

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

Eduardo Erlê dos Santos

**Implementação de um modelo de neurônios pulsados
para análise e visualização de formas de aprendizado
em tempo de operação em robôs**

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.

Florianópolis, Agosto de 2006

Implementação de um modelo de neurônios pulsados para análise e visualização de formas de aprendizado em tempo de operação em robôs

Eduardo Erlê dos Santos

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

Raul Sidnei Wazlawick, Dr.

Banca Examinadora

Mauro Roisenberg, Dr.

João Cândido Lima Dovicchi, Dr.

Jovelino Falqueto, Dr.

Edson Roberto de Pieri, Dr.

Mariana Graciela Terenzi, Dra.

*"The journey of a thousand miles, begins with the first step.
Beware the first step outside your door, you never know
where it will lead you."
Bilbo Baggins - The Lord of the Rings.*

Ofereço esta obra aos meus pais, por darem todo o apoio para que eu pudesse vencer todas as barreiras do caminho, até chegar ao ponto de finalizar este trabalho. Também ofereço o conteúdo desta obra a todos aqueles que conhecem, ou virão a conhecer, o prazer do estudo de uma área tão interessante, ainda tão cheia de sonhos e possibilidades. A todos que partilham seus ideais, idéias e colaboram tanto para a formação, como para o prazer de trabalhar com a área da Inteligência Computacional.

Agradecimentos

Agradeço a todos que percorreram este caminho comigo, me auxiliando quanto a conceitos, fórmulas e, principalmente, com força. Agradeço mais pontualmente à professora Mariana Graciela Terenzi pelos vários esclarecimentos no campo da neurociência, ao professor Mauro Roisenberg pela orientação, à Giseli de Sousa pelas horas compartilhadas de estudo, pesquisa e desenvolvimento e, finalmente, à Lanúsia Valgas por me dar força e compreender todo o tempo decorrido em função deste trabalho.

Sumário

Lista de Figuras	viii
Lista de Siglas	x
Lista de Símbolos	xi
Resumo	xii
Abstract	xiii
1 Introdução	1
1.1 Objetivos	2
1.2 Organização do texto	3
2 A Unidade Funcional do Sistema Nervoso: o neurônio	4
2.1 Classificação de neurônios	5
2.2 O corpo celular	6
2.3 O axônio	7
2.4 O dendrito	8
2.5 A membrana neuronal	9
2.6 O funcionamento do neurônio: o potencial de ação	9
2.7 A sinapse e a transmissão sináptica química	12
3 Memória e Aprendizado na Rede Biológica	15
3.1 Aprendizado não-associativo	16

3.1.1	Habituação	17
3.1.2	Sensibilização	18
3.2	Aprendizado associativo	19
3.2.1	Condicionamento clássico	19
4	Redes Neurais Pulsadas	21
4.1	Modelo de Resposta a Pulsos	22
4.2	O Modelo Hi-NOON	24
4.2.1	Modelagem dos neurônios	24
4.2.2	Modelagem das sinapses	26
4.2.3	Neurônios sensores e motores	27
4.2.4	Aprendizado não-associativo	27
4.2.5	Aprendizado associativo	28
4.3	CrITÉrios para escolha do modelo adotado	29
5	Aplicações Práticas	30
5.1	A aplicação robótica	30
5.1.1	Arquitetura robótica	31
5.1.2	Descrição da aplicação	32
6	Análise e alterações do modelo de neurônio pulsado	36
6.1	Modelagem dos neurônios	37
6.2	Modelagem das sinapses	40
6.2.1	Aprendizado associativo	40
7	Resultados	42
8	Conclusão	46
8.1	Trabalhos futuros	47
	Referências Bibliográficas	48

Lista de Figuras

2.1	Características comuns de um neurônio baseadas nos neurônios motores existentes na medula espinhal de mamíferos. (Modificada de [1])	5
2.2	Tipos de canais iônicos. (Modificada de [2])	10
2.3	Curva característica do potencial de ação em um neurônio pós-sináptico e seus respectivos estados. (Modificada de [3])	11
2.4	Mecanismo de geração do potencial de ação em um neurônio pós-sináptico. (Modificada de [4])	13
3.1	Habituação do reflexo de retirada da brânquia na <i>Aplysia californica</i> (Modificada de [2]).	17
3.2	Sensibilização do reflexo de retirada da brânquia na <i>Aplysia californica</i> (Modificada de [2]).	18
3.3	Condicionamento do reflexo de retirada da brânquia na <i>Aplysia californica</i> (Modificada de [2]).	20
4.1	Evolução do potencial de membrana com a geração de um potencial de ação (Modificada de [5]).	25
5.1	Detalhes da aplicação robótica: a, b) Detalhes laterais; c) detalhe dos sensores de colisão e de proximidade frontais; d) detalhe do sensor de colisão traseiro.	31
5.2	Esquema topológico da rede neural artificial utilizada no dispositivo robótico.	32
5.3	Esquema das sinapses que implementam como formas de aprendizados a habituação e a sensibilização dentro da topologia da rede neural.	33

5.4	Processo de aprendizado do dispositivo robótico: (Esquerda) 1. Em direção à parede, ele colide; 2. O sensor de colisão ativa o comportamento de desviar do obstáculo. (Direita) 1. Depois do aprendizado, logo que se aproximar do obstáculo o sensor de proximidade é suficiente para mudar sua direção.	33
5.5	Esquema das sinapses que implementam como formas de aprendizados a habituação e o condicionamento clássico dentro da topologia da rede neural.	34
6.1	Topologia do Gerador Central de Padrões existente na rede neural implementada.	38
6.2	Dinâmica do potencial de membrana dos neurônios do gerador central de padrões e do sensor traseiro de colisão do robô ARBIB.	39
7.1	Propagação dos estímulos no Gerador Central de Padrões.	42
7.2	Habituação sináptica causada por estímulos no neurônio sensor frontal de colisão.	43
7.3	Sensibilização sináptica causada por estímulos nos neurônios sensores frontal de colisão e de proximidade.	44
7.4	Condicionamento clássico causado por estímulos nos neurônios sensores frontal de colisão e de proximidade.	45

Lista de Siglas

GCP	Gerador Central de Padrões
EC	Estímulo Condicionado
EI	Estímulo Incondicionado
PM	Potencial de Membrana
PPS	Potencial Pós-sináptico
PPSE	Potencial Pós-sináptico Excitatório
PPSI	Potencial Pós-sináptico Inibitório
PRA	Período Refratário Absoluto
PRR	Período Refratário Relativo
RC	Resposta Condicionada
RNA	Rede Neural Artificial
RNP	Rede Neural Pulsada
SFC	Sensor Frontal de Colisão
SFP	Sensor Frontal de Proximidade
STC	Sensor Traseiro de Colisão

Lista de Símbolos

ϵ	Potencial Pós-sináptico
Σ	Combinador Linear
Σ_n	Somatório
η	Taxa de Incremento Pós-polarização
τ	Função de Tempo para Restauração do Equilíbrio Iônico da Membrana Neural
α	Contra-Incremento de Pós-Limiar
μ	Decremento de Pós-potencial de Pico
β	Constante de Restauração do Peso Sináptico
\wedge	Operador Lógico de Disjunção

Resumo

Este trabalho apresenta uma abordagem teórica e prática da aplicação de conceitos de uma classe específica de redes neurais, formadas por neurônios com potencial de ação, na área do aprendizado de sistemas robóticos. Adaptou-se o modelo de Redes Neurais Hierárquicas Orientadas a Objetos (Hi-NOON) para um dispositivo robótico simples. A fim de validar estas adaptações implementou-se alguns circuitos neurais em um robô LEGO® onde algumas formas de aprendizado em tempo de operação foram observadas. Os resultados obtidos e a discussão associada descrevem graficamente os relacionamentos entre neurônios e sinapses, bem como as alterações dos estados internos dos neurônios como efeito dos estímulos do aprendizado.

Palavras-chave: Inteligência Artificial, Redes Neurais Pulsadas, Neurônios Pulsados, Robótica, Aprendizado Biológico.

Abstract

This work presents theoretical and practical aspects when implementing a class of biological inspired neural network, compound by spiking neurons, in the robotic learning area. Some adaptations of the Hierarchical Neural Network Object Oriented (Hi-NOON) model were made for a simple robotic device. In order to validate the proposed model some neural circuitry was implemented in a LEGO© robot and some learning cases were observed. The results and associated discussion graphically describe the relationship between the neurons and synapses, as well as the changes in neurons internal states as a result of the learning stimulus.

Keywords: Artificial Intelligence, Pulsed Neural Network, Spiking Neurons, Robotics, Biological Learning.

Capítulo 1

Introdução

Os mecanismos biológicos vêm sendo há muito tempo fonte de inspiração para a implementação de sistemas inteligentes, podendo facilmente ser enumerados vários trabalhos na área como [6], [7] e [8]. Observa-se que o grau de fidedignidade ao paradigma biológico pode variar enormemente, podendo ser tênue e utilizar apenas idéias gerais, ou ser mais fiel, com a simulação do funcionamento detalhado de sistemas biológicos ([9] e [10]). No caso das redes neurais artificiais, modelos tais como as redes diretas e as técnicas de aprendizado por retropropagação de erros são amplamente difundidos, a despeito de serem metáforas tênues do funcionamento do sistema nervoso biológico [11].

O aumento da precisão na simulação de sistemas inteligentes biologicamente inspirados pode ser interessante, pois além de permitir uma melhor compreensão dos sistemas biológicos também pode fazer emergir aspectos de inteligência que não seriam possíveis no caso de implementações mais superficiais, tais como aspectos de aprendizado e comportamento dinâmico dos sistemas.

Em ambientes reais não é suficiente para um dispositivo robótico decorar a posição de um objeto, pois o ambiente pode sofrer grandes alterações à medida que o tempo evolui, bem como o dispositivo pode ser necessário em novos ambientes dos quais não possui informações necessárias para auxiliar decisões.

Redes neurais artificiais que possuem aprendizado de forma supervisionada, ou seja, com o auxílio de conjuntos de treinamento com situações pré-definidas não

são suficientes para resolver este tipo de problema. Neste caso o aprendizado deve ocorrer de forma não supervisionada, sem conjuntos de treinamento e em tempo real, evitando que o ambiente esteja totalmente modificado no momento em que concluir o treinamento da rede, tornando o resultado do aprendizado obsoleto.

Mesmo os mais simples seres vivos, como por exemplo, moluscos invertebrados, possuem um grau de autonomia tanto na sua relação ao ambiente, como na relação entre as funções dos sistemas internos que fazem parte do seu organismo [3]. Buscando a inspiração nestes sistemas existentes na natureza, que são suficientemente adaptáveis para permitir que uma espécie sobreviva a diversos desafios ambientais, é que a inteligência artificial encontra na inspiração biológica uma fonte de idéias e modelos para experimentar e, caso tenha sucesso, resolver problemas reais.

1.1 Objetivos

Sob este foco, os objetivos gerais deste trabalho são: modelar uma Rede Neural Artificial (RNA) utilizando uma abordagem mais próxima do neurônio real e; aplicar um mecanismo de aprendizado biologicamente inspirado, ou seja, observado em seres vivos.

Para isto, buscamos implementar uma RNA utilizando neurônios com potencial de ação, também conhecidos como neurônios 'spiking' ou pulsados. A informação codificada na rede é propagada por meio de uma frequência de pulsos elétricos e não pela sua intensidade, sendo este tipo de rede também conhecido como Rede Neural Pulsada (RNP) [12].

Em paralelo com o desenvolvimento da rede, é necessário modelar os mecanismos de aprendizado biologicamente inspirados, conhecidos como habituação, sensibilização e condicionamento clássico.

Na validação dos modelos utilizaremos simulações de circuitos neurais, e para finalizar, aplicaremos a rede neural resultante para fazer o controle de um dispositivo robótico.

1.2 Organização do texto

Este trabalho está organizado da seguinte forma: no segundo capítulo fundamenta-se alguns conceitos biológicos essenciais para a construção do modelo neural; no terceiro capítulo apresentam-se os conceitos relacionados ao aprendizado da rede, também do ponto de vista da inspiração biológica; no quarto capítulo discutem-se sobre alguns modelos existentes de RNPs e fundamenta-se a escolha do modelo; a seguir discutem-se as alterações feitas na proposta original visando sanar algumas deficiências encontradas por ocasião da implementação; no sexto capítulo a aplicação robótica tem a sua plataforma descrita; a seguir os dados coletados nas simulações realizadas com a aplicação são apresentadas e comentadas; por fim, apresentamos a conclusão e idéias de trabalhos futuros utilizando o conhecimento aqui adquirido.

Capítulo 2

A Unidade Funcional do Sistema

Nervoso: o neurônio

A modelagem de redes neurais buscando um maior grau de aproximação com sistemas biológicos existentes em seres vivos pressupõe um certo grau de conhecimento do sistema real a ser modelado, sendo assim, é correto iniciar este trabalho com um apanhado teórico sobre os mecanismos biológicos que fundamentam as redes neurais antes de discutir sobre os modelos e de justificar as modificações realizadas.

Generalizando o sistema nervoso existente em todos os seres vivos, é possível observar que eles apresentam "(...) uma unidade construtiva elementar em comum: uma célula excitável, o neurônio"[13], representado na figura 2.1. As funções do neurônio compreendem a coleta de informações do meio ambiente, o envio destas informações a outros neurônios e o controle das respostas corporais [1].

Levando em consideração a grande variedade estrutural e funcional dos neurônios não é possível classificar algo como um 'neurônio típico' [14], nem introduzir 'o' neurônio biológico. Em contrapartida, os neurônios têm, pelo menos, duas partes distinguíveis: o **corpo celular** e os **neuritos**.

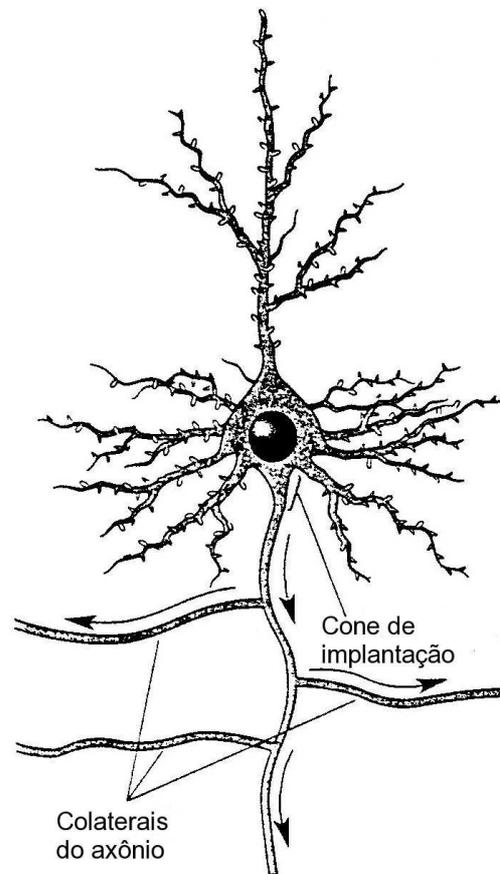


Figura 2.1: Características comuns de um neurônio baseadas nos neurônios motores existentes na medula espinhal de mamíferos. (Modificada de [1])

2.1 Classificação de neurônios

A classificação dos neurônios pode ocorrer em função do número de neuritos, do tipo da arborização dendrítica, do tipo de conexões, ou mesmo do comprimento do axônio [1]. Existem outros tipos de classificações, mas para fins deste estudo, e levando em consideração o modelo de rede neural artificial que buscamos embasar, é suficiente a classificação dos neurônios baseada nas suas conexões. Nessa classificação os neurônios são divididos em **neurônios sensoriais**, **neurônios motores** e **interneurônios**

[3]. Os neurônios sensoriais apresentam neuritos nas superfícies sensoriais do corpo, como a pele e a retina dos olhos. Eles coletam as informações (também chamadas de aferências) que chegam ao sistema nervoso a partir do seu ambiente. Os neurônios motores "(...) apresentam axônios que formam sinapses com os músculos e comandam os movimentos (...)" [1] ou controlam as secreções das glândulas. Os demais neurônios formam conexões apenas com outros neurônios e são conhecidos como **interneurônios**.

Os neurônios sensoriais podem ainda ser subdivididos em duas classes: os **sensores de proximidade** e os **sensores de distância**. Os sensores de proximidade reagem a estímulos provocados pela ativação da superfície sensível do nosso corpo, como os sensores do paladar ou do tato. Os sensores de distância recebem estímulos que permitem identificar objetos distantes, temos como exemplo os sensores da visão.

2.2 O corpo celular

O corpo celular, também conhecido como **soma** ou **pericário** consiste na região dilatada do neurônio. O diâmetro do soma pode variar da ordem de $2 \mu\text{m}$ até valores superiores a $0,5 \text{ mm}$.

O interior da célula nervosa é preenchido com um fluído aquoso, uma solução salgada e rica em potássio chamada **citossol**. Mergulhadas no citossol estão as **organelas**, que são estruturas membranosas presentes também nas demais células dos seres vivos. O citossol, bem como todas as organelas e demais componentes presentes no interior da célula constituem o **citoplasma**, com exceção do **núcleo** que, sozinho, forma outra importante estrutura no interior do corpo celular.

O soma irradia tubos finos que constituem a segunda parte do neurônio. Esses tubos são chamados de **neuritos** e podem ser subdivididos em dois tipos: os **axônios** e os **dendritos**.

2.3 O axônio

O axônio é encontrado apenas nos neurônios e geralmente existe um único axônio por corpo celular. Dependendo do ser vivo a qual pertence, bem como da sua função no sistema nervoso, são encontrados neurônios com axônios de características diversas. Dentre elas podemos destacar que o seu "comprimento pode se estender desde menos de um milímetro até mais de um metro e o seu diâmetro varia desde menos de 1 μm até aproximadamente 25 μm em humanos, podendo chegar à espessura de 1 mm na lula"[1]. Tanto sua membrana como as estruturas que o formam e o revestem tornam o axônio "especializado para a transferência de pulsos elétricos entre pontos distantes do sistema nervoso"[1]. O sinal elétrico que percorre o axônio, gerado a partir de mudanças no diferencial elétrico existente entre os meios interno e externo da membrana neural é chamado de **potencial de ação**. A velocidade do potencial de ação é inversamente proporcional ao diâmetro do axônio, ou seja, quanto menor for o diâmetro do axônio mais veloz o impulso elétrico. Outra característica que acelera a velocidade do sinal elétrico no axônio é o seu revestimento em capas de **mielina**. Os sistemas nervosos dos invertebrados não possuem esse revestimento, o que confere aos vertebrados uma vantagem na velocidade de propagação da informação pelo seu sistema nervoso.

O axônio também difere das outras regiões do neurônio por não apresentar a síntese de proteínas. Todas as proteínas presentes no axônio são sintetizadas no soma. A composição protéica da membrana do axônio é um dos fatores que permitem o tráfego de informações a longas distâncias dentro do sistema nervoso.

O segmento inicial do axônio é a região do soma chamada **cone de implantação**. Quando o axônio se ramifica estes segmentos gerados possuem um ângulo reto com o segmento gerador e estas ramificações são chamadas de **colaterais** [3]. Quando uma ramificação colateral retorna e comunica-se com a célula que teve origem é chamada de **colateral recorrente**.

A região final do axônio é chamada de **terminal axonal** ou **botão terminal**. A função do terminal é passar a informação para outras células, sejam neurônios, músculos ou glândulas. O local onde o axônio entra em contato com estas células chama-

se **sinapse**. Nas regiões terminais dos axônios podem existir várias ramificações. Estas ramificações formam sinapses com outros dendritos ou corpos celulares na mesma região e são chamadas coletivamente de **arborização terminal** [1].

Ao longo do eixo do axônio podem existir sinapses em regiões dilatadas, chamadas **botões de passagem** ou **varicosidades**. Em todo caso, quando um neurônio estabelece contato sináptico com outra célula, diz-se que ele **inerva** aquela célula, ou seja, promove sua **inervação** [1]. O terminal axonal contém numerosos glóbulos membranosos, chamados **vesículas sinápticas**, que possuem mediadores químicos chamados **neurotransmissores** [3].

2.4 O dendrito

À medida que se afastam do soma, os **dendritos** apresentam ramificações semelhantes a árvores, justificando seu nome que é derivado de uma palavra grega que significa 'árvore'. Coletivamente, os dendritos de um mesmo neurônio são denominados de **árvore dendrítica** [13]. Cada ramo desta árvore é denominado **ramo dendrítico**. Existem classificações de neurônios que levam em consideração forma e tamanho das árvores dendríticas dada a sua grande variedade.

A característica mais importante dos dendritos é ampliar a área de contato do neurônio para a recepção de informação, sendo que vários deles são recobertos por milhares de sinapses. Muitos dendritos estendem-se do corpo celular, raramente por mais de 2 mm, terminando, geralmente, em uma ponta fina. Nos pontos onde são formadas sinapses a membrana dendrítica apresenta moléculas de proteínas chamadas de **receptores** [11]. Os receptores são moléculas especializadas na detecção dos neurotransmissores responsáveis pelo fluxo da informação no sistema nervoso. Os neurotransmissores atuam por meio da excitação ou inibição do potencial de membrana no neurônio.

2.5 A membrana neuronal

O citoplasma, bem como o núcleo do neurônio, é separado do meio externo por uma membrana limitante, a **membrana neuronal**. Ela é sustentada por uma intrincada rede interna, dando a cada parte da célula sua aparência tridimensional característica.

As funções do neurônio dependem fortemente das estruturas e da constituição de sua membrana. Com aproximadamente 5 nm de espessura, a membrana neuronal é repleta de proteínas. Muitas destas proteínas controlam a entrada e saída de várias substâncias, por meio de diversos mecanismos, como podemos visualizar na figura 2.2. Estas proteínas são conhecidas como **canais iônicos** e se abrem para a entrada e saída de íons específicos. Esta permeabilidade seletiva da membrana permite que ocorra um desequilíbrio iônico, modificando o diferencial elétrico entre o exterior do neurônio e a região interior próxima à membrana.

A constituição protéica da membrana varia de acordo com a região do neurônio, ou seja, a constituição da membrana axonal é diferente da constituição da membrana neural que reveste o soma, e estes possuem constituição diferente da membrana dendrítica [1].

2.6 O funcionamento do neurônio: o potencial de ação

O princípio geral de funcionamento dos neurônios está ligado às propriedades do citosol e da membrana neural. A membrana neural possui diversos canais iônicos permeáveis a íons distintos, fazendo com que o interior da membrana celular seja rico em íons de potássio (K^+), contrastando com o seu exterior, rico em íons de sódio (Na^+), gerando um diferencial elétrico entre os meios interno e externo próximos da membrana, sendo o interior da membrana mais negativo.

O equilíbrio entre a concentração interna e externa da membrana celular é mantido por um processo de transporte ativo, ou seja, que consome energia metabólica, denominado **bomba de sódio e potássio**. O processo descrito a seguir e ilustrado na

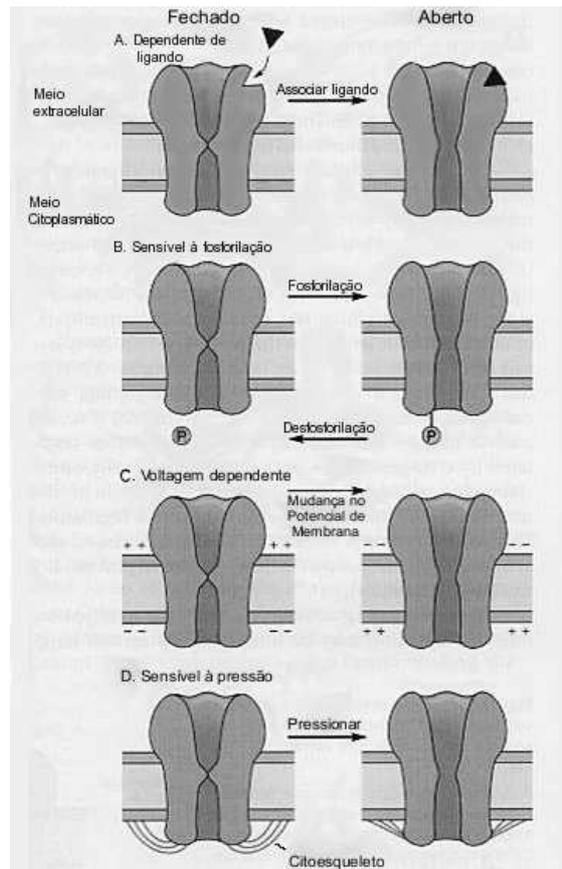


Figura 2.2: Tipos de canais iônicos. (Modificada de [2])

figura 2.3 é comum para os vários tipos de neurônios, mas os valores a seguir utilizados, expressos em milivolts, são específicos dos neurônios motores da medula espinhal de alguns mamíferos e foram extraídos de [1] e [4].

Sendo a membrana neural, no estado de repouso, muito mais permeável aos íons de potássio do que aos íons de sódio, ela garante "(...) uma corrente elétrica maior de íons de potássio de dentro para fora da célula do que a corrente de sódio no sentido contrário"[13]. Esta corrente iônica, causada pela permeabilidade seletiva da membrana, culmina em uma diferença de concentração entre os íons contidos no interior e no exterior da membrana, que vão sustentar um **potencial de repouso**. Este estado é caracterizado por ser algumas dezenas de milivolts mais eletronegativo no interior da membrana neuronal do que no seu exterior.

A partir do valor de potencial de membrana em repouso podemos classificar a membrana enquanto **depolarizada**, quando ela está menos eletronegativa, ou como **hiperpolarizada**, quando ela está mais eletronegativa.

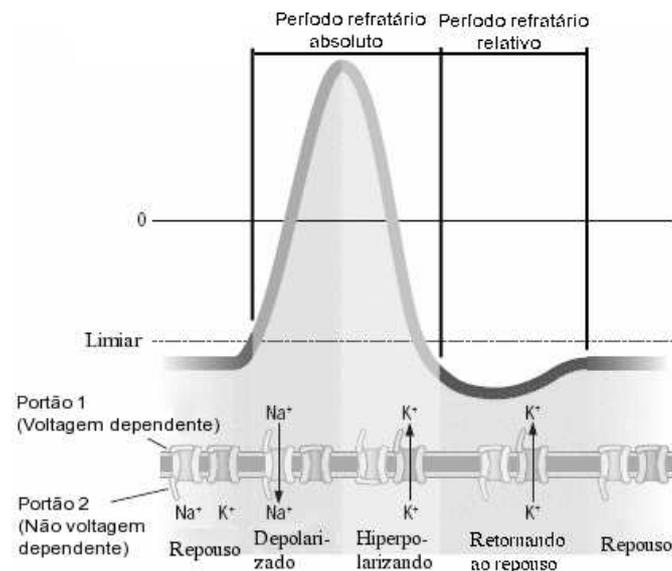


Figura 2.3: Curva característica do potencial de ação em um neurônio pós-sináptico e seus respectivos estados. (Modificada de [3])

Um neurônio no estado de repouso pode receber estímulos que interfiram no seu equilíbrio elétrico. Esses estímulos podem ser inibitórios, levando a membrana a ficar hiperpolarizada, ou excitatórios, deixando a membrana depolarizada. Existe um valor de potencial conhecido como **limiar de disparo**, que é atingido quando a membrana está suficientemente depolarizada. O valor de limiar é de aproximadamente -45 mV. Quando o limiar é atingido forma-se em um ponto arbitrário da membrana axonal um **potencial de ação**.

Quando o potencial de membrana atinge o limiar de disparo o comportamento da membrana com relação aos seus canais iônicos se altera provocando um influxo súbito de íons de sódio elevando o potencial de membrana a um valor positivo próximo dos 45 mV. Após atingir esse pico de depolarização os canais iônicos da membrana sofrem uma nova mudança de comportamento e diminuem o fluxo de sódio ao

mesmo tempo em que restabelecem o fluxo de potássio, hiperpolarizando até chegar aos -69 mV.

Durante o potencial de ação até o fim da hiperpolarização a membrana passa por um período refratário, onde a membrana não pode ser novamente despolarizada, ficando resistente, ou seja, refratária, aos novos estímulos. Todo este evento, do alcance do limiar de disparo até o retorno ao estado de repouso dura, dependendo do axônio ou mesmo da temperatura, menos de 1 ms e determina a duração do potencial de ação.

O período refratário é dividido em absoluto e relativo. O período no qual o neurônio fica incapacitado de gerar um outro potencial de ação, mesmo que ocorra uma nova depolarização da membrana neural, chamado de **período refratário absoluto** (PRA), e estipula um valor máximo para a frequência dos pulsos. O **período refratário relativo** (PRR) segue depois do PRA e é na verdade uma elevação do valor de limiar de disparo permitindo um novo potencial de ação caso ocorra uma depolarização maior que a normal.

Os períodos refratários terminam quando o valor do limiar de disparo retorna ao normal, ou seja, ao fim da hiperpolarização.

2.7 A sinapse e a transmissão sináptica química

O potencial de ação que ocorre nos axônios tem como função levar o sinal elétrico até os terminais dos mesmos, ou seja, até os **terminais sinápticos**. Esses terminais são os pontos de contato formados por neurônios com outros neurônios, células musculares ou glândulas.

Podemos caracterizar na sinapse dois lados, sendo um pré-sináptico que consiste geralmente de um terminal axonal, e um pós-sináptico que pode ser o dendrito ou o soma de outro neurônio. Entre as membranas pré-sináptica e pós-sináptica não existe contato, por isso, o espaço entre elas é chamado de **fenda sináptica**.

A transferência de informação pela fenda sináptica é chamada de **transmissão sináptica** e percorre o sistema nervoso em um sentido habitual do terminal pré-sináptica para a membrana pós-sináptica.

A transmissão sináptica ocorre através de um desequilíbrio elétrico na membrana neuronal pré-sináptica que gera um potencial de ação no seu axônio. Este processo é descrito em mais detalhe na seção 2.6 e na figura 2.4. O potencial de ação gerado no axônio faz com que a membrana axonal libere na fenda sináptica vesículas com neurotransmissores. Estes neurotransmissores alcançam a membrana dendrital do neurônio pós-sináptico, provocando uma alteração na permeabilidade iônica desta membrana neuronal e, com isto, alterando a sua polarização e dando continuidade ao ciclo de transmissão da informação neste neurônio [13].

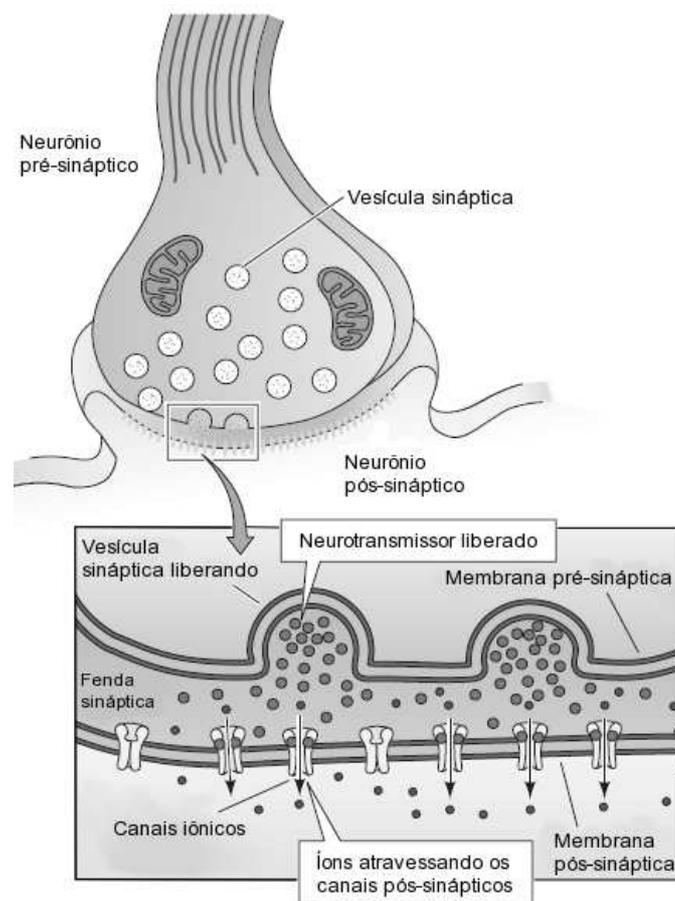


Figura 2.4: Mecanismo de geração do potencial de ação em um neurônio pós-sináptico. (Modificada de [4])

O tipo do neurotransmissor liberado na sinapse determina se a alteração

causada no neurônio pós-sináptico facilita ou inibe a formação de um potencial de ação no seu axônio. Assim sendo, dependendo do tipo do neurotransmissor essa sinapse é caracterizada como **excitatória** ou **inibitória** [3].

Capítulo 3

Memória e Aprendizado na Rede

Biológica

A modelagem de uma rede neural artificial (RNA), com seus neurônios e sinapses, não é suficiente para resolver problemas complexos. Para que a RNA possa resolver problemas é necessário o **treinamento**, ou **aprendizado**, da rede, adequando os pesos sinápticos da rede aos seus dados de entrada e saída, fazendo a correlação correta entre eles [9]. Partindo da inspiração biológica para definir um processo de aprendizado para a rede, são apresentados a seguir alguns conceitos que envolvem alterações de comportamento em seres vivos e seus mecanismos responsáveis.

Pode-se descrever o aprendizado como uma alteração relativamente permanente do comportamento, em virtude de estímulos externos [11]. A partir de experimentos em cães, realizados pelo famoso psicólogo russo Ivan Pavlov no início do século XX, alguns dos mecanismos de aprendizado em nível neural começaram a ser desvendados. Dependendo do conjunto de estímulos sendo propagados pelo sistema nervoso, há uma mudança no seu comportamento buscando a melhor resposta a estes estímulos iniciais. Este processo de codificação, armazenamento e recuperação da informação é o que chamamos de **memória** [4].

Atualmente são apontadas como bases da memória as alterações na efetividade de sinapses. Através da estimulação elétrica de células nervosas são produzidas

alterações sinápticas mensuráveis cujos mecanismos podem ser estudados. Uma das conclusões desses estudos é que os mecanismos utilizados para alterar a efetividade sináptica de mamíferos é bastante similar aos mecanismos de invertebrados [1].

Um dos primeiros estudos sobre os mecanismos da memória em nível celular foi feito nos anos 60 por Eric Kandel, Nobel de Medicina de 2000, e seus colaboradores da Universidade Columbia [2]. Kandel utilizou o molusco marinho *Aplysia californica*, que possui apenas alguns milhares de neurônios com o diâmetro de, em sua maioria, aproximadamente 1 mm, ou seja, comparado com animais mais complexos como os seres humanos esse molusco possui poucos neurônios, que são grandes o suficiente para facilitar as medições dos diferenciais elétricos em suas diversas partes. A simplicidade do sistema nervoso da *Aplysia* também facilita a identificação de neurônios e de circuitos específicos catalogando suas funções e propriedades individuais.

O aprendizado em seres vivos possui pelo menos duas formas. A primeira é o **aprendizado implícito**, também conhecido como **aprendizado não-declarativo** [2] [1]. Esta forma mais simples compreende o aprendizado de respostas motoras em reação a estímulos sensoriais. A outra forma de aprendizado é conhecida como **aprendizado explícito** ou **declarativo**, sendo esta responsável pela memorização de fatos, lugares e objetos [2].

O aprendizado implícito pode ser dividido em dois tipos: **aprendizado não-associativo** e **aprendizado associativo** que serão descritos nas seções seguintes.

3.1 Aprendizado não-associativo

O aprendizado não-associativo, uma das formas mais básicas de aprendizado, corresponde à alteração da resposta motora a um único estímulo. O aprendizado não-associativo possui duas formas: a **habituação** e a **sensibilização**.

3.1.1 Habituação

Na habituação, um estímulo que não tenha significado é ignorado após a exposição repetida do mesmo a neurônios sensores [15]. Por exemplo, uma pessoa que passa a utilizar óculos para corrigir alguma deficiência visual se sentirá, em um primeiro momento, incomodado com a sensação tátil consequente do seu uso, que logo será superada, e onde podem ocorrer situações como a de querer coçar os olhos e, sem querer, tocar nas lentes por esquecimento.

O comportamento da *Aplysia* utilizado no estudo da habituação foi o *reflexo de retirada da brânquia* que, como mostra a figura 3.1, ocorre quando um jato d'água é dirigido a uma região muscular chamada de sifão, causando a retração conjunta do sifão com a brânquia.

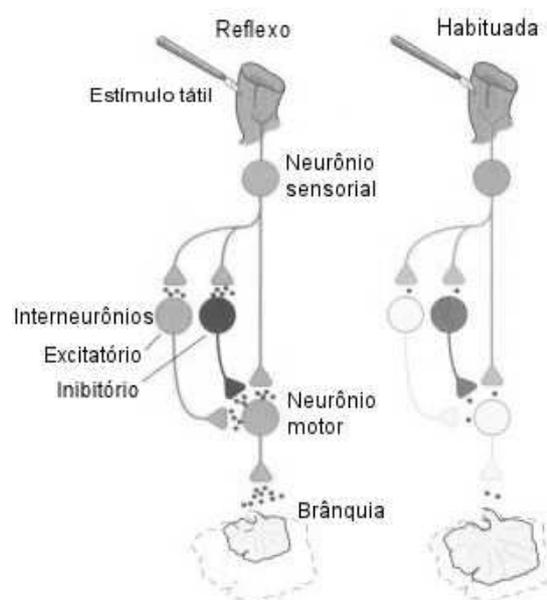


Figura 3.1: Habituação do reflexo de retirada da brânquia na *Aplysia californica* (Modificada de [2]).

No estudo realizado por Kandel, após analisada a reação da *Aplysia* foram levantadas três hipóteses sobre o local onde ocorria o processo de diminuição da resposta ao estímulo: nos terminais do neurônio sensorial, nos músculos e demais efeto-

res ou ainda, na sinapse entre neurônios. Após medições da propagação do estímulo na rede neural da *Aplysia* foi observado que a habituação resulta da diminuição do peso das conexões sinápticas entre interneurônios excitatórios e neurônios motores [2].

3.1.2 Sensibilização

Na sensibilização, fortes estímulos sensoriais intensificam as respostas a todos os estímulos, mesmo aqueles que previamente evocavam pouca ou nenhuma reação [1]. Um exemplo é o caso de uma pessoa que caminha à noite, calmamente, por uma via bem iluminada, quando repentinamente ocorre um blecaute. Os fortes estímulos sensoriais causados pelo blecaute sensibilizam os demais estímulos, fazendo com que, o barulho de passos que antes não perturbava, cause reações como medo.

O reflexo de retirada da brânquia da *Aplysia* também foi utilizado para estudar este caso, como representado na figura 3.2. A aplicação de um breve choque elétrico em sua cauda resultava na retirada exagerada da brânquia em resposta ao estímulo do sifão.

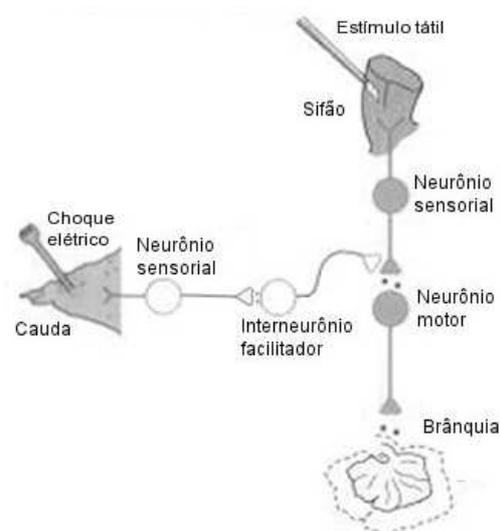


Figura 3.2: Sensibilização do reflexo de retirada da brânquia na *Aplysia californica* (Modificada de [2]).

Utilizando a mesma estratégia descrita para a análise e estudo da habituação, mais uma vez foram descobertas modificações na liberação de neurotransmissores, afetando a efetividade sináptica entre interneurônios excitatórios e neurônios motores [2].

3.2 Aprendizado associativo

Durante o aprendizado associativo, formamos associações entre eventos. É uma categoria que engloba uma grande parcela do que aprendemos como: aprender a ter medo, aprender a conversar, aprender uma língua estrangeira ou aprender a tocar piano [16]. Normalmente distinguimos dois tipos: **condicionamento clássico** e **condicionamento instrumental**.

3.2.1 Condicionamento clássico

Envolve a associação entre um estímulo que evoque uma resposta mensurável e um segundo estímulo que, normalmente, não evoca esta resposta. O primeiro estímulo, aquele que normalmente evoca a resposta, é chamado de **estímulo incondicionado** (EI), porque nenhum treino (ou condicionamento) é necessário para provocar uma resposta. O segundo tipo de estímulo, aquele que normalmente não evoca a mesma resposta, é chamado **estímulo condicionado** (EC), porque este requer treino (condicionamento) antes que produza essa resposta. O treino consiste em apresentar concomitantemente estes estímulos. Após muitas dessas apresentações o estímulo incondicionado é retirado e a resposta é evocada após ser apresentado apenas o estímulo condicionado. A resposta associada ao EC é chamada de *resposta condicionada* (RC).

O reflexo de retirada da brânquia foi novamente utilizado para descobrir o mecanismo biológico responsável pelo condicionamento clássico, como podemos visualizar na figura 3.3. Enquanto o EI era um forte choque na cauda, o EC era o estímulo do manto, de forma delicada, de modo que não causasse nenhuma resposta. Quando EI e EC eram realizados concomitantemente o RC, que no caso é o reflexo de retirada da brânquia, era muito maior do que se explicaria através da sensitização. Como nas formas

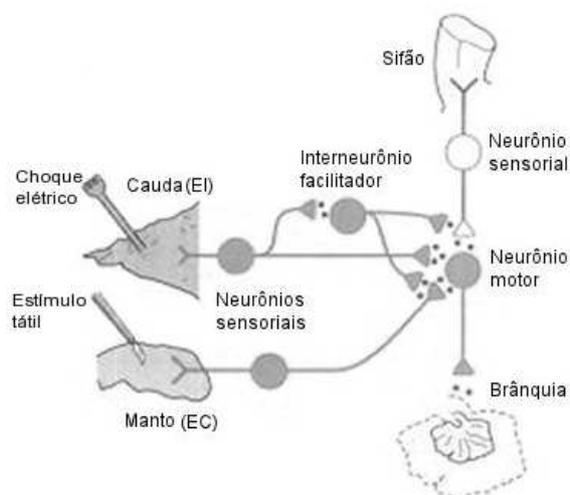


Figura 3.3: Condicionamento do reflexo de retirada da brânquia na *Aplysia californica* (Modificada de [2]).

de aprendizado apresentadas anteriormente, mudanças na efetividade sináptica causadas pelo aumento na liberação de neurotransmissores, é o que ocasiona o condicionamento clássico.

Há certos requisitos temporais para o condicionamento clássico ser bem-sucedido. O condicionamento ocorre se o EI e o EC são apresentados simultaneamente, ou se o EC precede o EI por um curto intervalo de tempo. Entretanto se o EC precede o EI por um tempo longo, o condicionamento é muito fraco, ou ausente. O condicionamento tipicamente não ocorre se o EC ocorre depois do EI [1].

Capítulo 4

Redes Neurais Pulsadas

As Redes Neurais Pulsadas (RNPs), formadas por neurônios pulsados, possuem características diversas das formadas por neurônios comumente utilizados em Redes Neurais Artificiais (RNAs) [17]. Buscando a maior proximidade das características reais de um neurônio, as RNP's apresentam um modelo que leva em consideração o comportamento iônico da membrana neural, chamados de **modelos de condutância**. Este modelo contrasta com o mais utilizado, conhecido como **modelo de limiar de disparo**, pelo critério utilizado para decidir quando um estímulo é propagado pela rede [12].

Os modelos de limiar de disparo calculam o valor do potencial pré-sináptico e verificam se ele atingiu um limiar, caso em que o sinal é propagado pelo seu axônio. Por sua vez, os modelos de condutância não necessariamente propagam o sinal caso o limiar tenha sido atingido. Como apresentado no capítulo /refcha:sistemanervoso, existem estados internos do neurônio onde este fica incapacitado de propagar o sinal, como no caso do período refratário absoluto.

A capacidade para resolução de problemas dessas redes pode ser comprovada em [18], onde é utilizado uma RNP para simular uma máquina de Turing. Atualmente estas redes são utilizadas em conjunto com outros conceitos de Inteligência Artificial como Algoritmos Genéticos ([19], [8], [20] e [21]).

Nas seções seguintes serão apresentados alguns modelos de RNPs, bem como os critérios utilizados na escolha do modelo base para este trabalho.

4.1 Modelo de Resposta a Pulsos

O conceito envolvido neste modelo é a simulação do valor do potencial de membrana a determinados estímulos. Como os estímulos pré-sinápticos são pulsos (spikes, em inglês) provenientes do axônio este modelo é conhecido como Modelo de Resposta a Pulsos (em inglês: Spike Response Model). Este modelo é amplamente conhecido, sendo citado em diversas fontes como, por exemplo, em [22], [12] e [14].

A diferença de potencial entre o interior da célula e o seu exterior é denotada como $u(t)$ e é chamada de potencial de membrana. Se não houver pulsos como entradas, o neurônio estará em estado de descanso, que é correspondente a uma constante de potencial de membrana (u_{rest}), dependente do tipo de célula nervosa, que geralmente tem um valor em torno de -65 mV.

$$u_i(t) = u_{rest} \quad (4.1)$$

Em um momento $t = 0$ o neurônio se encontra em equilíbrio, por isso o potencial de membrana é igual ao potencial de repouso, como demonstrado na figura 2.3 e modelado na equação (4.1).

$$\epsilon_{ij}(t) = u_i(t) - u_{rest} \quad (4.2)$$

O disparo de um pulso, a partir de um neurônio pré-sináptico j , desencadeia um **potencial pós-sináptico** (PPS) em um neurônio i . Este potencial é denotado pela equação (4.2), que representa a diferença entre o estado de repouso e o estado atual do neurônio pós-sináptico. Se $\epsilon_{ij}(t)$ é positivo temos um PPS excitatório (PPSE) e, se é negativo, temos um PPS inibitório (PPSI).

Segundo [12], o tempo de disparo de um neurônio j é denotado por $t_j^{(f)}$. Uma seqüência de pulsos de um neurônio j é inteiramente caracterizada pelo conjunto de tempos de disparo $F_j = \{t_j^{(1)}, \dots, t_j^{(n)}\}$, onde $t_j^{(n)}$ é o pulso mais recente do neurônio j .

$$u_i(t) = \sum_j \sum_f \epsilon_{ij}(t - t_j^{(f)}) + u_{rest} \quad (4.3)$$

Se considerarmos um conjunto J de neurônios pré-sinápticos, com um ou mais elementos j , podemos representar o potencial pós-sináptico como o resultado do somatório da equação (4.3).

Logo que o potencial de membrana atinge um valor crítico v , sua trajetória demonstra um comportamento completamente diferente de uma soma simples de PPSs: o potencial de membrana libera um pulso com amplitude em torno de 100 mV, a saber, um potencial de ação. O potencial de ação irá se propagar através do axônio do neurônio i para a sinapse de outros neurônios. Após o pulso, o potencial de membrana não retorna diretamente para o estado de repouso, mas atravessa uma fase de hiperpolarização de valor inferior ao valor de repouso. Essa hiperpolarização é chamada **período refratário**.

PPSEs isolados tem amplitudes em torno de um milivolt. O valor crítico para atingir o pulso é em torno de 20 à 30 mV acima do potencial de repouso. Na maioria dos neurônios, quatro pulsos não são suficientes para disparar um potencial de ação. Em vez disso, em torno de 20 a 50 pulsos pré-sinápticos tem que ser disparados num curto intervalo de tempo antes de disparar um potencial de ação.

$$\eta(t - t_i) = \begin{cases} \frac{1}{\Delta t}, & \text{para } 0 < t - t_i^{(f)} < \Delta t, \\ -\eta_0 \exp\left(\frac{-(t - t_i^{(f)})}{\tau}\right), & \text{para } \Delta t < t - t_i^{(f)}. \end{cases} \quad (4.4)$$

No momento que $u_i(t)$ alcança o limiar v_g podemos dizer que o neurônio i disparou um pulso. O momento que o limiar foi cruzado define o tempo de disparo $t_i^{(f)}$. O modelo se baseia no fato que potenciais de ação, à grosso modo, possuem uma mesma forma. A trajetória do potencial de membrana durante um pulso pode então ser denotado por um período de tempo padrão $\eta(t - t_i)$ cujo valor é obtido através da equação (4.4).

$$u_i(t) = \eta(t - t_i) + \sum_j \sum_f \epsilon_{ij}(t - t_j^{(f)}) + u_{rest} \quad (4.5)$$

Juntando todos os elementos temos a seguinte descrição da dinâmica neural. A variável u_i descreve o valor momentâneo do potencial de membrana do neurônio

i . Esse valor é dado pela equação (4.5), onde t_i representa o momento do último disparo do neurônio i , e é dado pela equação (4.6).

$$t_i = \max\{t_i^{(f)} | t_i^{(f)} < t\} \quad (4.6)$$

Segundo ([23]), este modelo é fortemente simplificado e negligencia muitos aspectos da dinâmica neural. Em particular, assume-se que todos os potenciais pós-sinápticos possuem a mesma forma, independente do estado do neurônio. Além disso, a dinâmica do neurônio i depende somente dos tempos de disparo mais recentes t_i .

No modelo introduzido, chamado em [22] de SRM_o , a forma de um potencial gerado por um pulso pré-sináptico em um tempo $t_i^{(f)}$ não depende do estado do neurônio pós-sináptico i . Isso é obviamente uma simplificação e a realidade é algo mais complexo.

4.2 O Modelo Hi-NOON

Abordagem baseada em neurônios pulsados, procura modelar os processos elétricos que desencadeiam o potencial de ação após atingir o limiar de disparo. O modelo de redes neurais com neurônios pulsados, proposto em [24], [5], [25], [26], [27], consiste de uma rede neural hierárquica orientada a objetos. Esta arquitetura de rede neural parte da definição de alguns atributos necessários à modelagem dos seus neurônios constituintes seguindo da implementação de classes que representam os neurônios e sinapses.

4.2.1 Modelagem dos neurônios

O potencial sináptico consiste no somatório das entradas sinápticas que influenciarão na atualização do potencial de membrana. O cálculo deste potencial segue a equação (4.7), onde i é o contador das células pré-sinápticas ativas, w_i é o peso sináptico de um neurônio pré-sináptico, k é a constante de aprendizado heurísticamente selecionada e seu valor é $1/450$ e $PMBase$ é a constante que corresponde ao potencial de repouso do

neurônio. A sigla PM será utilizada aqui representando o potencial de membrana atual à medida que ele varia no tempo [27].

$$S(t) = \sum_i w_i k (PM(t) - PMBase_i) \quad (4.7)$$

Internamente, os neurônios possuem estados que representam a dinâmica do potencial pós-sináptico. Os estados foram mapeados conforme o potencial de membrana caracterizando os potenciais: (A) acima do potencial e abaixo do limiar, (B) acima do limiar e abaixo do pico, (C) no pico, (D) hiperpolarizando, (E) no mínimo e (F) durante o período refratário, conforme a Figura 4.1.

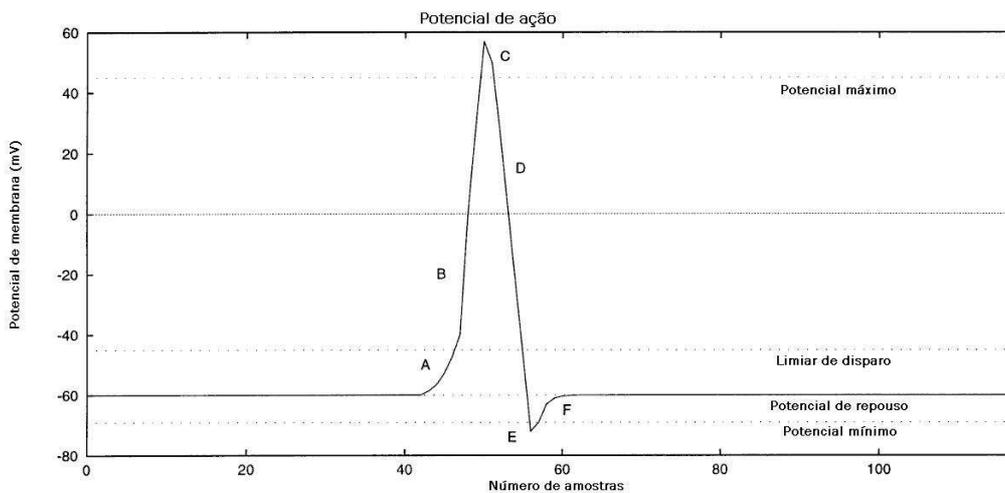


Figura 4.1: Evolução do potencial de membrana com a geração de um potencial de ação (Modificada de [5]).

Para cada estado o potencial de membrana vai variar segundo uma equação diferente, segundo a dinâmica dos canais iônicos da membrana neural.

$$PM(t+1) = \begin{cases} PM(t) - \tau + S(t), & \text{para o estado A,} \\ PM(t) - \alpha + S(t), & \text{para o estado B,} \\ h + S(t), & \text{para o estado C,} \\ PM(t) - \mu + S(t), & \text{para o estado D,} \\ l + S(t), & \text{para o estado E,} \\ PM(t) + (PMBase - PM(t))/\eta + S(t), & \text{para o estado F.} \end{cases} \quad (4.8)$$

Para compreender (4.8) é necessário esclarecer os seus parâmetros. No estado A, τ é a constante de tempo de um neurônio e representa o comportamento da membrana neural de restaurar o equilíbrio quando cessam os estímulos pré-sinápticos. No estado B, α é o contra-incremento de pós-limiar cujo valor é igual a 20. No estado C, h é o máximo PM pós-limiar e seu valor é igual a 45. Já no estado D, a constante μ representa o decremento de pós-potencial de pico de valor igual a 25. No estado E, l é o potencial de membrana mínimo e seu valor é -69. A última etapa antes do retorno ao potencial de repouso é o período refratário, representado neste modelo pelo estado F, onde η é a taxa de incremento após a hiperpolarização e o seu valor é 1.5. Alguns desses parâmetros, como τ e η , são dependentes de tempo e devem ser atribuídos empiricamente para ser ajustar à velocidade do processador que será utilizado, bem como às necessidades inerentes a implementação [5].

4.2.2 Modelagem das sinapses

Entre as funcionalidades básicas das sinapses, destacamos também a evolução do peso sináptico de acordo com o conjunto de equações descrito em (4.9), onde β é o parâmetro de recuperação e w_{base} é o valor inicial atribuído ao peso (tipicamente 0). Estes valores são atribuídos de forma individual para cada neurônio (da mesma forma que w_{min} e w_{max} , geralmente -16 e +16, respectivamente). O parâmetro de recuperação é uma constante (característica de cada sinapse) que determina quão rápido o valor do peso atual $w(t)$ retorna para o valor w_{base} após ser alterado. Para prevenir que os valores de peso sináptico cresçam indefinidamente, $w(t)$ é delimitado durante a simulação, segundo

os valores expressos pela equação (4.9).

$$W(t) = \begin{cases} w(t) - \beta, & \text{se } w(t) > w_{base}, \\ w(t) + \beta, & \text{se } w(t) < w_{base}, \\ w_{max}, & \text{se } w(t) > w_{max}, \\ w_{min}, & \text{se } w(t) < w_{min}, \\ w_{min}, & \text{em outros casos.} \end{cases} \quad (4.9)$$

4.2.3 Neurônios sensores e motores

Quanto aos neurônios motores, além dos comportamentos básicos vistos anteriormente, existe a necessidade da inclusão de um cálculo para a atividade motora, que é dado pela equação (4.10), onde γ é uma constante escalar dependente do hardware do robô, e seu sinal é determinado pela condição de direção adotada, se para frente ou para trás.

$$A(t) = |\pm (\gamma PM(t))/h| \quad (4.10)$$

Já os neurônios sensores possuem funções de atualização do PM que se ajustam ao tipo de sensor que coleta as informações do ambiente. Podemos utilizar vários tipos de sensores, como por exemplo, sensores de colisão, sensores de luz ou sensores de proximidade.

4.2.4 Aprendizado não-associativo

Como o aprendizado não-associativo ocorre através da mudança na efetividade das conexões sinápticas em resposta a um estímulo, tanto na habituação como na sensibilização o aprendizado é uma função de $w(t)$. A habituação ocorre através da diminuição do peso sináptico w_k por uma constante d conforme (4.11).

$$w_k(t+1) = \begin{cases} w_k(t) - d, & \text{se estado C} \wedge (w_k(t) > 0), \\ w_k(t) + d, & \text{se estado C} \wedge (w_k(t) < 0), \\ w_k(t), & \text{em outros casos.} \end{cases} \quad (4.11)$$

Na sensibilização, o aumento do peso sináptico depende da ocorrência de um estímulo simultâneo conforme a equação (4.12), onde w_{targ} é o peso da sinapse que sofre a sensibilização, w_{sos} é o peso da sinapse cujo estímulo funciona como facilitador do aumento do peso w_{targ} , e $fired$ é um predicado de aridade zero que é verdadeiro quando o estado interno do neurônio é igual a B, C ou D.

$$w_{targ}(t+1) = \begin{cases} w_{targ}(t) + w_{sos}(t), & \text{se } fired_{targ} \wedge fired_{sos}, \\ w_{targ}(t), & \text{em outros casos.} \end{cases} \quad (4.12)$$

4.2.5 Aprendizado associativo

No condicionamento clássico, como na sensibilização, o aumento do peso sináptico depende da ocorrência de dois estímulos simultâneos conforme a equação (4.13), onde w_{targ} é o peso da sinapse relacionada ao estímulo não-condicionado, w_{sos} é o peso da sinapse relacionada ao estímulo condicionado e $fired$ representa o mesmo predicado da sensibilização.

$$w_{targ}(t+1) = \begin{cases} w_{targ}(t) + kw_{sos}(t), & \text{se } fired_{targ} \wedge fired_{sos}, \\ w_{targ}(t), & \text{em outros casos.} \end{cases} \quad (4.13)$$

Como os estímulos devem obedecer a uma regra temporal, ou seja, devem ser concomitantes ou o EC deve ser apresentado antes do EI, o valor de w_{sos} é multiplicado por um valor k calculado na equação (4.14), onde nT representa o tempo desde a última passagem pelo estado C, ψ representa um fator escalar empírico de valor igual a 250 e ς é uma constante de valor igual a 500, escolhida para maximizar os efeitos do condicionamento quando EC precede EI por 0,5 s.

$$k = \frac{nT}{\psi} \exp\left(\frac{-nT}{\varsigma}\right) \quad (4.14)$$

4.3 Critérios para escolha do modelo adotado

Alguns critérios foram adotados para a escolha do modelo a implementar. O primeiro critério adotado foi a simplicidade, principalmente quanto a compreensão, modelagem e facilidade para fazer alterações no mesmo. O segundo e mais importante critério foi a possibilidade de implementar as formas de aprendizado apresentadas no capítulo 3.

Assim sendo, o modelo Hi-NOON foi adotado porque é mais fácil de implementar em software com a sua abordagem orientada a objetos, e porque possui em si a modelagem dos conceitos de aprendizado. Este modelo torna possível o aprendizado do dispositivo robótico a partir da sua experiência sensorial no mundo. Além disso, estas formas de aprendizado possuem características que garantem plasticidade do aprendizado na rede, já que as informações obtidas a partir de experiências que não se repetem por um tempo sejam esquecidas.

Capítulo 5

Aplicações Práticas

Como forma de validação do modelo proposto, decidimos gerar duas aplicações. Uma das aplicações foi um simulador de redes neurais, denominado 'SPINS' que culminou na dissertação de mestrado de Giseli de Sousa [28]. A outra, foi sua aplicação em robótica, descrita neste trabalho. A concepção desses sistemas foi gerada a partir dos conceitos do Hi-NOON, apresentados na seção 4.2, aplicando as modificações apresentadas no capítulo 6.

5.1 A aplicação robótica

Como o foco deste trabalho é o programa de controle do dispositivo robótico e não sua plataforma física, utilizamos o conjunto para construção de dispositivos robóticos LEGO® MINDSTORMS. Este conjunto consiste em uma CPU, motores, sensores, e um conjunto de peças acopláveis que permitem uma grande gama de possíveis combinações para a construção da plataforma física do robô, garantindo que o esforço realizado na execução do projeto seja voltado ao desenvolvimento e estudo do seu sistema lógico.

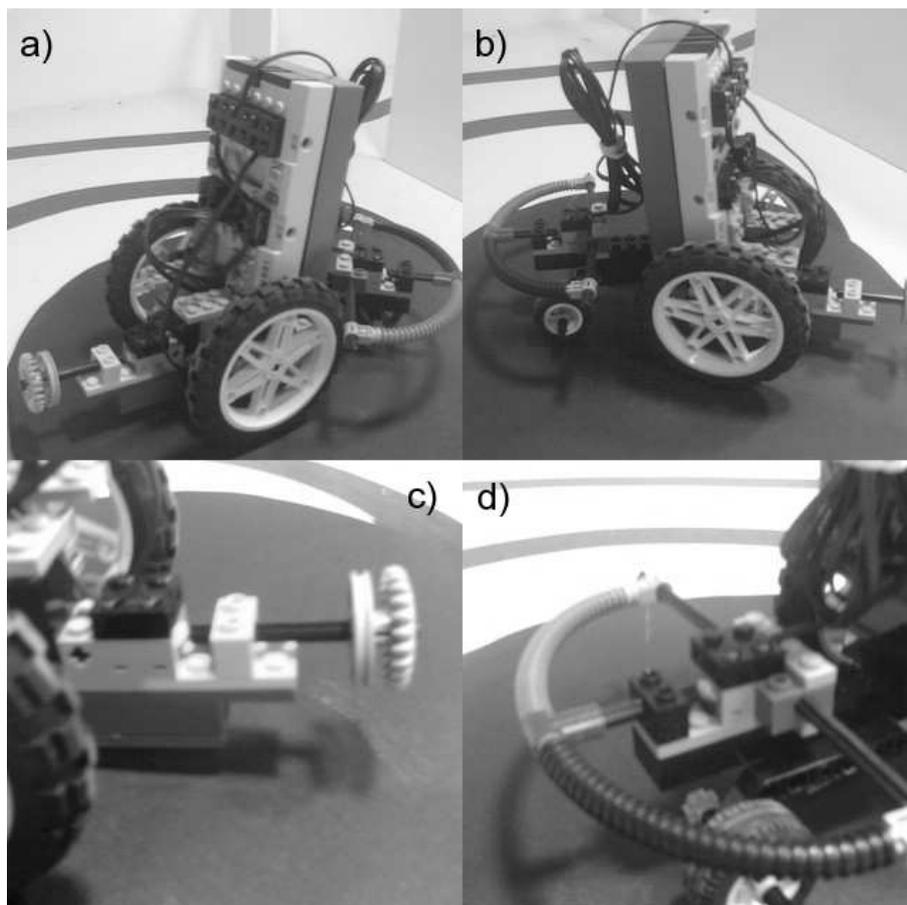


Figura 5.1: Detalhes da aplicação robótica: a, b) Detalhes laterais; c) detalhe dos sensores de colisão e de proximidade frontais; d) detalhe do sensor de colisão traseiro.

5.1.1 Arquitetura robótica

Para que o artefato robótico construído possuísse todas as funcionalidades descritas na Figura 5.2 dotamos o nosso protótipo de dois motores, dois sensores de colisão, sendo um traseiro e um dianteiro, e um sensor frontal de luz (Figura 5.1). O sensor frontal de luz age no modo ativo. Isso faz com que a luz emitida pelo sensor proporcione o aumento do estímulo recebido quando o robô se aproxima de algum objeto, funcionando assim como um sensor de proximidade. O sensor de luz opera em conjunto com o sensor de colisão dianteiro. Sobre cada um dos motores agem dois neurônios motores, que definem se o sentido do deslocamento é para frente ou para trás.

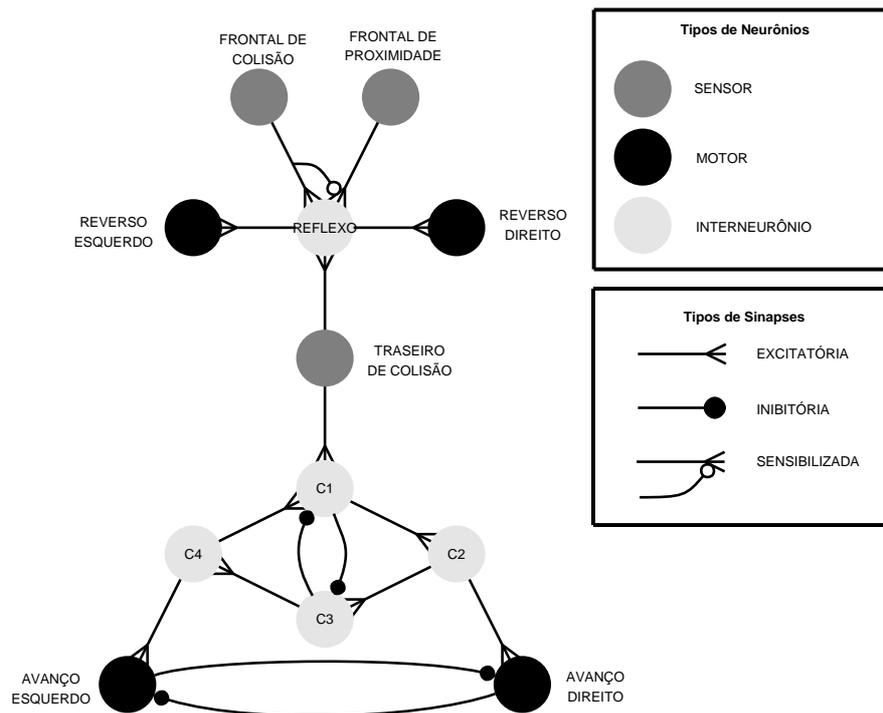


Figura 5.2: Esquema topológico da rede neural artificial utilizada no dispositivo robótico.

5.1.2 Descrição da aplicação

Quando o programa é carregado no robô todos os neurônios da rede estão no estado de repouso, ou seja, nenhum estímulo está percorrendo a rede e o robô não tem nenhuma ação motora. Para que inicie a propagação de sinal na rede, o sensor de colisão traseira deve ser acionado, inervando o interneurônio C1 e, através deste, iniciando o ciclo de propagação no Gerador Central de Padrões (GCP) e, através deste, ativando os neurônios motores de avanço.

Para ilustrar o caso de aprendizado por habituação, foi utilizada uma sinapse com essa característica entre o neurônio sensor de colisão dianteiro e o interneurônio de reflexo, como pode ser visto na figura 5.3. No princípio da aplicação, quando o dispositivo robótico colidir com algum obstáculo um estímulo será recebido. A partir desse estímulo, propagado na rede neural, será gerada uma resposta nos motores fazendo que o robô volte, desviando do obstáculo. Caso a colisão se repita, ocorrerá a

habituação, fazendo que o dispositivo robótico pare de dar a ré ao bater.

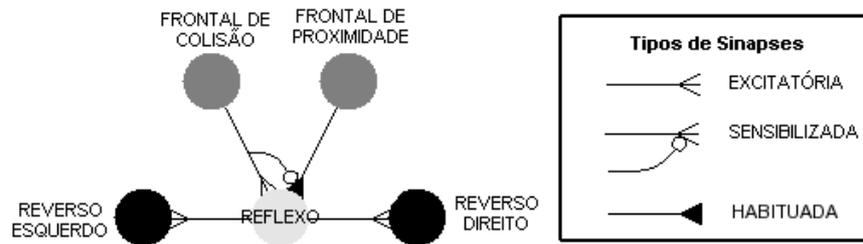


Figura 5.3: Esquema das sinapses que implementam como formas de aprendizados a habituação e a sensibilização dentro da topologia da rede neural.

A sinapse que sofre a sensibilização, bem como os demais elementos com ela relacionados também podem ser visualizados na figura 5.3. Como o peso sináptico entre o sensor de proximidade e o interneurônio de reflexo é iniciado com um valor nulo, caso ocorra a aproximação de algum objeto os estímulos recebidos por este sensor serão desprezados. Um esquema do processo de aprendizado pode ser visto na Figura 5.4.

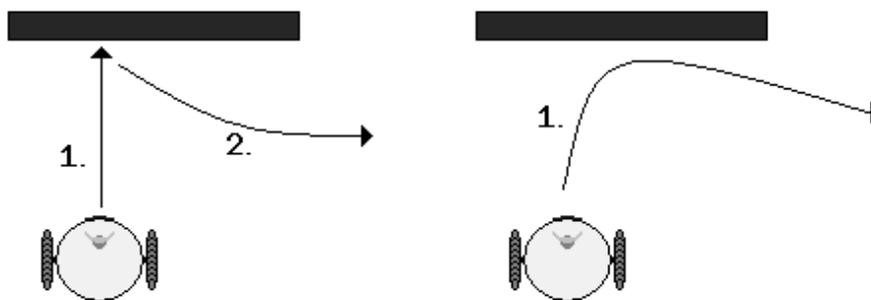


Figura 5.4: Processo de aprendizado do dispositivo robótico: (Esquerda) 1. Em direção à parede, ele colide; 2. O sensor de colisão ativa o comportamento de desviar do obstáculo. (Direita) 1. Depois do aprendizado, logo que se aproximar do obstáculo o sensor de proximidade é suficiente para mudar sua direção.

Ao bater num obstáculo, o sensor de colisão dianteiro é acionado, ao mesmo tempo em que a aproximação do obstáculo é detectada pelo sensor de proximidade. Com a junção destes dois estímulos entra em ação o aprendizado não-associativo caracterizado como sensibilização, reforçando o peso sináptico entre o sensor de proximidade e o interneurônio de reflexo de modo que, após algumas repetições, ao se aproximar de um objeto o estímulo propagado na rede através do sensor de proximidade é forte o suficiente para causar a inversão da rotação do motor e evitar o choque.

Colocando isto em outras palavras, podemos dizer que em princípio o robô consegue sentir a intensidade de luz do ambiente sem que isso cause nenhuma reação no seu sistema de controle. A partir do recebimento de um estímulo muito forte, no caso, da colisão com um obstáculo, começa a ocorrer a sensibilização, aumentando a importância da percepção da luz, que será mais alta perto do obstáculo, por utilizar um sensor de luz no modo ativo. Após o aprendizado, a aproximação do obstáculo vai causar uma resposta equivalente à do sensor de colisão, de forma que o dispositivo robótico ande para trás e desvie do obstáculo.

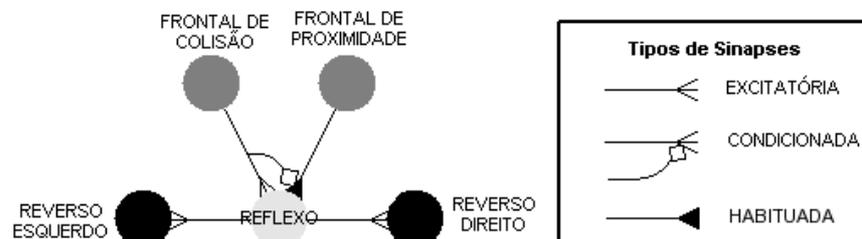


Figura 5.5: Esquema das sinapses que implementam como formas de aprendizados a habituação e o condicionamento clássico dentro da topologia da rede neural.

Para o estudo do condicionamento clássico foi utilizado o mesmo comportamento da sensibilização, como pode ser visto na figura 5.5, sendo que o estímulo condicionado (EC) é gerado pelo sensor de colisão frontal e o estímulo incondicionado (EI) é gerado pelo sensor de proximidade. Em princípio, a proximidade com um obstáculo

não faz com que o robô desvie. O comportamento de desviar de obstáculos é resposta ao estímulo do sensor de colisão, sendo este, um EI. A medida que o dispositivo robótico receber um estímulo do sensor de colisão e, em seguida, um estímulo indicando proximidade do obstáculo, ocorre o condicionamento clássico. A apresentação dos dois estímulos ao mesmo tempo, ou da colisão seguida rapidamente pela percepção da distância, o dispositivo começa a aprender a desviar quando estiver muito próximo do obstáculo.

Capítulo 6

Análise e alterações do modelo de neurônio pulsado

Uma vez definido o modelo conceitual de RNP, baseado na proposta HI-NOON de [26] e [27], procurou-se desenvolver uma aplicação prática através da implementação do modelo em um dispositivo real. Durante este processo de implementação, algumas limitações foram encontradas e alterações conceituais no modelo Hi-NOON foram sugeridas. Nesta seção, estas alterações são apresentadas e discutidas.

No cálculo do potencial sináptico descrito pela equação (4.7), o valor de $PM(t)$ pode variar de -69 mV até 45 mV. Diminuindo deste o valor de $PMBase$, o valor do potencial de repouso da membrana que é de -60 mV, o resultado pode variar de -9 até 105 mV, ou seja, quando o valor de $PM(t)$ é um valor abaixo de $PMBase$, observa-se que o potencial de membrana causa a inversão do sinal no resultado do cálculo do peso sináptico. Isto acontece, por exemplo, no estado D (Figura 4.1). Nessa situação um estímulo excitatório age como inibitório e vice-versa.

$$S(t) = \begin{cases} 0, & \text{caso qualquer neurônio pré-sináptico esteja inibindo,} \\ \sum_i w_i, & \text{em outro caso.} \end{cases} \quad (6.1)$$

Durante a evolução do modelo do cálculo do potencial sináptico adotamos duas abordagens. Na primeira abordagem, enquanto discutíamos as modificações

necessárias no modelo e buscávamos sua simplificação decidimos que um único estímulo inibitório seria o suficiente para inibir o neurônio pós-sináptico, conforme a equação (6.1).

$$S(t) = \sum_i w_i \quad (6.2)$$

Esta primeira versão é validada na dissertação de mestrado de Giseli de Sousa [28]. Após comprovar sua funcionalidade prática o modelo evoluiu em uma forma mais próxima do modelo biológico, onde o somatório dos estímulos excitatórios e inibitórios decide a forma que é inervado o neurônio pós-sináptico, como pode ser conferido na equação (6.2).

6.1 Modelagem dos neurônios

A análise do cálculo do potencial de membrana nos seus diversos estados, representado pela equação (4.8), leva à conclusão que o resultado do potencial sináptico pode alterar o período do potencial de ação. Para exemplificar essa situação tomaremos de exemplo o robô ARBIB (em português: Robô Autônomo Baseado em Inspiração Biológica), proposto em [5] e [25]. Em sua arquitetura é utilizado um mecanismo conhecido biologicamente por GCP (Gerador Central de Padrões), que correspondem aos neurônios C1 à C4 na Figura 6.1 (Um exemplo mais complexo de aplicação de um GCP para controle de funções diversas pode ser encontrado em [29]). As representação das sinapses inibitórias e excitatórias são feitas através de arestas que diferem em sua extremidade de acordo com o tipo da sinapse conforme a tabela apresentada na Figura 6.1. Nesta figura também podemos diferenciar cada tipo de neurônio utilizado nesta rede segundo a classificação apresentada no capítulo 2.

Quando o sensor traseiro de colisão (STC) é ativado ele excita o neurônio C1 iniciando o ciclo de propagação de sinal dentro do GCP. Em nossa experiência prática, quando o neurônio C1 é excitado, ele gera um sinal excitatório para C2, enquanto inibe C3. O período do potencial de ação em C1 e C2 são próximos pois o potencial sináptico do neurônio STC interfere no período de C1 como o de C1 interfere no de C2. Quando o

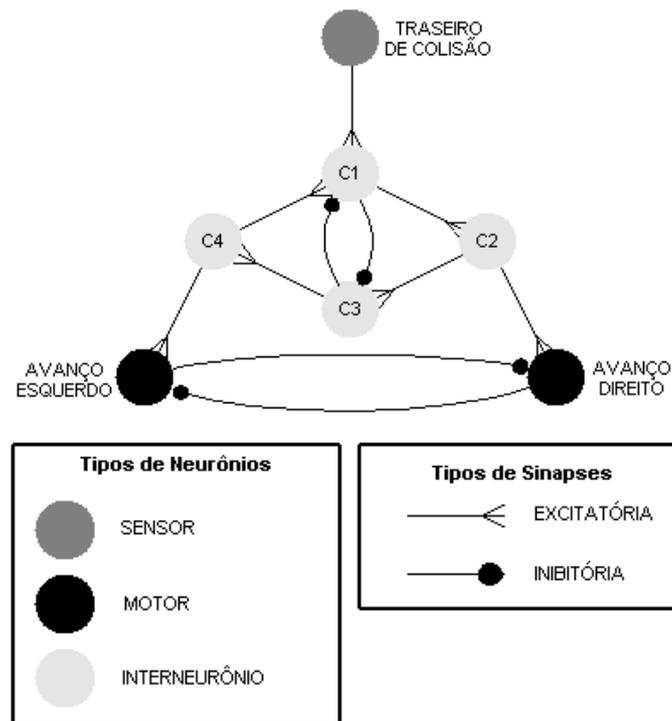


Figura 6.1: Topologia do Gerador Central de Padrões existente na rede neural implementada.

sinal é propagado para C3, após o estímulo inibitório de C1 cessar, o potencial de ação de C2 já chegou ao fim. A ausência de estímulos excitatório sobre C3 faz com que o período do seu potencial de ação seja maior. A influência de C3 sobre C4 faz com que o período do potencial de ação gerado em C4 seja mais curto do que o de C3, cessando antes da influência inibitória de C3 sobre C1, não permitindo que o sinal se propague como podemos acompanhar através da figura 6.2.

Para resolver este problema eliminamos a influência do potencial sináptico $S(t)$ sobre todos os estados com exceção do estado A. Isso garante que o período de potencial de ação seja o mesmo para neurônios instanciados com parâmetros iguais, mantendo a sincronização do sistema e a propagação do sinal adiante. De acordo com o estado interno do neurônio, as equações abaixo, descrevem o estado do neurônio para os estados B, C, D, E e F.

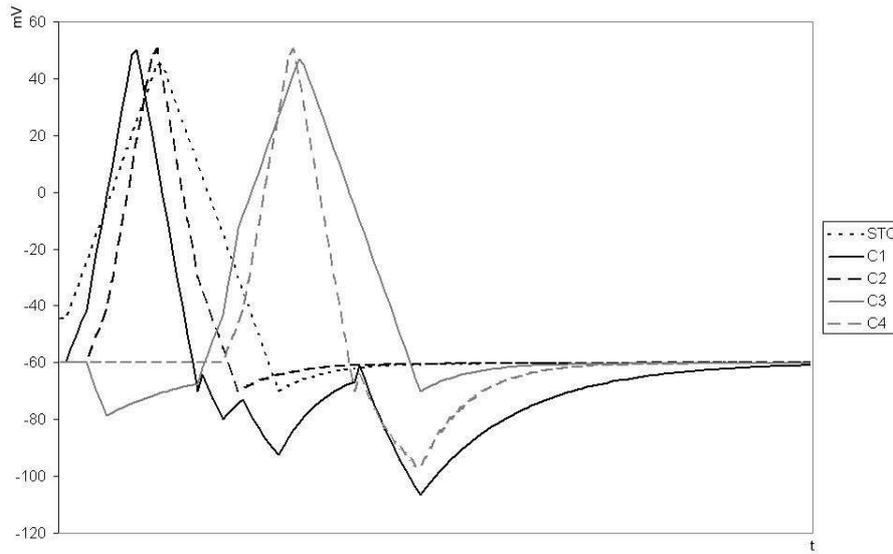


Figura 6.2: Dinâmica do potencial de membrana dos neurônios do gerador central de padrões e do sensor traseiro de colisão do robô ARBIB.

$$PM(t+1) = \begin{cases} PM(t) - \alpha, & \text{com } \alpha = 5, \text{ para o estado B,} \\ h, & \text{para o estado C,} \\ PM(t) - \mu, & \text{com } \mu = 5, \text{ para o estado D,} \\ l, & \text{com } l = -69, \text{ para o estado E,} \\ PM(t) + (PMBase - PM(t))/\eta, & \text{com } \eta = 0.1, \text{ para o estado F.} \end{cases} \quad (6.3)$$

O fator de tempo τ , utilizado no estado A (4.8), é responsável por fazer com que o potencial de membrana retorne ao estado de repouso caso fique sem receber estímulos por um longo tempo. Em sua abordagem original, referenciada nos artigos relativos ao Hi-NOON e ao ARBIB como, por exemplo, no artigo [5], τ é uma constante. Nesta abordagem τ é uma equação representada em (6.4). Esta alteração foi feita porque quando um neurônio estava em estado de repouso e não recebia mais estímulos ele iniciava um processo de hiperpolarização, como se estivesse recebendo pequenos estímulos inibitórios. Os elementos desta equação em si, não têm justificativa biológica, sua função é a de fazer com que o neurônio não excitado retorne ao seu equilíbrio, que é caracterizado

pelo estado de repouso, este comportamento sim, justificado nos neurônios biológicos. O valor da constante $TimeConst$ em nossa aplicação é igual a 0,05.

$$\tau = (PM(t) - PMBase) * TimeConst \quad (6.4)$$

6.2 Modelagem das sinapses

Na análise das sinapses, consideramos que o valor de w_{base} deve ser atribuído de acordo com a influência de sinapse sobre o neurônio pós-sináptico. Com relação ao ajuste dos pesos sinápticos, representados pelo conjunto de equações descrito em (4.9), mudamos apenas a última equação, resultando no conjunto de equações descritas em (6.5). Se nenhuma das quatro primeiras condições fosse verdadeira o valor atribuído ao peso seria o valor mínimo. Assim sendo, no caso de uma sinapse inibitória, ela teria seu peso aumentado, enquanto uma sinapse excitatória teria seu peso anulado. Esta alteração do modelo original visa manter a influência original de uma sinapse sobre um neurônio.

$$W(t) = \begin{cases} w(t) - \beta, & \text{se } w(t) > w_{base}, \\ w(t) + \beta, & \text{se } w(t) < w_{base}, \\ w_{max}, & \text{se } w(t) > w_{max}, \\ w_{min}, & \text{se } w(t) < w_{min}, \\ w(t), & \text{em outros casos.} \end{cases} \quad (6.5)$$

Na equação (6.5) o valor correspondente de β depende da aplicação. Em nossas experiências utilizamos o valor 0.00001.

6.2.1 Aprendizado associativo

Quanto ao aprendizado não-associativo, não houveram modificações em sua modelagem, mas ao implementarmos o aprendizado associativo em nossa plataforma robótica encontramos uma limitação que afeta a equação (4.14): a ausência da função exponencial logarítmica. O problema poderia ser resolvido pela construção de

uma tabela e interpolação de valores mas, como a forma da função não era tão importante, decidimos utilizar uma função linear que interpolasse apenas os pontos extremos, ou seja, na qual o valor do aprendizado será máximo com estímulos concomitantes e que vá decaindo com a distância dos estímulos até que atinja um valor irrisório ou nulo.

$$k = \begin{cases} \frac{T_{cond} - nT}{T_{cond}}, & \text{se } nT < T_{cond}, \\ 0, & \text{em outros casos.} \end{cases} \quad (6.6)$$

Nesta abordagem, descrita pela equação (6.6), T_{cond} é uma constante cujo valor limita o tempo de aprendizado. Quanto mais distante o tempo de disparo entre o EC e o EI, menor o valor no numerador e menor o efeito do aprendizado.

$$w_{targ}(t + 1) = w_{targ}(t) + kw_{sos}(t) \quad (6.7)$$

Outra modificação feita em nosso modelo foi a troca da equação (4.13) pela equação (6.7). Esta mudança se justifica no conceito do condicionamento clássico. O aprendizado pode existir mesmo quando o EC precede o EI em 0,5 s. Como o período do potencial de ação é de aproximadamente $2 \mu s$ a exigência de que os dois neurônios pré-sinápticos possuam o predicado *fired* verdadeiro vai contra o conceito anterior. Nesse caso, a equação (6.6) será responsável pelo critério de aprendizado.

Capítulo 7

Resultados

Na simulação realizada, após a ativação do sensor traseiro, os ciclos de propagação do sinal no GCP podem ser conferidos na Figura 7.1. Podemos também observar o processo de hiperpolarização de C3 após o primeiro potencial de ação do interneurônio C1, causado pela sinapse inibitória existente de C1 em C3.

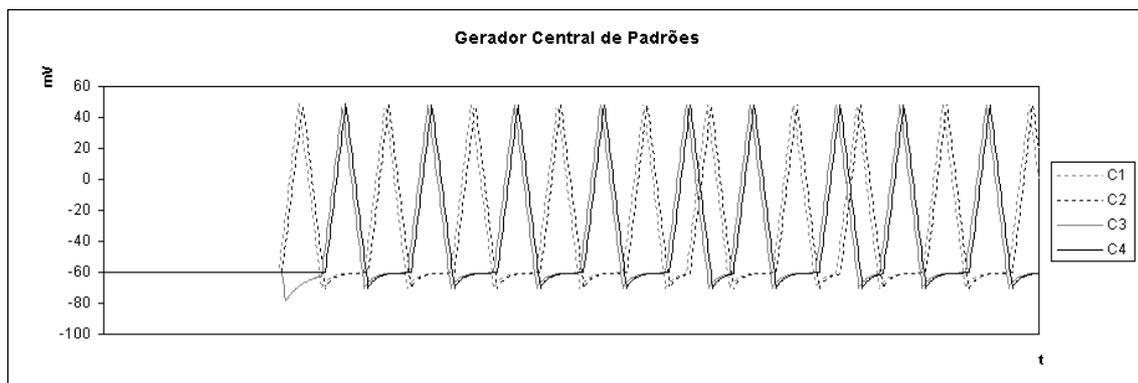


Figura 7.1: Propagação dos estímulos no Gerador Central de Padrões.

Os processos de aprendizado da rede podem ser acompanhados através dos gráficos contidos nas Figuras 7.2, 7.3 e 7.4. Nelas podemos observar os potenciais de ação gerados pelo neurônio sensor frontal de colisão (SFC) através do contato com algum obstáculo, onde cada potencial corresponde a um contato. Também podemos observar os potenciais de ação gerados pelo neurônio sensor frontal de proximidade (SFP), onde o

processo de depolarização na membrana deste neurônio aumenta à medida que o robô se aproxima de algum objeto.

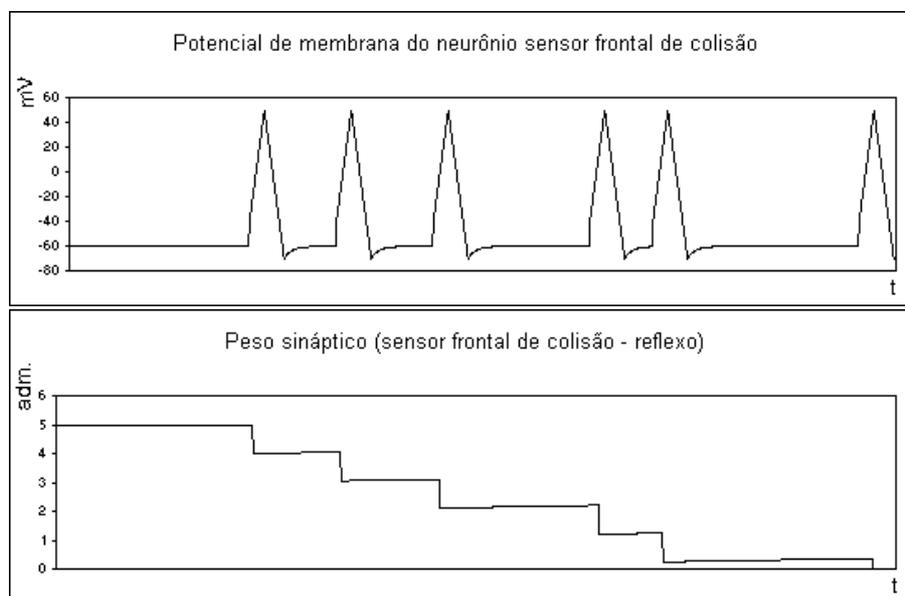


Figura 7.2: Habituação sináptica causada por estímulos no neurônio sensor frontal de colisão.

Através da Figura 7.2 podemos acompanhar a habituação da sinapse existente entre o neurônio SFC e o interneurônio do reflexo onde, a cada potencial disparado pelo sensor, o peso sináptico sofre uma queda, diminuindo a efetividade sináptica.

O aprendizado através da sensibilização pode ser acompanhado através da Figura 7.3. O processo ocorre na sinapse entre o neurônio SFP e o interneurônio de reflexo, facilitado pela sinapse que parte do neurônio SFC. Cada vez que os neurônios sensores envolvidos geram um potencial de ação, ao mesmo tempo a sinapse tem o seu peso reforçado. Podemos notar neste gráfico que no segundo potencial gerado pelo SFP não existe um correspondente no tempo vindo do SFC, assim sendo, não há o reforço do peso sináptico.

Finalmente, para comprovar o condicionamento clássico na rede, utilizamos os dados mostrados na figura 7.4. Neste gráfico podemos comprovar que a efetividade sináptica aumenta quando os critérios para o aprendizado são satisfeitos, ou seja, quando EC (gerado pelo SFP) é concomitante ou precede EI (gerado pelo SFC), por um

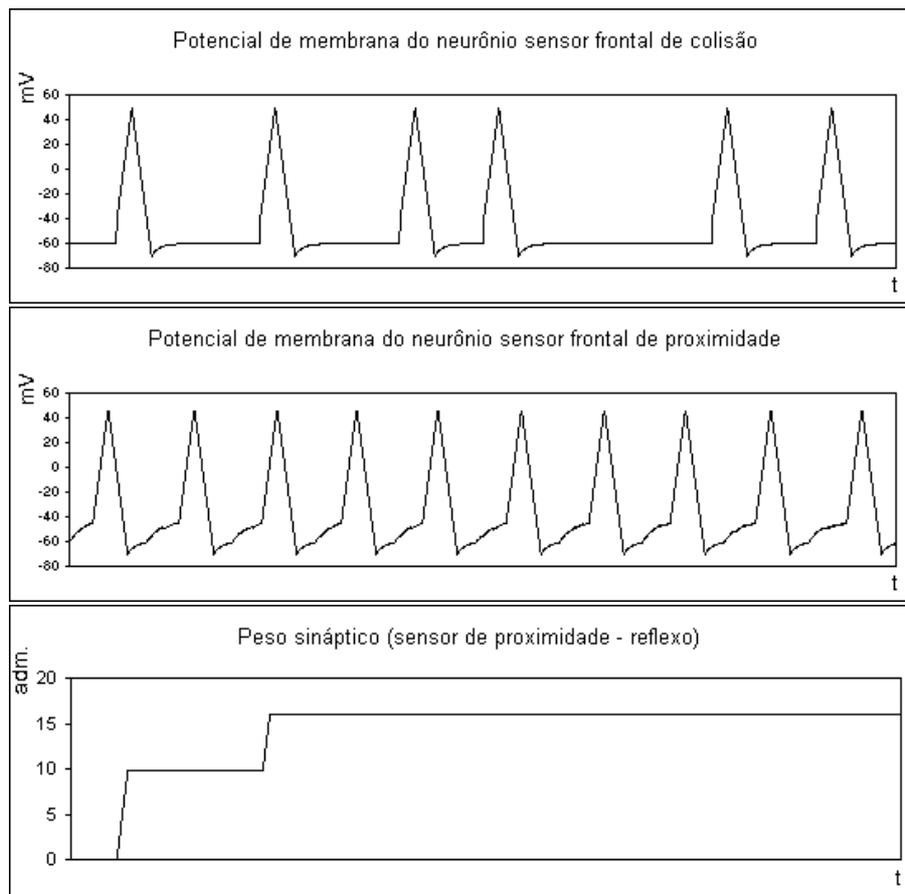


Figura 7.3: Sensibilização sináptica causada por estímulos nos neurônios sensores frontal de colisão e de proximidade.

curto período de tempo.

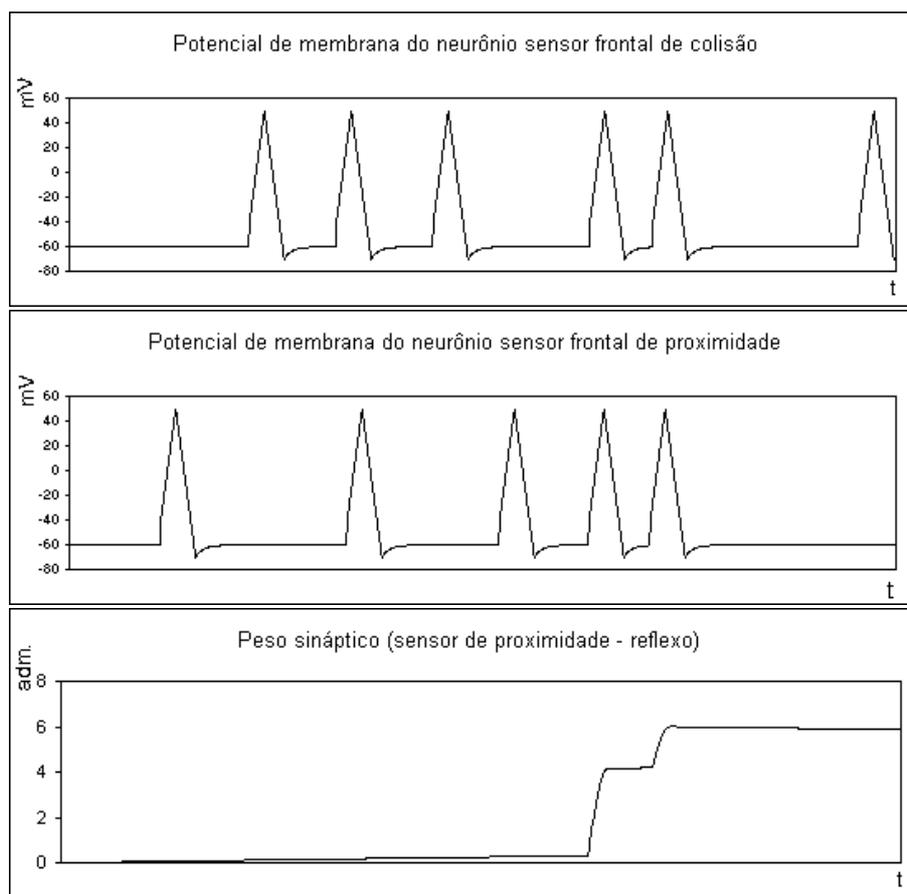


Figura 7.4: Condicionamento clássico causado por estímulos nos neurônios sensores frontal de colisão e de proximidade.

Capítulo 8

Conclusão

O apanhado teórico apresentado é fundamental para a reflexão sobre redes neurais que utilizam neurônios pulsados. Observando os modelos existentes podemos, a grosso modo, separá-los em modelos com enfoque em implementações em ‘hardware’, como VLSI ou similares, e sistemas que implementam em ‘software’ os conceitos anteriormente descritos, ambos buscando uma aproximação funcional do modelo real. Este trabalho é focado nos conceitos necessários para a implementação em ‘software’, tomando o devido cuidado para classificar e generalizar corretamente as classes de conceitos aqui abordadas.

Entre os modelos existentes, baseamos nosso trabalho no modelo Hi-NOON (em português: Rede de Neurônios Hierárquicos Orientada a Objetos), apresentado em [26]. Partindo deste trabalho, cujo enfoque era voltado pro campo da robótica, sentimos a necessidade de esclarecer todos os elementos biológicos relacionados à modelagem dessas redes.

A partir dos dados obtidos no capítulo 7, podemos observar a capacidade da aplicação robótica de adaptar-se ao ambiente de acordo com os estímulos recebidos, concluindo assim, que a emergência de um comportamento inteligente através dos mecanismos de aprendizado associativo e não-associativo podem ser alcançado através do modelo proposto.

8.1 Trabalhos futuros

Como o escopo deste trabalho se restringe ao nível mais básico de funcionamento de Redes Neurais Pulsadas utilizando o modelo neural aqui proposto, vários modos de utilização e modificações foram pensadas no decorrer deste que não puderam ser realizadas por falta de tempo hábil. A seguir são levantadas algumas destes possibilidades.

Um aspecto que pode ser incorporado futuramente é a modelagem do período refratário relativo do potencial de membrana do neurônio pois, neste modelo, se limitou à modelagem do período refratário absoluto.

A topologia utilizada no ARBIB foi criada sem referências biológicas, com o intuito de formalizar o modelo Hi-NOOM. Como a topologia utilizada nos seres vivos mais evoluídos é complexa, bem como possui um gigantesco número de neurônios interligados de várias maneiras, poderíamos tentar adotar algoritmos genéticos para criar e avaliar topologias para problemas específicos.

Também podemos inserir uma RNP como o nível inferior em uma arquitetura de assunção e, dentro deste escopo, realizar testes utilizando uma arquitetura mista para diversas funções de controle do dispositivo robótico.

A aplicação desta arquitetura no campo de agentes em software também é uma possibilidade de extensão deste trabalho. Imaginamos uma casa inteligente adaptativa, onde os dispositivos possuem neurônios e formam uma rede que aprende o padrão de comportamento do usuário. Esta opção surgiu principalmente por ser o ponto de partida dos estudos de nossa equipe que culminaram neste trabalho.

Referências Bibliográficas

- [1] BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neuroscience: Exploring the brain*. 2. ed. Baltimore: Lippencott Williams & Wilkins, 2001.
- [2] KANDEL, E. R.; SCHWARTZ, J. H.; JESSEL, T. M. *Principles of Neural Science*. 4. ed. New York: McGraw-Hill Medical, 2000. 1414 p.
- [3] KOLB, B.; WHISHAW, I. Q. *An Introduction to Brain and Behavior*. 2. ed. New York: Worth Publishers, 2001.
- [4] PURVES, D. et al. *Neuroscience*. 3. ed. Massachusetts: Sinauer Associates Inc, 2004.
- [5] DAMPER, R. I.; FRENCH, R. L. B.; SCUTT, T. W. Arbib: An autonomous robot based on inspirations from biology. In: *Robotics and Autonomous Systems*. [S.l.: s.n.], 2000. v. 31, n. 4, p. 247–274.
- [6] ROISENBERG, M. *Emergência da Inteligência em Agentes Autônomos através de Modelos Inspirados na Natureza*. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal de Santa Catarina, Florianópolis, 1998.
- [7] DEGRIS, T. et al. A spiking neuron model of head-direction cells for robot orientation. In: *Eighth International Conference on the Simulation of Adaptive Behavior, from Animals to Animats*. [S.l.: s.n.], 2004. p. 255–263.
- [8] FLOREANO, D.; ZUFFEREY, J.-C.; NICOUD, J.-D. From wheels to wings with evolutionary spiking circuits. In: *Artificial life*. Cambridge, MA, USA: MIT Press, 2005. v. 11, n. 1-2, p. 121–138.

- [9] FAUSETT, L. *Fundamentals of Neural Networks: architectures, algorithms and applications*. Upper Saddle River, New Jersey, USA: Prentice Hall, 1994.
- [10] VIDAL, J. M.; DURFEE, E. H. Multiagent systems. In: ARBIB, M. A. (Ed.). *The Handbook of Brain Theory and Neural Networks*. Cambridge, MA: The MIT Press, 2002. p. 707–711.
- [11] ARBIB, M. A. The handbook of brain theory and neural networks. In: _____. 2. ed. Cambridge, MA: The MIT Press, 2002. cap. 1. Introducing the Neuron, p. 3–23.
- [12] MAASS, W.; BISHOP, C. M. *Pulsed Neural Networks*. Cambridge, MA: The MIT Press, 2001.
- [13] KOVÁCS, Z. L. *O Cérebro e Sua Mente: Uma introdução à Neurociência Computacional*. Edição acadêmica. [S.l.: s.n.], 1997.
- [14] ARBIB, M. A. The handbook of brain theory and neural networks. In: _____. 2. ed. Cambridge, MA: The MIT Press, 2002. cap. 2. Background: The Elements of Brain Theory and Neural Networks, p. 26–80.
- [15] BYRNE, J. H.; CROW, T. Invertebrate models of learning: *Aplysia* and *Hermisenda*. In: ARBIB, M. A. (Ed.). *The Handbook of Brain Theory and Neural Networks*. Cambridge, MA: The MIT Press, 2002. p. 581–585.
- [16] BEGGS, J. M. et al. *Fundamental Neuroscience*. [S.l.: s.n.].
- [17] PRINCIPE, J. C. *The Electrical Engineering Handbook*. [S.l.: s.n.].
- [18] MAASS, W. Lower bounds for the computational power of networks of spiking neurons. *Neural Computation*, n. 8, p. 1–40, 1996.
- [19] KATADA, Y.; OHKURA, K. Artificial evolution of pulsed neural networks on the motion pattern classification system. In: *IEEE International Symposium on Computational Intelligence in Robotics and Automation*. Kobe, Japan: [s.n.], 2003. p. 318–323.

- [20] TEO, J. Evolving spike-timing dependent synaptic plasticity for robot control. In: *2nd International Conference on Artificial Intelligence in Engineering and Technology*. Kota Kinabalu, Sabah, Malaysia: [s.n.], 2004. v. 1, p. 7–13.
- [21] PAOLO, E. A. D. Evolving spike-timing dependent synaptic plasticity for robot control. In: *EPSRC/BBSRC International Workshop: Biologically-inspired Robotics, The Legacy of W. Grey Walter, WGW'2002*. Bristol: [s.n.], 2002.
- [22] GERSTNER, W.; KISTLER, W. *Spiking Neuron Models*. Cambridge, UK: Cambridge University Press, 2002.
- [23] GERSTNER, W. Integrate-and-fire neurons and networks. In: ARBIB, M. A. (Ed.). *The Handbook of Brain Theory and Neural Networks*. Cambridge, MA: The MIT Press, 2002. p. 577–581.
- [24] SCUTT, T. W.; DAMPER, R. I. Biologically-motivated learning in adaptive mobile robots. In: *IEEE International Conference on Systems, Man and Cybernetics*. Orlando: [s.n.], 1997. p. 475–480.
- [25] FRENCH, R. L. B.; DAMPER, R. I. Stability of learning in the arbib autonomous robot. In: *Supplement - International Conference on Simulation of Adaptive Behavior: From Animals to Animats*. Paris: [s.n.], 2000. p. 150–159.
- [26] DAMPER, R. I.; FRENCH, R. L. B.; SCUTT, T. W. The hi-noon neural simulator and its applications. In: *Small System Simulation Symposium*. Iugoslavia: [s.n.], 2000. p. 31–36.
- [27] DAMPER, R. I.; FRENCH, R. L. B.; SCUTT, T. W. The hi-noon neural simulator and its applications to animal, animat and humanoid studies. In: *First IEEE-RAS International Conference on Humanoid Robots*. Boston: [s.n.], 2000.
- [28] SOUSA, G. *SPINS - Um Simulador Neural para Visualização de Aspectos de Aprendizado utilizando Neurônios Spiking*. Dissertação (Mestrado em Ciências da Computação) — Universidade Federal de Santa Catarina, Florianópolis, 2005.

- [29] OKA, T.; INABA, M.; INOUE, H. Describing a modular motion system based on a real time process network model. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems*. Grenoble, France: [s.n.], 1997. v. 2, p. 821–827.