.1 Tela principal do simulador SPINS.....	75

Figura 5.2 Comportamento reflexo do ARBIB.	84
Figura 5.3 Condicionamento clássico do ARBIB.	85
Figura 5.4 Condicionamento de alta-ordem do ARBIB.	86
Figura 5.5 Rede neural completa do ARBIB simulado no SPINS.	87
Figura 5.6 Simulação da rede neural do ARBIB.	88

LISTA DE TABELAS

Tabela 2.1 Experimento de Pavlov.....	31
Tabela 3.1 Resumo das principais RNAs classificadas pelo método de aprendizagem.	42
Tabela 3.2 Parâmetros fixos em relação ao potencial de membrana do neurônio.....	56
Tabela 4.1 Comparação entre o cálculo de potencial de membrana original com o modelo proposto.	68
Tabela 4.2 Constantes alteradas no modelo proposto.....	71

LISTA DE SIGLAS

SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
PM	Potencial de Membrana
PPS	Potencial Pós-Sináptico
PPSE	Potencial Pós-Sináptico Excitatório
PPSI	Potencial Pós-Sináptico Inibitório
GCP	Gerador Central de Padrão
EI	Estímulo Incondicionado
EN	Estímulo Neutro
EC	Estímulo Condicionado
RI	Resposta Incondicionada
RC	Resposta Condicionada
RNA	Rede Neural Artificial
RNN	Rede Neural Natural
NA	Neurônio Artificial

LISTA DE SÍMBOLOS

Combinador Linear

Somatório

"

Função de Ativação

Limiar de Disparo

Menor ou Igual

Maior ou Igual

< Menor que

> Maior que

Conjunto de Neurônios Pré-Sinápticos

Potencial Pós-sináptico

Limiar

Período Refratário

Está Contido

Função Limiar

Função Peso

RESUMO

Os artefatos inteligentes podem ser considerados mecanismos inspirados biologicamente. Estes artefatos possuem a capacidade de simular características e comportamentos semelhantes aos dos seres vivos, através da modelagem biológica de seus sistemas neurais. Para obter um maior grau de fidelidade, o sistema nervoso destes artefatos deve implementar modelos neurais que se assemelhem ao modelo de neurônio biológico. Assim, acredita-se que a utilização de neurônios artificiais do tipo *spiking* - que são definidos como neurônios que apresentam como saída potenciais de ação - são os modelos mais recomendados para simular os neurônios biológicos.

Para a visualização do sistema nervoso, que na área de Inteligência Artificial é representada pela rede neural do artefato, foi proposto neste trabalho um simulador neural chamado SPINS (*Spiking Neurons Simulator*). Este simulador foi desenvolvido para fins didáticos, possibilitando a visualização da rede neural como um todo, na qual são mostradas as ativações de cada neurônio e os estados em que o mesmo se apresenta, sendo que o estado é definido pelo seu potencial de membrana atual.

Biologicamente, o aprendizado ocorre através de mudanças estruturais nas sinapses. Assim, através da organização de conexões sinápticas específicas, o simulador proposto permite visualizar aspectos de aprendizado, tais como habituação, sensibilização e condicionamento clássico.

A teoria biológica que fundamenta este trabalho, bem como as estruturas computacionais que representam os modelos biológicos, é apresentada para dar um maior embasamento teórico.

Por fim, o simulador proposto é validado através de um caso de uso o qual é implementada uma rede neural de um robô inspirado biologicamente.

Palavras Chaves: simulador neural, neurônio *spiking*, aprendizado, habituação, sensibilização, condicionamento clássico.

ABSTRACT

Intelligent devices can be considered biological inspired mechanisms. These devices have the ability to simulate characteristics and behaviors like those of living beings, by the modeling of their neural systems. To have a higher biological fidelity, the nervous system of these devices must implement neural models as close as possible to the biological neuron. By that reason, we believe that the use of artificial neurons like the spiking neurons - which are defined as neurons with action potential output - are the recommended solutions to simulate biological neurons.

To visualize the nervous system, which in the Artificial Intelligence area is represented by the neural network of the device, we proposed in this work a neural simulator called SPINS (*Spiking Neurons Simulator*). This simulator was developed with educational purposes, helping to visualize the entire neural network, which shows the activations of every neuron and the states in which it is at the moment, where the state is defined by the neuron's actual membrane potential.

Biologically, the learning process occurs by structural changes on synapses. Thus, by the organization of specific synaptical connections, the proposed simulator allows the visualization of learning characteristics, like the habituation, sensitization and classical conditioning.

The biological theory basis of this work, as well the computational structures that represent this biological models, is presented to help the reader to understand the choice of the SPINS.

At last, the proposed simulator is validated by its use in a case in which we implement a biological robot's neural network.

Keywords: neural simulator, spiking neurons, learning, habituation, sensitization, classical conditioning.

1 INTRODUÇÃO

Na busca do desenvolvimento de artefatos inteligentes que tenham características e comportamentos semelhantes aos seres vivos, os modelos biológicos de sistemas nervosos, evolução natural, aprendizado, interação social, entre outros, têm sido freqüentemente utilizados como paradigma e fonte de inspiração nas mais diversas áreas de aplicação [1]. Entre os modelos biológicos mais utilizados para o desenvolvimento de artefatos inteligentes, podemos destacar aqueles derivados dos sistemas nervosos e um de seus componentes básicos, os neurônios. O grau de fidelidade de um modelo biológico baseado em sistema nervoso pode variar conforme o nível de detalhamento que se deseja no artefato. Assim, conforme a finalidade da aplicação pretendida, o modelo neural pode ser baseado em sistemas nervosos muito rudimentares, tais como os apresentados pelos invertebrados, até sistemas extremamente detalhados e complexos, como o sistema nervoso do ser humano. Quanto mais próximo estiver o modelo neural artificial do modelo biológico, maior a chance de se alcançar a simulação de comportamentos inteligentes. Por esse motivo, vê-se a necessidade de se implementar modelos neurais baseados em inspiração biológica, que possam simular o sistema nervoso de diferentes seres. Para isso, surge a necessidade de se trabalhar com um simulador neural que implemente neurônios mais próximos aos neurônios biológicos.

Uma das características freqüentemente associadas ao funcionamento dos modelos inspirados no sistema nervoso é a capacidade de aprendizado. Esta capacidade está relacionada com a possibilidade de uma entidade alterar a longo prazo seu comportamento a fim de se adaptar a diferentes aspectos do ambiente. Nos modelos artificiais de redes neurais, a capacidade de aprendizado na maioria das vezes se dá através de formas de aprendizado supervisionado, onde exemplos das ações apropriadas a diversas situações do ambiente são apresentados à entidade inteligente. Entretanto, a emergência da inteligência nos seres vivos pode se dar por diversas outras formas de aprendizado associativo e não-associativo. Para comprovar que através de um simulador é possível emergir inteligência para que se possa chegar a artefatos inteligentes, tais formas de aprendizado podem ser implementadas. Os aprendizados por habituação, sensibilização e condicionamento clássico podem ser utilizados para tal validação.

Assim, para se visualizar comportamentos inteligentes em artefatos que simulam seres vivos, é proposto neste trabalho um simulador de rede neural, a qual é composta por neurônios artificiais que apresentam um modelo próximo ao modelo biológico e que permite a implementação de formas de aprendizado.

1.1 Motivação

Diferentemente das redes neurais artificiais mais comuns, que apresentam neurônios baseados no modelo de McCulloch-Pitts¹ apud [2], o sistema neural proposto necessita trabalhar com neurônios *spiking*, que ao invés de apresentar uma saída binária, como acontece com os neurônios artificiais comumente usados, sua saída se dá através da análise do potencial de membrana.

Outro ponto importante para o surgimento deste simulador é a necessidade da visualização dos estados de ativação de cada neurônio no decorrer da simulação. Atualmente, os simuladores em sua maioria apresentam como saída, gráficos ou arquivos em modo texto, que mostram os valores dos potenciais de membrana de cada neurônio no decorrer da simulação. Porém, essa visualização não é útil nos casos em que existe a necessidade de se visualizar os estados internos do neurônio durante a simulação, e não somente após o término da mesma.

Por fim, as redes neurais normalmente utilizam formas de aprendizado associativos (como o aprendizado supervisionado) e não-associativos (como os aprendizados não-supervisionado e por reforço) como métodos de aprendizagem da rede. A utilização de outras formas de aprendizado como habituação, sensibilização e condicionamento clássico não são empregados com a mesma frequência, mas apresentam importância equivalente para a implementação de comportamentos

¹ McCULLOCH, Warren.S.; PITTS, Walter H. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics. 1943. v.5. p.115-133.

inteligentes. Por esse motivo, estas formas de aprendizado foram escolhidas para serem implementadas neste simulador.

1.2 Objetivos

1.2.1 Objetivo geral

Desenvolver um simulador neural composto por neurônios *spiking* orientados a objetos para fins didáticos.

1.2.2 Objetivos específicos

Definir neurônios biológicos e artificiais, entre eles o modelo de neurônio *spiking*;

Expor os conceitos biológicos de sinapses;

Apresentar a definição das formas de aprendizado: habituação, sensibilização e condicionamento clássico;

Definir os comportamentos relevantes ao controle motor;

Apresentar e analisar as diferentes arquiteturas de redes neurais artificiais, em especial as redes neurais pulsadas;

Implementar um simulador neural, formado por um conjunto heterogêneo de neurônios e sinapses, que implemente as formas de aprendizado apresentadas;

Validar o simulador através de uma aplicação já existente.

1.3 Justificativa

Para obter um maior grau de fidelidade biológica, surgiu a necessidade de se trabalhar com um simulador que implementasse um modelo neural composto de neurônios *spiking*. Este tipo de neurônio apresenta como saída pulsos, também chamados potenciais de ação. Para que o potencial de ação seja gerado, o valor do potencial de membrana dos neurônios deve alcançar seu limiar. Assim, o parâmetro utilizado para a verificação do aprendizado da rede é o potencial de membrana.

Outro ponto a ser justificado é que os simuladores que atualmente implementam redes neurais compostas por neurônios *spiking*, chamadas redes neurais pulsadas, não apresentam uma forma de visualização que permite acompanhar os estados dos neurônios no decorrer da simulação. Por esse motivo, o desenvolvimento de uma ferramenta gráfica que mostre a variação do potencial de membrana de cada neurônio e qual o estado em que este se apresenta foi a maior inspiração para este trabalho.

1.4 Estruturação do Texto

Visando apresentar os conceitos que fundamentam o trabalho, o capítulo 2 inicia com a apresentação dos elementos biológicos que dão base ao simulador. A abordagem é feita a partir do sistema maior, no caso o Sistema Nervoso, até chegar às unidades que o compõem, os neurônios e sinapses. Apresenta também as formas de aprendizado, destacando aquelas utilizadas pela ferramenta proposta. Além disso, apresenta o conceito de comportamentos biológicos que podem ser simulados pela ferramenta, tal como os comportamentos de reflexos e os geradores centrais de padrão.

Ainda no intuito de contextualizar o trabalho ao leitor, o capítulo 3 apresenta uma explanação dos modelos de redes neurais, contextualizando os modelos de neurônios artificiais tradicionais e os modelos de neurônios *spiking*. Após, é fornecido o conceito de redes neurais pulsadas, que são redes formadas por neurônios *spiking*. O destaque é dado para a rede desenvolvida no simulador *Hi-NOON*, uma rede hierárquica de neurônios orientada a objetos, a qual é tomada como base para o simulador proposto neste trabalho. Neste capítulo é ainda apresentada uma idéia sobre as aplicabilidades das

redes neurais no campo da robótica, uma vez que o simulador proposto permite simular artefatos inteligentes, tais como robôs.

No capítulo seguinte, o cerne do trabalho, é apresentado o modelo de rede neural proposto que é concebido a partir das modificações do modelo de rede neural do *Hi-NOON*. Além disso, é apresentado em detalhes a implementação do SPINS – *Spiking Neurons Simulator*, que é a ferramenta de simulação proposta neste trabalho. No capítulo 5 é apresentado um exemplo de aplicação do simulador usando um modelo de robô autônomo baseado em inspiração biológica (ARBIB).

Por fim são apresentadas as considerações finais e as possibilidades de trabalhos futuros, que permitem dar prosseguimento ao trabalho neste campo ainda aberto de pesquisa.

2 FUNDAMENTAÇÃO BIOLÓGICA

Para que se possa simular um sistema nervoso como é proposto neste trabalho, primeiramente é necessário definir qual ser vivo será tomado como base.

Os elementos fundamentais do sistema nervoso – neurônios e sinapses – apresentam características e comportamentos semelhantes em todos os seres vivos, não mostrando diferença significativa em sua complexidade. Por isso, o estudo destes elementos pode ser feito sobre o sistema nervoso do ser humano.

Contudo, à medida que se passa a estudar a associação desses elementos e os comportamentos que emergem a partir destas associações, faz-se necessário o estudo de sistemas mais simples. Para isso, os cientistas das áreas de Neurociências e demais áreas correlatas, realizam estudos em invertebrados, que são seres que apresentam sistema nervoso mais simples, em comparação com o sistema nervoso humano. Além disso, são encontradas no sistema nervoso destes seres outras características que facilitam o estudo, que segundo Bear et al. [3] são: facilidade na identificação de neurônios (por apresentarem grandes células), facilidade na visualização dos circuitos neurais e simplicidade genética.

Assim, para efeito de estudo, a *Aplysia californica* - um molusco marinho com sistema nervoso extremamente simples, mas que apresenta comportamentos de locomoção, busca de comida, fuga de predadores entre outros comportamentos vitais [4] - é um tipo de invertebrado amplamente utilizado. Além disso, este molusco apresenta uma característica especial: a capacidade de modificar seu comportamento de acordo às necessidades e desafios do ambiente. Essa capacidade é possível através de formas de aprendizado que esse ser apresenta, através dos métodos de habituação, sensibilização e condicionamento clássico.

Para verificar como ocorre o funcionamento do sistema nervoso, as iterações entre neurônios e sinapses, a concepção das formas de aprendizado e demais comportamentos abordados neste trabalho, as seções subsequentes apresentam cada um destes itens individualmente.

2.1 Sistema Nervoso

O Sistema Nervoso tem como principal função processar as informações que chegam através de suas unidades de entrada - os neurônios sensoriais -, transmiti-las pelas vias aferentes até o Sistema Nervoso Central (SNC) e enviá-las através das vias eferentes para suas unidades de saída - os neurônios motores. Os neurônios sensoriais e os motores constituem o elo de ligação entre SNC e o ambiente externo (estando aqui incluído na definição de ambiente o próprio organismo que está sendo controlado pelo sistema nervoso). Este elo recebe o nome de Sistema Nervoso Periférico (SNP). O processamento de suas informações permite com que funções importantes do organismo sejam coordenadas e executadas, tais como respiração, reflexos, emoções, memória entre tantas outras funções vitais.

O Sistema Nervoso dos seres humanos pode ser dividido então em duas grandes partes: SNC e SNP [5]. Como é possível se visualizar na Figura 2.1, o SNC fica localizado na parte axial, sendo composto pelo encéfalo e medula espinhal; já o SNP localiza-se na parte apendicular e é formado por nervos e gânglios.

O SNC dos seres humanos é formado por mais de 100 bilhões de neurônios, onde cada neurônio pode ter até 100.000 conexões sinápticas [3,6], por onde é transmitida a informação neural. Cada uma destas unidades que compõem o sistema nervoso, por terem grande importância para o trabalho, será discutida nas seções que se seguem.

O encéfalo possui três partes comuns nos mamíferos: cérebro, cerebelo e tronco cerebral [3]. O cérebro é a parte maior do encéfalo, ficando localizado na parte frontal da caixa craniana. É dividido ao meio pela fissura sagital, onde cada lado controla os movimentos e sensações do lado oposto do corpo: o lado direito do cérebro controla a parte esquerda do corpo e vice e versa. O cerebelo é uma pequena parte do encéfalo, mas que contém o mesmo número de neurônios que o cérebro. Fica localizado atrás do cérebro e sua principal função é o controle dos movimentos. O tronco cerebral é um ponto de ligação entre encéfalo e medula espinhal, o qual capta informações do cérebro e leva para o cerebelo e medula espinhal e destes para o cérebro novamente. Além disso, controla funções vitais tais como respiração e controle de pressão arterial.



Figura 2.1 Representação esquemática da constituição morfofuncional do sistema nervoso de vertebrados.
(Extraído de Erhart [5])

A medula espinhal localiza-se na coluna vertebral, onde faz ligação com o tronco cerebral. Sua função é captar informações, através dos nervos espinhais (que fazem parte do SNP). Estes nervos que partem da pele, articulações, músculos e vísceras onde levam as informações até o cérebro, e após, devolvem a informação processada.

O SNP pode ser dividido em dois: SNP Somático e SNP Visceral. O SNP

2.2 Neurônio

Como visto, o sistema nervoso é capaz de processar informações e transformá-las em saídas efetoras. Para executar esse processamento, o sistema nervoso conta com unidades que possuem a capacidade de captar os estímulos do ambiente e interpretá-los, podendo armazenar a informação resultante ou simplesmente gerar uma resposta, na forma de impulso nervoso. Tais unidades são chamadas de neurônios.

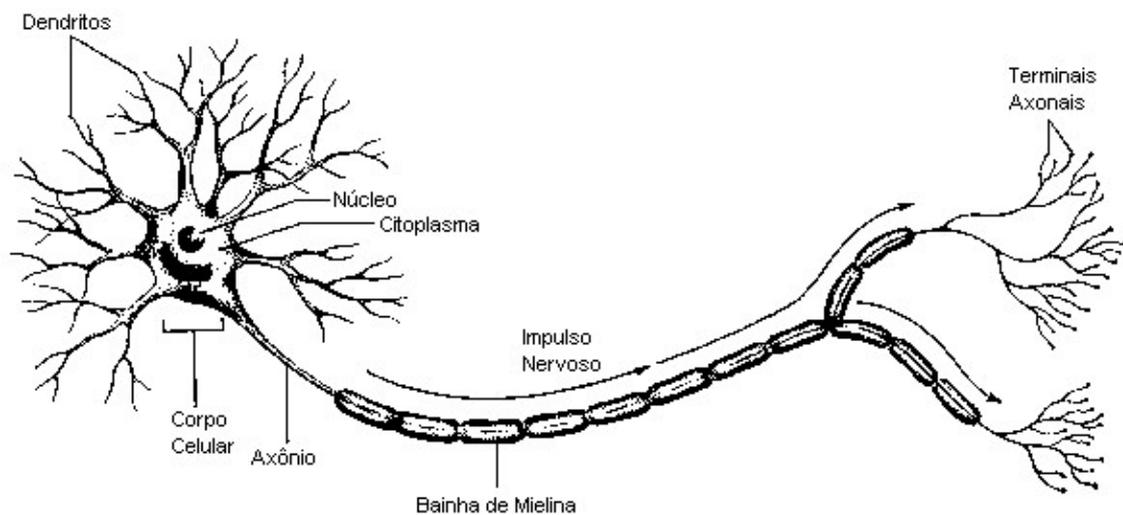


Figura 2.2 Anatomia de um neurônio típico.
(Modificado de Walsh [7])

Um neurônio típico possui a seguinte estrutura (destacadas na Figura 2.2):

Dendritos: são ramificações que partem do corpo celular. Geralmente numerosas e curtas. Cada ramo pode conter milhares de espinhos dendríticos, que são protuberâncias

açã()TJETEMC /Span <</MCI1D 4 >>BDC BT/TT0 1 T004 Tc

Corpo Celular: também conhecido como soma. É a parte central do neurônio que contém o núcleo, onde é armazenada a informação genética. Além disso, possui organelas citoplasmáticas, as quais são fontes geradoras de energia para o neurônio;

Axônio: ramo principal, revestido por uma bainha de mielina. Pode conter ramificações, geralmente menos numerosas que as ramificações dendríticas. Inicia no corpo celular e se ramifica na extremidade terminal, formando os terminais axonais. Sua função é transformar os potenciais elétricos graduados do corpo celular em impulsos nervosos e transmitir os impulsos nervosos para outros neurônios, células musculares ou glândulas, através de conexões sinápticas.

Pela estrutura apresentada é possível visualizar que a informação neural atravessa os neurônios através de impulsos nervosos. Esse impulso começa nas terminações pré-sinápticas – que são fibrilas nervosas que partem de outros neurônios - e se situam sobre a superfície dos dendritos e do corpo celular do neurônio. Após passarem pelo corpo celular, este impulso se dirige através do axônio para a parte terminal do neurônio, onde se dará o processo chamado transmissão sináptica, que é apresentado na seção 2.3.2.1.

2.2.1 Membrana neural e potencial de membrana

A membrana neural é uma parte importante do neurônio, pois a partir dela é que se dá a transmissão de informação. Mais do que um simples delimitador do citoplasma neural, sua principal função é a filtragem de substâncias que entram ou saem do neurônio, criando assim, desequilíbrio na distribuição de íons e moléculas entre o interior e o exterior da membrana.

O potencial de membrana (PM) é o termo utilizado para essa diferença de carga elétrica através da membrana neural.

O estudo do potencial de membrana é de grande valia para esse trabalho, pois este é utilizado como principal variável observada no simulador aqui proposto.

Potencial de Repouso

Nos períodos em que o neurônio não está transmitindo informação, seu potencial de membrana fica em estado de repouso. Para os neurônios do sistema nervoso central, além de outras fibras nervosas, como as do músculo liso, esse valor é próximo aos -65 mV [3,8], sendo o interior da membrana negativo em relação ao exterior, por definição.

O potencial de repouso é gerado pela maior seletividade da membrana à passagem de certos íons (K^+ principalmente) e não de outros (Na^+ , ânions protéicos, por exemplo). Dessa forma, como a concentração de K^+ é maior no interior da célula, este cátion tende a sair para o meio extracelular, através do processo de difusão. Já os íons de Na^+ sofrem o processo inverso: são bombeados para o exterior da célula através da bomba de sódio e potássio (bomba Na^+K^+). Como a saída de Na^+ não é acompanhada pela entrada de K^+ na mesma proporção, é gerado um gradiente elétrico, chamado de potencial de repouso, entre o interior e o exterior da célula, mantendo a membrana neural eletricamente carregada.

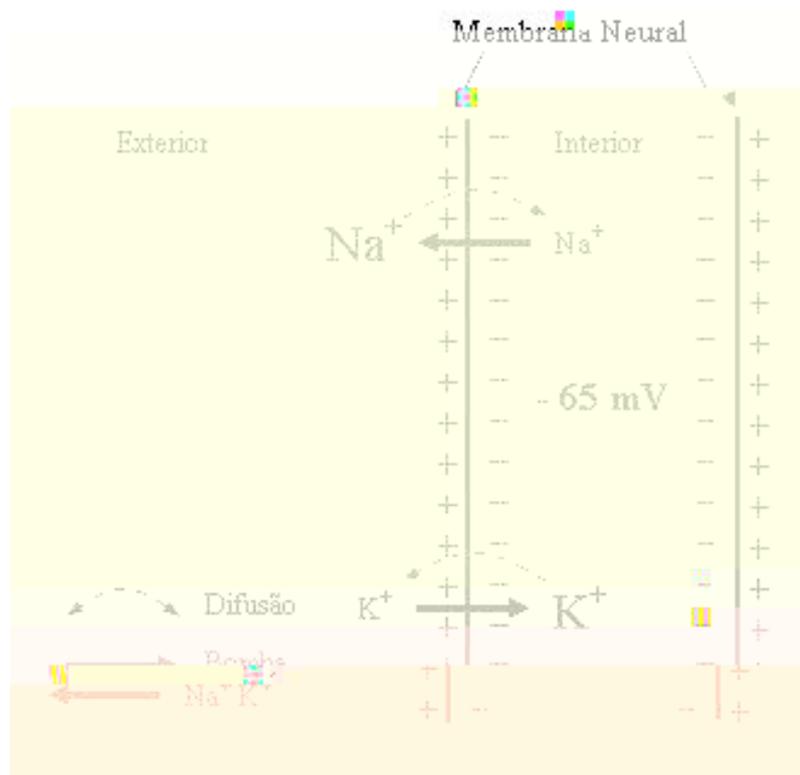


Figura 2.3 Potencial de repouso.
(Modificado de Guyton & Hall [8])

2.2.2 Potencial de ação

Como visto anteriormente, a informação neural, após ser captada pelos dendritos, é transmitida ao longo do neurônio. Essa transmissão ocorre através de rápidas variações do potencial de membrana, que ao ultrapassarem um valor crítico (chamado limiar) se tornam impulsos nervosos ou potenciais de ação (*spikes*). Esses potenciais são caracterizados por sinais oscilatórios, que apresentam a forma de onda conforme a Figura 2.4. Segundo Bear et al. [3], para codificar a informação, os neurônios modificam a frequência de tais ondas.

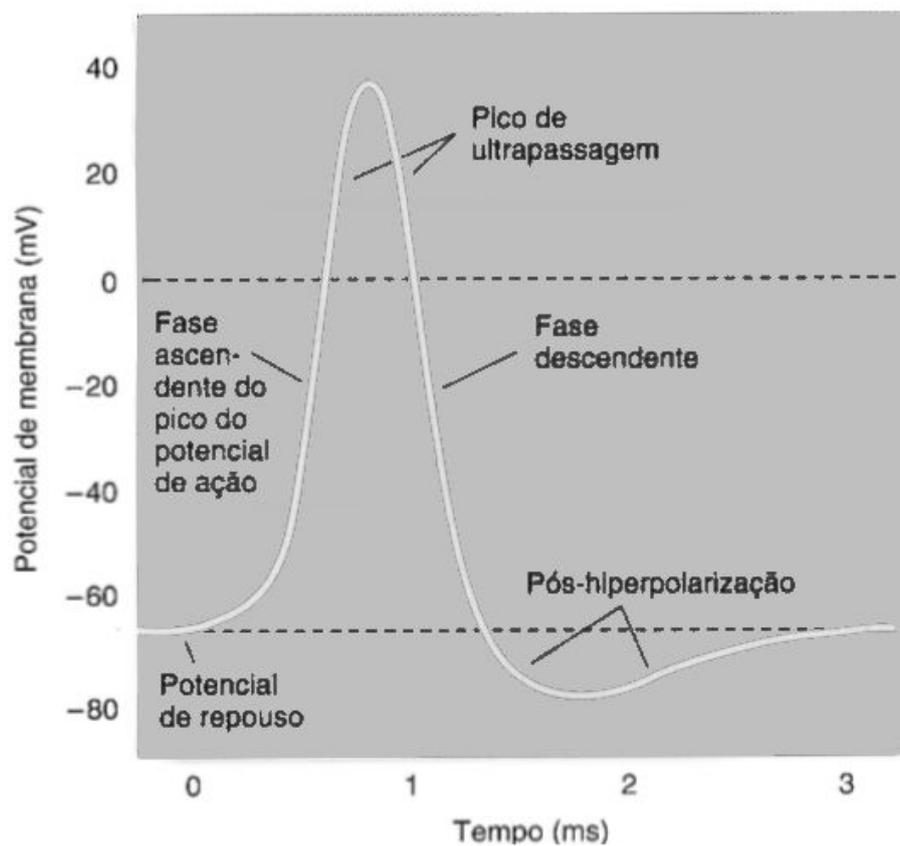


Figura 2.4 Potencial de ação típico, destacando suas fases.
(Modificado de Bear et al.[3])

O Processo de Geração de um Potencial de Ação

A transmissão de informação entre neurônios inicia-se através de fatores químicos, ocasionados pela transmissão sináptica (apresentada na seção 2.3.2.1). Ao chegar ao dendrito, essa informação altera a permeabilidade da membrana e a carga elétrica da mesma, criando o chamado potencial pós-sináptico (PPS). Esse potencial faz com que o valor do PM saia do estado de repouso, podendo assumir valores menos negativos, através de um potencial pós-sináptico excitatório (PPSE), ou mais negativo, potencial pós-sináptico inibitório (PPSI). Porém, para que essa perturbação se torne um potencial de ação, o PM necessita atravessar um valor crítico, conhecido como limiar. Por exemplo, o PM em repouso de um neurônio motor é de -65 mV e o limiar de -45 mV. Assim, para que seja alcançado o limiar, é necessário que chegue ao neurônio um PPSE de pelo menos 20 mV, isto é, que o valor do PM passe do estado de repouso (-65 mV) e ultrapasse o limiar (-45 mV). Porém, como o PPS gerado por um único neurônio apresenta valores entre $0,5$ e 1 mV [8], para que ocorra um potencial de ação, são necessários cerca de 40 a 80 potenciais sinápticos simultâneos.

Segundo Bear et al. [3], a onda característica do potencial de ação pode ser dividida em 5 partes:

1. Potencial de Repouso: estado onde a membrana se encontra polarizada, isto é, o PM se encontra com valor negativo, próximo a -65 mV. É o período que antecede o potencial de ação;
2. Fase Ascendente: nesta fase ocorre uma rápida despolarização da membrana, isto é, o PM tende a ficar menos negativo, podendo se tornar positivo. É nesse estado que o PM atravessa o limiar, iniciando o potencial de ação;
3. Ultrapassagem: estado onde ocorre a inversão da polaridade da membrana, devido ao acúmulo de íons positivos no lado interno da membrana;
4. Fase Descendente: nesta fase do potencial de ação ocorre uma rápida repolarização da membrana (o PM volta a ter valor negativo), chegando às vezes a valores mais negativos que o potencial de repouso, onde a membrana se torna hiperpolarizada;

5. Pós-hiperpolarização: é a última fase do potencial de ação. Neste período, a membrana retorna ao potencial de repouso.

O potencial de ação leva cerca de 2 ms para completar as 5 fases.

2.2.3 Tipos de neurônios

Os neurônios podem ser classificados em diversas categorias [3]: quanto ao número de neuritos, quanto ao tipo de dendrito, quanto ao comprimento do axônio, etc. Mas, devido à importância dada a este trabalho, serão estudadas aqui duas classificações: a primeira é baseada no sinal que é transmitido pelo neurônio, onde dependendo do efeito pós-sináptico (PPSE ou PPSI) do neurotransmissor liberado na sinapse (ver seção 2.3.2.2), o neurônio é classificado como excitatório ou inibitório. A segunda é baseada nas conexões neurais que pode ser aferentes (levando informação ao SNC), interneurais (processando a informação no SNC) ou eferentes (levando a informação aos efetores).

2.2.3.1 Classificação conforme o efeito do sinal transmitido

Podem-se classificar os neurônios através da informação que eles transmitem aos outros neurônios, podendo ser uma mensagem que excita ou inibe os neurônios pós-sinápticos, isto é, neurônios que realizam sinapse com o neurônio emissor da informação. Assim, existem duas grandes classes de neurônios: excitatórios e inibitórios [9].

Os neurônios excitatórios são aqueles que mandam mensagens despolarizantes, isto é, que podem fazer com que o neurônio pós-sináptico dispare (gere um potencial de ação). Essas mensagens são passadas através de sinapses excitatórias (apresentadas na seção 2.3.2.2). Já os neurônios inibitórios transmitem mensagens hiperpolarizantes ou estabilizantes (através das sinapses inibitórias), que fazem com que o neurônio pós-sináptico seja inibido, isto é, que não gere um potencial de ação.

2.2.3.2 Classificação conforme o tipo de conexão neural

Existem nessa classificação três tipos de neurônios: sensoriais, interneurônios e motores. Os neurônios sensoriais, ou aferentes, captam informação dos receptores sensoriais e levam ao cérebro; os interneurônios fazem ligação com os neurônios sensoriais, processando a informação; e por último, os neurônios motores, ou eferentes, que levam a informação processada pelos interneurônios aos músculos e glândulas. Um circuito neural que mostra estes três tipos de neurônios trabalhando em conjunto é o circuito do arco reflexo, apresentado na seção 2.5.1.

Através da Figura 2.5 é possível visualizar as diferentes características que cada tipo de neurônio apresenta.

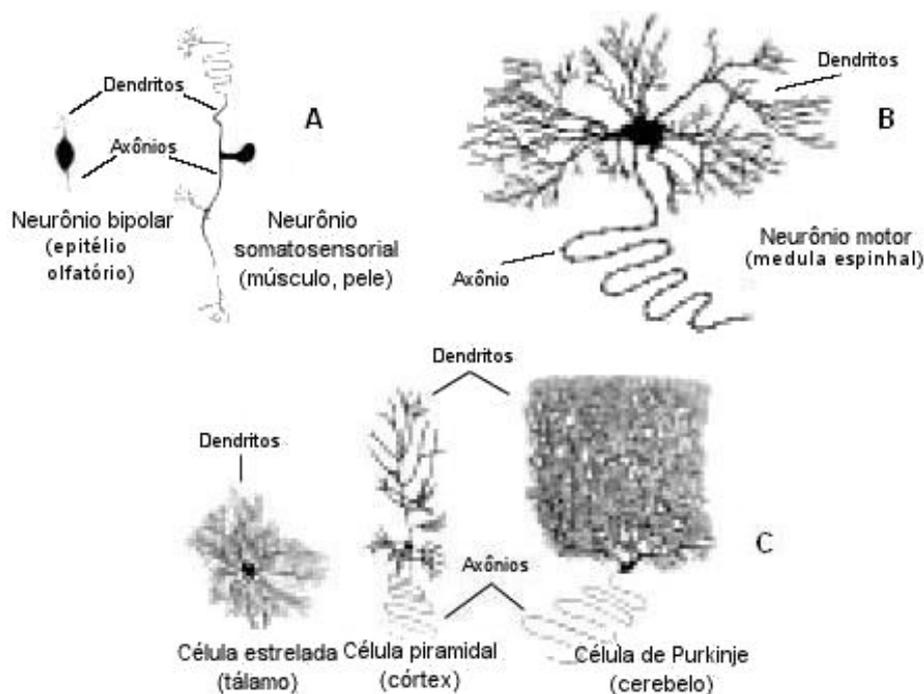


Figura 2.5 Tipos de neurônios.

A. Neurônios sensoriais; B. Neurônio motor; C. Interneurônios.
(Modificado de Kolb & Whishaw [10])

Neurônio Sensorial

Esse tipo de neurônio tem como função captar os estímulos do ambiente, tais como pressão, luz, temperatura, entre outros, e transformá-los em sinais nervosos que

serão processados pelo sistema nervoso. O resultado do processamento pode gerar uma reação imediata ou ser armazenado pelo cérebro para determinar ações futuras.

Os estímulos são captados através dos receptores sensoriais (células neurais ou não neurais). Nas células neurais, o efeito do estímulo é a geração de um potencial receptor, que é caracterizado pela alteração do potencial de membrana do receptor. Assim, os receptores podem ser classificados conforme a geração do potencial receptor [8]:

Mecanoreceptores: sofrem deformação mecânica do receptor (estiramento da membrana). São, por exemplo, os receptores táteis, auditivos, de equilíbrio e de pressão arterial;

Termoreceptores: detectam a alteração de temperatura (que altera a permeabilidade da membrana). São, por exemplo, os receptores de frio e calor;

Receptores Eletromagnéticos: sofrem efeito da radiação eletromagnética (altera permeabilidade da membrana). São, por exemplo, os receptores da visão;

Quimiorreceptores: detectam a presença de substâncias químicas na membrana. São os receptores da gustação, olfato, oxigênio, CO₂, etc.

O potencial receptor tem funcionamento similar ao potencial de membrana: uma vez que seu valor ultrapassa o limiar, inicia-se a geração de potenciais de ação no neurônio sensorial. Assim, quanto maior a intensidade do estímulo, maior é seu potencial receptor e conseqüentemente, maior a freqüência dos potenciais de ação. Porém, os receptores sensoriais possuem uma característica de adaptação ao estímulo, isto é, quando é aplicado um estímulo contínuo, os receptores apresentam uma queda progressiva da amplitude do potencial receptor e conseqüentemente, da freqüência dos potenciais de ação, até não apresentarem mais nenhuma resposta ao estímulo aplicado.

Essa característica de adaptação ao estímulo deve ser levada em consideração no estudo dos neurônios sensoriais, uma vez que se procura com esse trabalho simular características dos neurônios do SNC.

Interneurônios

Também conhecidos como células de associação [10] ou neurônios de circuito local [11], os interneurônios ligam os neurônios sensoriais aos neurônios motores, ou ligam-se entre si, servindo como ponto de convergência e integração entre os neurônios do SNC. Possuem uma característica que os difere dos demais tipos de neurônios: apresentam o corpo celular e o axônio completamente dentro do SNC [12]. Esse tipo de neurônio representa aproximadamente 95% dos neurônios do SNC.

Esses neurônios podem assumir o papel de elementos lógicos no sistema nervoso, executando operações de “E” e “OU” com suas entradas [12]. Mas para que essas operações lógicas sejam executadas, os neurônios que chegam ao interneurônio devem disparar ao mesmo tempo ou com intervalo muito próximo. Esse comportamento do interneurônio será melhor discutido no capítulo sobre Redes Neurais Artificiais (capítulo 3).

Neurônio Motor

Esse tipo de neurônio é responsável pelas funções motoras do sistema nervoso: contração dos músculos esqueléticos, lisos e cardíaco e secreção das glândulas exócrinas. Apresentam seu corpo celular na medula espinhal e no tronco, mas seus axônios se estendem por várias partes do corpo, atuando sobre as fibras musculares. Desta forma, segundo o padrão de impulsos que ele gera, as fibras musculares irão contrair ou relaxar [2].

2.3 Sinapse

A sinapse é o ponto de “contato” entre um neurônio e outra célula (neurônio, músculo ou glândula), para a transmissão de informação. O neurônio que envia a informação é chamado neurônio pré-sináptico, já o que recebe a informação é o neurônio pós-sináptico. Na maioria das sinapses (apresentadas na seção 2.3.2), a transmissão sináptica é feita através de um espaço, a fenda sináptica, onde são lançadas as substâncias mensageiras, chamados neurotransmissores.

Como descrito acima, o principal papel das sinapses é transmitir informações entre os neurônios e seus alvos. Mas elas também desempenham outras funções como:

Determinar a direção em que o impulso nervoso trafega pelo sistema nervoso;

Atuar como seletora de sinais, onde bloqueiam os impulsos mais fracos e permitem a passagem dos fortes;

Atuar no armazenamento de informações (o que gera a memória), através do processo chamado facilitação: após os impulsos nervosos passarem um grande número de vezes por uma sinapse, essa se torna facilitada, fazendo com que ela dispare de forma mais eficiente (aumento do ganho sináptico);

Modificar os impulsos nervosos, fazendo com que se tornem repetitivos ou sejam integrados para gerar padrões.

Existem dois tipos de sinapses: sinapses elétricas e sinapses químicas. A diferença básica entre elas está no modo de transmissão, como é possível se observar na Figura 2.6.

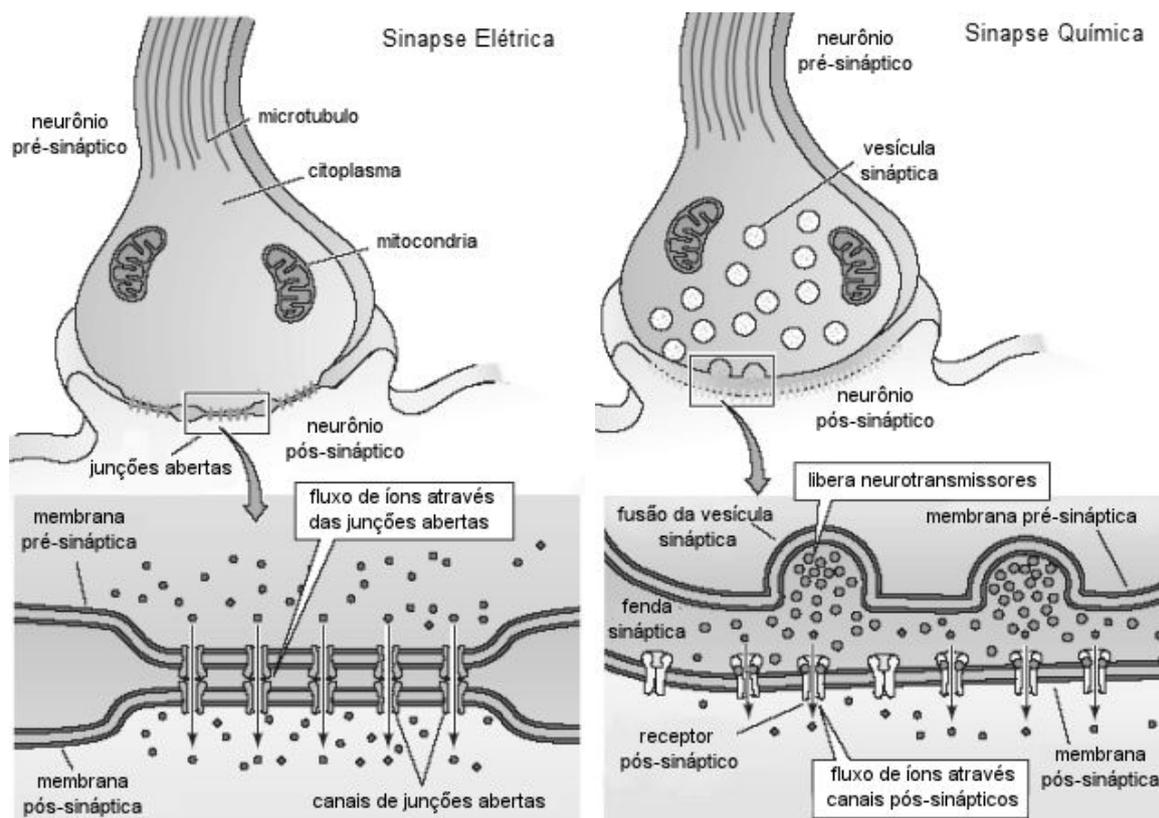


Figura 2.6 Comparação entre sinapse elétrica e sinapse química.
(Modificado de Purves et al. [11])

2.3.1 Sinapses elétricas

As sinapses elétricas permitem a passagem direta de sinais elétricos entre os neurônios pré e pós-sináptico. Essa transmissão é feita através de canais chamados junções abertas (*gap junction*), que por serem canais largos, permitem a passagem dos da maioria dos íons celulares, além de permite a passagem de pequenas moléculas orgânicas.

Devido a seus canais, a transmissão através das sinapses elétricas é muito rápida, não havendo um atraso na transmissão como acontece nas sinapses químicas. Além disso, a transmissão pode ser bidirecional, onde a informação pode atravessar os canais em direção tanto ao neurônio pré-sináptico quanto ao neurônio pós-sináptico.

Esse tipo de sinapse representa a minoria das sinapses do SNC dos mamíferos, pois são encontradas somente em locais que requerem uma grande sincronização de

sinais e também em células não neurais [3]. Mas, em outros animais, tais como os invertebrados, esse tipo de sinapse é comum, pois seu sistema nervoso necessita de transmissão sináptica rápida, para assim, por exemplo, ter uma resposta rápida diante predadores [3,11].

2.3.2 Sinapses químicas

As sinapses químicas são as mais comuns do SNC dos mamíferos. O maior benefício desse tipo de sinapse é a capacidade de controlar a passagem de informação entre neurônios.

A transmissão da informação na sinapse química é feita via secreção de neurotransmissores, que são agentes químicos que atuam sobre as proteínas receptoras da membrana do neurônio pós-sináptico. O efeito do neurotransmissor é alterar a permeabilidade da membrana do neurônio pós-sináptico.

Segundo Guyton & Hall [8] e Purves et al. [11], os neurotransmissores podem ser classificados em dois grandes grupos: transmissores de molécula pequena e neuropeptídeos.

Os transmissores de molécula pequena possuem ação rápida, isto é, o sinal transmitido pela sinapse que possui esse tipo de neurotransmissor é transmitido de forma mais rápida. Esses transmissores atuam nas sinapses sensoriais que enviam informação ao cérebro e, nas sinapses neuro-musculares que atuam sobre os músculos (apresentadas na seção 2.3.2.3). Exemplos de neurotransmissores de molécula pequena são ácido gama-aminobutírico (GABA), glutamato, acetilcolina e óxido nítrico.

Os neuropeptídeos, por serem moléculas grandes, atuando de forma mais lenta e prolongada. Seus efeitos sobre a sinapse são: alteração a longo prazo do número de receptores, abertura e fechamento de certos canais iônicos de forma mais lenta e, conseqüentemente, alteração do número ou tamanho das sinapses. Os neuropeptídeos mais conhecidos são os da família dos opióides e a substância P.

Nas próximas seções será apresentado como ocorre a transmissão de informação nas sinapses químicas e como estas podem ser classificadas.

2.3.2.1 Transmissão sináptica

A transmissão sináptica se dá através de uma sequência de passos, como descritos a seguir:

1. Inicialmente ocorre a despolarização da membrana do terminal axonal, que é causada por um impulso nervoso que chega ao neurônio pré-sináptico.
2. A despolarização faz com que vesículas sinápticas, as quais são bolsas que armazenam os neurotransmissores, movam-se em direção à membrana pré-sináptica.
3. As vesículas então se fundem com a membrana, liberando os neurotransmissores, que são lançados na fenda sináptica (espaço entre os neurônios pré e pós-sináptico).
4. Após atravessarem a fenda sináptica, os neurotransmissores se ligam aos receptores pós-sinápticos, que são proteínas localizadas na membrana pós-sináptica.
5. Os receptores pós-sinápticos, quando ativados, podem causar a excitação ou inibição do neurônio pós-sináptico (conforme descrito na seção 2.3.2.2).
6. Em ambos os casos (excitação ou inibição), a ativação dos receptores pós-sinápticos causa alteração de permeabilidade da membrana pós-sináptica e, portanto produzem uma diferença de concentração de íons através da mesma.
7. Essa diferença de concentração de íons faz com que a voltagem da membrana seja alterada, gerando assim um PPS, que retira a membrana do estado de repouso, e pode desencadear um potencial de ação, se for PPSE, como visto na seção 2.2.2.
8. Para controlar o seu efeito sobre a membrana pós-sináptica, o neurotransmissor é removido ou destruído por enzimas específicas para cada tipo de neurotransmissor.

2.3.2.2 Classificação conforme o efeito do neurotransmissor

A principal diferença entre a sinapse excitatória e a inibitória é o tipo de PPS que estas geram. As sinapses excitatória geram um PPSE, onde o efeito do neurotransmissor sobre a membrana é causar uma despolarização, isto é, o PM fica menos negativo. Já nas sinapses inibitórias o efeito é o inverso: o neurotransmissor faz com que o PM fique mais negativo, causando uma hiperpolarização na membrana pós-sináptica, o que gera um PPSI.

O efeito das sinapses excitatórias e inibitórias sobre o neurônio resultam na alteração do seu estado. Diz-se que um neurônio está excitado quando o somatório das sinapses excitatórias é maior que as inibitórias, o que permite que seja gerado um potencial de ação. Mas, se o efeito das sinapses inibitórias é maior que as excitatórias têm-se um neurônio inibido.

Vale ressaltar aqui que quanto mais próxima a sinapse estiver do corpo celular ou do axônio do neurônio, maior é seu efeito, pois é menor o caminho que o sinal tem de percorrer até o início do axônio, onde se inicia o potencial de ação.

2.3.2.3 Classificação conforme o tipo de conexão

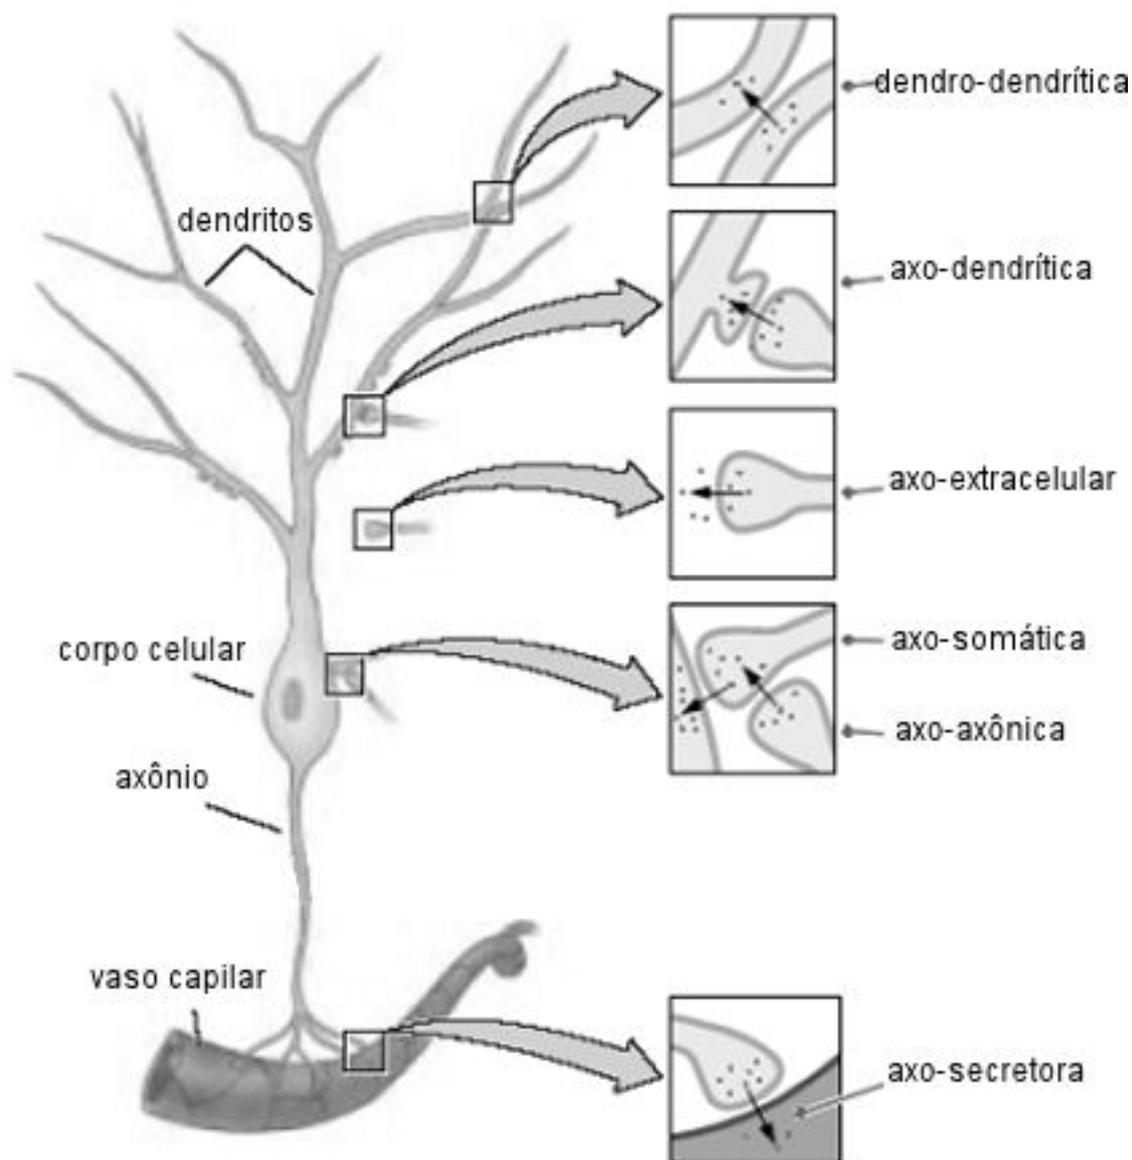


Figura 2.7 Tipos de sinapses.
(Modificado de Kolb & Whishaw [10])

As sinapses podem ser classificadas conforme o tipo de conexão, isto é, quais as partes envolvidas na conexão sináptica, como mostrado na Figura 2.7. Essas podem ser partes do neurônio (dendrito, corpo celular ou axônio), estruturas como vasos sanguíneos ou músculos, ou ainda o meio extracelular. Segundo Kolb & Whishaw [10], a classificação é assim apresentada:

Dendro-dendríticas: a transmissão sináptica ocorre entre dois dendritos;

Axo-dendrítica: o terminal axonal do neurônio pré-sináptico faz sinapse com o dendrito do neurônio pós-sináptico;

Axo-extracelular: a sinapse ocorre no meio extracelular, não havendo, portanto, um ponto específico no neurônio pós-sináptico para realizar a transmissão;

Axo-somática: o terminal axonal do neurônio pré-sináptico faz sinapse com o corpo celular do neurônio pós-sináptico;

Axo-axônica: o terminal axonal termina no terminal axonal de outro neurônio;

Axo-secretora: a sinapse é feita entre o terminal axonal do neurônio pré-sináptico e um vaso sanguíneo, onde os neurotransmissores são secretados diretamente no sangue;

Axo-muscular: o axônio do neurônio motor faz sinapse com o músculo.

Segundo Bear et al. [3] e Kolb & Whishaw [10], as sinapses feitas com os dendritos, como as axo-dendríticas e dendro-dendríticas, são tipicamente excitatórias. Já as sinapses realizadas com o corpo celular, no caso as axo-somáticas, ou com o terminal axonal (axo-axônicas), são geralmente inibitórias.

2.4 Aprendizado

O ser humano, assim como outros animais, tem a capacidade de aprender. O aprendizado, do ponto de vista da Neurociência, é a habilidade das sinapses neurais de se adaptarem como resultado de experiências vividas pelo organismo [10].

Segundo a descoberta de Hebb² *apud* Kolb & Whishaw [10], o aprendizado ocorre através de mudanças estruturais nas sinapses. Tais sinapses, que possuem a capacidade de adaptação, são conhecidas como *sinapses de Hebb* [10,12]. Assim, para que seja aprendida uma nova informação, estas sinapses precisam ter seu peso sináptico alterado, ocorrendo assim o aprendizado de Hebb ou do tipo Hebbiano. Esse é o principal ponto observado ao se explicar sobre as formas de aprendizado, mostradas nas próximas seções.

Como dito no início desse capítulo, o estudo das formas de aprendizado será apresentado sobre a *Aplysia californica*, um invertebrado com a capacidade de aprender através de um aprendizado procedural, onde apresenta uma resposta motora em reação a uma entrada sensorial [3].

O comportamento estudado na *Aplysia* é seu reflexo defensivo, onde ocorre o recolhimento de suas partes vulneráveis - brânquia (por onde realiza a respiração) e sifão (por onde excreta água marinha e excrementos) - quando se sente ameaçada. A *Aplysia* e as partes apresentadas durante o estudo do aprendizado estão destacadas na Figura 2.8.

² HEBB, Donald O. **The organization of behavior**. New York: Wiley, 1949.

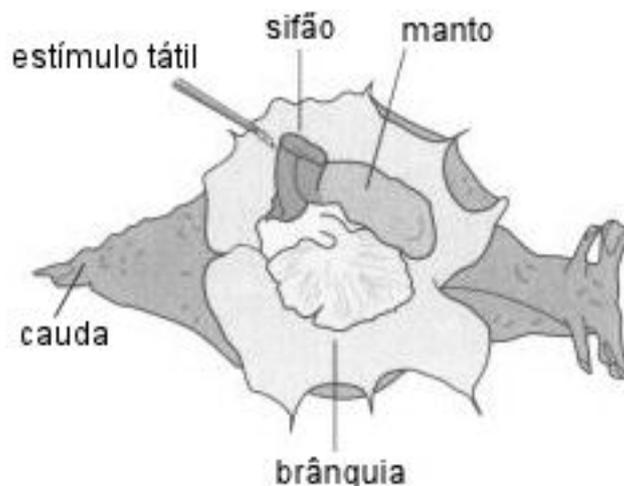


Figura 2.8 A *Aplysia*.
(Modificado de Kandel et al.[13])

O processo de aprendizado é discutido devido à importância deste assunto para este trabalho, uma vez que o simulador utiliza as formas de aprendizado que são aqui discutidas.

2.4.1 Formas de aprendizado

O aprendizado pode ser dividido em dois tipos: não-associativo e associativo. Segundo Bear et al. [3], o aprendizado não-associativo “descreve a mudança na resposta comportamental que ocorre ao longo do tempo em resposta a um único tipo de estímulo”. Dois tipos de aprendizado que se enquadram nessa categoria: habituação e sensibilização, apresentados na seção 2.4.1.1 e 2.4.1.2.

A outra forma de aprendizado, o aprendizado associativo, se refere à associação de eventos, onde ocorre a ligação de estímulos não relacionados. Existem dois tipos de aprendizados associativos: condicionamento clássico e condicionamento instrumental. Esse trabalho se limita ao condicionamento clássico, que é apresentado na seção 2.4.1.3.

É importante destacar aqui que as formas de aprendizado estudadas (habituação, sensibilização e condicionamento clássico) são aprendizados de curta duração, isto é, após algum tempo o comportamento aprendido é “esquecido”. Para que se tornem aprendizados de longa duração, o período de cada experiência ou o número de experiências do aprendizado deve ser maior. Esses períodos e número de tentativas

variam para cada tipo de aprendizado, mas não serão levados em consideração, pois o aprendizado de longa duração não é o objetivo deste trabalho.

Nas próximas seções será apresentada uma idéia geral sobre cada uma das formas de aprendizado. Maiores informações podem ser encontradas em [3,8,10,11,12].

2.4.1.1 Habituação

A habituação é uma forma de aprendizado onde o indivíduo aprende a ignorar estímulos fracos, que não trazem benefícios nem prejudicam. Para o ser humano, essa forma de aprendizado é utilizada a todo o momento. Por exemplo, quando se está em um lugar onde existem carros que passam próximo, inicialmente o barulho dos carros é percebido, mas passado algum tempo, o som dos carros passa a não ser mais notado. Isso resulta da habituação a esse estímulo sonoro.

Para o estudo da habituação, o comportamento analisado na *Aplysia* é o reflexo de recolhimento da brânquia. Esse reflexo inato ocorre após o sifão ter sido excitado através de um estímulo tátil (ver Figura 2.9). Segundo os estudos de Kandel et al. [13], ao se estimular repetidamente o sifão, a *Aplysia* aprende a não apresentar mais contração do músculo de recolhimento da brânquia, se tornando habituada ao estímulo.

Do ponto de vista neural, a habituação ocorre devido à diminuição da força sináptica entre os interneurônios e neurônios motores, isto é, menos neurotransmissores são liberados entre esses neurônios. O resultado é que o potencial de membrana do neurônio motor se torna menor, fazendo com que o músculo da brânquia não apresente mais resposta.

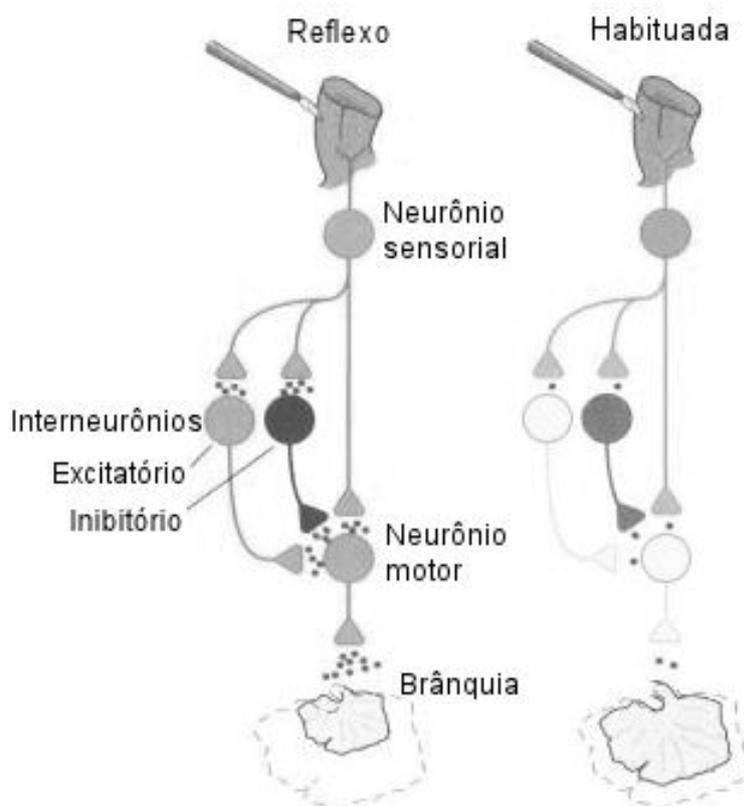


Figura 2.9 O circuito reflexo da *Aplysia* e sua habituação.
(Modificado de Kandel et al. [13])

2.4.1.2 Sensibilização

A sensibilização, ao contrário da habituação, é um tipo de aprendizado onde o indivíduo aprende a ter uma resposta mais intensa aos estímulos que previamente não evocavam nenhum tipo de reação. Porém, de modo similar à habituação, é um tipo de aprendizado utilizado constantemente. Por exemplo, depois que uma pessoa ouve um forte barulho, como em uma batida de carro ou uma explosão, pequenos ruídos passam a assustá-la, sendo que se não fosse antecedido pela barulho, esses ruídos nem seriam percebidos.

O comportamento observado na *Aplysia* para a verificação da sensibilização é o mesmo da habituação: o reflexo de recolhimento da brânquia. Verifica-se que, se este reflexo for precedido por um estímulo (toque ou choque elétrico) aplicado em sua cauda, em um curto espaço de tempo, o reflexo será mais intenso. Assim, ao se tocar no sifão (após ocorrer o toque na cauda), a *Aplysia* apresentará um recolhimento da

brânquia por um tempo maior que seu reflexo normal, mostrando que ocorreu uma sensibilização deste comportamento.

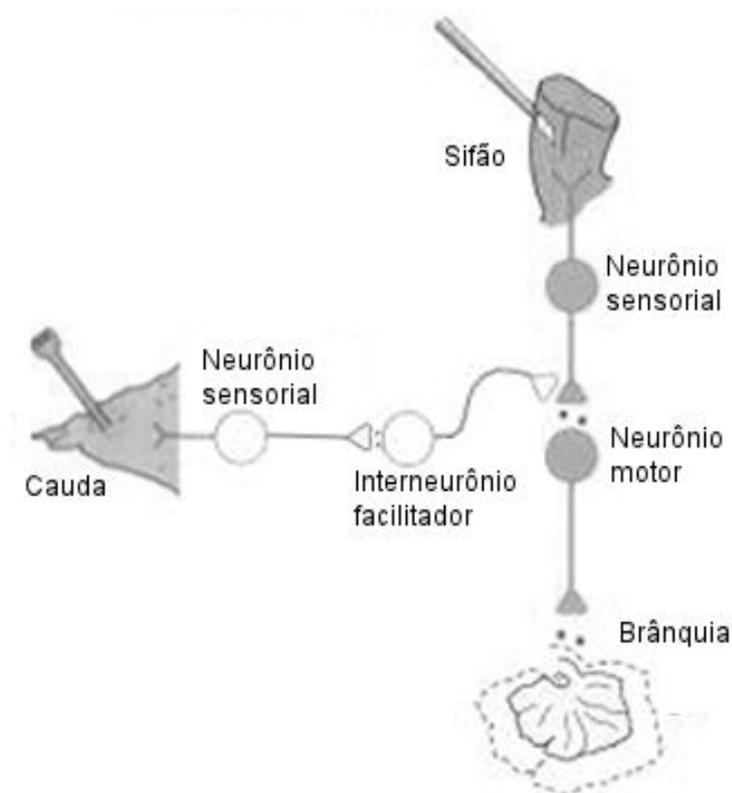


Figura 2.10 Circuito de sensibilização da *Aplysia*.
(Modificado de Kandel et al. [13])

Essa forma de aprendizado ocorre devido ao mecanismo de facilitação, como mostrado na Figura 2.10. O estímulo na cauda da *Aplysia* faz com que seu neurônio sensorial seja acionado. Este neurônio excita o interneurônio facilitador, que libera neurotransmissores na sinapse axo-axônica, realizada com o neurônio sensorial do sifão. Esse neurotransmissor, a serotonina, faz com que o potencial de ação do neurônio sensorial seja prolongado, tornando a *Aplysia* mais sensível aos estímulos no sifão e conseqüentemente, seu reflexo de recolhimento da brânquia será mais duradouro.

2.4.1.3 Condicionamento clássico

O condicionamento clássico ocorre através da associação de dois tipos de estímulos: um estímulo incondicionado (EI), o qual gera uma resposta inata, incondicionada (RI), isto é, sem qualquer aprendizado; e um estímulo neutro (EN), o qual não gera nenhuma resposta, se apresentado sozinho. O resultado deste tipo de aprendizado é uma resposta condicionada (RC), onde o estímulo incondicionado passa a ser um estímulo condicionado (EC).

Esse aprendizado, também conhecido como condicionamento Pavloviano [12], como o nome sugere, surgiu através das pesquisas de Ivan Pavlov, um fisiologista russo que estudava a digestão em cães. Durante seus experimentos, Pavlov notou que os cães salivavam (RI) ao ver a comida (EI). Com isso, resolveu testar se os cães apresentavam o mesmo comportamento ao tocar um sino ao apresentar a comida. Assim, seu experimento consistia em: a cada vez que mostrasse um pedaço de carne (EI), toca-se um sino (EN), e ele verificou que os cães continuavam a salivar (RI). Ele notou que após ter mostrado algumas vezes a carne e tocado o sino, os cães salivavam somente ao tocar o sino. Como resultado, cada vez que o cão ouvia o sino (EC), resposta era salivar (RC), comprovando assim o condicionamento do cão.

Tabela 2.1 Experimento de Pavlov.

Estímulo	Resposta
Sino (EN)	→ Nenhuma
Carne (EI)	→ Salivar (RI)
Sino (EN) + Carne (EI)	→ Salivar (RI)
Sino (EC)	→ Salivar (RC)

Pode-se resumir o experimento de Pavlov através do esquema apresentado na Tabela 2.1.

Para que ocorra o aprendizado por condicionamento, algumas regras devem ser seguidas [3,12]:

EC (sino) deve preceder o EI (carne);

EC e EI devem ser apresentados simultaneamente ou em um curto espaço de tempo;

O intervalo entre EC e EI deve ser definido para cada exemplo de condicionamento.

Na *Aplysia*, o condicionamento clássico apresenta o mesmo resultado da sensibilização: o aumento da intensidade do reflexo de recolhimento da brânquia. Assim, ao se estimular o sifão ou o manto (ECs),

Porém, esse reflexo pode ser obtido através da associação dos estímulos sobre o sifão ou sobre o manto (EC), juntamente com o estímulo sobre a cauda (EI), como mostrado na Figura 2.11. Assim, para que haja o condicionamento, é necessário que o sifão (ou manto) seja estimulado e logo após a cauda ser estimulada.

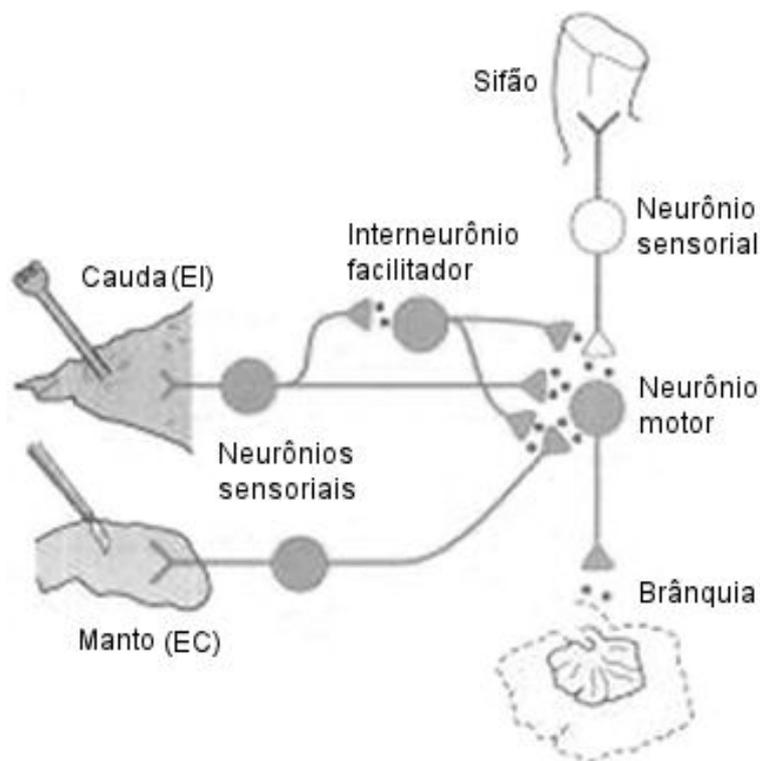


Figura 2.11 Condicionamento clássico na *Aplysia*.
(Modificado de Kandel et al. [13])

Essa possibilidade de escolha do estímulo a ser condicionado se deve pelo fato do interneurônio facilitador (que é ativado pelo estímulo aplicado sobre a cauda (EI)) realizar sinapses axo-axônicas com o neurônio sensorial do sifão e do manto (EC).

Para que ocorra o condicionamento, o EI (sobre a cauda) deve preceder o EC (sobre o manto ou sifão) com um intervalo de 0,5 s. Se a precedência e o intervalo forem respeitados, será obtido o aprendizado por condicionamento clássico.

2.5 Controle Motor

As informações sensoriais captadas pelo SNC podem ser levadas à medula espinhal - gerando uma resposta reflexa, ou podem ser filtradas e processadas por circuitos geradores de padrões - que geram as respostas motoras. Ambas as respostas são executados pelas unidades motoras (associação de neurônio motor e músculo) e geram os comportamentos motores, tais como locomoção, postura, respiração e demais comportamentos relacionados ao controle motor.

Nas próximas seções serão apresentados comportamentos motores simples, tais como reflexos e locomoção, e os mecanismos que fazem emergir tais comportamentos. Através do estudo destes mecanismos, é possível se obter o conhecimento necessário para realizar uma simulação na ferramenta proposta e verificar se tais comportamentos emergem através dos circuitos simulados.

2.5.1 Reflexos

Reflexos são comportamentos motores que emergem de estímulos sensoriais específicos. Tais estímulos necessitam ter certa intensidade ou estar restritos a determinadas regiões do corpo [12]. Exemplos comuns são os reflexos patelar (percussão de um martelo sobre o tendão patelar), reflexo de retirada (mão sobre o fogo ou pisar em um prego), reflexo de coçar, reflexo de postura e reflexo de locomoção. Será estudado aqui o exemplo de reflexo que será utilizado no exemplo do simulador: o reflexo de retirada.

O reflexo de retirada, também conhecido como reflexo de flexão [11] ocorre quando algum estímulo ativa os receptores cutâneos (como por exemplo, localizados na mão ou pé) e que, por sua vez, ativa um circuito localizado na medula espinhal que é responsável pela flexão (retirada) do membro estimulado (braço ou perna).

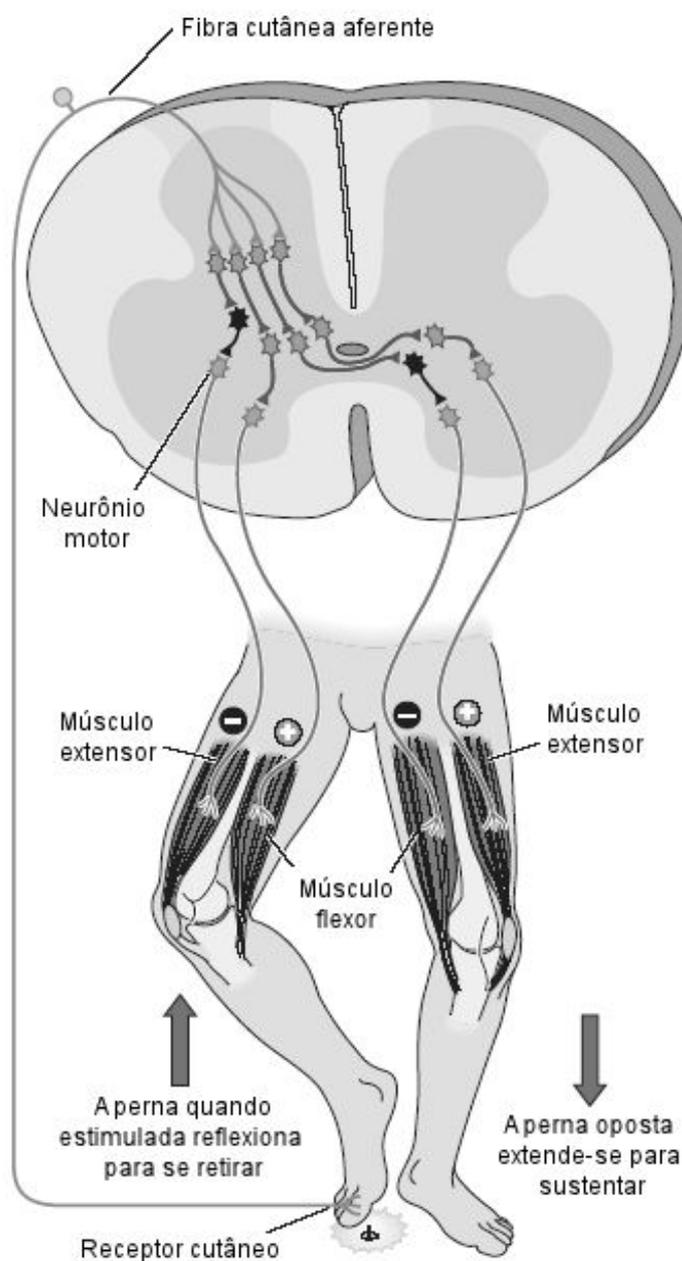


Figura 2.12 Circuito neural de um reflexo de retirada.
(Modificado de Purves et al. [11])

Um exemplo típico do reflexo de retirada é quando uma pessoa pisa em um prego ou tachinha, como mostrado na Figura 2.12. Seu circuito neural funciona da seguinte forma: ao pisar sobre a tachinha, os receptores cutâneos localizados sob o pé são ativados. Esses receptores enviam informações através das fibras aferentes até a medula espinhal. Na medula espinhal, a informação é transmitida aos interneurônios, que por

sua vez, excitam os neurônios motores que se ligam ao músculo flexor e inibem os neurônios motores do músculo extensor, onde ambos os músculos se localizam no mesmo lado em que ocorreu a fonte do estímulo, gerando assim a flexão do membro estimulado (a perna). Já no membro localizado do lado oposto, ocorre uma reação inversa (isto é, os neurônios motores ativam o músculo extensor e inibem o músculo flexor), fazendo com que o membro se estenda, para assim sustentar o corpo.

Esse reflexo é de grande importância, pois serve como base dos comportamentos estudados e utilizados na simulação do exemplo de aplicação proposto.

2.5.2 Geradores centrais de padrão

Os comportamentos rítmicos, tais como respiração, batimento cardíaco e locomoção, são produzidos através de circuitos neurais que apresentam saídas oscilatórias [13,14]. Esses circuitos, chamados geradores centrais de padrão (GCPs), são responsáveis pelo controle do tempo e coordenação de cada comportamento rítmico.

O GCP possui a capacidade de gerar atividade motora rítmica na ausência de entradas sensoriais. Para isso, o GCP depende de 3 grupos de fatores [13, 15]:

Das propriedades de cada um dos neurônios que formam o circuito, tais como: limiar e frequência de disparos; potencial em platô, que é um tipo de potencial de ação mais prolongado, onde a membrana permanece mais tempo despolarizada; ressalto (*rebound*) pós-inibitório, onde o limiar é reduzido a um valor mais negativo que o potencial de repouso; e comportamento endógeno explosivo (*burster*), na qual permite que o neurônio crie seu próprio sinal oscilatório, através de longas seqüências de disparos (explosão).

Das propriedades das sinapses existentes no circuito, entre eles: peso sináptico; tipo (elétrica ou química); e facilitação.

Do padrão de conexão do circuito que pode ser: inibição recíproca ou recorrente; excitatório e inibitório; ou excitação mútua.

Segundo estes fatores, os GCPs dos invertebrados podem ser divididos em três classes [14]:

1. GCPs com comportamento endógeno ou explosivo: nesse grupo não existe um ciclo, o comportamento rítmico é gerado pela capacidade de cada neurônio produzir seu próprio ritmo. Ex: circuito neural que gera o batimento cardíaco das lagostas (Figura 2.13 - A);
2. GCPs cujo ritmo é gerado pela atividade cooperativa de neurônios não-explosivos (*non-bursting*): para que seja produzido um ritmo nesse circuito, os neurônios formam ciclos e, geralmente, suas ligações sinápticas são inibitórias e recíprocas. Para que haja início, esse tipo de GCP recebe uma entrada sensorial ou via neurônio explosivo. Ex: circuito neural que controla comportamento de nadar da *Tritonia*, uma lesma-do-mar (Figura 2.13 - D);
3. GCPs que geram ritmos através da associação de neurônios e redes com propriedades rítmicas, isto é, circuitos formados pelas outras duas classes. Ex: circuitos neurais do batimento cardíaco dos parasitas, da alimentação das lesmas e do comportamento de nadar da *Clione*, um molusco marinho (Figura 2.13 - B, C e E, respectivamente).

Cada um dos circuitos descritos acima pode ser verificado na Figura 2.13.

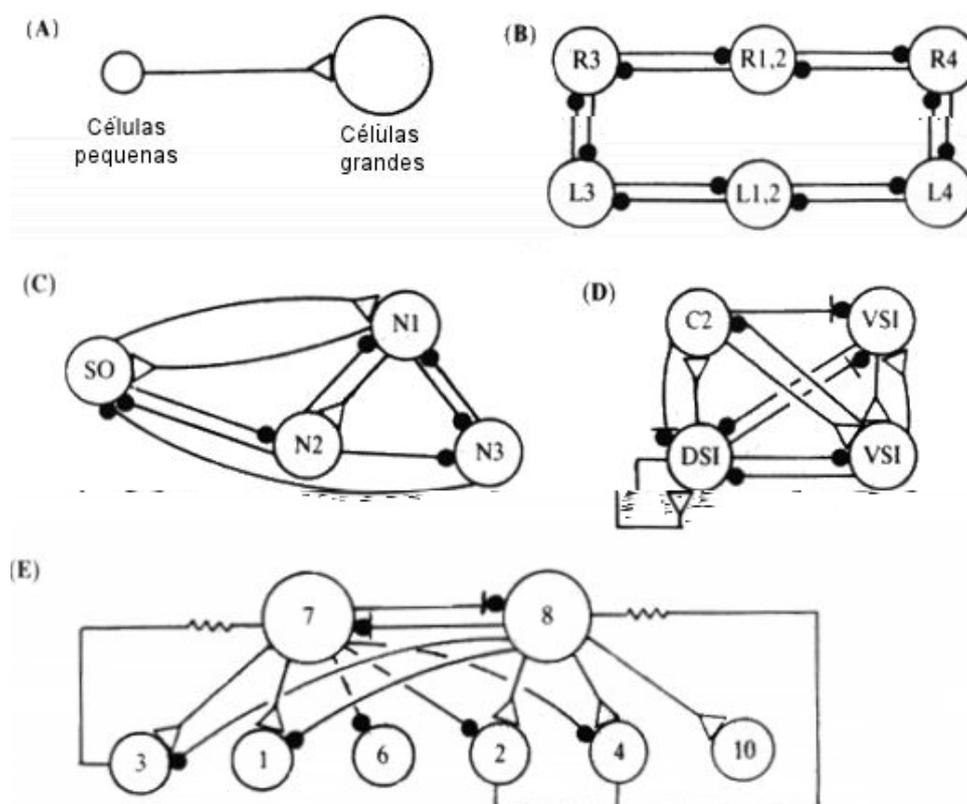


Figura 2.13 Circuitos geradores centrais de padrão dos invertebrados.
 A. Batimento cardíaco de lagostas; B. Batimento cardíaco de parasitas;
 C. Alimentação de lesmas; D. Natação da *Tritonia*; E. Natação da *Clione*.
 (Modificado de Allen & Mazzoni [14])

Esses circuitos, assim como os reflexos mostrados na seção anterior, podem ser modelados pelo simulador proposto, caracterizando assim sua importância para este trabalho.

3 REDES NEURAIIS ARTIFICIAIS

O propósito de uma Rede Neural Artificial (RNA) é simular uma rede neural natural (RNN) através da reprodução de características relevantes ao funcionamento do sistema nervoso e dos neurônios biológicos, para assim fazer emergir aspectos de comportamento inteligente. As RNAs apresentam outras importantes capacidades, tais como [16]:

Mapeamento de entrada-saída: permite que a rede aprenda através de exemplos, apresentando uma resposta desejada para cada amostra de entrada;

Adaptabilidade: através da alteração de seus pesos sinápticos, a rede tem a capacidade de ser retreinada mediante as pequenas modificações do ambiente;

Tolerância a falhas: a RNA, quando implementada em hardware, apresenta a capacidade inerente de ser tolerante a falhas, onde seu desempenho é pouco degradado na presença de operações adversas, tais como danos aos neurônios ou em suas conexões;

Processamento paralelo: os pesquisadores da área de redes neurais buscam através desta propriedade construir um computador com alto grau de paralelismo [17].

Com essas propriedades, as RNAs são utilizadas em aplicações para reconhecimento e classificação de padrões, processamento de imagem, processamento de sinais, problemas de controle, entre outros [18,19].

Uma rede neural artificial é constituída basicamente de três tipos de camadas: de entrada, intermediária ou oculta, e de saída. Fazendo uma analogia com o SNC, pode-se dizer que a camada de entrada é composta pelos neurônios sensoriais, que captam as informações externas; a camada intermediária é constituída por interneurônios, cujo papel é interligar os neurônios das camadas de entrada e saída e filtrar as informações que passam por eles; já a camada de saída é formada por neurônios motores, onde apresentam como resultado o processamento da informação.

Ao se projetar uma RNA, alguns pontos devem ser observados:

A escolha dos modelos neurais;

A topologia de rede apropriada;

O método de aprendizagem.

Modelos Neurais

Os neurônios que compõem uma RNA são baseados nos modelos biológicos, conforme apresentados no capítulo anterior. Porém, estes neurônios, chamados neurônios artificiais (NA), apresentam definições matemáticas distintas para cada modelo. O modelo geral de NA, baseado no modelo de McCulloch-Pitts, assim como o modelo neural utilizado neste trabalho - o neurônio *spiking* -, são apresentados na seção 3.1.

Topologias de rede

Segundo Haykin [16] e Azevedo et al. [17], a RNA pode ser representada por um grafo orientado, cujos vértices e arcos são rotulados, isto é, distinguíveis um dos outros por nomes ou rótulos. Esses vértices representam os NAs, e seus arcos os pesos sinápticos ou as funções de ativação entre os neurônios vértices.

Tomando como base o grafo que representa as RNAs, pode-se classificá-las em três tipos:

1. Redes Diretas ou com Alimentação para Frente (*Feedforward*): redes cujo grafo não contém ciclos. Podem ser de camada única³ ou com múltiplas camadas (onde apresenta uma ou mais camadas ocultas). São utilizadas para aproximação de funções não-lineares. Um exemplo típico são as redes

³ Refere-se somente a camada de saída, pois a camada de entrada existe em todas as RNAs e não necessita ser mencionada [16].

do tipo *Perceptron*, que utilizam o método de aprendizado de retropropagação (*backpropagation*), mostrado na Figura 3.1-A.

2. Redes com Ciclos ou com Realimentação (*Feedback*): apresentam grafo com um ou mais ciclos. Um caso especial deste tipo de rede são as redes recorrentes, na qual apresentam neurônios dinâmicos. As redes com ciclos são utilizadas na representação de conhecimento localizado [17]. As redes de Hopfield são exemplos de redes com ciclos (Figura 3.1-B).
3. Redes Simétricas: são redes com ciclos, cuja matriz de conectividade é uma matriz simétrica. Apresentam vantagens sobre as redes com realimentação por possuírem um ponto de equilíbrio durante seu aprendizado, garantido a estabilidade da rede.

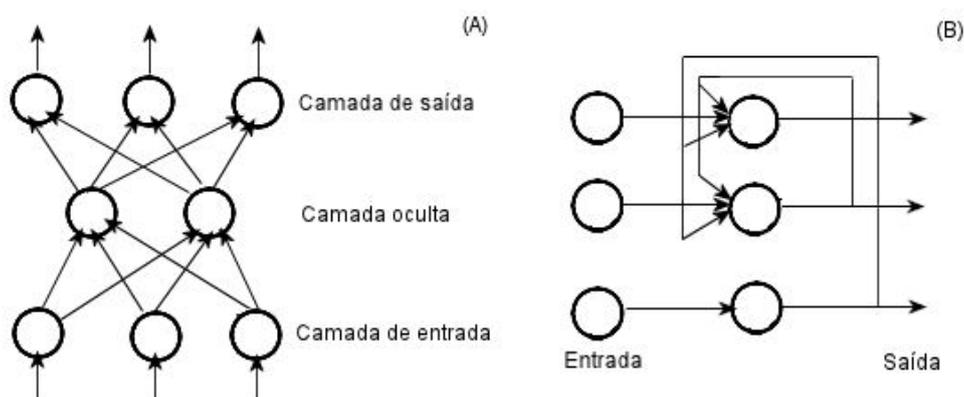


Figura 3.1 Topologias de redes neurais artificiais.

A. Rede Direta com Múltiplas Camadas (*Perceptron* de Múltiplas Camadas).

B. Rede com Ciclo (Hopfield).

Métodos de aprendizagem

O aprendizado em RNA acontece pela adaptação dos parâmetros da rede, devido a alterações causadas por estímulos fornecidos pelo ambiente [16]. Seu método de aprendizagem é baseado nos modelos biológicos (associativo e não-associativo), como descritos na seção 2.4.1.

No aprendizado associativo, a rede aprende pela associação de pares de estímulos. Essa forma de aprendizado biológico serve como modelo para o aprendizado

supervisionado das RNAs, onde existe a presença de um “professor” que supervisiona a aprendizagem. O professor conhece o conjunto de exemplos de entrada-saída e tem a capacidade de apresentar uma resposta desejada durante a fase de treinamento da rede. As redes do tipo *Perceptron*, as redes de Hopfield e BAM (*Bidirectional Associative Memory*) são exemplos de redes que utilizam esse tipo de aprendizado.

Já o aprendizado não-associativo, que apresenta somente um estímulo, seu aprendizado ocorre pela repetição desse estímulo. Esse tipo de aprendizado serve como base para o aprendizado não-supervisionado e por reforço. As redes ou mapas Auto-Organizáveis de Kohonen, por exemplo, utilizam aprendizado não-supervisionado.

Existe ainda um terceiro modelo de aprendizagem, o aprendizado híbrido. Esse tipo, apresentado por Fausett [19], combina os aprendizados supervisionado e não-supervisionado para atualização dos pesos sinápticos.

Tabela 3.1 Resumo das principais RNAs classificadas pelo método de aprendizagem.
(Modificado de Jain et al. [20])

Aprendizado	Regra de Aprendizado	Arquitetura ⁴
Supervisionado	Correção de erro	<i>Perceptron</i> de Única ou Múltiplas Camadas
	Bolztmann	Recorrente
	Hebbiana	<i>Feedforward</i> com Múltiplas Camadas
	Competitiva	Competitiva, ART
Não-Supervisionado	Correção de erro	<i>Feedforward</i> com Múltiplas Camadas
	Hebbiana	<i>Feedforward</i> , Competitiva
	Competitiva	Kohonen, ART
Híbrido	Correção de erro, Competitiva	Função de Base Radial

⁴ Maiores informações sobre as arquiteturas de redes citadas podem ser encontradas em [17,18,19,19].

Esses três tipos de aprendizado utilizam algoritmos distintos, que diferem pela forma que realizam o ajuste do peso sináptico, tais como aprendizagem por correção de erro, baseada em memória, competitiva, de Boltzmann e Hebbiana. Essas regras de aprendizado são utilizadas por diferentes arquiteturas de redes, como mostra a Tabela 3.1. Porém, neste trabalho será discutido somente o aprendizado Hebbiano, por ser o paradigma de aprendizado utilizado na rede proposta. Os algoritmos e outras informações de cada regra de aprendizado podem ser consultados em [16,18,19,20].

O aprendizado hebbiano é um modelo inspirado no aprendizado biológico, o qual utiliza a sinapse de Hebb (apresentada na seção 2.4). Segundo Haykin [16], a sinapse hebbiana utiliza um mecanismo dependente de tempo (a qual necessita de um tempo exato para o disparo), do local (a modificação sináptica ocorre em um local específico), da interatividade entre os neurônios (depende dos sinais pré e pós-sinápticos) e da função de correlação (os sinais pré e pós-sinápticos devem ocorrer ao mesmo tempo). Assim, para que ocorra o aprendizado, os neurônios que estão conectados pela sinapse de Hebb, devem disparar ao mesmo tempo, para que o peso sináptico seja alterado.

3.1 Neurônio Artificial

O neurônio artificial (NA) é um modelo matemático do neurônio biológico. Sua principal função, assim como no neurônio biológico, é processar as informações que trafegam pela rede neural, através de funções de mapeamento entrada-saída.

Segundo Koch et al. [21], os tipos de NAs variam conforme as funções matemáticas que cada um implementa, podendo ser lineares ou não-lineares, estáticas ou adaptativas, reproduzidas em hardware ou software. Cada uma destas funções é uma interpretação matemática simplificada para o potencial de ação de um neurônio biológico. Os modelos de McCulloch-Pitts, Perceptron, Hopfield e polinomiais seguem essa teoria. Porém, esses modelos, classificados por Koch et al. [21] como modelos formais, desconsideram uma importante característica dos neurônios biológicos: a sincronização dos impulsos gerados. Para os modelos biológicos, não existe uma sincronização dos tempos de disparo de cada neurônio, como existe nos modelos formais. O momento na qual o neurônio dispara depende somente de seu estado interno e do valor de entrada. Essa característica é levada em consideração nos modelos de Integração-e-Disparo (*Integrate-and-Fire*) e Hodgkin-Huxley, modelos de neurônios do tipo *spiking*, isto é, neurônios que apresentam como saída uma seqüência de potenciais de ação, ao invés de saídas binárias.

Nas próximas seções serão mostrados os modelos neurais formais de McCulloch-Pitts e *Perceptron*, por serem os modelos precursores na área de redes neurais, e os modelos de neurônio do tipo *spiking*, dando ênfase ao modelo de Integração-e-Disparo, por ser este o modelo utilizado na rede neural proposta a este trabalho.

3.1.1 Modelos formais

Cada modelo formal de neurônio apresenta três características comuns, como mostradas na Figura 3.2.

1. Um conjunto de sinapses, representadas pelos seus pesos (w);

2. Um combinador linear dos valores de entrada ponderados pelos seus pesos sinápticos ();
3. Uma função de ativação que delimita o intervalo dos valores de saída do neurônio ().
- 4.

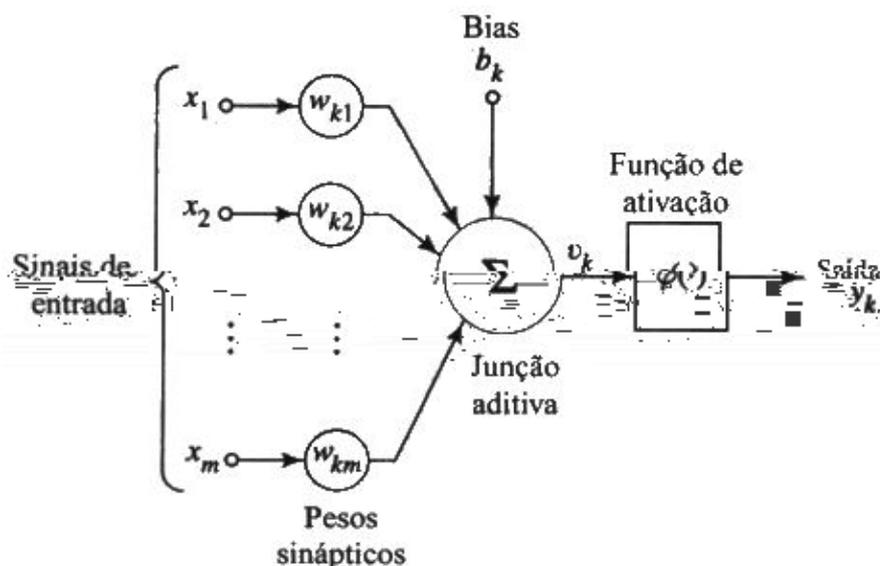


Figura 3.2 Modelo de neurônio artificial.
(Modificado de Haykin [16])

O processamento de um NA ocorre através das seguintes etapas:

1. Os sinais x_m são apresentados à entrada do neurônio;
2. Cada sinal é multiplicado por um peso w_{km} que indica sua influência na saída da unidade;
3. É feita a soma ponderada dos sinais, através do combinador linear Σ , que produz um nível de atividade;
4. Se este nível de atividade, após passar pela função de ativação $\phi(\cdot)$, exceder o limiar θ , a unidade produz uma saída, representado por y_k .

O modelo pode ainda apresentar um *bias*, que é uma entrada externa que modifica o valor de saída do combinador linear, aumentando ou diminuindo seu valor.

3.1.1.1 Neurônio de McCulloch-Pitts

As primeiras pesquisas na área de RNA, iniciaram-se em 1943 com o surgimento do modelo de neurônio de McCulloch e Pitts. Esse modelo assume que cada pulso gerado pelo neurônio representa uma saída lógica (ativado ou desativado) e que os pulsos de entrada são síncronos e sem variação [21]. Assim, a ativação do neurônio é conhecida como o processo de “tudo ou nada”.

O modelo matemático do neurônio de McCulloch-Pitts considera que se houver uma entrada inibitória, o neurônio não será ativado. Mas, se as entradas são excitatórias e o seu valor multiplicado pelo peso sináptico alcançar o limiar, então esse será ativado. A equação a seguir mostra esse modelo matemático:

$$Y = \begin{cases} 1 & \text{se } \sum_i x_i w_i \geq \theta \text{ e } x \text{ não for inibitório} \\ 0 & \text{nos demais casos} \end{cases} \quad (3.1)$$

onde i representa o neurônio, x_i representa as entradas no neurônio i , w_i o peso sináptico do neurônio i e θ o limiar de disparo.

3.1.1.2 Perceptron

Esse modelo de NA foi apresentado por Rosenblatt em 1958, onde apresenta uma estrutura matemática semelhante ao modelo de McCulloch-Pitts. A grande diferença está em seu valor de saída não ser um valor binário, e sim um valor real, que varia entre dois números (geralmente de -1 a 1). Esses valores de saída, que representam a média da taxa de disparos, são determinados por:

$$Y = g\left(\sum_i x_i w_i\right) \quad (3.2)$$

onde g é uma função não linear do tipo sigmoidal.

Outra diferença do modelo neural do perceptron para o de McCulloch-Pitts é a presença de aprendizado para o ajuste dos pesos. Esse aprendizado ocorre através de um algoritmo simples que verifica se a saída do neurônio (y) é igual à saída desejada (d), caracterizando um aprendizado supervisionado. Se esta saída for diferente, o peso sináptico (w_i) é atualizado conforme a equação (3.3):

$$w_i \leftarrow n(d - y) x_i \quad (3.3)$$

cujo n é o coeficiente de aprendizado.

Além disso, neste modelo, uma sinapse inibitória não inibe completamente o disparo do neurônio, como acontece no modelo de McCulloch-Pitts.

Os perceptrons são utilizados como classificadores de padrões do tipo linearmente separáveis [16,18], isto é, padrões se encontram em lados opostos de um hiperplano, tais como as funções lógicas “e” e “ou”. Essa restrição a problemas linearmente separáveis foi demonstrada por Minsky e Papert, em seu livro *Perceptrons* [22], onde propuseram a associação de múltiplas camadas de perceptrons, para assim conseguir resolver problemas não linearmente separáveis, tais como a função do “ou-exclusivo”.

3.1.2 Neurônios *spiking*

O neurônio *spiking* é o modelo de neurônio artificial que mais se aproxima do modelo biológico, pois apresenta como saída potenciais de ação (*spikes*) ao invés de valores discretos (como no neurônio de McCulloch-Pitts) ou contínuos (como nos perceptrons). Para codificar a informação, o neurônio *spiking* utiliza características baseadas no potencial de ação, tais como média temporal dos disparos, intervalo entre os pulsos, seqüência dos disparos e forma da onda, além do estudo dos mecanismos iônicos que determinam a geração e transmissão de tal potencial [23,24].

Segundo as características apresentadas, os neurônios *spiking* podem ser classificados em diferentes modelos [25]:

Modelos de Limiar de Disparo (*Threshold-Fire Models*): o disparo ocorre no momento que o potencial de membrana ultrapassa o limiar. Os modelos de Resposta por Potencial de Ação (*Spike Response Models*) e Integração e Disparo (*Integrate-and-Fire Models*) são exemplos típicos deste modelo.

Modelos Baseados em Condutância (*Conductance-Based Models*): são baseados na dinâmica dos mecanismos iônicos e na estrutura espacial do

neurônio. O modelo de Hodgkin-Huxley é um exemplo clássico deste modelo.

3.1.2.1 Modelo de resposta por potencial de ação

O modelo de resposta por potencial de ação (*Spike Response Model*) é baseado no modelo de limiar de disparo e por ser um modelo bastante genérico, será tomado como base para a explicação do modelo matemático dos neurônios *spiking*.

Conforme a definição biológica, apresentada na seção 2.2.2, o potencial de ação ocorre quando o potencial de membrana u_i do neurônio i ultrapassa o limiar θ_i . Esse momento, representado por $t_i^{(f)}$, representa o início do pulso gerado por i . O conjunto de todos os disparos de i é definido por:

$$F_i = \{t_i^{(f)}; 1 \leq f \leq n\} \quad (3.4)$$

onde $t_i^{(n)}$ é o pulso mais recente do neurônio i .

Para que o potencial de membrana u_i alcance o valor de limiar θ_i , é necessário que os neurônios pré-sinápticos de i , definidos por:

$$P_i = \{j | j \text{ é pré-sináptico de } i\} \quad (3.5)$$

gerem potenciais pós-sináptico (PPS). Este potencial, definido por Gerstner & Kistler [6] como a diferença entre o potencial de membrana no instante t e potencial de repouso u_{rest} , é representado como

$$u_{ij}(t) = u_i(t) - u_{rest} \quad (3.6)$$

onde u_{rest} é estado do repouso do neurônio, caracterizado por não apresentar impulsos (*spikes*) como entrada, que depende do tipo de neurônio, apresentam valores próximos a -65mV, como no caso dos neurônios motores.

Segundo a equação (3.6), quando $u_{ij}(t)$ é positivo, tem-se um PPS excitatório (PPSE); já quando $u_{ij}(t)$ é negativo tem-se um PPS inibitório (PPSI), como mostrado na Figura 3.3. Isso permite que o valor de u_i aumente ou diminua. Além disso, o peso

das conexões sinápticas w_{ij} que partem dos neurônios j e chegam a i também influi em seu potencial de membrana.

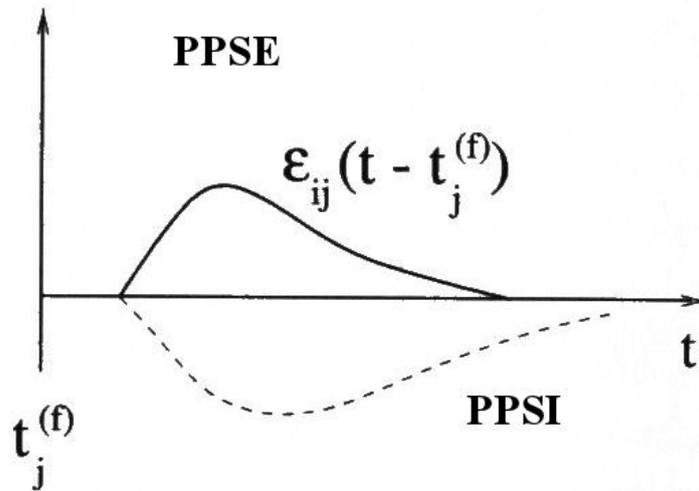


Figura 3.3 Forma do potencial pós-sináptico excitatório (PPSE) e inibitório (PPSI) (Modificado de Gerstner [25])

Após a geração do potencial de ação no tempo $t_i^{(f)}$, o valor de v_i passa pelo período refratário e após retorna ao potencial de repouso. Esse período refratário, destacado na Figura 3.4, pode ser representada pela variável $v_i(t - t_i^{(f)})$, onde sua representação matemática é dada por Gerstner & Kistler [6]:

$$v_i(t - t_i^{(f)}) = \begin{cases} 0 & \text{para } 0 \leq t - t_i^{(f)} < \Delta t \\ \exp\left(-\frac{t - t_i^{(f)}}{\Delta t}\right) & \text{para } t - t_i^{(f)} \geq \Delta t \end{cases} \quad (3.7)$$

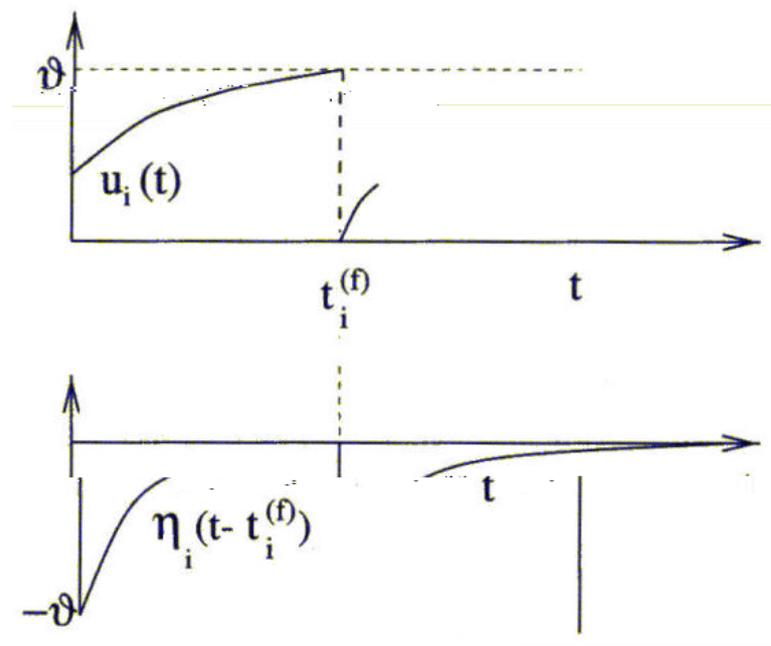


Figura 3.4 Período refratário $\eta_i(t - t_i^{(f)})$.

Na parte superior está destacado o momento em que $u_i(t)$ alcança o limiar θ . Neste momento o $u_i(t)$ retorna a zero, através da função $\eta_i(t - t_i^{(f)})$, como mostrado na parte inferior. (Modificado de Gerstner [25])

Como o parâmetro de saída observado neste modelo é o potencial de membrana (u_i), pode-se então defini-lo matematicamente como:

$$u_i(t) = \sum_{j=t_j^{(f)}}^{t_i^{(f)}} w_{ij} \eta_j(t - t_j^{(f)}) \quad (3.8)$$

onde $t_i^{(f)} = F_i$, $j = i$ e $t_j^{(f)} = F_j$.

A definição de potencial de membrana apresentada por Gerstner [25] é amplamente discutida em outros artigos da mesma obra e em Gerstner & Kistler [6], onde pode ser encontrados mais detalhes.

Este modelo de neurônio *spiking* é bastante simplificado e negligencia muitos aspectos da dinâmica neural. Em particular, assume-se que todos os potenciais de ação sempre possuem a mesma forma. Além disso, a equação para cálculo do potencial de membrana é único e pode ser aplicado em qualquer momento, mesmo durante a geração do potencial de ação. Por isso, para o modelo de neurônio *spiking* utilizado neste trabalho, este cálculo de potencial de membrana foi modificado, pois o mesmo utiliza

um cálculo diferente para cada estado/fase da onda do potencial de ação. Essa modificação será do modelo será apresentada na seção 4.1.

3.1.2.2 Modelo de integração e disparo

O modelo neural de integração e disparo (*Integrate-and-Fire Models*) é um modelo de limiar de disparo, que apresenta duas fases distintas: um período prolongado, na qual ocorre a soma das entradas do neurônio (integração); e um período rápido, onde o ocorre o disparo.

Esse modelo de neurônio *spiking*, assim como o modelo de Resposta por Potencial de Ação, apresentado na seção anterior, é relativamente simples, por não levar em consideração a forma da onda. Porém, suas vantagens estão em permitir analisar matematicamente a dinâmica do neurônio na rede e apresentar particular eficiência ao modelar grandes sistemas [23].

O circuito que representa este modelo é um circuito básico de RC (resistência-capacidade), como mostrado na Figura 3.5, cujo funcionamento é extremamente simples: a corrente de entrada $I(t)$, que representa o valor de todas as entradas sinápticas, gera uma voltagem V , que é armazenado no capacitor C até chegar a um limiar. Devido à presença do resistor R , para que V gere um pulso é necessário que as entradas excitatórias apresentem um determinado valor para chegar ao limiar. Ao ultrapassar esse limiar, o pulso é gerado, descarregando por completo o capacitor e retornando o valor de V para zero.

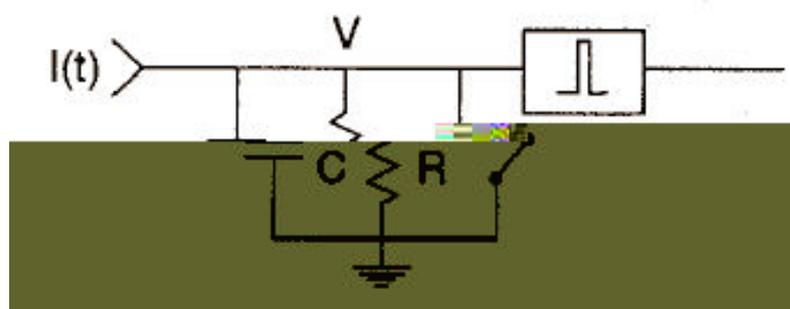


Figura 3.5 Circuito “integração e disparo” de um neurônio
(Extraído de Koch et al. [21])

3.1.2.3 Modelo de Hodgkin-Huxley

O modelo de Hodgkin-Huxley é um modelo de neurônio *spiking* mais preciso que os modelos apresentados anteriormente [25]. Foi desenvolvido por Hodgkin e Huxley, através de seus estudos em axônios de lulas gigantes.

É um modelo baseado em condutância, onde se analisa a passagem das correntes iônicas, tais como dos íons de sódio (Na^+) e potássio (K^+), através da membrana neural. Como mostrado na Figura 3.6, a membrana neural é semipermeável, apresentando canais de íons voltagem-dependentes, um para Na^+ e outro para K^+ , que controlam o fluxo destes íons através da membrana. Nesse modelo, a membrana neural funciona como um capacitor: ao se injetar uma corrente I , esta pode ser adicionada como carga ao capacitor ou sair através dos canais iônicos, como mostrado no lado direito da Figura 3.6. Esse fluxo através da membrana faz com que a concentração de íons dentro e fora da célula seja diferente, representando assim, uma bateria.

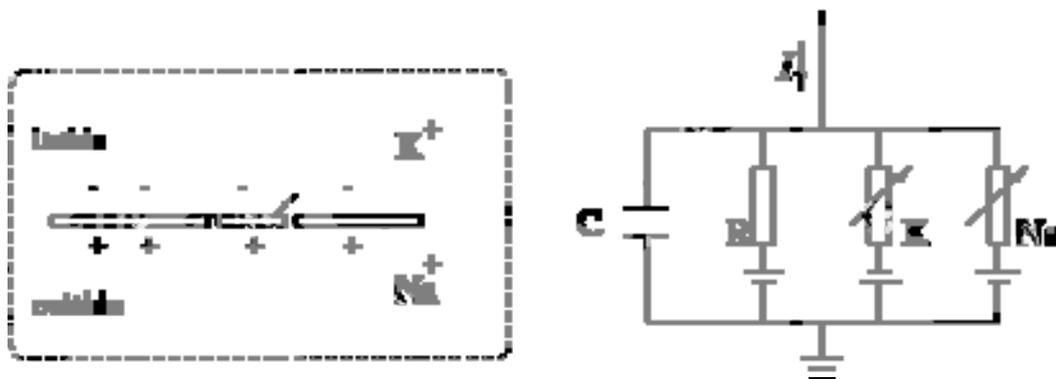


Figura 3.6 Diagrama esquemático do modelo de Hodgkin-Huxley
(Extraído de Gerstner & Kistler [6])

Para maiores informações, recomenda-se a leitura de [6,21,25].

3.2 Redes Neurais Pulsadas

Segundo Mass [26], as redes neurais pulsadas representam a terceira geração de redes neurais, sendo redes que utilizam os neurônios *spiking*, cujo conceito foi apresentado na seção 3.1.2.

A definição formal de uma Rede Neural Pulsada, apresentada por Mass [27], é a seguinte:

Um grafo direto finito (V,E) , onde o conjunto V apresenta como elementos os neurônios e o conjunto E as sinapses;

Um conjunto de entrada $V_{in} \subseteq V$, que representa os neurônios de entrada;

Um conjunto de saída $V_{out} \subseteq V$, que representa os neurônios de saída;

Uma função limiar θ_v , para cada neurônio $v \in V - V_{in}$;

Uma função resposta $\sigma_{u,v}$ e uma função peso

objeto, para permitir uma maior portabilidade do código a ser implementado em diferentes tipos de hardware. Esse simulador não apresenta uma interface independente, sendo necessário a utilização de robôs físicos ou simulados, tais como o Khepera⁵, para sua execução.

Os neurônios da rede implementada no *Hi-NOON* são neurônios *spiking*, baseados no modelo de Limiar de Disparo (mostrado na seção 3.1.2.1): a geração do potencial de ação ocorre no momento em que o potencial de membrana ultrapassa o limiar. Por esse motivo, o parâmetro observado na rede é o potencial de membrana (MP^6).

Como o nome sugere, todos os elementos que compõem a rede - neurônios, sinapses e ela própria - são tratados como objetos. Essa característica é uma grande vantagem apresentada pela rede, pois possibilita facilmente implementada em software e em hardware. Outra vantagem está na definição dos tipos de neurônios e sinapses que a rede implementa, pois através destes é possível montar redes neurais que simulem aprendizado e outros comportamentos inteligentes.

3.2.1.1 Os neurônios

Os neurônios *spiking* que compõem a rede apresentam parâmetros fixos e variáveis, que determinam o funcionamento dos mesmos. Os parâmetros fixos *BaseMP*, *Threshold* e *TimeConst* () correspondem ao potencial de repouso, limiar de disparo e constante de tempo do neurônio, respectivamente. Já os parâmetros dinâmicos são *MP* que modela o potencial de membrana atual à medida que ele varia no tempo; *SynPot* ($S(t)$) que acumula o somatório das entradas sinápticas com seus respectivos pesos, sendo que no próximo instante de tempo influenciarão na atualização do *MP*; e *fired* que informa se o neurônio está disparando um pulso no instante de tempo atual.

⁵ Khepera é um robô desenvolvido pela K-Team Corporation (<http://www.k-team.com>).

⁶ Optou-se por manter a sigla *MP* (*membrane potencial*) para representar o potencial de membrana, a fim de seguir as definições apresentadas por Damper et al.[4].

Esta rede é formada uma população de neurônios não-homogênea, isto é, implementa diferentes tipos de neurônios, conforme sua funcionalidade. Isso permite que a rede se assemelhe ao sistema nervoso dos seres vivos, onde existem neurônios sensoriais, motores e interneurônios. Os tipos de neurônios implementados são:

Basic (básico): é o neurônio *spiking* do tipo limiar de disparo, o qual faz suas sinapses dispararem quando seu potencial de membrana (MP) ultrapassa o limiar (*Threshold*);

Noisy: é um tipo similar ao *basic*, mas apresenta um componente de ruído (*noise*) determinado pela entrada do peso sináptico e influencia o MP do próximo neurônio;

Ramp: é um tipo similar ao *noisy*, mas tem a habilidade de aumentar a geração de pulsos;

Burst: similar ao *noisy*, mas tem a capacidade de produzir pequenas “explosões” (*burst*) de pulsos quando o MP ultrapassa o limiar;

Sensor (sensorial): é um neurônio similar ao *basic*, que atua como um neurônio sensorial, captando informações externas à rede;

Motor: neurônio similar ao *basic*, que atua como um neurônio motor, responsável pela função de saída, apresentando respostas ao ambiente.

Como já citado, todos os neurônios implementados nesta rede são baseados no modelo de neurônio *spiking*, que apresentam como saída potenciais de ação (*spikes*). Por esse motivo, a análise deste pulso se faz necessário. Como apresentado na seção 2.2.2, o potencial de ação pode ser dividido em fases distintas. Essas fases, chamadas aqui de estados, são determinadas conforme o valor do potencial de membrana (MP) em relação a um dos valores fixos do neurônio, conforme apresentado na Tabela 3.2. Estes valores são baseados nos potenciais de membrana de um neurônio biológico do tipo motor.

Tabela 3.2 Parâmetros fixos em relação ao potencial de membrana do neurônio.

Parâmetro	Valor (em mV)
Potencial mínimo (<i>minimum MP</i>)	-69
Potencial de repouso (<i>resting MP</i>)	-60
Limiar de disparo (<i>threshold</i>)	-45
Potencial de pico (<i>peak MP</i>)	+45

Os estados do potencial de ação, mostrados na Figura 3.7, determinam o estado atual do neurônio e são assim definidos:

Estado A: MP se encontra acima do potencial de repouso e abaixo do limiar,

Estado B: MP acima do limiar e abaixo do pico,

Estado C: o valor de MP se encontra no pico,

Estado D: o MP está no pós-disparo,

Estado E: MP se encontra no mínimo,

Estado F: MP hiperpolarizado.

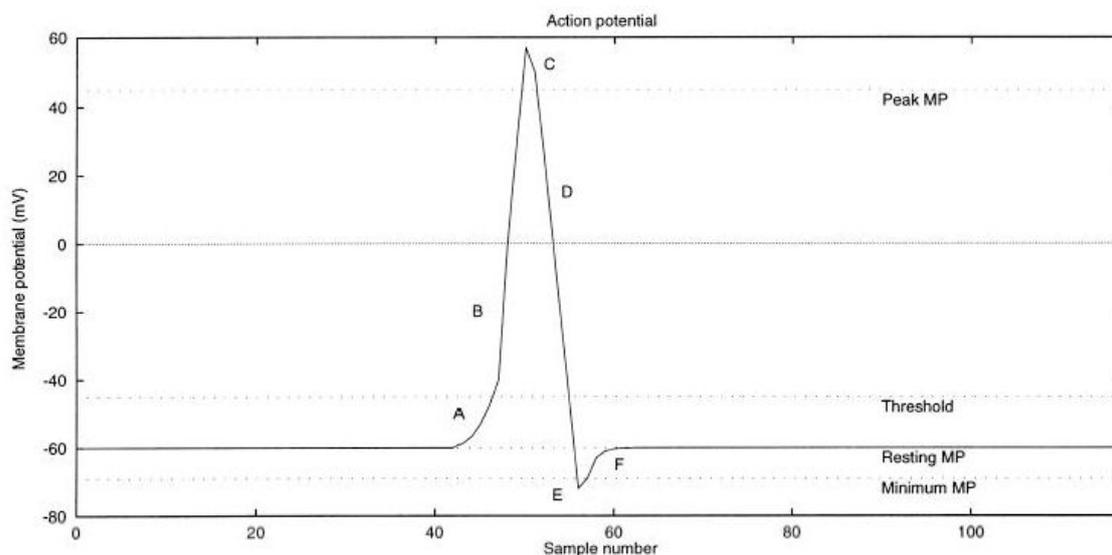


Figura 3.7 Potencial de ação (*spike*) de um neurônio, destacando os estados. (Extraído de Damper et al. [4])

Diferentemente do modelo de neurônio de Resposta por Potencial de Ação, o modelo de neurônio aqui descrito não apresenta uma fórmula única para o cálculo do potencial de membrana. Cada tipo de neurônio apresenta uma forma de calcular o MP, como mostrado abaixo.

O MP de um neurônio do tipo básico é calculo em relação ao estado do neurônio, como apresentado nas seguintes equações:

$$\text{Estado A: } MP(t+1) = MP(t) - \beta + S(t);$$

$$\text{Estado B: } MP(t+1) = MP(t) - \beta S(t);$$

$$\text{Estado C: } MP(t+1) = h + S(t);$$

$$\text{Estado D: } MP(t+1) = MP(t) - \beta + S(t);$$

$$\text{Estado E: } MP(t+1) = l + S(t);$$

$$\text{Estado F: } MP(t+1) = MP(t) + \frac{BaseMP - MP(t)}{\beta} S(t).$$

onde:

$S(t) = \sum_i w_i k MF_i(t)$ é o cálculo do potencial sináptico (*SynPot*) no tempo t .

i é o contador de neurônios pré-sinápticos ativos do neurônio;

w_i é o peso sináptico de um neurônio pré-sináptico i ;

β é a constante de tempo do neurônio;

h é o contra-incremento de pós-limiar cujo valor é igual a 20;

β é o decremento do potencial de pico de valor igual a 25;

β é a taxa de incremento após a hiperpolarização e o seu valor é 1.5;

k é a constante de aprendizado gerada heurísticamente e seu valor é 1/450;

h é o MP máximo pós-limiar e seu valor é 45;

l é o MP mínimo antes de atingir a hiperpolarização e seu valor é -69.

Alguns desses parâmetros, como μ e Δ , são dependentes de tempo e devem ser atribuídos empiricamente para ser ajustar à velocidade do processador, bem como à implementação.

Os neurônios sensoriais e motores também apresentam cálculo de MP distintos. Os neurônios sensoriais implementados na rede reagem a mudanças de luz e à proximidade dos objetos. Esses neurônios sensoriais que reagem à luz foram inspirados no sentido da visão do molusco *Pecten maximus*, o qual apresenta aproximadamente 60 olhos, que detectam luz, cor e movimento. Cada olho é formado por células sensoriais proximais e distais () que respondem ao aumento ou diminuição da intensidade da luz, respectivamente. Suas respostas a essas mudanças de intensidade são dadas pelos modos proximal e distal desse neurônio, conforme apresentado abaixo:

Modo Proximal: despolariza a membrana com o aumento da intensidade da luz, cujo cálculo é dado por:

$$MP(t) = \mu \Delta \left(\frac{MP(t)}{MP(t)} \right) \text{ nos outros casos}$$

Modo Distal: despolariza a membrana com a diminuição da intensidade da luz, cujo cálculo é dado por:

$$MP(t) = \mu \Delta \left(\frac{MP(t)}{MP(t)} \right) \text{ nos outros casos}$$

onde:

$$\Delta t = k \Delta t - 1 \Delta t$$

sendo Δt corresponde ao valor de entrada fornecido pelo sensor (dispositivo físico) e k um fator determinado empiricamente dependendo do sensor físico.

Já os neurônios sensoriais de proximidade apresentam resposta conforme a variação da localização do objeto que está sendo percebido. O cálculo do potencial de membrana é dado por:

$$MP(t) = 1 \cdot MP(t) + sR(t)$$

onde R é o valor de entrada que corresponde a variação da distância ao objeto, representa a função de nivelamento das entradas e s é um fator empírico cujo valor é definido conforme o sensor físico empregado.

Os neurônios motores, por sua vez, correspondem aos atuadores do sistema, onde sua função está relacionada à ativação de motores físicos, utilizados em robôs. O cálculo do MP para determinar sua ativação é dado por:

$$A(t) = \frac{MP(t)}{h}$$

onde $A(t)$ determina a velocidade dos motores e h é uma constante para a adaptação do hardware do robô utilizado.

3.2.1.2 As sinapses

As sinapses, assim como os neurônios, também possuem parâmetros fixos e dinâmicos. Esses parâmetros são relacionados ao peso sináptico, sendo *BaseWeight* (w_{base}) o valor que representa o peso base de uma sinapse, sendo uma constante; *Weight* ($w(t)$) contém o valor do peso sináptico atual, o qual varia durante a simulação; *Recovery* é uma constante (característica de cada sinapse) que determina quão rápido $w(t)$ retorna para o valor w_{base} . Para prevenir que os valores de peso sináptico cresçam indefinidamente, $w(t)$ é delimitado durante a simulação, não podendo ultrapassar os valores *MaxWeight* (w_{max}) e *MinWeight* (w_{min}), que são respectivamente os valores máximo e mínimo admissíveis para o peso sináptico.

As sinapses basicamente são classificadas em *noisy* (com ruídos) e *noise-free* (sem ruídos). A diferença entre estas duas sinapses está no momento em que elas disparam. A sinapse *noise-free*, também chamada sinapse básica, dispara sempre que o neurônio pré-sináptico estiver no estado B, C ou D. Já a sinapse *noisy* para disparar necessita respeitar a condição apresentada abaixo:

condição para disparo p no estado B, C ou D $\frac{MP_p}{h} \times 100 \geq \text{rand mod } 100$

onde p se refere ao neurônio pré-sináptico.

A sinapse básica é uma sinapse mono-sináptica, equivalente à sinapse biológica do tipo axo-dendrítica, que parte do axônio do neurônio pré-sináptico (k) e chegam ao dendrito do neurônio pós-sináptico (j). Sua representação gráfica é mostrada na Figura 3.8.

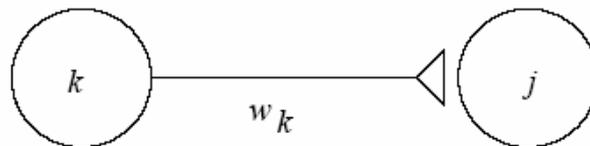


Figura 3.8 Representação gráfica da sinapse básica
(Extraído de Damper et al. [30])

O peso sináptico do neurônio pré-sináptico é apresentado como w_k . Esse peso, como mostrado anteriormente, influencia o cálculo do potencial de membrana do neurônio pós-sináptico. Para a sinapse básica, a atualização deste peso sináptico é dado por:

$$w(t) = \begin{cases} w(t) & \text{se } w(t) < w_{base} \\ w(t) & \text{se } w(t) > w_{max} \\ w_{max} & \text{se } w(t) > w_{max} \\ w_{min} & \text{se } w(t) < w_{min} \\ w_{min} & \text{em outros casos} \end{cases}$$

onde τ é o parâmetro de recuperação (*Recovery*), w_{base} é o peso base (apresentando valor tipicamente igual a 0) e w_{min} e w_{max} , os pesos máximos e mínimos, cujo valores utilizados são -16 e +16, respectivamente.

As sinapses básicas podem ser classificadas como excitatórias ou inibitórias. As sinapses excitatórias implementam o peso sináptico positivo e as inibitórias um peso sináptico negativo.

3.2.1.3 O aprendizado da rede

O aprendizado da rede neural apresentada pelo *Hi-NOON* utiliza formas de aprendizados baseado biologicamente, tais como os aprendizados não-associativos de habituação e sensibilização, e o aprendizado associativo baseado no condicionamento clássico, como descritos na seção 2.4.1. Essas formas de aprendizado são implementadas segundo a teoria de Hebb, cujo aprendizado ocorre através modificação estrutural da sinapse. Para dar suporte a essa teoria, o *Hi-NOON* implementa três tipos de sinapses: habituada, sensibilizada e condicionada.

A sinapse do tipo habituada (*habituating*) é uma sinapse mono-sináptica, como a mostrada na Figura 3.8. Em termos neurais, a habituação ocorre quando o neurônio k faz sinapse com o neurônio j e k dispara repetidamente, então a força sináptica entre k e j diminui, fazendo com que j reduza sua resposta. No *Hi-NOON*, a sinapse habituada é implementada através da diminuição do *Weight* (peso sináptico) a cada vez que a sinapse dispara, onde o *Weight* retorna para o valor *BaseWeight*, no tempo determinado pelo parâmetro *Recovery*. A atualização do peso sináptico deste tipo de sinapse é definido por:

$$w(t+1) = \begin{cases} w(t) - d & \text{se o neurônio pré-sináptico } k \text{ está no estado C} \\ w(t) & \text{nos outros casos} \end{cases}$$

onde d é uma constante de decremento (tipicamente próxima a 1).

As sinapses do tipo sensibilizada e condicionada são sinapses do tipo axo-axônica (*synapse-on-synapse*), como mostradas na Figura 3.9.

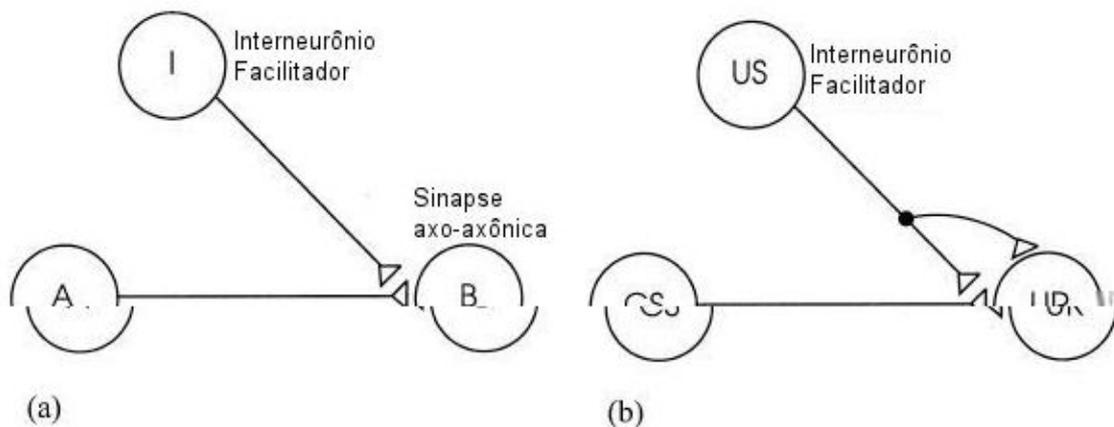


Figura 3.9 Sinapse axo-axônica sensibilizada (a) e condicionada (b).
(Modificada de Damper et al. [4])

O mecanismo de sensibilização é constituído de um interneurônio facilitador I , que realiza sinapse axo-axônica - chamada sinapse SOS (*sinapse-on-sinapse*) - com a sinapse entre os neurônios A e B - chamada sinapse *target* (alvo). Esse esquema é ilustrado na Figura 3.9a. A sensibilização ocorre quando o neurônio I dispara, após o disparo de A, fazendo com que a força sináptica entre os neurônios A e B aumente. O cálculo do peso sináptico da sinapse *target* é definida como:

$$w(t) = \begin{cases} w(t)_{target} + \Delta w(t)_{target} & \text{se a sinapse target e a sinapse SOS estão disparadas} \\ w(t) & \text{nos outros casos} \end{cases}$$

O condicionamento clássico apresenta um mecanismo semelhante ao da sensibilização. A diferença está em associar dois estímulos para alcançar o aprendizado. Como já apresentado na seção 2.4.1.3, o condicionamento clássico ocorre quando um estímulo condicionado (CS) precede um estímulo não-condicionado (US) por um curto intervalo de tempo. A sinapse realizada entre o estímulo CS e a resposta não-condicionada (UR) é aumentada sempre que o interneurônio que representa US dispara, conforme esquema da Figura 3.9b. Esse aumento é relativamente proporcional ao tempo que o disparo de CS precede US, conforme mostrado no gráfico da Figura 3.10.

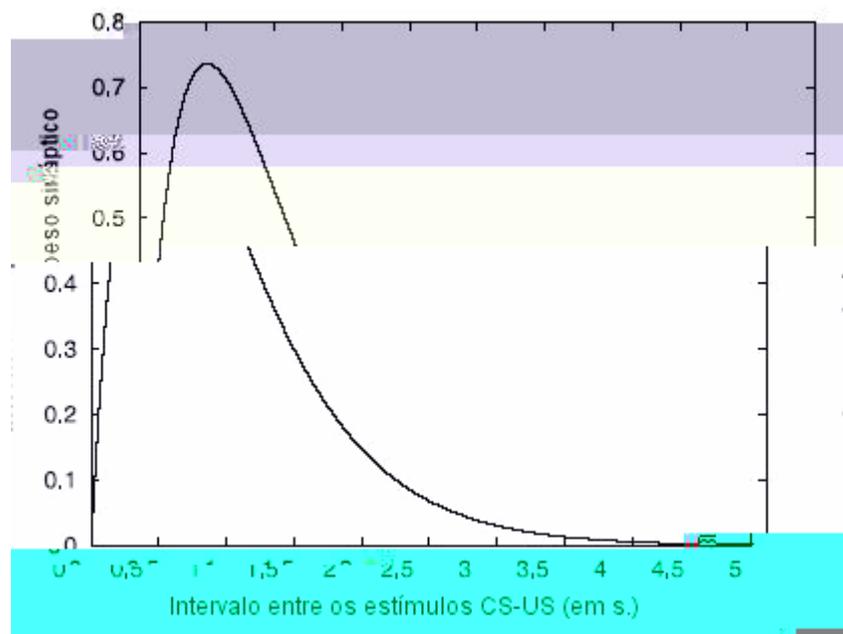


Figura 3.10 Aumento do peso sináptico durante o aprendizado condicionado.
(Modificado de Damper et al. [30])

Então, para que ocorra o aprendizado por condicionamento clássico, o peso da sinapse *target*, realizada entre os neurônios CS e UR, deve ser alterado conforme a equação:

$$w(t) = \begin{cases} w(t)_{target} + kw(t)_{sos} & \text{se a sinapse target e a sinapse SOS estão disparadas} \\ w(t) & \text{nos outros casos} \end{cases}$$

onde:

$$k = \frac{1}{1 + \exp(-nT)}$$

e nT é um contador iniciado quando o neurônio CS se encontra no estado C, fator determinado empiricamente ($=250$), k é uma constante ($=500$) que maximiza o efeito do condicionamento quando o estímulo condicionado precede o estímulo não-condicionado pelo tempo de 0,5 s.

O modelo aqui proposto foi implementado na ferramenta de simulação proposta por este trabalho, apresentando algumas modificações que serão discutidas na seção 4.1.

3.3 Aplicabilidade em Robótica

Segundo Bekey & Goldberg [32], robôs são “dispositivos físicos construídos para imitar aspectos de comportamento humano ou animal que envolve interação com o mundo, tal como manipulação ou locomoção”. Através desta definição, é possível perceber que os estudos nas áreas de Robótica e Redes Neurais Artificiais são baseados na mesma teoria: a inspiração biológica.

A robótica inspirada biologicamente, também chamada de biorrobótica, surgiu com os estudos de Grey Walter⁷ apud Sharkey [1] em 1953, os quais se baseavam na teoria de tropismo: o comportamento de reagir a determinados estímulos. A biorrobótica se refere às pesquisas em robótica relacionadas às ciências da vida (biologia, psicologia, neurociência, etologia e teoria evolucionária) e pode ser dividida, segundo Sharkey [1], em três classes: generalizada, específica e teórica. A biorrobótica generalizada segue a linha de estudos de Grey Walter, aplicando teorias de comportamento animal aos robôs; a abordagem específica utiliza a biorrobótica generalizada nos estudos de organismos específicos, para assim desenvolver novos métodos de modelagem científica; e a biorrobótica teórica realiza estudos em diversas áreas, desde robótica à natureza da vida.

As RNAs são utilizadas no campo da Robótica em diversos tipos de aplicações: sistemas de controle, tais como geração de trajetória, movimento de braços, controle de posição e força; resposta a estímulos sensoriais, tais como comando de voz; reconhecimento de padrões; aprendizado e adaptação ao ambiente; entre outras aplicações. Mais informações pode ser vista em [32, 33]. Tais aplicações podem ser implementadas em hardware ou em software, neste último caso através de simuladores.

Os simuladores robóticos permitem que comportamentos específicos sejam visualizados, além de possibilitar a simulação de ambientes e iterações com o robô, sem a necessidade de uma implementação física. Comparada a robôs reais, a simulação apresenta vantagens por ser rápida, barata e permitir que experimentos sejam repetidos em condições idênticas [34]. Alguns simuladores atualmente utilizados nesta área são o

⁷ WALTER, W. Grey. **The Living Brain**. New York: W W Norton, 1953. 311p.

GENESIS, *PDP++*, *SNNS* ou softwares matemáticos tais como *MATLAB*. Informações sobre esses softwares podem ser encontradas em [35,36,37,38].

4 MODELO PROPOSTO

O modelo de simulador neural proposto neste trabalho é baseado no simulador *Hi-NOON*, desenvolvido por Damper et al [4,30,31], cuja estrutura foi apresentada na seção 3.2.1. O *Hi-NOON* é simulador neural concebido para simular pequenos sistemas biológicos, permitindo assim a visualização de comportamentos de animais de nível inferior. Esse simulador utiliza recursos de baixo nível através da linguagem C orientada a objeto, que facilita sua programação em diferentes tipos de hardware, tais como em pequenos robôs, e em software, através da implementação de simuladores. Porém, uma desvantagem apresentada por esse simulador é que o mesmo apresenta o resultado da simulação através de números, em formato de texto. Esse tipo de simulação não apresenta uma saída gráfica que facilite sua visualização. Deste modo, torna-se difícil verificar a rede como um todo, pois não é possível descrever ao mesmo tempo todas as ativações e valores de potencial de membrana de cada neurônio que compõem a rede.

Devido às restrições descritas acima, viu-se a necessidade de se implementar uma ferramenta que possibilitasse a visualização da rede como um todo, permitindo que os aspectos de aprendizado que são implementados pelo *Hi-NOON* sejam facilmente mostrados através de uma ferramenta gráfica.

Assim, o simulador proposto neste trabalho utiliza a rede neural do *Hi-NOON*, porém sua implementação apresenta uma interface gráfica para permitir a visualização da rede neural. Além disso, algumas modificações da rede do *Hi-NOON* foram realizadas para que este modelo de rede neural se adequasse ao simulador aqui proposto. Essas modificações são apresentadas na seção 4.1 e o simulador é descrito na seção 4.2.

4.1 Modificações do Modelo

Devido à necessidade de adequar o modelo de rede proposto por Damper et al. [4,30,31] ao simulador desenvolvido neste trabalho, algumas alterações ao modelo foram realizadas.

A primeira modificação está relacionada à interpretação da linguagem de programação utilizada. Foi escolhido trocar a linguagem de programação C, utilizada pelo *Hi-NOON* para Pascal orientado a objeto, devido à facilidade de se implementar uma ferramenta gráfica nesta linguagem. Isso também permitiu que o código reescrito fosse mais legível, devido à nova implementação ter separado os classes de objetos em módulos distintos, uma vez que isso não era feito no código original.

As demais modificações estão relacionadas às alterações em parâmetros e métodos implementados na rede. Essas alterações foram necessárias para adequar o modelo da rede neural do *Hi-NOON* ao modelo proposto, pois o mesmo não apresentava um comportamento satisfatório para as simulações realizadas.

As principais alterações realizadas no modelo da rede neural foram sobre os cálculos de atualização do potencial de membrana e do potencial sináptico. Essas modificações foram necessárias para permitir que a geração do potencial de ação fosse completada. Isso se deve ao fato de o modelo apresentar um cálculo que, para alguns casos (tais como nos circuitos com ciclos), não permite que a transição entre os estados fosse completada, fazendo com que o potencial de ação terminasse em um estado diferente do estado final (F). O mesmo se aplica às modificações dos valores de constantes, que foram alteradas a partir do modelo original. Essas constantes faziam com que a transição entre os estados ocorresse de forma assíncrona, não apresentando um comportamento adequado para esse modelo de rede. Além disso, funções para normalização do potencial de membrana e dos valores de entradas dos sensores foram criadas, pois o modelo original somente cita, mas não descreve tais funções.

Nas seções seguintes será apresentada detalhadamente cada uma destas modificações.

4.1.1 Função de atualização do potencial de membrana

O cálculo para a atualização do potencial de membrana dos neurônios foi a principal modificação do modelo. Essa alteração foi realizada devido à necessidade de sincronização dos estados (A-F) que cada neurônio apresenta, como mostrado na descrição dos neurônios da seção 3.2.1.1. Ao se implementar a rede, verificou-se que os circuitos com ciclos, tais como o gerador central de padrão (GCP), apresentavam problemas de sincronização dos estados. Isso acontecia devido ao fato de o modelo original permitir que o potencial sináptico ($S(t)$) influenciasse em todos os estados. Em um estudo mais detalhado, chegou-se à conclusão que essa influência deveria somente se limitar ao estado inicial do neurônio (estado A), pois revendo o conceito biológico, as entradas sinápticas de um neurônio somente influenciam o início do potencial de ação (caracterizado aqui pelo estado A) e não os demais estados.

Assim sendo, o novo cálculo do potencial de membrana para o neurônio básico é apresentada em comparação ao modelo original, conforme Tabela 4.1:

Tabela 4.1 Comparação entre o cálculo de potencial de membrana original com o modelo proposto.

Estado	Modelo Original	Modelo Proposto
A	$MP(t+1) = MP(t) - \frac{MP(t) - \beta}{\tau} + S(t)$	$MP(t+1) = MP(t) + \frac{MP(t) - \beta}{\tau} + S(t)$
B	$MP(t+1) = MP(t) - \frac{MP(t) - \beta}{\tau}$	$MP(t+1) = MP(t) - \frac{MP(t) - \beta}{\tau}$
C	$MP(t+1) = h + S(t)$	$MP(t+1) = h$
D	$MP(t+1) = MP(t) - \frac{MP(t) - \beta}{\tau} + S(t)$	$MP(t+1) = MP(t) - \frac{MP(t) - \beta}{\tau}$
E	$MP(t+1) = l + S(t)$	$MP(t+1) = l$
F	$MP(t+1) = MP(t) + \frac{BaseMP - MP(t)}{\tau} + S(t)$	$MP(t+1) = MP(t) + \frac{BaseMP - MP(t)}{\tau}$

⁸ A constante de tempo (*timeConst*), representada por τ , foi mantida na equação modificada por motivo de comparação. Porém, seu valor é desprezado (setado para zero) na modelagem proposta.

Além da retirada do potencial sináptico do cálculo dos potenciais de membrana dos estados B a F, é possível visualizar, através da Tabela 4.1, que outras simplificações foram realizadas, tais como a retirada do cálculo do potencial pós-sináptico ($BaseMP-MP(t)$) e a modificação da constante de tempo (τ), que permitiram que a transição entre os estados ocorresse. Essas alterações permitiram que a geração do potencial de ação terminasse em estados diferentes do estado final (F), como apresentava o modelo original.

O cálculo do potencial de membrana dos neurônios sensoriais também foi outra alteração aplicada ao modelo. Devido o modelo original apresentar somente o cálculo de potencial de membrana para os neurônios sensoriais de luz e proximidade, foi necessário implementar este cálculo para os sensores de colisão, que também são utilizados no simulador original. A definição do cálculo do MP para cada estado foi baseada na idéia que o sensor de colisão é um mecanismo binário, isto é, apresenta dois estados: acionado e não-acionado. Assim, para manter a definição de neurônio *spiking* onde existem seis estados distintos, o MP é calculado através de um valor de entrada que deve ser suficientemente alto para disparar o potencial de ação. Desse modo, as equações de cada estado foram definidas como:

$$\text{Estado A, Estado B: } MP(t+1) = MP(t) + input_value;$$

$$\text{Estado C: } MP(t+1) = MP(t);$$

$$\text{Estado D: } MP(t+1) = MP(t) - 2 * input_value;$$

$$\text{Estado E: } MP(t+1) = MP(t) - 2 * input_value;$$

$$\text{Estado F: } MP(t+1) = MP(t) - input_value;$$

onde o *input_value* é o valor lido pelo sensor físico.

4.1.2 Normalização do potencial de membrana

Os valores que o potencial de membrana pode assumir devem sempre estar entre a faixa de valores aceitáveis pelo neurônio aqui definido, apresentando um valor máximo

de 60 mV e um valor mínimo de -80 mV. Por esse motivo, durante o cálculo de atualização do potencial de membrana, é necessário que seja feita uma normalização dos valores de saída da função, pois a função $MP(t+1)$ pode levar a valores fora dessa faixa.

Assim, a função de normalização implementada é dada por.

$$\text{normaliza} \left\{ \begin{array}{l} MP(t+1) = -80, \text{ se } MP(t) < -80 \\ MP(t+1) = 60, \text{ se } MP(t) > 60 \\ MP(t+1) = MP(t), \text{ nos demais casos} \end{array} \right.$$

4.1.3 Cálculo do potencial sináptico

O cálculo do potencial sináptico (*Synpot*), segundo o modelo original, possui uma grande influência sobre a atualização do potencial de membrana. Segundo os testes realizados, esse potencial deve ter uma influência menor, uma vez que ele é necessário somente para o início da geração do potencial de ação. Por esse motivo, além de ter sido retirado da atualização dos estados B a F, outras três alterações foram realizadas no cálculo do *Synpot*. A primeira está relacionada às sinapses inibitórias, que não foram descritas no modelo original. Neste caso, foi decidido pela facilidade de implementação, que se houver alguma sinapse inibitória entre as sinapses de entrada do neurônio, este será inibido, levando ao valor do potencial sináptico a zero. Esse comportamento é necessário para que as redes com ciclos não entrem em *deadlock*, isto é, não passem por uma situação de travamento, onde não é possível alcançar o próximo estado.

A segunda modificação foi realizada sobre a equação que calcula o *Synpot*, apresentada abaixo:

$$S(t) = \sum_i w_i k_i MP_i(t) - BaseMP_i$$

Essa equação foi simplificada, retirando a parte do cálculo do potencial pós-sináptico ($BaseMP - MP(t)$), pois, segundo o ponto de vista estudado, não faz sentido o cálculo de o potencial sináptico ser influenciado pelo potencial pós-sináptico. Assim, a equação final do *Synpot* ficou igual a $S(t) = \sum_i w_i k_i$.

A última alteração é aplicada sobre a função de atualização dos pesos $w(t+1)$, que para a sinapse básica proposta pelo modelo original, apresenta valores entre +16 e -16. Porém essa variação no peso sináptico não permita com que haja um controle do potencial sináptico resultante, gerando assim uma falta de sincronização entre os estados do neurônio. Assim, assume para o w_i um valor único ($=0,5$), determinado empiricamente.

4.1.4 Constantes

Algumas constantes foram modificadas para a adequação das equações alteradas, tais como para o cálculo do potencial de membrana e do potencial sináptico. As constantes que foram alteradas e seus motivos são apresentadas na Tabela 4.2:

Tabela 4.2 Constantes alteradas no modelo proposto.

Constante	Valor Original	Valor Fixado	Motivo
<i>TimeConst</i> ()	não especificado	0	Valor determinado pela velocidade do processador
<i>MinMP</i>	-69	-75	Variações do MP ocorrem de 15 em 15 mV, sendo este o valor escolhido para a transição dos estados
β	1,5	5	Devido ao corte do PPS, seu valor deve ser maior
	25	5	Diminuir o cálculo do MP no estado D para que não tenha uma transição muito brusca
	20	-5	Diminuir o cálculo do MP no estado A para que não tenha uma transição muito brusca
<i>D</i>	1	-1	O valor do peso sináptico para habituação deve aumentar e não diminuir

4.1.5 Normalização das entradas sensoriais

Como as entradas são realizadas pela simulação de sensores físicos (colisão, IR e luz), é necessário que seja definida uma função de normalização destas entradas. Essa

normalização foi definida para que os valores de entrada variem entre 0 e um valor máximo aceitável pelo sensor que esta sendo utilizado (*MaxSensor*). Esta entrada deve sempre apresentar valores variando de 15 em 15, pois estes são os valores entre a transição dos estados. Assim, a função de normalização é dada por:

$$\text{normaliza_sensores} = \text{input_value} \text{ div } \text{MaxSensor} * 15$$

Através das modificações descritas nesta seção foi possível implementar o simulador proposto neste trabalho, que é apresentado na seção seguinte.

4.2 Simulador

O SPINS, acrônimo de *Spiking Neurons Simulator*, é um simulador neural que utiliza neurônios *spiking* para visualização de aspectos de aprendizado. Sua concepção foi dada a partir do simulador *Hi-NOON*, apresentado na seção 3.2.1 e aplicando as modificações apresentadas na seção 4.1.

4.2.1 Funcionamento

A visualização das formas de aprendizado é dada pela montagem da rede, que permite utilizar conexões sinápticas para gerar o aprendizado. Por exemplo, a habituação é uma forma de aprendizado que pode ser obtida através da conexão de dois neurônios ligados através de uma sinapse do tipo habituada, como apresentada pelo simulador Hi-NOON.

Além disso, o simulador permite acompanhar a ativação de cada neurônio durante a simulação. Inicialmente, os neurônios se encontram no estado de repouso, que é caracterizado pelo potencial de membrana apresentar o valor igual a -60 mV. Para que os neurônios saiam do estado de repouso e conseqüentemente sejam ativados, suas entradas sinápticas devem ser ativadas através de um pulso gerado por outros neurônios ou por entradas externas no caso dos neurônios sensoriais. Assim, como os neurônios implementados no simulador são do tipo *spiking*, a ativação de cada neurônio ocorre pela geração de impulsos ou potenciais de ação (*spikes*). Esses impulsos são obtidos quando o potencial de membrana do neurônio chega a um limiar, definido no simulador como -45 mV. O potencial de ação gerado por um neurônio é então transmitido para os demais neurônios ligados ele, se a conexão sináptica for do tipo excitatória. Assim, os neurônios subseqüentes, chamados pós-sinápticos serão ativados, alterando seu valor de potencial de membrana.

A ferramenta mostra ainda qual o estado atual do neurônio. O estado do neurônio é determinado pelo seu potencial de membrana, o qual é mostrado no rótulo do objeto visual que representa o neurônio. A definição de cada estado (A-F) segue a divisão feita sobre a onda característica do potencial de ação, como mostrado na Figura 3.7. Assim, o

neurônio pode se encontrar em um de seis estados, cuja representação gráfica do estado é dada através de um esquema de cores.

4.2.2 Desenvolvimento da ferramenta

O simulador SPINS foi desenvolvido utilizando linguagem de programação Pascal orientada a objetos. O ambiente de desenvolvimento utilizado foi o Delphi 7, pois apresenta uma IDE (*Integrated Development Environment*) que facilita o desenvolvimento de ferramentas com interface gráfica, tais como o simulador aqui proposto.

Para proporcionar uma interface de fácil utilização, foram desenvolvidas bibliotecas gráficas, a partir de algumas já existentes, que permitem o desenho de componentes visuais para representar os objetos que compõem a rede neural (neurônios e sinapses).

4.2.3 Interface

Sua interface foi desenvolvida com o propósito de se conceber uma ferramenta didática, de fácil utilização e que permita a visualização da rede neural como um todo, como mostra a Figura 4.1.

Para tornar mais ampla a utilização do simulador no ambiente de pesquisa e facilitar sua divulgação internacionalmente, sua interface se apresenta em inglês, assim como os demais simuladores desenvolvidos com o mesmo propósito. Além disso, optou-se por essa língua pelo fato de que os termos utilizados nas áreas de Redes Neurais e de Neurociências não são habitualmente traduzidos para o português, devido à falta de termos totalmente equivalentes na língua portuguesa.

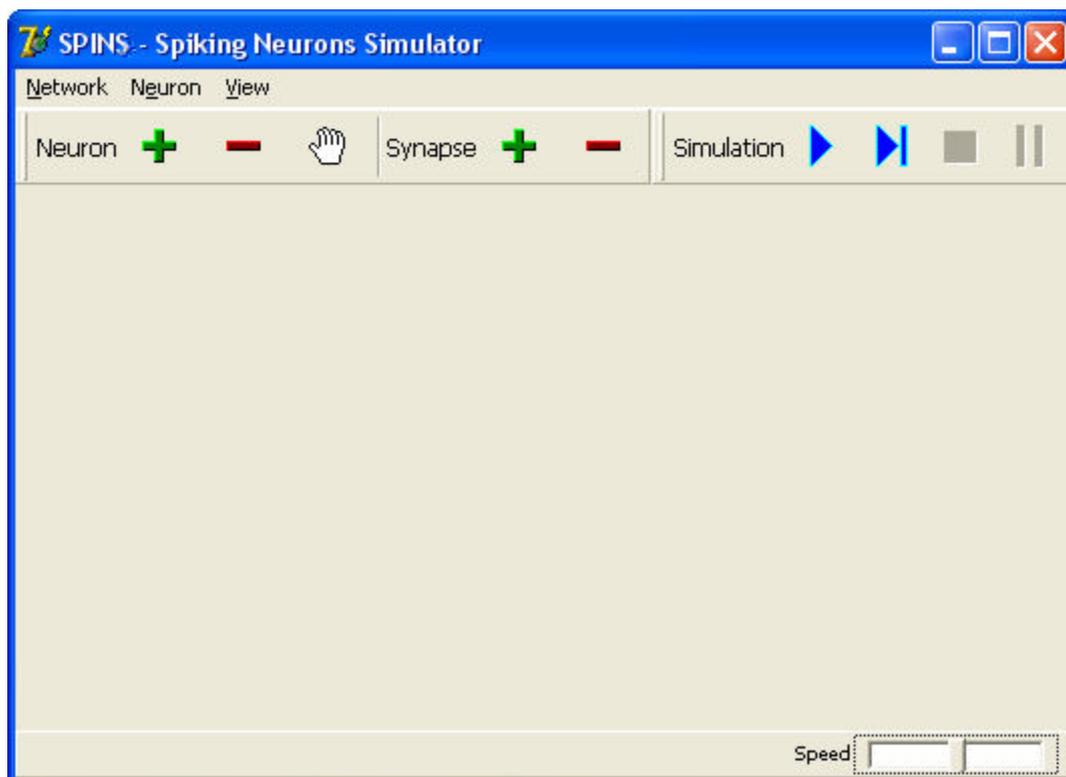


Figura 4.1 Tela principal do simulador SPINS.

4.2.4 Objetos do Sistema

Os objetos que compõem o sistema são objetos gráficos que representam os principais componentes de uma rede neural: neurônios e sinapses. Estes objetos são discutidos nas seções seguintes.

4.2.4.1 Os neurônios

Os neurônios, representados aqui por círculos, são objetos visuais que apresentam três características básicas:

nome: identifica o neurônio na rede;

tipo: identifica qual o tipo do neurônio, que pode ser *Basic*, *Sensor* (divididos em *Bumper*, *LDR*, *IR*), *Noisy*, *Ramp* e *Burst*;

parâmetros iniciais: permite com que os parâmetros do neurônio (*MP*, *BaseMP*, *Threshold*, *SynPot*, *TimeConst* e *Fired*) sejam iniciados com valores pré-definidos.

O nome é apresentado no rótulo do objeto. A identificação do tipo do neurônio é feita através de cores. O esquema de cores segue conforme os esquemas apresentados por Damper et al [4,30,31]: neurônios sensores em cinza, neurônios motores em preto e os demais tipos de neurônios em branco, como mostrados na Figura 4.2. Mas, o simulador permite personalizar essas cores conforme o desejado.

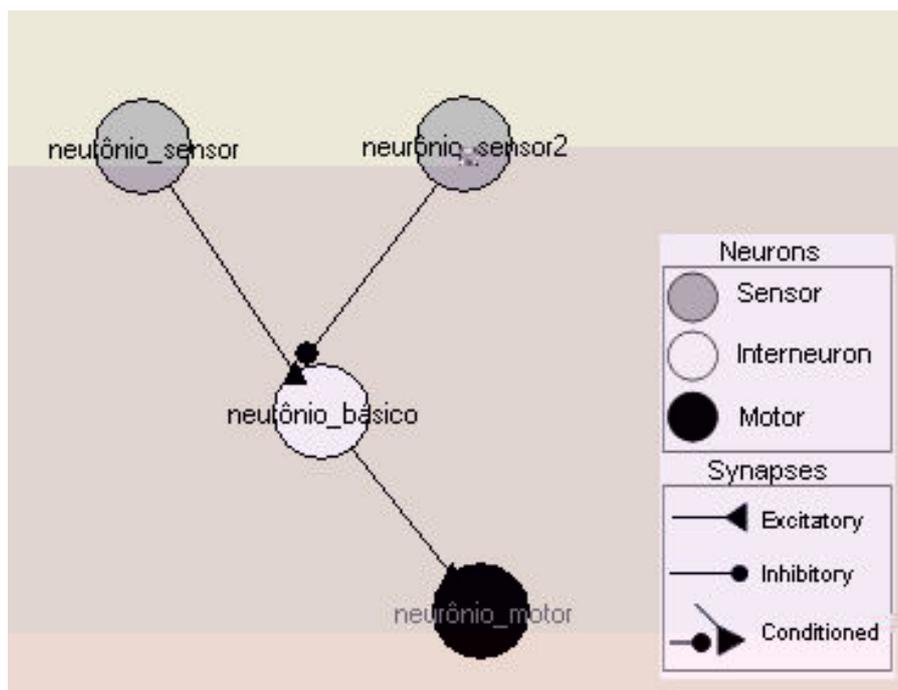


Figura 4.2 Elementos visuais do SPINS.

4.2.4.2 As sinapses

As sinapses são objetos gráficos representados por setas, cuja ponta varia conforme o tipo da sinapse. As sinapses podem ligar dois neurônios ou um neurônio e outra sinapse, onde ambos devem ser previamente criados. As características básicas da sinapse são:

nome: identifica a sinapse na rede;

tipo: informa qual o tipo da sinapse, que pode ser *Basic*, *Habituated*, *Sensitized*, *Conditioned*;

inibida: valor booleano que indica se a sinapse é inibitória.

As sinapses do tipo *Basic* e *Habituated* são monossináptica, na qual ligam um neurônio ao outro. São representadas graficamente por uma seta com um triângulo na ponta. Já as sinapses *Conditioned* e *Sensitized* são sinapses do tipo axo-axônicas (*synapse-on-synapse*), ligando um neurônio a outra sinapse, que deve ser monossináptica. Essas sinapses são representadas por setas com círculos preenchidos na ponta, sobrepondo o triângulo da sinapse alvo (básica ou habituada). A representação gráfica destes tipos de sinapses pode ser visualizada na Figura 4.2.

4.2.5 Funcionalidades

As principais funcionalidades do simulador são fornecidas pelas barras de ferramentas e menu de comandos, conforme mostrado na Figura 4.3.

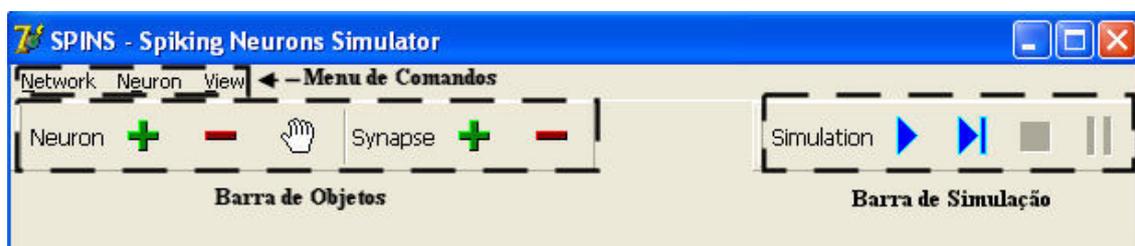


Figura 4.3 Barras de ferramentas do SPINS.

A barra de objetos, localizada a esquerda do simulador, permite a criação e deleção dos objetos neurônios e sinapses. Além disso, permite mover os neurônios, que consequentemente, movem as sinapses ligadas a ele.

A barra de simulação, localizada à direita, apresenta os comandos necessários para executar a simulação, tais como iniciar, simulação passo a passo, cancelar ou parar a simulação.

O menu de comandos permite realizar operações relacionadas à rede neural, tal como criar uma rede completa, baseada no exemplo pré-definido (modelo neural do ARBIB, que será apresentado no capítulo 5), ler e salvar a rede em um arquivo e

destruir a rede. Além disso, apresenta os comandos para criar, deletar, editar e mover neurônios. Conta ainda com um menu para customizar a ferramenta, permitindo a visualização ou não das barras de ferramentas e das legendas de estados e objetos do sistema.

Cada uma destas funcionalidades citadas acima, além de outras que o simulador apresenta, são descritas a seguir.

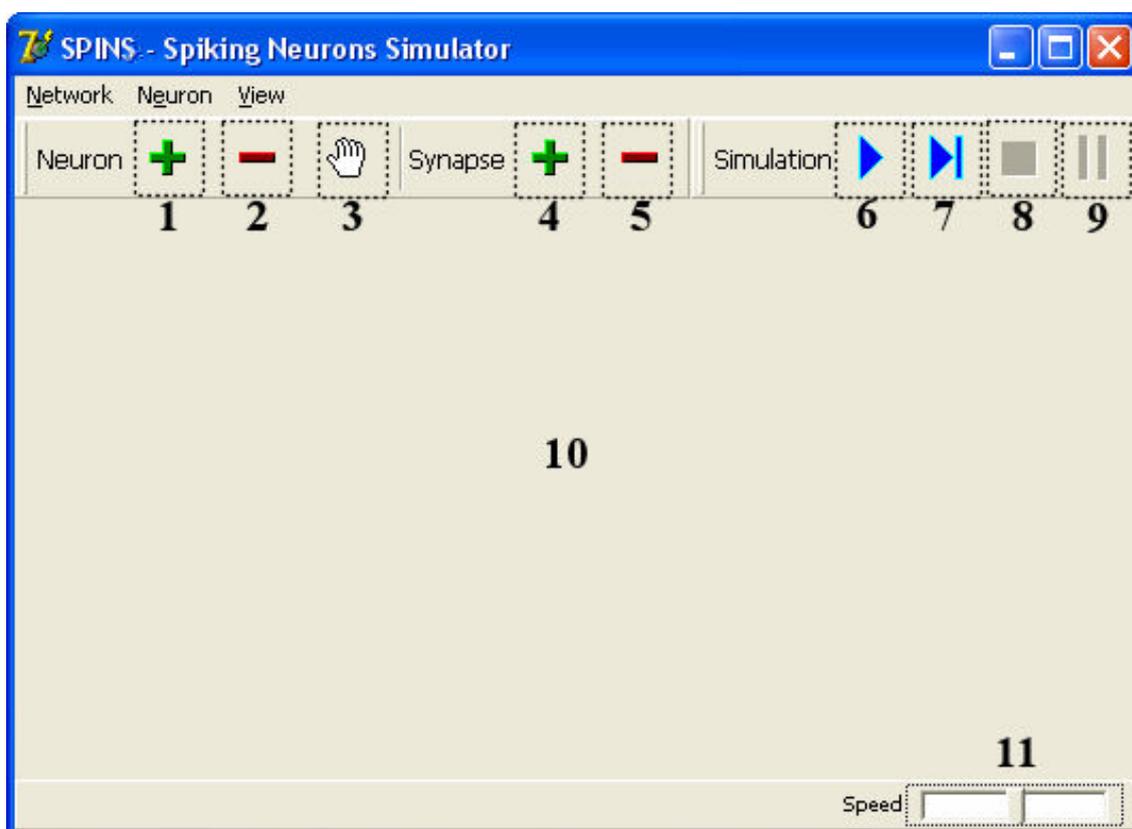


Figura 4.4 Principais funcionalidades do SPINS.

Criar neurônios e sinapses

A criação de neurônios e sinapses é feita pelos botões identificados na Figura 4.4 por 1 e 4 respectivamente. Esses objetos devem ser criados, na área identificada como 10, para a montagem da rede neural. A criação da sinapse deve ser feita somente quando os objetos que esta conecta - os neurônios pré e pós-sinápticos (no caso da sinapse

básica) ou o neurônio pré e a sinapse a ser condicionada (no caso da sinapse axo-axônica) - estiverem criados.

Deletar neurônios e sinapses

Esta funcionalidade permite deletar neurônios, através do botão 2, e sinapses, pelo botão 5. Ao se deletar um neurônio, todas as sinapses ligadas a ele (pré ou pós sinápticas) serão deletadas.

Mover neurônios

Permite mover os neurônios de posição, juntamente com as sinapses ligadas a ele. Esta funcionalidade é ativada pelo botão identificado como 3 na Figura 4.4.

Controlar simulação

A simulação pode ser iniciada de forma direta ou de modo passo a passo, através dos botões 6 e 7, respectivamente. Após iniciada, a simulação pode ser cancelada (acionando o botão 8) ou parada (botão 9), sendo que a opção de parar permite a simulação seja retomada.

Maiores detalhes sobre a simulação serão apresentados na seção 4.2.6.

Editar parâmetros dos neurônios

Os neurônios apresentam parâmetros iniciais (que foram apresentados na seção 4.2.4.1). Esses parâmetros permitem que o cada neurônio tenha seu valor padrão, como por exemplo um limiar de disparo próprio, representado pelo parâmetro *threshold*.

Definir cores dos neurônios

Os neurônios apresentam um esquema de cores padrão, como visto na seção 4.2.4.1, que podem ser alterados conforme a necessidade. Porém, esta funcionalidade não se estende para as cores durante a simulação.

Carregar e salvar rede

Essas funcionalidades permitem que uma rede possa ser reutilizada em outras simulações. Isso representa uma grande vantagem, visto que a montagem das redes neurais composta por um grande número de neurônios e sinapses levar tempos consideráveis.

Criar rede completa

Essa funcionalidade cria a rede exemplo do simulador, que se refere à rede neural do robô ARBIB, apresentado na seção 5.1.

Destruir rede

Permite que uma rede criada seja destruída, reiniciando o simulador.

Customizar ferramenta

O simulador apresenta duas barras de ferramentas, que foram mostradas na Figura 4.3, as quais podem ser ocultadas. Isso permite com que a área de desenho (área 10 da Figura 4.4) seja expandida. Além disso, existem duas legendas - uma que mostra as cores dos estados de cada neurônio, como visto na Figura 4.5, e outra que mostra os objetos do sistema, como mostrado na Figura 4.2 - que podem ser mostradas ou não, onde a ferramenta permite escolher a posição que estas se encontram, podendo ser um dos quatro cantos da área de desenho.

Gerar log de processamento da rede

O arquivo de log gerado após a simulação (chamado spins.log) armazena as informações referentes ao neurônio, a cada passo da simulação. As informações armazenadas são: nome do neurônio, estado atual, valor do potencial sináptico (*SynPont*) e valor do potencial de membrana (MP).

4.2.6 Simulação

A simulação pode ser realizada de duas formas: direta ou passo a passo. Na simulação direta, os passos da simulação são executados de modo contínuo. Já no modo passo a passo, cada passo da simulação é decorrido a cada acionamento do botão.

Ao ser iniciada a simulação, é necessário informar em quantos passos será concluída. Esse número de passos é utilizado por um contador global da rede, que permitir controlar cada objeto em cada instante de tempo (determinado por um passo). Cada passo da simulação do tipo direta é executado num intervalo de tempo de 1 s. Porém esse tempo pode ser alterado para não haver intervalo (0 s) ou ter um intervalo de

até 2 s entre cada passo. Esse controle de tempo é realizado pela barra de velocidade (*speed*), apresentada no canto direito inferior da ferramenta, como mostra a Figura 4.5.

A simulação pode ainda ser parada ou cancelada. Se parada, a simulação pode ser retomada do ponto atual. Ao ser cancelada, a simulação será definitivamente encerrada, sem que possa ser retomada.

Para iniciar uma simulação, a rede na qual se pretende simular deve estar construída, podendo ser montada manualmente ou através da leitura de um arquivo. Na figura abaixo (Figura 4.5), é mostrado a simulação de uma rede que representa um gerador central de padrão.

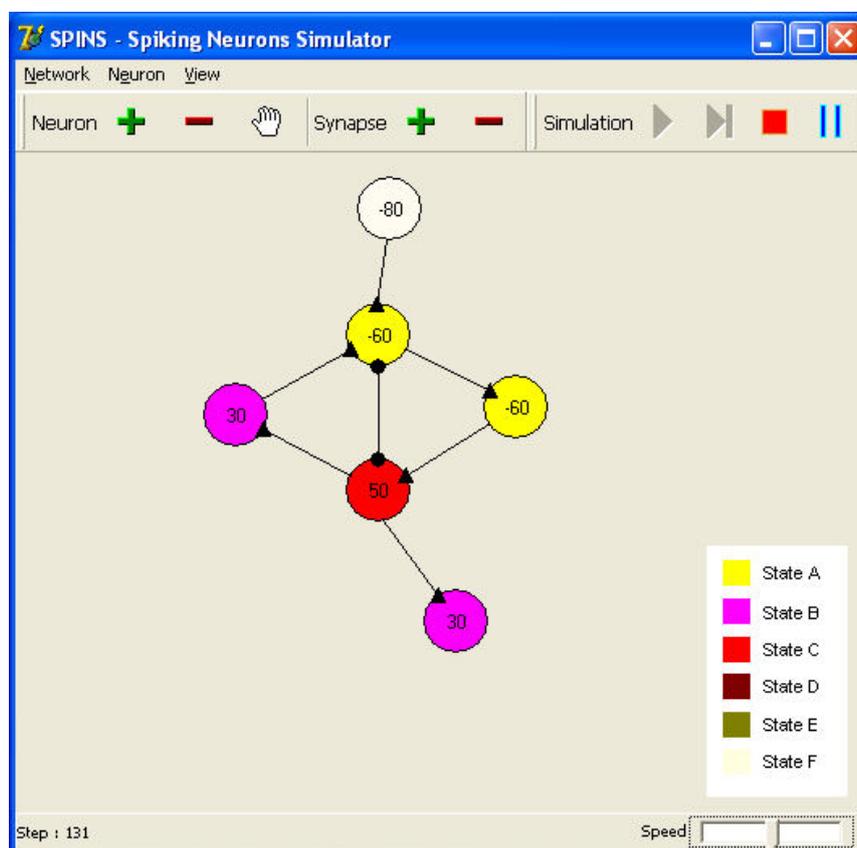


Figura 4.5 Simulação de um gerador central de padrão.

Um exemplo de simulação que apresenta uma rede mais complexa é mostrado no próximo capítulo, onde o robô ARBIB é tomado como exemplo de aplicação.

5 EXEMPLO DE APLICAÇÃO

Para provar a capacidade de simular aspectos de aprendizado, foi implementado um robô baseado em inspiração biológica, que aprende através dos métodos associativos e não-associativos. Esse robô, chamado ARBIB, será apresentado na seção que se segue.

5.1 ARBIB

ARBIB, cuja sigla significa Um Robô Autônomo Baseado em Inspiração Biológica, é um trabalho que foi desenvolvido por Damper et al. [4] em 2000 e discutido por French & Damper [29]. O objetivo principal desse trabalho foi testar se um robô teria um aprendizado eficiente, utilizando métodos associativos, como condicionamento clássico e de alta ordem, baseado nos mecanismos de métodos não-associativos, tais como habituação e sensibilização. Para provar essa teoria, o sistema nervoso do ARBIB foi implementado em um simulador neural chamado *Hi-NOON* (Rede Hierárquica de Neurônios Orientados a Objeto), que utiliza o conceito de neurônios *spiking*. Tais conceitos foram apresentados mais detalhadamente na seção 3.1.2 e 3.2.1

O sistema neural deste robô apresenta diferentes circuitos, implementados através do *Hi-NOON*, para simular comportamentos inteligentes. Esses comportamentos e circuitos são apresentados abaixo.

5.1.1 Gerador central de padrão

É um circuito oscilatório, responsável pelo comportamento de perambular do ARBIB. Esse gerador central de padrão (GCP) é baseado no circuito neural que implementa o comportamento de nadar da *Clione*, um molusco marinho apresentado na seção 2.5.2. É basicamente constituído de quatro neurônios interligados, que apresentam inibição mútua para a geração do padrão oscilatório, conforme mostrado na Figura 5.1.

As ligações entre os neurônios C2 e C4 com as direções direita e esquerda são feitas por sinapses do tipo *noisy*, que faz com que a sinapse dispare dependendo da atividade do neurônio pré-sináptico. Isso permite que o robô não permaneça caminhando em linha reta, quando este está percorrendo grandes distâncias.

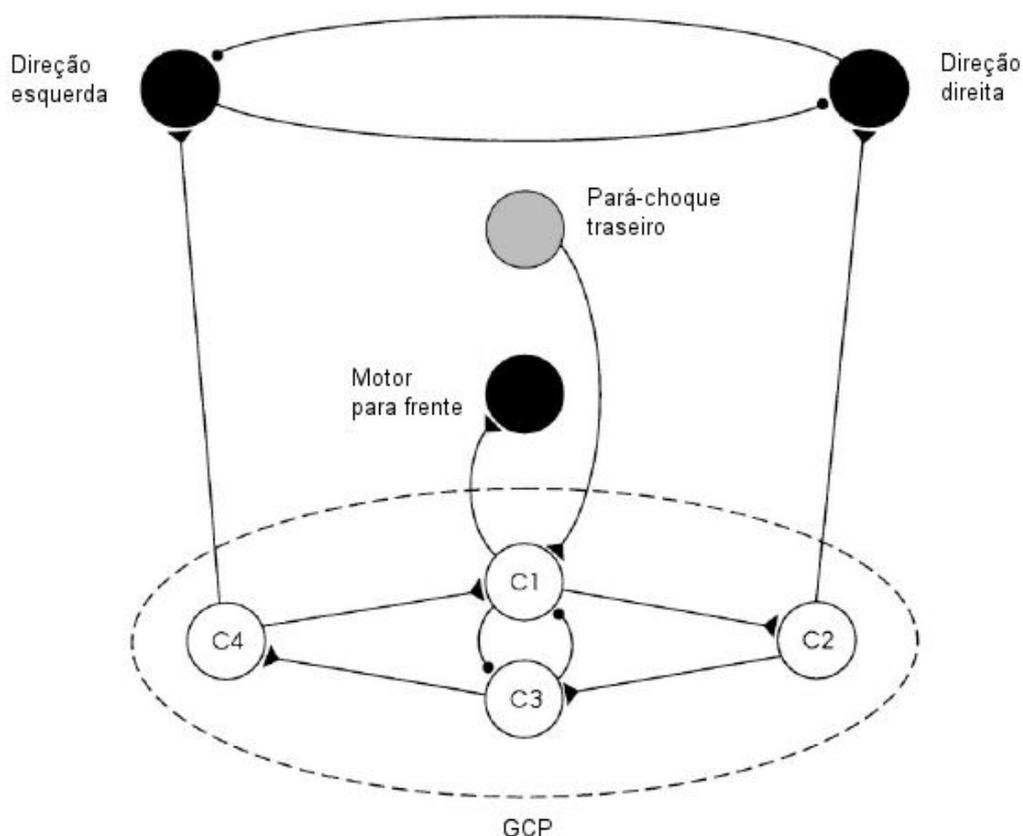


Figura 5.1 Gerador central de padrão do ARBIB.
(modificado de Damper et al. [4])

5.1.2 Reflexo

Segundo Damper et al. [4], os reflexos são comportamentos inatos que o robô apresenta para sobreviver ao ambiente, os quais são utilizados como estímulos não-condicionados no processo de aprendizado por condicionamento clássico. No ARBIB, essas respostas reflexas são implementadas pelo circuito apresentado na Figura 5.2. O reflexo do ARBIB é similar ao reflexo de retirada, discutido na seção 2.5.1, pois apresenta uma resposta à colisão.

O funcionamento deste circuito reflexo é simples: sempre que um dos sensores de colisão é ativado, o robô anda para trás se distanciando do objeto contra o qual colidiu, ao mesmo tempo em que muda de direção. Estes comportamentos são realizados pelos neurônios motores reverso e de direção, que estão ligados aos interneurônios reflexos. Além disso, a sinapse inibitória entre o sensor traseiro e o motor reverso irá fazer com que o robô pare de andar para trás quando este bater em algo.

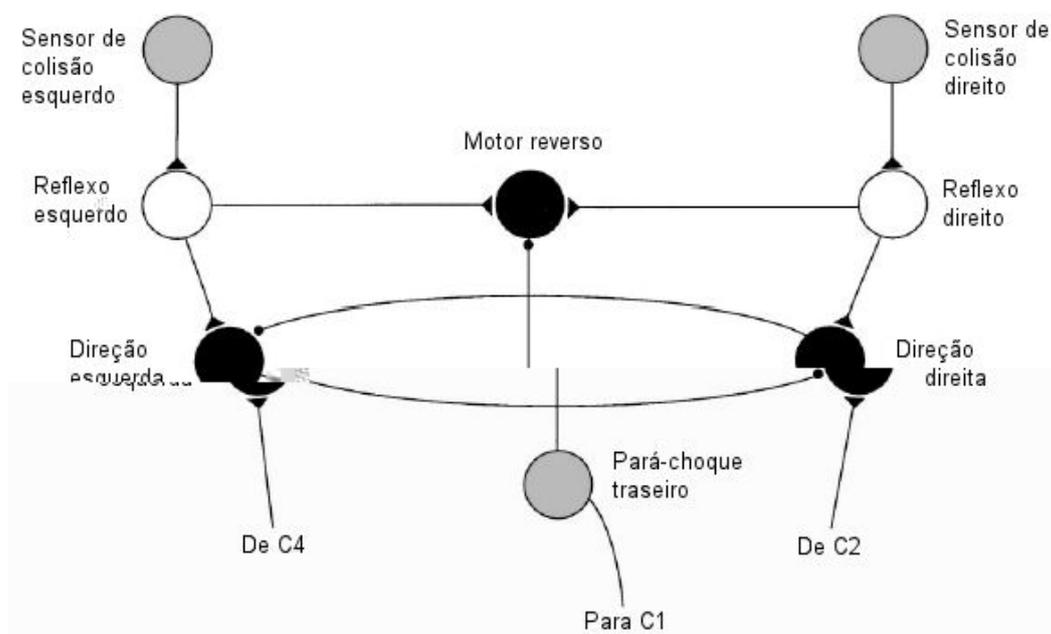


Figura 5.2 Comportamento reflexo do ARBIB.
(modificado de Damper et al. [4])

5.1.3 Condicionamento clássico

O aprendizado por condicionamento clássico é realizado através das conexões sinápticas do tipo axo-axônica, como mostrado durante a descrição do simulador *Hi-NOON* (seção 3.2.1). O comportamento aprendido pelo ARBIB é de evitar a colisão, aprendendo a utilizar os sensores de proximidade, do tipo infravermelho (IR). Esses sensores permitem que o robô perceba a presença de obstáculos sem que bata neles, através de um mecanismo que faz com que o sinal infravermelho seja refletido ao se aproximar de algum objeto.

O aprendizado ocorre da seguinte forma: à medida que o robô caminha, os sensores de IR serão ativados sempre que encontrar um obstáculo. Porém, como a conexão entre os sensores de IR e os interneurônios IIL e IIR é fraca, devido à sinapse ser do tipo axo-axônica, o robô continua em frente até colidir com o obstáculo. Essa colisão faz com que a sinapse entre o neurônio sensorial IR e o interneurônio IIL ou IIR seja facilitado, aumentando seu peso. Após algumas colisões, a força sináptica entre os IRs e o IIL ou IIR é suficientemente alta para que a próxima detecção do objeto feita pelo neurônio sensorial IR. Isso faz com que seja disparado o interneurônio reflexo, o qual gera o comportamento reflexo de recuo, sem que haja a necessidade da colisão. O mecanismo descrito acima, que implementa o aprendizado condicionado no ARBIB, é mostrado na Figura 5.3.

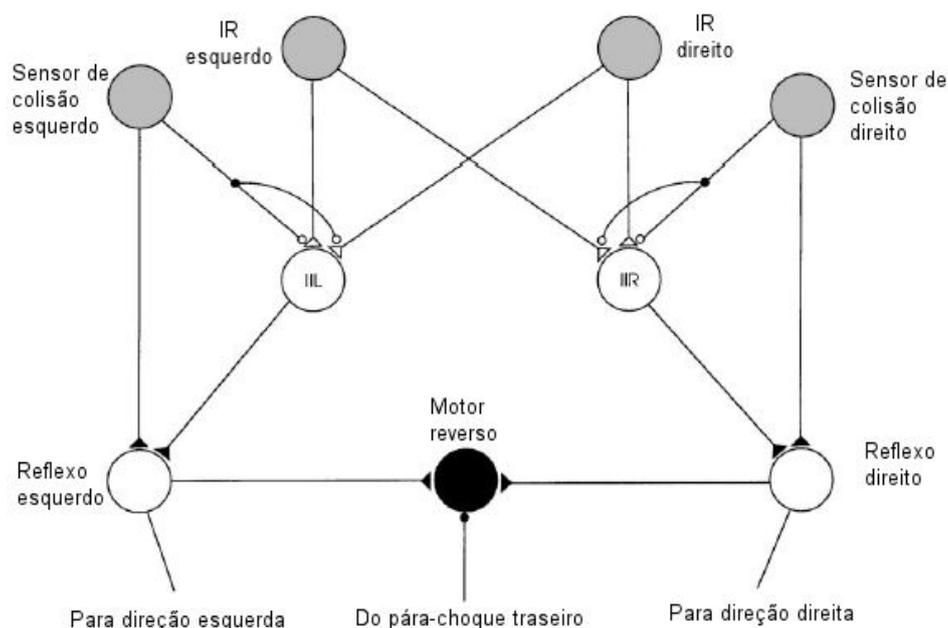


Figura 5.3 Condicionamento clássico do ARBIB.
(modificado de Damper et al. [4])

5.1.4 Condicionamento de alta-ordem

É um tipo de condicionamento que acontece após ocorrer o condicionamento clássico. A concepção deste tipo de condicionamento para o robô é a mesma: aprender a utilizar os sensores para evitar a colisão.

Nesse tipo de aprendizado, o robô aprende a substituir o estímulo condicionado (captado pelo sensor de IR) por outro estímulo condicionado, que neste caso é a percepção da sombra do objeto. A vantagem desse tipo de aprendizado é que o robô não necessita se aproximar do objeto para percebê-lo. A simples presença de sua sombra já faz com que o robô desvie do objeto.

Esse comportamento é implementado através de sensores que respondem à variação de intensidade de luz, chamados resistores de detecção de luminosidade (LDR), conforme mostrado na Figura 5.4.

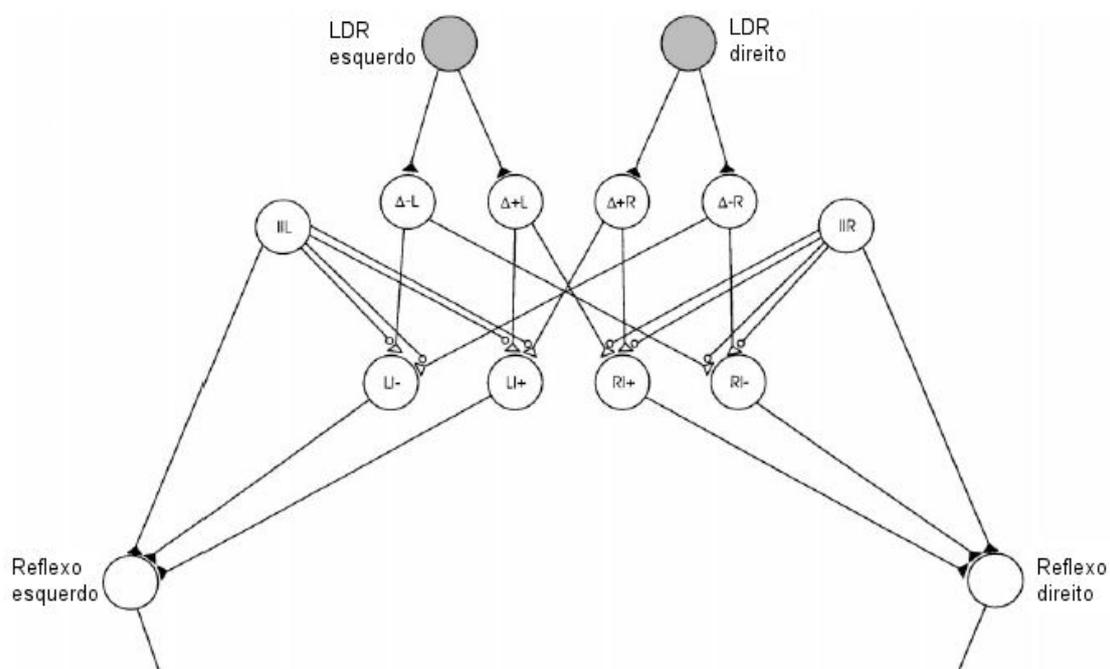


Figura 5.4 Condicionamento de alta-ordem do ARBIB.
(modificado de Damper et al. [4])

Maiores informações sobre os comportamentos e circuitos descritos aqui podem ser encontrados em [4,29,30,31].

5.2 Simulação

A rede neural completa do ARBIB é montada pelo simulador através do menu *Network* → *Create*. A rede gerada é mostrada pela Figura 5.5.

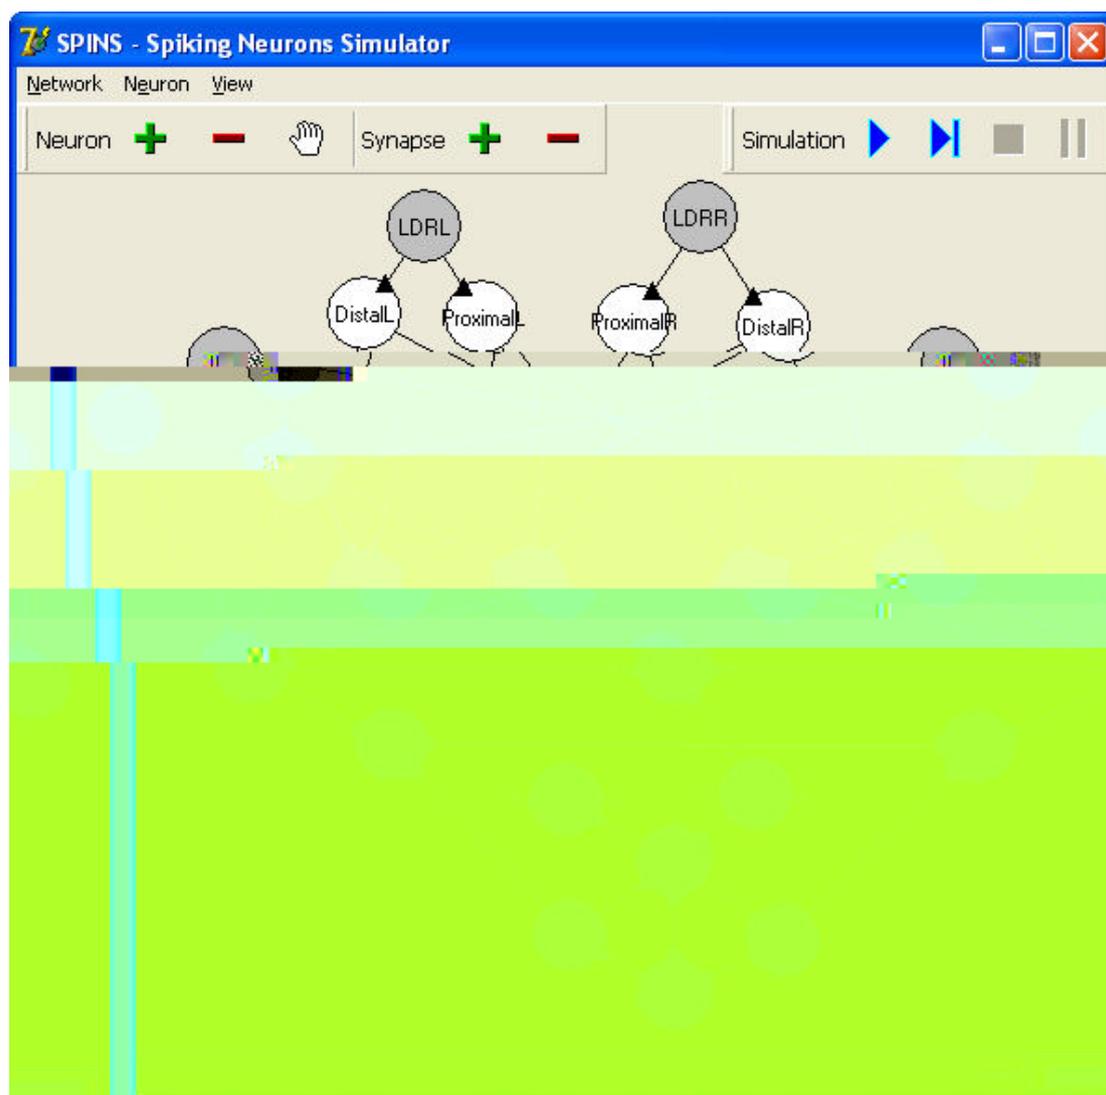


Figura 5.5 Rede neural completa do ARBIB simulado no SPINS.

Durante a simulação, a rede apresenta os estados de cada neurônio, como mostrado na Figura 5.6

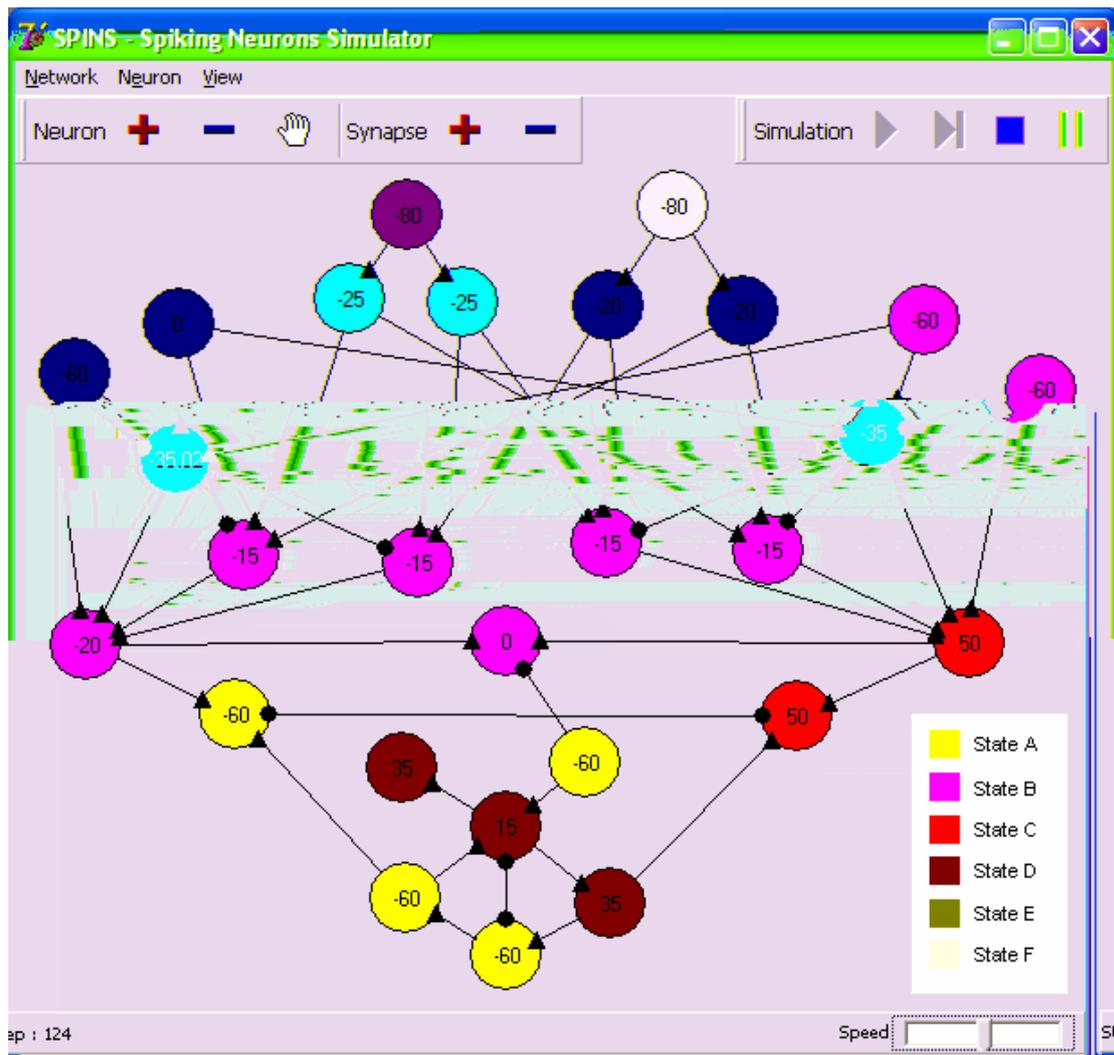


Figura 5.6 Simulação da rede neural do ARBIB.

6 CONSIDERAÇÕES FINAIS

Atualmente os simuladores neurais não apresentam uma visualização satisfatória da rede neural como um todo. Através do simulador proposto foi possível suprir a necessidade de uma ferramenta mais didática para a visualização dos estados dos neurônios durante a simulação da rede neural. Além disso, através deste simulador é possível se entender como ocorrem, a nível neural, os mecanismos de aprendizado.

6.1 Contribuições

Este trabalho foi baseado no modelo neural do simulador *Hi-NOON*. A partir deste simulador podem ser destacadas algumas correções do modelo neural e melhorias de sua interface:

Implementação de uma interface independente de qualquer dispositivo físico ou mesmo de outros simuladores. Como descrito durante o trabalho, o *Hi-NOON* é um simulador que necessita ser executado sob outros simuladores, tais como o simulador do robô Khepera, pois não apresenta uma interface para a visualização da simulação;

Modificações dos cálculos de atualização do potencial de membrana e do potencial sináptico para corrigir o problema apresentado pelos circuitos neurais com ciclos. Esses circuitos, tais como o gerador central de padrão, apresentavam problemas na sincronização dos estados de cada neurônio, caracterizando uma situação de travamento (*deadlock*);

Desenvolvimento de uma interface gráfica que permite a visualização da rede como um todo, onde é possível identificar a ativação de cada neurônio e seu estado atual, determinado pelo potencial de membrana.

6.2 Trabalhos Futuros

Para dar continuidade a este trabalho, alguns pontos são sugeridos para ampliar e complementar a ferramenta de simulação aqui proposta:

Implementar outros modelos de neurônios *spiking*, como por exemplo, o modelo de Hodgkin-Huxley que é um modelo neural mais preciso, devido à sua característica de analisar a geração do potencial de ação a nível iônico;

Implementar sinapses químicas, onde a transmissão sináptica é feita a nível de íons, para assim tentar nos aproximar do modelo biológico;

Desenvolver mecanismos que permitam a entrada de sensores físicos, através de leitura de porta serial ou outro meio, para que a simulação destes sensores se torne mais precisa;

Permitir ao simulador interagir com robôs físicos, captando informações externas, a partir dos sensores do robô, e apresentando saída através seus motores. Isso possibilitaria que fosse mostrado o processamento de redes neurais implementadas em artefatos físicos, através do simulador;

Agregar módulos que possibilitem visualizar o potencial de membrana e a geração do potencial de ação de cada neurônio através de gráficos ou outras formas de visualização;

Gerar relatórios customizados do processamento da rede, visto que atualmente essa informação é mostrada somente através do arquivo de log;

Permitir salvar simulações feitas para análise posterior;

Melhorar as funcionalidades relativas aos objetos visuais, permitindo uma maior customização dos mesmos.

7 REFERÊNCIAS BIBLIOGRÁFICAS

1. SHARKEY, Noel E. Biologically Inspired Robotics. In: ARBIB, Michel A. (Ed.). **The Handbook of Brain Theory and Neural Networks**. 2. ed. Cambridge, MA: The MIT Press, 2002. p.160-164.
2. ARBIB, Michel A. Background: The Elements of Brain Theory and Neural Networks. In: _____ **The Handbook of Brain Theory and Neural Networks**. 2. ed. Cambridge, MA: The MIT Press, 2002. p. 3-23.
3. BEAR, Mark F.; CONNORS, Barry. W.; PARADISO, Michael. A. **Neuroscience: Exploring the brain**. 2. ed., Baltimore: Lippincott Williams & Wilkins. 2001.
4. DAMPER, Robert I.; FRENCH, Richard L. B.; SCUTT, Tom W. ARBIB: An autonomous robot based on inspirations from biology. **Robotics and Autonomous Systems**, v.31 n.4, p.247-274, 2000.
5. ERHART, Eros Abrantes. **Neuranatomia**. 5. ed. São Paulo: Atheneu, 1974. 420 p.
6. GERSTNER, Wulfram; KISTLER, Werner M. **Spiking Neuron Models: Single Neurons, Populations, Plasticity**. 1. ed. Cambridge, UK: University Press Cambridge, 2002. 400p.
7. WALSH, Anthony A. **Introduction to Psychology Unit 3: Biological Foundations of Behavior**. Disponível em: <http://www.sruweb.com/~walsh/intro_unit_three.html>. Acesso em: 05 set. 2005.
8. GUYTON, Arthur C.; HALL, John E. **Tratado de fisiologia médica**. 9. ed. Rio de Janeiro: Guanabara Koogan, 2002. 973p.
9. TOLEDO-RODRIGUEZ; Maria et al. Neocórtex: Basic Neuron Types. In: ARBIB, Michel A. (Ed.). **The Handbook of Brain Theory and Neural Networks**. 2. ed. Cambridge, MA: The MIT Press, 2002. p.719-725.
10. KOLB, Bryan; WHISHAW, Ian Q. **An Introduction to Brain and Behavior**. 2. ed. New York: Worth Publishers, 2001. 608p.

11. PURVES, Dale et al. **Neuroscience**. 3. ed. Massachusetts: Sinauer Associates Inc, 2004. 773p.
12. ZIGMOND, Michael J. et al. **Fundamental Neuroscience**. 1. ed. San Diego: Academic Press, 1999. 1600p.
13. KANDEL, Eric R.; SCHWARTZ, James H.; JESSEL, Thomas M. **Principle of Neural Science**. 4. ed. New York: McGraw-Hill Medical, 2000. 1414p.
14. ALLEN, Selvertston; MAZZONI, Pietro. Flexibility of Computational Units in Invertebrate CPGs. In: DURBIN, Richard; MIAL, Christopher; MITCHISON, Graeme (Eds.). **The Computing Neuron**. New York: Addison-Wesley Publishing Co., 1989. p. 205-228.
15. HOOPER, Scott L. Crustacean Stomatogastric System. In: ARBIB, Michel A. (Ed.). **The Handbook of Brain Theory and Neural Networks**. 2. ed. Cambridge, MA: The MIT Press, 2002. p. 304-308.
16. HAYKIN, Simon. **Redes Neurais: Princípios e prática**. Tradução de Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001. Tradução de: Neural Networks: a comprehensive foundation.
17. AZEVEDO, Fernando M.; BRASIL, Lourdes M.; OLIVEIRA, Roberto C. L. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas**. Florianópolis: Visual Books, 2000. 401p.
18. FREEMAN, James A.; SKAPURA, David M. **Neural Networks: Algorithms, Applications and Programming Techniques**. MA: Addison-Wesley, 1991. 401p.
19. FAUSETT, Laurene. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**. Upper Saddle River, NJ: Prentice Hall, 1994. 461p.
20. JAIN, Anil K.; MAO, Jianchang; MOHIUDDIN, K. M. Artificial Neural Networks: A Tutorial. **IEEE Computer**, v. 29, n. 3, p. 31-4, 1996.
21. KOCH, Christof; MO, Chun-Hui; SOFTKY, William. Single-Cell Models. In: ARBIB, Michel A. (Ed.). **The Handbook of Brain Theory and Neural Networks**. 2. ed. Cambridge, MA: The MIT Press, 2002. p. 1044-1049.

22. MINSKY, Marvin L.; PAPERT, Seymour A. **Perceptrons: An Introduction to Computational Geometry - Expanded Edition**. Cambridge, MA: The MIT Press, 1988. 275p.
23. GERSTNER, Wulfram. Integrate-and-Fire Neurons and Networks. In: ARBIB, Michel A. (Ed.). **The Handbook of Brain Theory and Neural Networks**. 2. ed. Cambridge, MA: The MIT Press, 2002. p. 577-581.
24. TIMOSZCZUK, Antonio P. **Reconhecimento Automático do Locutor com Redes Neurais Pulsadas**. 2004, 235 p. Tese (Doutorado em Engenharia) – Departamento de Engenharia de Telecomunicações e Controle, Escola Politécnica da Universidade de São Paulo, São Paulo, 2004.
25. GERSTNER, Wulfram. Spiking Neurons. In: MASS, Wolfgang; BISHOP, Christopher M. (Ed.). **Pulsed Neural Networks**. Cambridge, MA: The MIT Press, 2001. p. 3-53.
26. MASS, Wolfgang. Networks of Spiking Neurons: The Third Generation of Neural Network Models. **Neural Networks**, v. 10, n. 9, p. 1659-1671, 1997.
27. MASS, Wolfgang. On the Computational Complexity of Networks of Spiking Neurons. **Proceedings of the Conference on Computational Learning Theory**, Tennessee, p. 54-61, 1997.
28. MASS, Wolfgang; BISHOP, Christopher M. **Pulsed Neural Networks**. Cambridge, MA: The MIT Press, 2001. 377 p.
29. FRENCH, Richard L. B; DAMPER, Robert I. Stability of Learning in the ARBIB autonomous robot. In **Proceedings of Supplement - International Conference on Simulation of Adaptive Behavior: From Animals to Animats**. Paris, 2000, p. 150-159.
30. DAMPER, Robert I; FRENCH, Richard L. B; SCUTT, Tom W. The Hi-NOON neural simulator and its applications. In **Proceedings of Small System Simulation Symposium**. Iugoslavia, 2000, p. 31-36.
31. DAMPER, Robert I; FRENCH, Richard L. B; SCUTT, Tom W. The Hi-NOON Neural Simulator and its Applications to Animal, Animat and Humanoid

- Studies. In **Proceedings of First IEEE-RAS International Conference on Humanoid Robots**. Boston, MA, 2000.
32. BEKEY, George A; GOLDBERG, Kenneth Y. **Neural Networks in Robotics**. Norwell, MA: Klumer Academic Publishers, 1992. 580p.
 33. ROISENBERG, Mauro. **Emergência da Inteligência em Agentes Autônomos através de Modelos Inspirados na Natureza**. 1998. 206 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Santa Catarina, Florianópolis, 1998.
 34. LEE, Ten-min; NEHMZOW, Ulrich; HUBBOLD, Roger. Mobile Robot Simulation by Means of Acquired Neural Network Models. **European Simulation Multiconference**, Manchester, p. 465-469, 1998.
 35. JAHNKE, Axel; ROTH, Ulrich; SCHÖNAUER, Tim. Digital Simulation of Spiking Neural Networks. In: MASS, Wolfgang; BISHOP, Christopher M. (Ed.). **Pulsed Neural Networks**. Cambridge, MA: The MIT Press, 2001. p. 237-257.
 36. **The GENESIS SIMULATOR**. Disponível em: <<http://www.genesis-sim.org/GENESIS/>>. Acesso em: 29 out. 2005.
 37. **The PDP++ Software Home Page**. Disponível em <<http://www.cnbc.cmu.edu/Resources/PDP++/PDP++.html>>. Acesso em: 29 out. 2005.
 38. UNIVERSITY OF STUTTGART. **Stuttgart Neural Network Simulator**. Disponível em <<http://www-ra.informatik.uni-tuebingen.de/SNNS/>>. Acesso em: 29 out. 2005.

8 APÊNDICES

A - Glossário

NEURÔNIOS SPIKING (em inglês *spiking neurons*): são neurônios cuja informação é transmitida através de potenciais de ação (*spikes*). O termo *spiking* foi mantido devido à falta de um termo para sua tradução.

APRENDIZADO: denominação geral dada a mudanças permanentes de comportamento como resultado de treino ou experiência anterior.

COMPORTAMENTO: conjunto das reações que se podem observar num indivíduo, estando este em seu ambiente, e em dadas circunstâncias.

NEURITOS: ramificações que partem do corpo celular. Existem dois tipos: axônios e dendritos.

LIMIAR: valor que o potencial de membrana necessita atravessar para que seja dado início ao potencial de ação.

HIPERPOLARIZAÇÃO: processo na qual a membrana apresenta potenciais abaixo de seu potencial de repouso.

ENDÓGENO: de origem interior, que é gerado sem a intervenção externa.

GRAFO: conjunto não vazio finito de vértices juntamente com um conjunto não ordenado de arcos conectando certos pares de vértices [16].

Livros Grátis

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

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

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

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

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