

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO
INSTITUTO DE MATEMÁTICA
INSTITUTO TERCIO PACITTI

Higo Fernandes Ferreira

**Neurociências e Machine Learning: modelo computacional
de condicionamento por medo como parte do programa de
planejamento de um robô**

Rio de Janeiro

2011

Higo Fernandes Ferreira

**Neurociências e Machine Learning: modelo computacional de
condicionamento por medo como parte do programa de
planejamento de um robô**

Dissertação submetida ao corpo docente do
Instituto de Matemática e Instituto Tércio Pacitti
da Universidade Federal do Rio de Janeiro como
parte dos requisitos necessários para obtenção do
grau de Mestre em Informática.

Orientadores: Carlos Alberto da Silva Franco, D. Sc.
Josefino Cabral de Melo Lima, Docteur.

Rio de Janeiro
2011

F383 Ferreira, Higo Fernandes

Neurociências e machine learning: modelo computacional de condicionamento por medo como parte do programa de planejamento de um robô. / Higo Fernandes - 2011
80 f.: il

Orientadores: Josefino Cabral de Melo Lima ; Carlos Alberto da Silva Franco
Dissertação (Mestrado em Informática) – Universidade Federal do Rio de Janeiro, Instituto de Matemática, Instituto Tércio Pacitti, 2011.

1. Neurociências. 2. Machine Learning. 3. Modelos biologicamente realistas. 4. Redes Neurais. 5. Lógica Fuzzy. 6. Robô. 7. Simulador. - Teses. I. Lima, Josefino Cabral de Melo. (Orient.). II. Franco, Carlos Alberto da Silva. (Orient.). III. Universidade Federal do Rio de Janeiro, Instituto de Matemática, Instituto Tércio Pacitti. III. Título.

CDD.

Higo Fernandes Ferreira

**Neurociências e Machine Learning: modelo computacional de
condicionamento por medo como parte do programa de
planejamento de um robô**

Dissertação submetida ao corpo docente do
Instituto de Matemática e Instituto Tércio Pacitti
da Universidade Federal do Rio de Janeiro como
parte dos requisitos necessários para obtenção do
grau de Mestre em Ciências.

Aprovada em:

Prof. Josefino Cabral de Melo Lima – Docteur

Prof. Carlos Alberto da Silva Franco – D.Sc.

Prof. Adriano Joaquim de Oliveira Cruz – Ph. D.

Prof. Eber Assis Schmitz – Ph. D.

Prof. Antonio Alberto Fernandes de Oliveira, D.Sc.

Agradecimentos

Agradeço aos meus pais, por terem me dado a educação e estrutura necessárias para atingir todos os objetivos em minha vida.

À minha esposa, pelas inúmeras noites em claro realizando comigo a revisão do texto, lendo e ouvindo sobre um assunto até então desconhecido para ela.

Ao meu orientador Carlos Alberto da Silva Franco, pela oportunidade e confiança em desenvolver um trabalho tão gratificante e desafiador.

A todos os professores do PPGI, pelos ensinamentos transmitidos.

À minha chefe Regina Torraca, pelo apoio e compreensão quando precisei flexibilizar meu horário de serviço para me adaptar à nova rotina de estudo.

A todos que me apoiaram e nunca me deixaram desanimar ou desistir de concluí-lo, mesmo nos momentos de maior dificuldade.

Resumo

FERREIRA, Higo Fernandes. **Neurociências e machine learning**: modelo computacional de condicionamento por medo como parte do programa de planejamento de um robô. 2011. 80 f. Dissertação (Mestrado em Informática) – Instituto de Matemática, Instituto Tércio Pacitti, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

A proposta da pesquisa presente neste trabalho é de simular um comportamento emotivo de medo em um autômato contido em um ambiente virtual. Para isto, nós integramos convenientemente a ele um modelo computacional construído em um ambiente de simulação de redes neurais biologicamente realistas do cérebro, que apresenta uma informação de sensação de medo para um dado conjunto de informações situacionais que o ambiente fornece para o autômato em um determinado momento. Essa informação é utilizada pelo autômato como método auxiliar no planejamento de sua rota dentro do ambiente virtual. Posteriormente, numerosos testes foram realizados para medir o desempenho do autômato tendo o auxílio do modelo computacional, comparando ao método tradicional utilizado por ele originalmente. No final, apresentamos tabelas com os resultados, além de sugestões para trabalhos futuros.

Palavras-chave: Neurociências, Machine Learning, Modelos biologicamente realistas, Redes Neurais, Lógica Fuzzy, Robô, Simulador.

Abstract

FERREIRA, Higo Fernandes. **Neurociências e machine learning**: modelo computacional de condicionamento por medo como parte do programa de planejamento de um robô. 2011. 80 f. Dissertação (Mestrado em Informática) – Instituto de Matemática, Instituto Tércio Pacitti, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2011.

The research proposed in this work is to simulate a fear emotional behavior for a robot contained in a virtual environment. For this, we conveniently integrate a computational model built in a simulation environment for biologically realistic neural networks of the brain, which presents information from a feeling of fear to a given set of situational information that provides the environment for the robot at any given time. This information is used by the robot as an auxiliary method in planning your route in the virtual environment. Subsequently, numerous tests were conducted to measure the performance of the robot with the help of the computer model, compared to the traditional method used by him originally. At the end, we present tables with results, and suggestions for future work.

Keywords: Neuroscience, Machine Learning, biologically realistic models, Neural Networks, Fuzzy Logic, Robot, Simulator.

Lista de Figuras

Figura 1 - Esquema cerebral representando o sistema límbico (ARAUJO, 2008).....	25
Figura 2 – Condicionamento por medo em ratos (ARAUJO, 2008)	26
Figura 3 - Em A, a relação entre o estímulo condicionado (CS) à apresentação de um estímulo incondicionado (US), no tempo. Em B, após o condicionamento, a apresentação de um CS causa os mesmos efeitos viscerais do US isoladamente (LEDOUX, 2000).	27
Figura 4 – O ambiente do Emergent	29
Figura 5 – Arquitetura final da rede (ARAUJO, 2008)	30
Figura 6 – Rede com uma camada de entrada, uma camada de saída e uma camada oculta ...	34
Figura 7 – Rede com duas camadas ocultas	35
Figura 8 - Arquitetura	39
Figura 9 - Exemplo de tela do simulador	40
Figura 10 - O ambiente virtual do Simulador Experimental.....	42
Figura 11	43
Figura 12 – Interface da proposta do novo simulador experimental	47
Figura 13 - Comportamento do RI com a luz acesa (raio de medo inalterado).....	49
Figura 14 - Comportamento do RI com a luz apagada (raio de medo acrescido para 60 unidades)	49
Figura 15 - Inicialização dos pesos da rede, no início do treinamento	55
Figura 16 - Rede logo após o treinamento inicial.....	56
Figura 17 - Abrindo servidor de comunicação do Emergent	71
Figura 18 - Abrindo servidor de comunicação do Emergent, confirmado a operação	71
Figura 19 - Abrindo o modelo	72
Figura 20 - Executando o treinamento inicial da rede do modelo	73

Figura 21 - Executando o simulador experimental.....	74
Figura 22 - Opção que ativa o modelo computacional	74
Figura 23 - Opções de execução do simulador experimental.....	75

Lista de Tabelas

Tabela 1 - Testes preliminares, Caso 1, Movimento Line	57
Tabela 2 - Testes preliminares, Caso 1, Movimento Eight	57
Tabela 3 - Testes preliminares, Caso 1, Movimento Follower.....	57
Tabela 4 - Resumo, Testes preliminares, Caso 1.....	58
Tabela 5 - Testes preliminares, Caso 2, Movimento Line	58
Tabela 6 - Testes preliminares, Caso 2, Movimento Eight	59
Tabela 7 - Testes preliminares, Caso 2, Movimento Follower.....	59
Tabela 8 - Resumo, Testes preliminares, Caso 2.....	59
Tabela 9 - Após Aprendizado, Caso 1, Movimento Follower.....	60
Tabela 10 - Resumo, Após Aprendizado, Caso 1.....	61
Tabela 11 - Após Aprendizado, Caso 2, Movimento Eight	61
Tabela 12 - Após Aprendizado, Caso 2, Movimento Follower.....	61
Tabela 13 - Resumo, Após Aprendizado, Caso 2.....	62
Tabela 14 - Modo de Emergência, Caso 1, Movimento Line	62
Tabela 15 - Modo de Emergência, Caso 1, Movimento Eight	63
Tabela 16 - Modo de Emergência, Caso 1, Movimento Follower.....	63
Tabela 17 - Modo de Emergência, Caso 2, Movimento Line	63
Tabela 18 - Modo de Emergência, Caso 2, Movimento Eight	64
Tabela 19 - Modo de Emergência, Caso 2, Movimento Follower.....	64

Sumário

Agradecimentos	vi
Resumo	vii
Abstract	viii
Sumário	ix
Lista de Figuras	Erro! Indicador não definido.
Lista de Tabelas	Erro! Indicador não definido.
Capítulo 1 Introdução	15
1.1 Neurociência e Robótica	16
1.2 Objetivos	17
1.3 Motivações	18
Capítulo 2 Neurociência das Emoções	20
2.1 Emoções x sentimentos	20
2.2 Robôs e Emoções	22
2.3 Memória emocional e o Condicionamento por Medo	23
2.3.1 O sistema Límbico	24
2.3.2 Condicionamento por medo	25
2.4 Condicionamento do contexto	28
2.5 O Emergent	28
2.6 Modelagem Computacional do Condicionamento por Medo	29
Capítulo 3 Aprendizado de Máquinas	32
3.1 Aprendizado	32
3.2 Redes Neurais Artificiais (RNA)	33
3.2.1 Aprendizado das RNA	35

3.3	Trabalhos anteriores	37
3.3.1	Affective Cognitive Learning and Decision Making: The Role of Emotions	37
3.3.2	Behavioral task processing for cognitive robots using artificial emotions	38
Capítulo 4	Solução Proposta	41
4.1	Introdução	41
4.2	A antiga solução: O Simulador experimental e o raio de emergência	41
4.2.1	O Raio de medo	44
4.2.2	O Modo de Emergência	44
4.2.3	Interface do simulador experimental	45
4.3	Funcionamento do modelo proposto	46
4.3.1	Replanejamento	48
4.3.2	Aprendizado	49
4.4	Vantagens a verificar	50
Capítulo 5	Experimentos	51
5.1	Metodologia	52
5.2	Treinamento da rede do modelo de condicionamento do medo	54
5.3	Testes preliminares	56
5.4	Aprendizado	60
5.5	Modo de Emergência	62
5.6	Análise dos resultados	64
Capítulo 6	Conclusões	66
6.1	Trabalhos futuros	67
6.1.1	Múltiplos RB's	67
6.1.2	Extinção de memória	68
6.1.3	Níveis de medo	68

6.2	Últimas considerações	69
Apêndice A - Usando o Emergent e o Simulador Experimental		70
	Preparando o ambiente	70

Capítulo 1

Introdução

Os robôs estão tomando um espaço importante na sociedade atual, na esperança de que auxiliem os seres humanos a resolverem problemas que desafiam os seus limites, com os que exigem uma dose extra de força, os que se baseiam em repetição de tarefas ou que representem risco à integridade física de pessoas de carne e osso. Essa busca por máquinas que substituam pessoas em tais tipos de tarefas nem sempre resulta em criações com características anatômicas humanas completas. Autômatos em uma linha de montagem de automóveis frequentemente são constituídos apenas por uma estrutura que se assemelha a um único braço de dimensões generosas. Robôs usados em sites de busca na internet, como o Googlebot, nem ao menos possuem representação física, e mesmo assim são softwares cada vez mais usados por todos que navegam pela rede.

Existem características humanas, porém, bastante desejadas em alguns robôs usados em determinadas aplicações específicas. No campo da psicologia, robôs capazes de reagir a estímulos humanos e produzir respostas a esses estímulos podem ser usados na reabilitação de crianças em hospitais. Robôs que atuam em dutos petrolíferos, fechando válvulas, identificando bloqueios, danos na estrutura de um navio, ou mesmo que possam realizar alguns tipos de reparos, em áreas inatingíveis pelos humanos ou mesmo muito perigosas para tal, geralmente são caros e preciosos. Seria altamente desejável que essas máquinas que atuam em locais críticos fossem dotadas de algum tipo de mecanismo que proporcionasse a elas capacidade de prever e evitar danos à sua estrutura. Seria bastante útil se esses robôs

pudessem sentir medo. Tal capacidade diminuiria custos e evitaria que o robô ficasse fora de ação, mesmo que por pouco tempo. Em todos os casos, o elemento comum é a emoção.

1.1 Neurociência e Robótica

A emoção, uma experiência cerebral amplamente estudada pela Neurociência, é um dos eixos deste trabalho. A classificação mais aceita para as emoções é a de PLUTCHIK (1980), que as divide em oito consideradas básicas: alegria, medo, tristeza, nojo, surpresa, raiva, curiosidade, aceitação. Segundo ele, tais emoções são primitivas em termos biológicos. Todos os animais as possuem, porém as características evolutivas podem determinar a maneira como elas são experimentadas ou expressadas. O ser humano, a título de exemplo, expressa alegria através de um sorriso, enquanto um gato o faz ronronando. A emoção a ser considerada neste trabalho será, especificamente, o medo.

A união entre a Neurociência e a Robótica permite construir sistemas embarcados em autômatos utilizando algoritmos com base em modelos biologicamente realistas, ou seja, modelos que simulam totalmente ou parcialmente o funcionamento do cérebro humano. Estes modelos possuem vantagens inerentes à sua própria natureza, que serão discutidas mais adiante.

Sistemas construídos com base nestes modelos são úteis principalmente no controle e simulação do comportamento, envolvendo soluções para o controle motor, percepção e tomada de decisão. A inclusão de componentes emocionais nestes sistemas abre espaço para trabalhos pioneiros, onde é possível a simulação de comportamentos emotivos humanos em autômatos, como confiança, medo e apatia, ou até mesmo comportamentos mais complexos, como interações sociais.

1.2 Objetivos

O objetivo geral deste trabalho de pesquisa é simular uma resposta de medo em um ambiente controlado que reproduz a movimentação de autômatos em um mundo virtual, desenvolvido por alunos do Programa de Pós-Graduação em Informática da UFRJ (PPGI), denominado doravante de Simulador Experimental, utilizando para isto um modelo computacional de condicionamento por medo proposto por ARAÚJO (2008), implementado no software Emergent, devidamente adaptado para as necessidades particulares deste estudo. Este modelo será chamado de Modelo de Condicionamento por Medo.

O trabalho pretende averiguar se é possível atingir uma maior eficiência em determinadas tarefas caso um robô possa experimentar uma resposta emocional de medo, de acordo com informações contextuais do ambiente onde ele se encontra. Parte-se da hipótese de que o medo tem um efeito de proteção, que vai valer tanto para o robô (o que representa menores custos por diminuir as perdas materiais) quanto para pessoas que em determinadas situações estejam próximas a ele.

Para isso, a saída indicativa de nível de medo para diversos valores de entrada do modelo, entradas estas representadas por informações de contexto do ambiente virtual do simulador experimental, será utilizada por um mecanismo de planejamento dos movimentos de um autômato específico, chamado de robô inteligente, auxiliando seu método utilizado na simulação de previsão de movimentos de outros autômatos (conceitos que serão explicados em detalhes mais adiante). Assim, pretende-se verificar se o uso do modelo de medo permitirá uma melhor tomada de decisão por parte de do robô inteligente na tarefa de atingir seu objetivo, em comparação com os seus métodos de planejamento utilizados atualmente.

1.3 Motivações

Há poucos estudos acerca do uso da Neurociência em Machine Learning, principalmente considerando o uso de modelos computacionais que simulam o funcionamento do cérebro, também conhecidos como modelos biologicamente realistas. Os que existem são relativamente bem recentes, e suas conclusões ainda não estão completamente sedimentadas. Tais trabalhos serão apresentados no capítulo 3. Sendo assim, esse trabalho explora esse campo no sentido de buscar novas descobertas ou mesmo corroborar conhecimentos de trabalhos anteriores.

No contexto da Neurociência, os modelos computacionais são eficientes por reduzirem um processo biologicamente complexo, como a cognição, em mecanismos que simulam componentes cerebrais. Baseado na afirmação de O'REYLLY e MUNAKATA (2000), de que as vantagens do uso de modelos se sobrepõem às suas desvantagens, este trabalho acopla um modelo biologicamente realista, que será apresentado mais adiante, ao simulador experimental. Espera-se, com isso, que as reações de medo do robô inteligente do simulador perante aos dados de contexto do ambiente sejam as mais próximas possíveis da reação apresentada pelo cérebro.

Um modelo biologicamente realista busca reproduzir as estruturas do cérebro, fidelizando-as em suas funções, tanto individualmente quanto no contexto geral do órgão como um todo. Seria perfeitamente possível construir uma rede neural tradicional para implementar uma solução para um problema de reconhecimento de padrões, porém tal rede não diria absolutamente nada (ou quase nada) sobre como o cérebro resolve esse problema. Utilizando um modelo biologicamente realista, é mais provável obter esta informação. Não obstante a afirmação de O'REYLLY e MUNAKATA, é importante discutir as vantagens e desvantagens do uso de modelos computacionais em Neurociência.

Entre as vantagens de se usar modelos, cabe citar:

- Complexidade: É possível lidar com vários níveis de complexidade, ajudando a compreender os argumentos e hipóteses criados intuitivamente a respeito do assunto que está sendo pesquisado. O modelo pode corroborar os argumentos ou até mesmo permitir novas descobertas.
- É explícito: um modelo geralmente se propõe ser o mais próximo quanto se deseja, em termos funcionais, do objeto que está sendo modelado. Sendo assim, explicita em detalhes o objeto de estudo e contribui para o entendimento do problema, forçando que se aceite as hipóteses corroboradas em torno deste.
- Controle: Em um modelo computacional, é possível controlar um bom número de variáveis. É possível alterar seus valores, seccionar o modelo de forma a desativar algumas das suas funcionalidades, e testar qual o efeito disto no resultado geral da simulação.

Por outro lado, podemos citar como desvantagens:

- Simplicidade demais: A simplicidade pode ajudar a entender o problema, mas pode ocultar e desconsiderar detalhes importantes a respeito da mecânica do processo que está sendo modelado, o que pode prejudicar a validade do modelo.
- Complexidade em excesso: Se um modelo é muito complexo, pode representar conceitos desnecessários ao entendimento do problema em questão. Isto pode provocar um comportamento indesejável e difícil de ser compreendido.

Capítulo 2

Neurociência das Emoções

Se fosse pedido a várias pessoas para que definissem o conceito de inteligência, surgiriam respostas de várias naturezas para este complexo conceito. Em todas elas, porém, percebe-se características tipicamente, ainda que não exclusivamente, humanas. Qualidades como capacidade de adaptação ao meio e aprendizado com experiências anteriores (NEISSER, *et al.*, 1998) podem ser observadas em vários seres vivos. Um conceito específico de inteligência, porém, pode ser especialmente atribuído aos animais, principalmente aos seres humanos.

O conceito de inteligência emocional pode ser definido como “... *capacidade de identificar os nossos sentimentos e os dos outros, de nos motivarmos e de gerenciar bem as emoções dentro de nós e nos nossos relacionamentos.*” (GOLEMAN, 1998). O estudo das emoções e seus desdobramentos aplicados ao Aprendizado de Máquinas (Machine Learning) é um dos pontos centrais deste trabalho.

2.1 Emoções x sentimentos

De acordo com FREITAS MAGALHÃES, A. (2007), a Emoção, numa definição geral, “*é um impulso neural que move um organismo para a ação. Ela se diferencia do sentimento porque é um estado neuropsicofisiológico.*” As Emoções são respostas neurológicas complexas a estímulos externos dos mais variados. São mais flexíveis e adaptáveis em mais circunstâncias imprevisíveis que os reflexos (FELLOUS & ARBIB, 2005), sendo estes apenas respostas diretas sem processamento do córtex pré-frontal. Possuem uma natureza adaptativa, sendo as respostas de medo as mais representativas nesse sentido. A fim de exemplificar esse conceito, proporciona-se a um rato uma situação de risco que lhe cause medo. Em função das

circunstâncias, ele irá apresentar uma resposta de fuga e fugir ou congelar e manter-se imóvel, dependendo de sua avaliação de qual opção de comportamento é mais vantajosa no momento. De acordo com Daniel Goleman, a respeito dos desafios enfrentados pelo indivíduo ao longo de sua existência, “à medida que, ao longo da evolução humana, situações desse tipo foram se repetindo, a importância do repertório emocional utilizado para garantir a sobrevivência da nossa espécie foi atestada pelo fato de esse repertório ter ficado gravado no sistema nervoso humano como inclinações inatas e automáticas do coração” (GOLEMAN, 2001). Sendo assim, muitas vezes, respostas emocionais podem significar a diferença entre a existência ou a extinção de uma espécie.

Os sentimentos são uma crítica da experiência consciente das emoções, o aspecto que nos faz tomar consciência do estado do próprio corpo, e muitas vezes o estado do corpo de outra pessoa (FELLOUS & ARBIB, 2005). A tristeza, a alegria, ciúme e simpatia são exemplos. Há muito mais do que sentimentos envolvidos quando uma pessoa experimenta uma emoção, mas sem sentimentos não é possível ter uma experiência emocional completa. Joe LeDoux chama as emoções que não envolvem sentimentos de “emoções básicas”, e Russell, em concordância com LeDoux, sugere que tais emoções podem ser melhor definidas como “guias”, uma vez que funcionam apenas como respostas inconscientes para estímulos externos, como as respostas viscerais (LEDoux, 2001). ANTÔNIO DEMASIO (1999) e JAAK PANKSEPP (1998) elaboraram em detalhes um ponto de vista a respeito do sentimento, criando a ideia de que indivíduo pode “sentir as emoções”. Essa ideia consiste em consultar o corpo e registrar a resposta sensorial obtida. É tanto a ação quanto a percepção. O sentimento funciona como a percepção consciente das emoções experimentadas pelo indivíduo.

A experiência sensorial consciente é uma habilidade cerebral de interação com o ambiente, a fim de obter informações sobre ele. Dentro do próprio cérebro, a experiência

sensorial consciente depende do envio de sinais das regiões de processamento de alto nível para regiões mais baixas para sondar ou reconstruir as representações sensoriais em níveis mais baixos (PASCUAL-LEONE & WALSH, 2001). Sentir as emoções, portanto, consiste em uma sondagem, uma pergunta, e uma entrada registrada em resposta a essa sonda (DAMÁSIO, 1999). Ao experimentar um sentimento de tristeza, por exemplo, não se toma conhecimento de alguma propriedade de uma representação mental de tristeza, mas sim das atividades distribuídas de perguntarmos como nos sentimos, e as informações que recebemos geram a consciência que nos sentimos tristes. Por outro lado, sentimentos conscientes não são necessários para produzir respostas emocionais. Assim como os processos cognitivos, as emoções envolvem mecanismos de processamento inconsciente. (ÖHMAN 1992; LEDOUX 1996; LEDOUX, 2000).

2.2 Robôs e Emoções

A ficção científica sempre relacionou robôs com emoções. Em “O Homem Bicentenário”, o ator principal interpreta um robô que reprograma seu software para que possa experimentar emoções e sentimentos humanos. Em “Eu, Robô”, há um robô coadjuvante que, numa clara demonstração de evolução adaptativa disparada por uma emoção (no caso, compaixão), toma atitudes que vão contra as instruções programadas em seu software interno. Em “O Exterminador do Futuro 3”, acontece algo semelhante. O estudo das emoções humanas para aplicação na robótica ganhou certa notoriedade na década passada, basicamente a partir de um paper de Rosalind Picard (PICARD, R., 1997), uma das origens do estudo na área da Computação Afetiva. As pesquisas de Picard foram essenciais para o desenvolvimento da área, que estuda a captação pelas máquinas dos estados emocionais humanos e sua adaptação aos comportamentos destes, exibindo uma resposta apropriada.

A computação afetiva envolve tecnologias de reconhecimento de características humanas, como tons de voz, gestos corpóreos e expressões faciais. Paralelamente à aplicação destas tecnologias, os conceitos de Machine Learning são altamente utilizados, uma vez que é constante a aquisição e recuperação de informações em bases de conhecimento, a respeito das percepções emocionais humanas por parte do autômato.

Com base nestes conceitos, robôs dotados de emoções simuladas e interações sociais são criados com o objetivo de entreter, servir ou até mesmo de serem utilizados no tratamento psicológico de humanos. Um exemplo é o humanóide¹ NAO², dotado da capacidade de reagir aos estímulos humanos através de respostas emotivas, como alegria, tristeza, apego e ojeriza. Ele tem sido desenvolvido para acompanhar o tratamento de crianças diabéticas em hospitais, e pode até reconhecer e “preferir” estar com uma pessoa que o trata melhor. O NAO foi desenvolvido para reagir emocionalmente como uma criança de dois anos.

2.3 Memória emocional e o Condicionamento por Medo

De acordo com o seu conteúdo, a classificação mais aceita até para os tipos de memória no cérebro foi proposta por EICHENBAUM (2002). Ele definiu três tipos principais: procedural, declarativa e emocional.

A memória procedural, também chamada de memória implícita, geralmente é armazenada e recuperada de forma inconsciente e por muitas vezes tem natureza reflexa. Ela inclui procedimentos motores, como andar de bicicleta ou dirigir, até mesmo andar de maneira ereta sobre as duas pernas. É uma memória de longa duração, uma vez adquirida, e geralmente não pode ser explicitada por palavras.

¹ Robô com características físicas de um humano, sem que o seja.

² ALDEBARAM ROBOTICS, 2010. **NAO for education** (<http://www.aldebaran-robotics.com/en/naoeducation>)

A memória declarativa é a que pode ser declarada por palavras. Nomes de pessoas e fatos ocorridos se encaixam nessa classificação. É possível contar a alguém sobre uma viagem realizada e os acontecimentos relacionados a ela, de maneira a formar uma imagem mental na cabeça dessa pessoa a respeito do fato, ainda que não tenha a mesma riqueza de detalhes de quem realizou a viagem. Ainda neste contexto, as memórias declarativas se dividem entre memórias episódicas, que são aquelas que definem um episódio específico, com referência temporal (como por exemplo, uma viagem realizada para uma dada região do país ou uma festa de 15 anos de uma prima próxima) e a memória semântica, que se referem a aspectos gerais e atemporais, sem data específica (lembrar que viagens mais longas geralmente são feitas por vias aéreas e não terrestres ou que festas de 15 anos tradicionalmente são comemoradas por pessoas do sexo feminino).

A distinção entre memória episódica e semântica foi identificada em pesquisas através de testes em pacientes epiléticos, que frequentemente se lembravam de eventos específicos, porém não evocavam em suas memórias fatos semânticos relacionados a estes eventos. Isto sugere a existência de sistemas separados de memória para organizar eventos com referência temporal em comparação àqueles sem data específica de ocorrência. (STERNBERG, 2000).

A memória emocional é o tipo de memória tratada nesta pesquisa. Para o correto entendimento das bases de funcionamento deste tipo de memória, é necessário conhecer e compreender as estruturas que participam do processamento das emoções no cérebro.

2.3.1 O sistema Límbico

A principal estrutura envolvida no processamento das emoções no cérebro é o sistema límbico, inicialmente conhecido como circuito de Papez (1937) e rebatizado com o novo nome por Paul MacLean (1949, 1952) após a adição de algumas novas regiões, notadamente a Amígdala (GAZZANIGA, 2006). As principais regiões do sistema límbico são hipotálamo, tálamo, amígdala e hipocampo. Estas regiões, entre outras, estão representadas na figura 1.




Figura 1 - Esquema cerebral representando o sistema límbico (ARAÚJO, 2008)

A estrutura diretamente responsável pela experiência emocional é a amígdala, atuando como um gatilho. Ela fornece as respostas fisiológicas e comportamentais aos estímulos provenientes do córtex e do tálamo, avaliando sua natureza emocional.

Já o hipocampo é a estrutura que participa ativamente no processo de condicionamento contextual, que será visto mais à frente.

2.3.2 Condicionamento por medo

As teorias de IVAN PAVLOV (1927) são um bom ponto de partida para o estudo da memória emocional. Elas descrevem o condicionamento clássico, que ocorre quando um estímulo neutro (EN) é apresentado em conjunto com um estímulo incondicionado (EI), criando uma associação entre eles. A partir de então, o EN fica condicionado ao EI que já era relevante por si só e passa a ser denominado estímulo condicionado (EC), produzindo as mesmas respostas que o EI produziria individualmente.

O condicionamento por medo, também conhecido como condicionamento aversivo, é uma especificação desse processo. Um clássico exemplo para o estudo do condicionamento por medo é o de ratos em uma gaiola. Inicialmente, um som específico (EN) é apresentado individualmente ao rato. Ainda que o animal se surpreenda um pouco com o acender e apagar da luz, em pouco tempo ele se habitua a essa situação. Posteriormente, o EN é apresentado em conjunto com um choque (EI), que invariavelmente dispara uma resposta de medo na amígdala, gerando um par som + choque. O som, antes um EN, passa a figurar como um EC. Após o condicionamento promovido pelo pareamento dos dois estímulos o som é apresentado ao rato e aquele, por si só, dispara respostas de medo na amígdala, gerando reações fisiológicas típicas viscerais típicas da apresentação do EI biologicamente significante de maneira isolada, anterior ao condicionamento.

Os conceitos a respeito do condicionamento por medo são ilustrados nas figuras 2 e 3.




Figura 2 – Condicionamento por medo em ratos (ARAUJO, 2008)




Figura 3 - Em A, a relação entre o estímulo condicionado (CS) à apresentação de um estímulo incondicionado (US), no tempo. Em B, após o condicionamento, a apresentação de um CS causa os mesmos efeitos viscerais do US isoladamente (LEDOUX, 2000).

A amígdala é diretamente responsável pelo condicionamento por medo. Lesões na amígdala geralmente não bloqueiam uma resposta incondicionada (RI) a um evento, como o choque que é aplicado ao rato, isoladamente. A resposta de medo a esse evento é natural, resultado de um processo instintivo do animal. Por outro lado, uma eventual lesão na estrutura prejudica a capacidade de adquirir uma resposta condicionada (RC) proveniente de EM associados a estímulos aversivos (GAZZANIGA, 2006).

2.4 Condicionamento do contexto

O condicionamento do contexto, como o próprio nome sugere, compreende o condicionamento de um EI a informações contextuais do ambiente onde se insere o indivíduo no momento da apresentação do EI.

Tais informações são compostas por estímulos alheios ao EC e ao EI, como por exemplo, a luminosidade e a temperatura do ambiente. No momento do condicionamento, o EC incorpora o contexto, ou seja, as respostas de medo provocadas pela posterior apresentação do EC sem um estímulo biologicamente significativo serão potencializadas pelo contexto.

Utilizando novamente o experimento de PAVLOV onde um rato foi posto em uma gaiola, já tendo sido condicionado ao EC, observa-se que o animal também fica condicionado à gaiola onde foi posto, pois o simples fato de o rato estar na gaiola já provoca nele reações típicas de medo. Na apresentação de um EC (um som, por exemplo), a gaiola onde o rato se encontra provocará nele tais reações em intensidade ainda maior.

No condicionamento do contexto, o hipocampo tem papel fundamental. É uma região importante para a consolidação da memória, inclusive as de natureza emocional. Em experimentos semelhantes aos de PAVLOV, os ratos apresentam respostas semelhantes em vários contextos diferentes, sendo sua resposta emocional um reflexo apenas da apresentação (ou ausência) do EC (GLUCK e MYERS, 2001, p. 190-191).

2.5 O Emergent

O *Emergent*³, antigo *PDP++*, é um ambiente de simulação, de código aberto, onde é possível criar modelos sofisticados do cérebro e de processos cognitivos usando modelos de

³Emergent Neural Network Simulation System (2010) (http://grey.colorado.edu/emergent/index.php/Main_Page)

redes neurais. Ele possui ferramentas para criação das redes neurais, controle de suas entradas e saídas, bem como análise do comportamento da rede e de seus dados gerados. Observe a interface do ambiente na figura 4.




Figura 4 – O ambiente do Emergent

O Emergent suporta uma considerável gama de algoritmos, incluindo o *Backpropagation* e o *LEABRA*, utilizado no escopo deste trabalho. É neste framework que foi desenvolvido o Modelo de condicionamento por medo, que será visto na próxima seção.

2.6 Modelagem Computacional do Condicionamento por Medo

Uma das bases para o trabalho que foi desenvolvido nesta dissertação é um modelo computacional que simula os circuitos envolvendo a aquisição da memória emocional (mais especificamente os circuitos que envolvem a amígdala e o hipocampo), utilizado como ferramenta para melhor compreensão dos conceitos de memória e emoção, e como eles se manifestam na dinâmica cerebral (ARAÚJO, 2008). O modelo computacional de

condicionamento por medo simula como funciona o medo no cérebro humano, incluindo a representação das estruturas envolvidas e de seu funcionamento esperado.

O modelo foi implementado utilizando a ferramenta *Emergent*, utilizando o algoritmo LEABRA (*Local, Error-driven and Associative, Biologically Realistic Algorithm*), desenvolvido por O'REILLY e MUNAKATA (2000). Em comparação com a maioria dos algoritmos que utilizam retroalimentação, o principal diferencial do LEABRA é se basear nos princípios do realismo biológico, Aprendizado Hebbiano⁴, competição inibitória e ativação bidirecional, além dos princípios de representações distribuídas e aprendizado orientado por erro já utilizados pelos demais (O'REILLY, 1998).

A figura 5 mostra a arquitetura final da rede utilizada na pesquisa.




Figura 5 – Arquitetura final da rede (ARAUJO, 2008)

⁴ Deriva da lei de Hebb, que diz, numa maneira geral, que a estimulação repetida em uma célula de um estímulo fraco e outro forte aumenta o poder da sinapse sobre aquela célula (GAZZANIGA, 2006). Especifica um mecanismo de plasticidade cerebral, onde o estímulo constante em uma ligação neuronal pode promover mudanças celulares duradouras e estáveis.

A saída do modelo, para diversas entradas, é um valor binário que indica se a rede retorna uma resposta de medo (valor de saída 1) ou não (valor de saída 0) para o conjunto de valores de entrada considerado. Este conjunto de valores de entrada representa as condições do contexto do ambiente no qual o indivíduo está inserido e eventuais estímulos apresentados a ele, auditivos e somestésicos.

Capítulo 3

Aprendizado de Máquinas

Este capítulo apresenta o conceito de aprendizado de Máquinas e um mecanismo de aprendizado bastante utilizado na área, as redes neurais. Por fim, são apresentados alguns trabalhos desenvolvidos utilizando Aprendizado de Máquinas e Neurociências, áreas de estudo que são os pilares desta dissertação.

3.1 Aprendizado

Segundo Piaget, um dos maiores estudiosos no desenvolvimento Cognitivo, o aprendizado é a construção do conhecimento através das interações externas ao indivíduo, através de estruturas já existentes (PIAGET, 1964). Tais interações externas podem ocorrer entre o indivíduo com objetos quaisquer, ou com o ambiente no qual ele se insere. Quando essa interação é acompanhada de reforços positivos (uma recompensa) e negativos (supressão de um fator desagradável) para atitudes corretas, ou castigos para comportamentos não desejados, o fenômeno do aprendizado se intensifica.

A memória possui papel essencial no aprendizado. É essencial que se possa armazenar o que aprendeu e criar um repositório de situações e conceitos, que serão utilizados futuramente. Assim, a memória representa a persistência do aprendizado em um estado que possa ser recuperado posteriormente (SQUIRE, 1987). A cada experiência, o indivíduo acessa na memória as experiências passadas e decide, por associação (para situações muito semelhantes) ou por generalização (para situações que mantém semelhança com a situação atual em um ou mais aspectos), qual a atitude mais adequada para o momento. No capítulo 2, foram apresentados os conceitos de memória emocional e aprendizado por condicionamento pelo contexto. O condicionamento é um bom exemplo de aprendizado assistido por reforços.

O Aprendizado de Máquinas é “a programação de computadores (isto é, criação de algoritmos) para otimizar um critério de performance utilizando dados de exemplo ou experiências passadas” (NILSSON, J. N., 1998). Como todo processo de aprendizado, compreende um “conjunto de processos difíceis de definir precisamente” (NILSSON, J. N., 1998), mas cujos resultados são essenciais no comportamento do indivíduo, ainda que este seja um autômato.

O objetivo principal de implementar o aprendizado em uma máquina é provê-la da capacidade de generalizar situações. Através da generalização, uma máquina pode apresentar uma resposta adequada inclusive para situações pelas quais nunca passou, desde que situações semelhantes tenham sido experimentadas. Há vários tipos de modelos de aprendizado computacionais para este fim em Machine Learning, como árvores de decisão, funções estatísticas e redes neurais (NILSSON, J. N., 1998). Todos estes se enquadram em dois métodos de aprendizado: o aprendizado supervisionado e o não-supervisionado. Tais conceitos serão apresentados adiante, focando no modelo computacional utilizado neste trabalho – as Redes Neurais – que implementam algoritmos que se enquadram nos dois métodos citados.

3.2 Redes Neurais Artificiais (RNA)

As RNA são estruturas computacionais criadas a partir de uma abstração a respeito do funcionamento do cérebro humano. Em sua essência, elas seguem os mesmos princípios de funcionamento do encéfalo, porém apresentam soluções com extrema rapidez ao abstrair detalhes do funcionamento do órgão biológico. Geralmente são utilizadas na resolução de problemas que envolvem reconhecimento de padrões, classificação de elementos em um conjunto finito e previsões de séries numéricas.

Uma Rede Neural é constituída de elementos chamados nós, que simulam neurônios humanos. Esses nós são interligados por conexões que assumem certos valores, chamados pesos, formando uma estrutura em forma de rede, como na figura 6:




Figura 6 – Rede com uma camada de entrada, uma camada de saída e uma camada oculta

A arquitetura de uma RNA pode assumir vários formatos, o que depende principalmente do objetivo da rede, ou seja, o tipo de problema ao qual ela se aplica. Por exemplo, para resolver problemas mais complexos, como os de natureza não-linear, é necessário utilizar uma rede de topologia multicamada, como a apresentada na figura 7:




Figura 7 – Rede com duas camadas ocultas

3.2.1 Aprendizado das RNA

O aprendizado da RNA é uma fase em que os pesos de suas conexões são ajustados através de um processo iterativo, no intuito de criar uma representação do problema em questão.

Há vários tipos de regras de aprendizado em redes neurais, que podem ser classificadas nos dois métodos de aprendizado já citados anteriormente.

3.2.1.1 Aprendizado não-supervisionado

Não há um “supervisor”, ou seja, não existe a apresentação de uma saída desejada, apenas de uma entrada. Não há cálculo de erro, nem tão pouco retroalimentação deste erro a fim de ajustar os pesos da rede e promover o aprendizado. No caso geral, a entrada x dada é aplicada a uma função $f(x)$, de forma a minimizar um custo C . A função de custo, onde se insere $f(x)$, pode ser complexa e depende essencialmente da aplicação.

Como não é apresentada uma saída desejada juntamente com a entrada, neste método de aprendizado não se conhece previamente a classe dos dados da entrada. Isso faz do aprendizado não-supervisionado, apesar de limitado, especialmente útil para treinamentos com uma grande massa de dados, como reconhecimento de voz, ou para classificação de elementos em um conjunto de dados de vários tipos, inicialmente desconhecidos.

3.2.1.2 Aprendizado supervisionado

No processo de aprendizado supervisionado, além do vetor de entrada, é apresentada à rede a saída desejada. Um erro é gerado a cada iteração, e uma função de minimização usa este erro e a saída dada para ajustar os pesos de cada conexão entre os nós da rede de modo que uma dada entrada produza a saída desejada.

O algoritmo mais utilizado no aprendizado supervisionado é a *regra do delta*, cujo ajuste dos pesos na rede é dado pela expressão:

$$w_i(t+1) = w_i(t) + \alpha (d(t) - y(t)) x_i(t)$$

Onde: t é o instante atual e $t+1$ o instante seguinte, $w_i(t+1)$ é o peso da conexão em $t+1$, $w_i(t)$ é o peso em t , $d(t)$ é a saída desejada em t , $y(t)$ é a saída obtida pela rede em t e α é a taxa de aprendizado.

O algoritmo de *Backpropagation*, uma generalização da regra do delta para uso em redes multicamadas, ajusta os pesos de acordo com a seguinte fórmula:

$$E = \frac{1}{2} \sum_{i=1}^k (d_i - y_i)^2$$

Onde: d_t é a saída desejada, y_t é a saída obtida pela rede, k é o número de neurônios na saída e E é o erro gerado.

3.3 Trabalhos anteriores

Uma extensa revisão na literatura revelou outros trabalhos na área de Machine Learning e Neurociências, mais especificamente no uso de Emoções com robôs. Esta seção mostra dois dos mais importantes encontrados. A proposta desta dissertação, porém, traz algumas diferenças importantes a considerar:

- Nenhuma das soluções encontradas usa como base modelos biologicamente realistas. Estes modelos trazem vantagens, já apresentadas no capítulo 1.
- O uso de uma rede neural permite generalização para situações ainda não conhecidas. Isto permite a utilização de um ambiente completamente dinâmico e imprevisível para o autômato.
- Por último, o uso de um modelo de condicionamento por contexto permite a inclusão das informações de contexto no ambiente.

3.3.1 Affective Cognitive Learning and Decision Making: The Role of Emotions

Este artigo, proposto por Picard em 2006, foi uma das inspirações para o modelo descrito neste trabalho.

O trabalho apresenta um novo framework cujo objetivo é sintetizar comportamentos tipicamente humanos, através da sua análise ao natural. Neste contexto, a aprendizagem e a tomada de decisão de um agente inteligente são influenciadas tanto por uma “recompensa externa ou extrínseca” (representada pelo objetivo final ou por menores custos de caminho) quanto por uma “recompensa interna ou intrínseca” dos múltiplos circuitos emocionais

(representada pelas suas saídas, como medo, fúria, alegria). A integração entre esses dois fatores pode colaborar para aumentar a eficácia da aprendizagem e da tomada de decisão.

3.3.2 Behavioral task processing for cognitive robots using artificial emotions

O artigo em questão apresenta uma arquitetura de controle de autômatos em um ambiente virtual, baseado em Cognição e Emoção. Um modelo matemático estocástico controla o processo de transição de estados emocionais (em um conjunto discreto e finito) do autômato no ambiente dinâmico em que ele está inserido.

O modelo utiliza um algoritmo de aprendizado por reforço, que atualiza a memória do autômato (seu espaço de regras). De acordo com as probabilidades de transição entre os estados emocionais, o autômato experimenta emoções artificiais que ditam seu comportamento e a sequência de ações que ele irá tomar a longo prazo na intenção de atingir seus objetivos, controlando sua velocidade e torque gerado pelos motores ligados às rodas do robô.

As figuras 8 e 9 ilustram a arquitetura do modelo e um exemplo de sua interface principal (DAGLARLI, 2009).




Figura 9 - Exemplo de tela do simulador

Capítulo 4

Solução Proposta

4.1 Introdução

A proposta núcleo deste trabalho é a de introduzir uma experiência de medo em um dos autômatos do simulador experimental, obtida da resposta de um modelo biologicamente realista do funcionamento da emoção de medo no cérebro, a partir de informações sobre o contexto do ambiente virtual no qual tal autômato está inserido. Utilizar um modelo com realismo biológico oferece vantagens em relação ao modelo atual do Simulador Experimental, uma vez que sua resposta de medo é a mais próxima possível da que o cérebro real forneceria nas mesmas condições. Tais vantagens serão vistas adiante.

Como já foi discutido anteriormente, o modelo de condicionamento criado no Emergent gera como resultado uma saída binária que indica se, para um dado conjunto de entradas de informações de contexto do ambiente virtual, a rede gerou uma resposta de medo ou não. Associando essa resposta da rede aos métodos de previsão e planejamento utilizados no Simulador experimental, pretende-se atingir uma maior eficiência na tarefa do autômato de percorrer o ambiente virtual de um ponto a outro, medida em termos adequados.

4.2 A antiga solução: O Simulador experimental e o raio de emergência

O Simulador Experimental é um sistema que simula um ambiente onde um robô, dotado de um detector e previsor de movimentos alheios, tenta alcançar um objetivo sem colidir com outro robô de movimento previamente determinado. Este sistema é constituído por um ambiente virtual representando uma sala de $m \times n$ pixels, limitado por paredes e não possuindo nenhum outro obstáculo além destas. A sala foi concebida com o eixo y sobre a

parede vertical orientado para baixo e com o eixo x sobre a parede horizontal orientado para a direita. Observe a figura 10.





Figura 10 - O ambiente virtual do Simulador Experimental

Esta sala é populada inicialmente por dois robôs. Um deles é denominado Robô Inteligente (RI), que representa o robô que tentará chegar de um ponto ao outro do ambiente, mais exatamente de um Ponto Inicial (PI) na parede esquerda, até um Ponto Objetivo (PO) na parede direita. Este robô é responsável por “perceber” o ambiente à sua volta, assim como o movimento variado (porém previamente programado) do outro tipo de autômato chamado Robô Burro (RB). Cada robô é representado por uma circunferência de diâmetro de 10 unidades de medida e se movimenta segundo o critério de velocidade variada descrita por um vetor bidimensional (figura 11) que indica a velocidade em cada eixo ortogonal. O intervalo de variação da velocidade em cada eixo fica entre -20 e 20 unidades de medida por ciclo de simulação.

**Figura 11**

O RI é capaz de captar e aprender detalhes sobre o movimento do RB, de forma que ele pode prever quais serão os próximos passos destes e planejar qual será o melhor conjunto de movimentos que formará um caminho para que ele possa chegar ao PO, partindo do PI, sem tocar no RB nem em parede alguma da sala virtual durante toda a simulação.

O modelo original do Simulador Experimental consiste em dois macro-elementos, que podem ser considerados como duas fases que ocorrem entre a partida do RI do PI e sua posterior chegada ao PO. Essas fases serão chamadas a partir de então de Previsão e Planejamento.

A Previsão é determinante no sucesso no Planejamento. Ela consiste de algoritmos que permitem ao RI prever quais serão os próximos movimentos do RB, possibilitando que aquele se antecipe ao movimento deste, evitando possíveis colisões através do Planejamento de suas ações.

Já o Planejamento de movimentos para o RI engloba dois métodos: o Planejamento de rota por busca informada e o planejamento pelo método do círculo. Ambos recebem o conjunto de pontos previstos como provável caminho para o RB dentro do ambiente e traçam uma rota que objetive ao RI atingir seu objetivo com colisões com nenhum outro robô.

4.2.1 O Raio de medo

O RI conta com um fator de proteção contra eventuais colisões com outros RB no ambiente, chamado “raio de medo”. Este valor, configurado no início da simulação e estático durante todo o processo, determina um valor mínimo de distância que o RI deve manter no cálculo do planejamento da sua rota. Embora o planejamento leve em consideração o valor do raio de medo, aquele não se altera durante todo o caminho do RI entre o PI e o PO. O ambiente e suas condições atuais não influenciam na decisão do RI sobre que caminho seguir, apenas a posição do RB.

É importante notar que a implementação original do raio de medo não reflete nada sobre a maneira como o cérebro real processa a emoção de medo. É apenas um valor artificial utilizado pelo RI, a fim de definir o quanto ele irá desviar do RB no cálculo da rota a seguir a caminho do PO.

4.2.2 O Modo de Emergência

Complementando a proteção contra colisões do RI com o RB, o simulador experimental traz o Modo de Emergência. Essa proteção também não é dinâmica, ou seja, não leva em consideração as condições do ambiente onde o RI se encontra. O modo de emergência é um recurso utilizado em último caso, no momento em que o planejamento não foi suficiente para manter o RI longe do RB durante todo o seu percurso. Este recurso é disparado quando a distância entre o RI e o RB é menor do que a metade do valor do raio de medo acrescido de 20 unidades, ou simplificarmente:


$$d(R_i, R_b) < (r/2) + 20$$

Onde: $d(R_i, R_b)$ é a distância entre o RI e o RB e r é o valor definido para o raio de medo.

Este recurso é desligado no momento em que a condição acima deixa de ser verdadeira. Porém, uma vez utilizado, o planejamento de rota traçado anteriormente pelo RI é abandonado, de forma que não será garantido que ele levará o RI até o seu PO almejado primariamente.

4.2.3 Interface do simulador experimental

A seguir, uma tela da interface principal do Simulador Experimental, com uma breve explicação de seus principais componentes.



- Choose a dumb robot: Permite a escolha do tipo de movimento do robô burro que irá se movimentar pelo ambiente virtual. É possível escolher entre “Line” (movimento em linha reta), Wave (em forma de onda), Square (em forma de quadrado), Eight (em forma de 8), Random (movimentos completamente aleatórios) e follower (o RB segue o RI).

- IR fear radius: Define estaticamente o valor do raio de medo para o RI. O valor padrão da ferramenta é de 40 unidades. Esse valor será o mesmo durante toda a simulação.
- IR Arrival's point (PO): Define o ponto de chegada do RI no ambiente, representado pelo círculo azul escuro identificado como "Goal".
- DR Start Position (DRSP): Define o ponto de partida do RB, identificado na tela de exemplo como o círculo branco.
- Planning Type: Permite definir o tipo de Planejamento a ser utilizado na simulação.
- Prevision: Define o tipo de previsão que o RI irá utilizar para prever os movimentos do RB.

4.3 Funcionamento do modelo proposto

Um novo método de Planejamento para o Simulador Experimental foi criado, sendo adicionada uma nova opção entre as disponíveis: "Emergent". Internamente, o planejamento primário dos movimentos do RB é feito pelo método de busca informada, o método padrão da versão original do simulador. Uma nova e importante informação, porém, irá auxiliar o RI na sua tomada de decisão, ao influenciar no resultado gerado pelo seu algoritmo de Planejamento: o medo. Basicamente, a informação de medo (ou ausência dele) irá alterar o resultado do Planejamento ao alterar, em tempo real, o raio de medo do RI.

O Simulador experimental sofreu certas alterações para se adequar ao novo modelo proposto. A nova interface do simulador está representada na figura 12:




Figura 12 – Interface da proposta do novo simulador experimental

Pode-se observar novos elementos na interface. Há um agrupamento de três caixas de seleção chamado “Environment”, cujas opções representam as informações do ambiente que são repassadas ao RI. Todas essas informações foram convenientemente associadas às informações que o modelo do Emergent já aceita como entrada, que são som, choque (ou estímulo somestésico) e informação espacial. São elas:

- Light: indica se a luz do ambiente virtual está ligada (Yes) ou desligada (No). Essa informação representa um estímulo biologicamente significante, ou seja, o RI naturalmente apresenta uma reação típica de medo ao experimentar a escuridão. Essa opção apresenta efeito análogo ao choque aplicado em ratos de laboratório nos experimentos de Pavlov (capítulo 2), portanto é utilizada associada com a informação de choque do modelo. Utilizou-se a informação de luz apenas para melhor didática, já que não faria sentido um autômato temer um choque elétrico.

- Floor: Representa a cor do piso do ambiente virtual, que pode ser vermelha (Red) ou cinza (Gray). Esta é uma informação de contexto, análoga à informação captada pelo córtex etorrinal do modelo do Emergent.
- Sound: Indica se é apresentado um som (um tom específico) ou não ao RI no ambiente virtual. Esta também é uma informação de contexto análoga ao tom sonoro apresentado ao modelo computacional de condicionamento do medo.

4.3.1 Replanejamento

A cada vez que há uma mudança nas informações de ambiente do simulador (opções da seção “Environment”), as informações que representam a atual condição de contexto que o ambiente proporciona ao RI em tal momento são coletadas pelo simulador e disponibilizadas como entrada para a rede neural do Emergent. A rede então retornará um valor indicando se em determinada condição o RI deve ou não “sentir medo”.

Se a rede retornar uma saída de medo, o planejamento de rota do RI é recalculado, baseando-se num raio de medo maior, aumentado de 10 para 60 unidades. O cálculo desse valor foi baseado no fato de representar um aumento significativo do raio de medo, de forma que através de poucos testes, conclui-se que um aumento maior não traria ganhos extras, e ainda aumentaria desnecessariamente a distância total percorrida. Caso contrário, o planejamento de mantém com o raio de medo padrão inalterado, ainda que isso aumente o risco de uma eventual colisão. Todo o processo é feito em tempo de execução do simulador, ou seja, com o RI em movimento, após o seu Planejamento inicial.




Figura 13 - Comportamento do RI com a luz acesa (raio de medo inalterado)




Figura 14 - Comportamento do RI com a luz apagada (raio de medo acrescido para 60 unidades)

4.3.2 Aprendizado

A cada vez que há uma colisão entre o RI e o RB, o simulador detecta as condições do ambiente em que houve a colisão e inclui nas tabelas do modelo de medo a informação de medo para aquelas condições, treinando novamente a rede. Se em determinadas condições de contexto do ambiente o RI não sentia medo até então, ele passará a sentir a partir das próximas rodadas do simulador.

O sistema de aprendizado implementa um mecanismo de trauma para o RI. A informação de contexto em que o RI estava no momento em que houve a colisão é persistente,

ou seja, perdura para as próximas rodadas do Simulador experimental. Com o tempo e o número de colisões, o RI aumenta sua base de dados com situações potencialmente perigosas.

4.4 Vantagens a verificar

Como já foi citado anteriormente, o simulador experimental faz uso do modo de emergência quando o planejamento traça um percurso que coloca o RI em uma situação perigosa, ou seja, suficientemente próximo ao RB. Porém esse recurso falha uma vez que, quando ativado, ignora o planejamento e não garante que o RI atinja seu objetivo. Além disso, em uma situação com autômatos reais, perfeitamente possível em uma implementação embarcada do simulador experimental, outras variáveis estarão presentes. O motor de passo presentes nos autômatos físicos pode exibir um atraso de resposta considerável em mudanças de trajetória, algo inaceitável em uma situação emergencial.

O fato de existir uma base de dados prévia sobre situações que geralmente representam perigo permite uma análise prévia da situação, em nível de planejamento, buscando melhorar o desempenho do RI em relação ao obtido através do modo de emergência.

A proposta deste trabalho altera o raio de medo em tempo de execução, dinamizando-o. A natureza estática deste valor na atual implementação do simulador experimental causa um comportamento que peca na eficiência. Um valor baixo para o raio de medo pode não evitar de maneira satisfatória uma colisão. Um valor alto pode aumentar consideravelmente a distância percorrida e aumentar desnecessariamente os custos do trajeto, ainda que tais custos não sejam considerados neste trabalho.

Capítulo 5

Experimentos

Este capítulo descreve os experimentos realizados durante esta pesquisa, incluindo sob que condições estes experimentos foram realizados, a metodologia adotada e os casos de testes com seus resultados.

Todos os experimentos descritos nas próximas seções foram realizados sob as seguintes condições:

- A versão do *Emergent* utilizada foi a versão para Windows 4.0.15. Ela pode ser obtida no seguinte endereço: <[ftp://grey.colorado.edu/pub/emergent/emergent-4.0.15-win32.exe](http://grey.colorado.edu/pub/emergent/emergent-4.0.15-win32.exe)>
- O sistema operacional utilizado foi o Windows 7 Home Premium em português de 64-bit, rodando em um processador Intel(R) Core(TM)2 Duo P7550 2.26GHz, 4,00GB de memória RAM e com uma placa de vídeo Intel 4 Series Express.
- É necessário a versão mais recente do JRE (Java Runtime Environment) instalado para executar o simulador experimental. O JRE pode ser obtido no endereço <<http://www.oracle.com/technetwork/java/javase/downloads/index.html>>

Acreditamos que, para testes e comparações futuras, principalmente referentes ao tempo de treinamento, estas informações devam ser consideradas.

5.1 Metodologia


Os testes procuram coletar os resultados de desempenho do RI, para determinados tipos de movimentos do RB, na métrica “número de colisões” em cada bateria de testes. Uma bateria de testes é composta de duas tuplas de valores para chegada do RI (Ponto objetivo - PO) e de saída do RB (Dumb Robot Starting Point - DRSP) e um conjunto de combinações de situações de contexto para o ambiente. O RI sempre parte do mesmo ponto (o valor de PI – ponto inicial do RI – não varia).

As duas tuplas de valores para PO e DRSP escolhidas, em suas coordenadas X e Y, foram ilustradas e justificadas a seguir:

Caso 1:

PO: X = 500, Y = 220


DRSP: X = 700, Y = 100



Caso 2:

PO: X = 500, Y = 180

DRSP: X = 700, Y = 150



Basicamente, as duas tuplas de posições se diferenciam pela distância vertical entre os pontos PO e DRSP. Parece razoável imaginar que, quanto mais perto do PO for o ponto em que o RB parte, maior as chances de ele interceptar a trajetória do RI, dificultando a tarefa deste de não colidir com ele. Assim, o caso 2 configura uma situação onde a colisão é mais provável, enquanto no caso 1 essa probabilidade é menor. Os testes verificarão isso.

Apenas para recapitular, as informações do ambiente percebidas pelo RI são a luz, que pode ser estar ligada (1) ou desligada (0), um tom sonoro, que pode ser apresentado (1) ou não (0) e a cor do piso do ambiente, que será vermelho (v) ou cinza (c). Para facilitar a compreensão, a lógica que representa a luz foi invertida. Sendo assim, convencionou-se que o RI experimentaria uma escuridão (1) ou ausência desta escuridão (0), já que é este estímulo que eventualmente causa medo ao RI, e não a luz em si.

O conjunto de situações para o ambiente virtual está descrito a seguir:

- som0_esc0_pisoc – Sem som, sem escuridão, piso cinza.
- som0_esc1_pisoc – Sem som, com escuridão, piso cinza.
- som1_esc1_pisov – Com som, com escuridão, piso vermelho.
- som1_esc0_pisoc – Com som, sem escuridão, piso cinza
- som1_esc0_pisov – Com som, sem escuridão, piso vermelho

- som0_esc0_pisov – Sem som, sem escuridão, piso vermelho

As duas primeiras representam duas situações em que não importa o contexto, ou seja, testam se o RI experimenta medo somente caso a luz seja apagada. A terceira testa a reação do RI diante da presença de um tom sonoro e o piso vermelho, diante da escuridão. As duas seguintes testam o condicionamento do RI às condições do contexto, em dois pisos diferentes: piso cinza e piso vermelho. A última, finalmente, testa a influência do contexto do piso, isoladamente, no medo do RI.

Uma vez que o ambiente do simulador experimental é de natureza predominantemente determinística (apresenta a mesma saída e resultados em rodadas diferentes, para um mesmo conjunto de valores de entrada), conclui-se que não se faz necessário repetir várias vezes as baterias de teste para uma mesma entrada.

Os tipos de movimento escolhidos foram o “Line”, “Eight” e “Follower”. Esses movimentos foram escolhidos devido à sua natureza, de complexidade crescente. O movimento “Line” é o mais simples, enquanto o movimento “Eight” é significativamente mais complexo e rápido. O movimento “Follower”, por sua vez, revela-se mais imprevisível para o RI, o que torna o planejamento tradicional menos eficiente. Os outros movimentos têm natureza semelhante e considerou-se desnecessário realizar os testes para eles.

Ao final, os dados são analisados em termos de obtenção de sucesso (se houve ou não colisão), por resposta da rede do modelo computacional (se o RI experimentou ou não medo), por tempo de simulação e por distância total até o PO.

5.2 Treinamento da rede do modelo de condicionamento do medo

A rede do modelo computacional de condicionamento do medo possui dois programas para treinamento, chamados de “Ambientação” e “Condicionamento”. O primeiro treina a

rede apresentando somente exemplos que não refletem um condicionamento por contexto, ou seja, não associam o estímulo biologicamente significativo (a luz apagada) a qualquer outro estímulo de contexto do ambiente. Já no segundo programa, a rede é treinada utilizando dados de contexto detectados pelo RI, provenientes do ambiente em que o ele se encontra.

Ao iniciar o simulador pela primeira vez, a rede é treinada com o programa de Ambientação, com os dados primários presentes na tabela. Seus pesos são ajustados baseados em exemplos que traduzem somente situações em que não há condicionamento por contexto. Mais especificamente, até este momento, o RI nunca se deparou com uma situação em que devesse experimentar uma emoção de medo sob um determinado contexto, ou seja, suas experiências de medo ainda não estão condicionadas a uma dada situação do ambiente. Sendo assim, espera-se que o RI sinta medo somente nas situações em que o estímulo biologicamente significativo (a luz apagada) seja apresentado a ele. Fazendo uma analogia com o cérebro animal, este estágio representa um cérebro que possui somente as conexões básicas necessárias à sobrevivência instintiva do indivíduo.




Figura 15 - Inicialização dos pesos da rede, no início do treinamento




Figura 16 - Rede logo após o treinamento inicial

5.3 Testes preliminares

Os testes preliminares foram realizados logo após o treinamento inicial da rede do modelo computacional, ou seja, ainda sem nenhuma informação de condicionamento por contexto. As tabelas a seguir mostram os resultados para este caso.

As situações marcadas com um asterisco (*) indicam os casos em que a ocorrência da colisão disparou o sistema de aprendizado do RI. Espera-se que estes casos apresentem um melhor desempenho em rodadas seguintes.

Como nessa etapa a rede ainda não possui informação de contexto, apenas o programa para treinamento da fase de ambientação foi executado.

Tabela 1 - Testes preliminares, Caso 1, Movimento Line

Movimento “Line”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
som0_esc0_pisoc	Não	Não	43,70	513,99	-
som0_esc1_pisoc	Não	Sim	45,50	513,99	-
som1_esc1_pisov	Não	Sim	44,00	513,99	-
som1_esc0_pisoc	Não	Não	44,30	513,99	-
som1_esc0_pisov	Não	Não	46,40	513,99	-
som0_esc0_pisov	Não	Não	45,10	513,99	-
Total			-		100

Tabela 2 - Testes preliminares, Caso 1, Movimento Eight

Movimento “Eight”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
som0_esc0_pisoc	Não	Não	44,30	513,99	-
som0_esc1_pisoc	Não	Sim	45,10	513,99	-
som1_esc1_pisov	Não	Sim	46,05	513,99	-
som1_esc0_pisoc	Não	Não	42,90	513,99	-
som1_esc0_pisov	Não	Não	43,80	513,99	-
som0_esc0_pisov	Não	Não	45,50	513,99	-
Total			-		100

Tabela 3 - Testes preliminares, Caso 1, Movimento Follower

Movimento “Follower”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
*som0_esc0_pisoc	Sim	Não	76,29	522,27	-
som0_esc1_pisoc	Não	Sim	36,90	513,99	-
som1_esc1_pisov	Não	Sim	37,50	513,99	-
*som1_esc0_pisoc	Sim	Não	31,10	522,27	-
*som1_esc0_pisov	Sim	Não	40,10	522,27	-
*som0_esc0_pisov	Sim	Não	37,70	522,27	-
Total			-		33,33

Tabela 4 - Resumo, Testes preliminares, Caso 1

Resumo					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
Total	22,22%	33,33%	-	-	77,77%

No caso 1, para os dois primeiros movimentos, o RI apresentou um bom desempenho. Isso se deve ao fato de que nos dois casos o RB executou movimentos regulares, e de trajeto distante do RI e seu PO. Já no movimento Follower, o cenário foi substancialmente diferente. Ainda assim, nos casos em que experimentou medo diante de mudanças de situações de contexto, o RI conseguiu desviar do RB, aumentando o raio de medo acima do valor padrão. Para as outras situações, houve colisão.

Tabela 5 - Testes preliminares, Caso 2, Movimento Line

Movimento “Line”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
som0_esc0_pisoc	Não	Não	43,60	505,71	-
som0_esc1_pisoc	Não	Sim	43,20	522,27	-
som1_esc1_pisov	Não	Sim	42,40	522,27	-
som1_esc0_pisoc	Não	Não	43,20	505,71	-
som1_esc0_pisov	Não	Não	44,20	505,71	-
som0_esc0_pisov	Não	Não	45,10	505,71	-
Total			-		100

Tabela 6 - Testes preliminares, Caso 2, Movimento Eight

Movimento “Eight”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
*som0_esc0_pisoc	Sim	Não	72,50	509,85	-
som0_esc1_pisoc	Não	Sim	42,10	551,27	-
som1_esc1_pisov	Não	Sim	45,10	551,27	-
*som1_esc0_pisoc	Sim	Não	40,40	509,85	-
*som1_esc0_pisov	Sim	Não	45,60	509,85	-
*som0_esc0_pisov	Sim	Não	44,20	509,85	-
Total			-		33,33

Tabela 7 - Testes preliminares, Caso 2, Movimento Follower

Movimento “Follower”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
*som0_esc0_pisoc	Sim	Não	86,69	505,71	-
som0_esc1_pisoc	Não	Sim	38,90	522,27	-
som1_esc1_pisov	Não	Sim	38,30	522,27	-
*som1_esc0_pisoc	Sim	Não	37,10	505,71	-
*som1_esc0_pisov	Sim	Não	43,90	505,71	-
*som0_esc0_pisov	Sim	Não	43,00	505,71	-
Total			-		33,33

Tabela 8 - Resumo, Testes preliminares, Caso 2

Resumo					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
Total	44,44%	33,33%	-	-	55,55%

Assim como no Caso 1, o teste para o RB de movimento do tipo Line apresentou bons resultados. A maior proximidade do PO com o DRSP, porém causou problemas para o RI com o RB de movimento do tipo Eight. Mais uma vez, o contexto do ambiente determinou a

ocorrência de uma colisão. Diante das situações em que o RI experimentou medo, o planejamento foi recalculado com um maior raio de medo, e a colisão não ocorreu.

5.4 Aprendizado

A cada colisão, as informações de contexto do ambiente referentes ao momento da colisão são coletadas, incluídas como novo exemplo na rede do modelo computacional, que posteriormente sofreu um novo treinamento, desta vez utilizando o programa de treinamento de Condicionamento, combinado com o de Ambientação. Esperou-se que, com isso, a rede do modelo computacional de condicionamento do medo passasse a apresentar uma resposta de medo para situações semelhantes de contexto. Após os testes preliminares, novas rodadas foram realizadas para os casos em que houve colisão do RI com o RB sob tais contextos. Avaliou-se, então, se o RI passou a experimentar medo em novas rodadas diante das mesmas condições, se houve uma melhoria de desempenho em relação ao teste anterior e qual foi o nível desta melhoria. Os resultados estão apresentados a seguir.

Tabela 9 - Após Aprendizado, Caso 1, Movimento Follower

Movimento “Follower”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
som0_esc0_pisoc	Não	Sim	41,90	513,99	-
som0_esc1_pisoc	Não	Sim	36,90	513,99	-
som1_esc1_pisov	Não	Sim	37,50	513,99	-
som1_esc0_pisoc	Não	Sim	37,30	513,99	-
som1_esc0_pisov	Não	Sim	37,40	513,99	-
som0_esc0_pisov	Não	Sim	37,80	513,99	-
Total			-		100

Tabela 10 - Resumo, Após Aprendizado, Caso 1

Resumo					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
Total	0%	55,55%	-	-	100%

Como se nota através dos resultados da tabela acima, o mecanismo de aprendizado evitou em 100% dos casos uma nova colisão, para o único tipo de movimento onde ela ocorria, no caso 1.

Tabela 11 - Após Aprendizado, Caso 2, Movimento Eight

Movimento “Eight”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
som0_esc0_pisoc	Não	Sim	40,40	551,27	-
som0_esc1_pisoc	Não	Sim	42,10	551,27	-
som1_esc1_pisov	Não	Sim	45,10	551,27	-
som1_esc0_pisoc	Não	Sim	43,10	551,27	-
som1_esc0_pisov	Não	Sim	45,40	551,27	-
som0_esc0_pisov	Não	Sim	44,80	551,27	-
Total			-		100

Tabela 12 - Após Aprendizado, Caso 2, Movimento Follower

Movimento “Follower”					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
som0_esc0_pisoc	Não	Sim	37,10	522,27	-
som0_esc1_pisoc	Não	Sim	38,90	522,27	-
som1_esc1_pisov	Não	Sim	38,30	522,27	-
som1_esc0_pisoc	Não	Sim	38,30	522,27	-
som1_esc0_pisov	Não	Sim	38,10	522,27	-
som0_esc0_pisov	Não	Sim	39,20	522,27	-
Total			-		100

Tabela 13 - Resumo, Após Aprendizado, Caso 2

Resumo					
	Colidiu com RB	Apresentou medo	Duração (em segundos)	Distância ao PO (em pontos)	(%) de chegadas
Total	0%	77,77%	-	-	100%

Mais uma vez, o aprendizado evitou que o RI se chocasse com o RB ao experimentar novamente as mesmas situações de contexto do ambiente.

5.5 Modo de Emergência

Para efeitos de comparação com a antiga solução do simulador experimental, alguns testes foram repetidos com o modo de emergência ligado, porém sem o auxílio do modelo computacional de condicionamento do medo. Nesta situação, o RI não leva em consideração as informações contextuais, e não experimenta medo. Por este motivo, não faria sentido testar o desempenho do RI para as várias situações definidas anteriormente, uma vez que, neste caso, estas não importam para o planejamento do RI.

O modo de emergência abandona o planejamento do RI, em uma tentativa de evitar a colisão com o RB, ainda que isto signifique não atingir o PO.

Tabela 14 - Modo de Emergência, Caso 1, Movimento Line

Movimento “Line”					
	Colidiu com RB	Ativou modo de emergência	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
-	Não	Não	44,90	513,99	-
Total			-		100

Tabela 15 - Modo de Emergência, Caso 1, Movimento Eight

Movimento “Eight”					
	Colidiu com RB	Ativou modo de emergência	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
-	Não	Não	44,80	513,99	-
Total			-		100

Tabela 16 - Modo de Emergência, Caso 1, Movimento Follower

Movimento “Follower”					
	Colidiu com RB	Ativou modo de emergência	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
-	Não	Sim	42,40	505,71	-
Total			-		0

Para os movimentos Line e Eight, o RI atingiu um bom desempenho utilizando o modo de Emergência. Cabe ressaltar que o modo de Emergência não foi ativado, pois o movimento do RB para estes dois casos é bastante regular. A trajetória do RB passou longe do caminho do RI, o objetivo foi atingido. Já no caso do movimento Follower, o RI ativou o modo de emergência, não colidiu com o RB, porém abandonou o planejamento e não conseguiu atingir o PO.

Tabela 17 - Modo de Emergência, Caso 2, Movimento Line

Movimento “Line”					
	Colidiu com RB	Ativou modo de emergência	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
-	Não	Sim	(Não atingiu o PO)	-	-
Total			-		0

Tabela 18 - Modo de Emergência, Caso 2, Movimento Eight

Movimento “Eight”					
	Colidiu com RB	Ativou modo de emergência	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
-	Sim	Sim	43,00	501,56	-
Total			-		0

Tabela 19 - Modo de Emergência, Caso 2, Movimento Follower

Movimento “Follower”					
	Colidiu com RB	Ativou modo de emergência	Duração (em segundos)	Distância percorrida (em pontos)	(%) de chegadas
-	Sim	Sim	42,40	505,71	-
Total			-		0

No caso 2, em que o ponto que o RB parte e o PO estão bem próximos, o RI não atingiu um bom desempenho para nenhum dos três tipos de movimentos. Embora o modo de Emergência tenha sido ativado pelo RI para os três casos, houve uma colisão com o RB para os tipos de movimento Eight e Follower. No modo de movimento do tipo Eight, foi possível evitar a colisão reduzindo artificialmente o valor “Y Peak” de 20 unidades (o padrão) para 10 unidades, de modo que o caminho do RB apenas tangenciasse o trajeto do RI.

5.6 Análise dos resultados

Os testes mostraram um padrão em que a versão original do simulador experimental mais apresenta falhas. Esse padrão é definido por duas variáveis: a complexidade do movimento do RB e a proximidade entre o PO e o DRSP (ponto de partida do RB). Por complexidade de movimento do RB, entende-se o quão fiel pode ser o resultado do

planejamento dos movimentos deste. Se o RB segue um padrão bem definido de movimento, regular e periódico, mais precisa será a previsão de seus movimentos.

Para o caso de movimentos aleatórios e imprevisíveis, a nova proposta do simulador experimental descrita neste trabalho apresentou resultados animadores. Em alguns casos, uma mudança de contexto que causasse medo no RI, por si só, já evitou uma colisão. A taxa de colisões caiu significativamente, porém, com o aprendizado. Indicar ao RI que ele deve experimentar medo em situações contextuais em que ele passou por uma colisão, evitou uma colisão nas rodadas subsequentes em todos os casos testados.

O aumento do raio de medo levou, na maioria dos casos testados, a um aumento na distância necessária para chegar ao PO. Isso se compensou, porém, com um planejamento de uma rota mais segura, em que o risco de uma eventual colisão foi reduzido, ou até mesmo eliminado.

Vale lembrar que os testes foram realizados em condições que representassem bem a contribuição da nova proposta. Foram demonstradas situações em que o RI tinha um desempenho inadequado, e o uso do novo modelo possibilitou inverter este quadro. Como já foi dito, o desempenho do RI dentro do ambiente é sensível ao PO, ao DRSP e às situações de contexto. Essas variáveis não são controladas pelo RI. Tanto no mundo real quanto no simulador experimental, o RI não conhece de antemão o ambiente onde ele foi inserido. Apenas possui sensores capazes de observar o movimento do RB e detectar as condições contextuais do que está à sua volta. Sob outras condições diferentes das apresentadas neste trabalho, o modelo pode ter um desempenho mais fraco, ou ainda melhor do que o demonstrado aqui. Parece razoável supor que o desempenho não piora com a nova proposta, em nenhuma situação, uma vez que caso o modelo não forneça uma saída de medo para o RI em determinada situação de contexto, o autômato se comporta exatamente como na versão original do simulador experimental.

Capítulo 6

Conclusões

A proposta inicial deste trabalho de pesquisa era somente o de acoplar o modelo biologicamente realista ao simulador experimental, com o objetivo de ampliar e aprimorar a experiência do robô inteligente na tarefa de cruzar o ambiente virtual, rumo ao ponto objetivo, sem colidir com nenhum robô burro durante o trajeto. Por si só, a ideia já era razoavelmente interessante: utilizar um modelo de medo real de medo, que possibilitasse uma resposta emocional nos mesmos moldes do cérebro biológico ao condicionamento de medo por contexto. O RI do simulador experimental passaria a reagir às mudanças à sua volta, possibilitando o uso de um ambiente dinâmico, geralmente o que ocorre na maioria das situações reais. Antes disso, o simulador experimental possuía apenas um modo de emergência, que abandonava o planejamento elaborado pelo RI em prol de uma última tentativa de evitar uma colisão iminente, utilizando para isso um raio de segurança chamado de raio de medo.

Em determinado ponto do desenvolvimento da dissertação, nos deparamos com a seguinte pergunta: uma vez que o ambiente é determinístico, ou seja, para os mesmos dados de entrada (situação de contexto, posição inicial do RB e ponto objetivo do RI), a resposta do RI e seu caminho a percorrer serão os mesmos, o que acontecerá se o planejamento do RI falhar, em determinadas condições de contexto, e houver uma colisão porque o modelo não retornou uma resposta e medo? Não seria interessante que o RI pudesse sentir medo na próxima vez que se encontrasse em uma situação semelhante, tanto em termos de estímulos condicionados (o som) quanto em termos de informações de contexto? Assim surgiu a ideia de desenvolver o sistema de aprendizado do RI.

O aprendizado proporcionou que o robô adquirisse uma “memória” entre as rodadas, de forma que seu desempenho melhorasse continuamente com o passar destas, através da informação de medo para as situações que ofereceram algum risco efetivo em rodadas anteriores. Os testes demonstraram situações em que o aprendizado foi determinante para o sucesso do RI durante a simulação.

A reação às condições do ambiente permitiu o uso de outros sensores em eventuais autômatos que venham a utilizar o simulador experimental de maneira embarcada, ampliando as possibilidades de uso do simulador experimental.

6.1 Trabalhos futuros

O assunto desenvolvido nesta dissertação abriu a possibilidade de desenvolvimento de trabalhos futuros em ambas as frentes: Tanto o simulador experimental quanto o modelo de condicionamento por medo. Já que ambos os sistemas foram combinados, alterações em cada um deles contribuem de maneira significativa para o conjunto.

6.1.1 Múltiplos RB's

O Simulador experimental pode ser adaptado para que o RI perceba múltiplos RB's no ambiente virtual.

A sugestão é a de que o RI avalie o movimento de cada RB separadamente, e o caminho traçado no planejamento seja eficiente o suficiente para que não haja colisão com nenhum dos RB. Caso haja alguma colisão, o mecanismo de aprendizado é disparado para incluir as informações de contexto atuais nas situações consideradas pelo Modelo computacional.

Há duas abordagens possíveis nesse caso. O planejamento pode ser realizado considerando a previsão de movimentos para todos os RB's simultaneamente, ou pode ser processado por prioridade. No primeiro caso, o planejamento só seria alterado em tempo de

execução caso houvesse alguma alteração no contexto do ambiente virtual. Já no segundo, ele seria feito somente para um RB de cada vez, mais especificamente o RB mais próximo. Seria interessante confrontar as duas opções em testes, visando indicar a mais proveitosa na maioria das situações.

6.1.2 Extinção de memória

Segundo Izquierdo (2002), é muito difícil desfazer naturalmente um EC após a sua construção, o que explica parcialmente o mecanismo do trauma. Porém, é possível atingir este objetivo com a apresentação repetida de um estímulo contrário ao que causou o EC, fato este conhecido como Extinção de Memória. Imagine que uma pessoa é assaltada em uma praça. Nas idas posteriores a essa praça, essa pessoa experimentará medo ainda que nenhum assaltante se encontre nela. Com o passar do tempo, esse medo se extinguirá, pois a quantidade de vezes em que ela experimentou uma sensação neutra ou agradável na mesma situação contextual do assalto acabou desfazendo o EC formado anteriormente.

A sugestão é desenvolver no simulador um mecanismo de extinção de memória e de condicionamento do medo. Uma vez que o RI deixou de colidir com o RB após o condicionamento causado por uma colisão em determinado contexto, após determinado número de rodadas sem nenhuma colisão este condicionamento acaba desfeito e o RI deixa de sentir medo naquela situação. Isto pode ser útil para que se evite manter um robô excessivamente cauteloso, o que poderia prejudicar o custo e o tempo da simulação.

6.1.3 Níveis de medo

O modelo de condicionamento por medo, em sua solução atual, provê em sua saída um valor binário que indica se o modelo retornou ou não um indicativo de medo para as entradas de informações do ambiente percebidas pelo autômato. Uma alteração no modelo de condicionamento por medo poderia possibilitar que este retornasse níveis de medo em sua

saída, em uma escala entre 0 e 1, e não apenas um valor que indicasse a presença ou a ausência de medo. Isso permitiria que fossem implementadas uma gama de reações do RI, que vão desde controle do tamanho do acréscimo ao valor do raio de medo, até o controle da velocidade do RI após o replanejamento do caminho a seguir.

6.2 Últimas considerações

Esta dissertação procurou apresentar uma solução para controle da movimentação de autômatos utilizando um modelo biologicamente realista do cérebro humano. Esperou-se assim que, em determinadas condições do ambiente em que ele se encontrasse, o robô experimentasse uma emoção de medo que pudesse auxiliar em sua tomada de decisão e evitasse sua colisão com outros obstáculos, notadamente outro robô.

Uma vez que o modelo possui natureza determinística, este trabalho não considerou várias rodadas para um mesmo conjunto de dados de entrada. Os testes apresentaram situações em que os resultados foram positivos, apresentando melhorias em relação à solução do modo de emergência previsto na versão original do Simulador Experimental, além de resultados em que a nova solução não apresentou melhoria significativa. Parece bem razoável supor que, em uma simulação onde o RI não colide com o RB em dada situação de contexto, a experiência de medo não muda o resultado final, apenas aumenta o raio de medo utilizado pelo RI. Isto pode aumentar os custos do caminho percorrido, ainda que este trabalho considere como variável principal para a avaliação dos testes o sucesso na simulação (ou seja, a ocorrência ou não da colisão). O custo do caminho foi apresentado como artifício para ilustrar e enriquecer as informações acerca das situações consideradas.

Acredita-se que este trabalho traga contribuições importantes no antigo sonho humano de criar uma máquina à sua imagem e semelhança, que possa com ele interagir e transformar a caminhada do homem neste planeta em uma jornada menos solitária.

Apêndice A - Usando o Emergent e o Simulador Experimental

Este capítulo foi escrito para orientar em relação ao uso do Emergent e do Simulador Experimental, a quem desejar reproduzir os experimentos realizados neste trabalho.

Preparando o ambiente

A nova proposta descrita neste trabalho é composta de dois sistemas que executam de maneira integrada. O modelo computacional de condicionamento por medo executa no software Emergent. Existe uma página Wiki, atualizada constantemente, com informações a respeito da instalação do Emergent, acessada pelo endereço <[http://grey.colorado.edu/emergent/index.php/Installation_\(Win\)](http://grey.colorado.edu/emergent/index.php/Installation_(Win))>. Ali estão disponíveis instruções para instalação e execução do Emergent no Windows, bem como para outros sistemas operacionais.

O Simulador experimental é um software construído na linguagem Java, e para tal necessita da versão mais recente do JRE (Java Runtime Environment, também conhecido como máquina virtual Java) para executar. O simulador foi desenvolvido utilizando o ambiente de desenvolvimento Netbeans, e pode ser portado para vários sistemas operacionais e configurações diferentes.

Para que o Simulador Experimental pudesse obter a resposta de medo da saída da rede do modelo computacional de medo, foi criada uma interface de comunicação entre os dois sistemas. Essa interface também foi desenvolvida em Java, e foi embutida no Simulador Experimental. Seu funcionamento é transparente ao operador do sistema.

Executando o simulador

O roteiro a seguir descreve um passo a passo básico para realização dos testes.

1. Antes de tudo, é necessário executar o Emergent e abrir o servidor de comunicação com o Simulador Experimental. Para isto, abra o software e escolha a opção “Open Remote Server”, como indicado nas figuras 17 e 18. Na figura 18, basta confirmar, clicando no botão OK.




Figura 17 - Abrindo servidor de comunicação do Emergent




Figura 18 - Abrindo servidor de comunicação do Emergent, confirmado a operação

2. A seguir, abra o Modelo de condicionamento por medo, escolhendo a opção indicada na figura 19.




Figura 19 - Abrindo o modelo

3. Em seguida, devemos realizar o treinamento inicial da rede, onde somente dados não condicionados (ou seja, que representam situações de medo instintivo) são apresentados. Isto é feito entrando na opção “programs > Ambientação”, na árvore do menu à esquerda, e clicando no botão “Run”. Observe a figura 20.




Figura 20 - Executando o treinamento inicial da rede do modelo

4. Já podemos agora Executar o Simulador Experimental e rodar as simulações. Primeiramente, executamos o Netbeans para que este execute o simulador. Também é possível, em alguns sistemas, executar o arquivo \dist\robos_mestrado.jar. Observe a figura 21.




Figura 21 - Executando o simulador experimental

5. A conexão com o modelo computacional é automática, bastando para isso que seja escolhida a opção “Emergent”, no menu “Planning Type”, como na figura 22.




Figura 22 - Opção que ativa o modelo computacional

6. A partir deste ponto, basta selecionar as opções de tipo de RB, posições de partida do RB e chegada do RI, e opções de contexto. Para executar a simulação, basta clicar no botão “Create” e a seguir em “Run” (figura 23).

The image shows a software interface for an experimental simulator, divided into two main panels: 'Main' and 'Options'.

Main Panel:

- Choose a dumb robot:** A dropdown menu with 'Follower' selected.
- Movement Parameters:** A sub-panel containing:
 - Speed:** Input field with '-2'.
 - Unused:** Input field with '-2'.
 - Direction:** Input field with '0'.
 - Unused:** Input field with '-2'.
- IR Arrival's point:** A sub-panel containing:
 - X position:** Input field with '500'.
 - Y position:** Input field with '180'.
- Buttons:** 'Create', 'Run', and '>>' buttons.

Options Panel:

- DR Start Position:** A sub-panel containing:
 - X position:** Input field with '700'.
 - Y position:** Input field with '150'.
- IR fear radius:** Input field with '10'.
- Environment:** A sub-panel containing:
 - Light:** Dropdown menu with 'Yes' selected.
 - Sound:** Dropdown menu with 'No sound' selected.
 - Floor:** Dropdown menu with 'Gray' selected.
- Planning type:** Dropdown menu with 'Emergent' selected.
- Prevision:** Dropdown menu with 'Neural Prevision' selected.

Figura 23 - Opções de execução do simulador experimental

REFERÊNCIAS

AHN. H. ; PICARD, R. W. Affective cognitive learning and decision making: the role of emotions. In: EUROPEAN MEETING ON CYBERNETICS AND SYSTEMS RESEARCH, 18., 2006, Vienna. **Proceedings ...** Vienna: Austrian Society for Cibernetic Studies, 2006. (EMCSR 2006).

ALDEBARAM ROBOTICS, **NAO for education**. 2010. Disponível em:
<http://www.aldebaran-robotics.com/en/naoeducation>>. Acesso em: 17 out 2010.

ARAUJO, E. P. **Modelagem computacional do condicionamento por medo**. 2008. 79 f. Dissertação (Mestrado em Informática) – Núcleo de Computação Eletrônica, Instituto de Matemática, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

ARBIB, M. A. ; FELLOUS J. Emotions: from brain to robot. **Trends in Cognitive Sciences**, Cambridge, MA, v.8, n. 12, p. 554-561, 2004

BBC. **Nao the first robot with 'emotions' unveiled**. Disponível em:
http://news.bbc.co.uk/local/threecounties/hi/people_and_places/newsid_8900000/8900417.stm>. Acesso em: 17 out 2010.

DAGLARLI E. et al., Behavioral task processing for cognitive robots using artificial emotions. **Neurocomputing**, Nijmegen Netherlands, v. 72, n. 13-15, Aug. 2009.

EICHENBAUM H. **The Cognitive neuroscience of memory: an introduction**. New York: Oxford University Press, 2002.

EMERGENT. **About Emergent**. 2010. Disponível em:
< http://grey.colorado.edu/emergent/index.php/About_Emergent >. Acesso em: 17 jun 2010.

EMERGENT. **Demos**. 2010. Disponível em:

<<http://grey.colorado.edu/emergent/index.php/Demos> >. Acesso em: 12 Ago 2010.

_____. **Getting Started**. 2010. Disponível em:

< http://grey.colorado.edu/emergent/index.php/Getting_Started >. Acesso em: 23 ago 2010.

_____. **Installation** (Win). 2010. Disponível em:

http://grey.colorado.edu/emergent/index.php/Getting_Started >. Acesso em: 17 Jun 2010,

_____. **Neural Network Simulation System**, 2010. Disponível em:

< http://grey.colorado.edu/emergent/index.php/Main_Page >. Acesso em: 17 jun 2010.

.

_____. **Server Protocol**. 2010. Disponível em:

< http://grey.colorado.edu/emergent/index.php/Server_Protocol >. Acesso em: 20 mai 2010,

_____. **Tutorials**. 2010. Disponível em:

< <http://grey.colorado.edu/emergent/index.php/Tutorials> >. Acesso em: 15 ago 2010.

FELLOUS, J. ; ARBIB, M. A. **Who needs emotions?** the brain meets the robot, New York: Oxford University Press, 2005. (Series in Affective Science).

FREITAS-MAGALHÃES, A. **A Psicologia das emoções**: o fascínio do rosto humano. 2. ed. Universidade Fernando Pessoa, 2007.

GAZZANIGA, M. S. ; IVRY, R. B. ; MANGUN, G. R. **Neurociência cognitiva**: a biologia da mente. 2. ed. Porto Alegre: Artmed, 2006.

GLUCK M. A. ; MYERS C. E. **Gateway to memory**. Cambridge: MIT Press, 2001.

IZQUIERDO, I. **Memória**. Porto Alegre: ArtMed, 2002.

GOLEMAN, D. **Inteligência emocional**: teoria revolucionária. Objetiva, 2001.

JAVA SE Downloads, 2011. Disponível em:

< <http://www.oracle.com/technetwork/java/javase/downloads/index.html> >. Acesso em: 05 mai 2010.

LANE, R. D. ; NADEL, L. **Cognitive neuroscience of emotion**. New York: Oxford University Press, 2000.

LEDOUX, J. **O Cérebro emocional**: os misteriosos alicerces da vida emocional. Rio de Janeiro: Objetiva, 2001. 332 p.

_____. Emotion circuits in the brain. **Annual Review of Neuroscience**, Palo Alto, v. 23, p. 155-185, Mar. 2000.

NEISSER, U. et al. Intelligence: knowns and unknowns. **American Psychologist**, Washington, DC, v. 51, n. 2, p. 77-101, Feb. 1996.

NETBEANS 6.8 Downloads, 2011. Disponível em:<<http://services.netbeans.org/bouncer/index.php?product=netbeans-6.8-ml-javase&os=windows>>. Acesso em: 22 abr. 2011.

NILSSON, N. J. **Introduction to machine learning**, na early draft of a proposed textbook. Stanford: [s.n.] 1997. Free e-book.

O'REILLY, R. C. Six principles for biologically based computational models of cortical cognition. **Trends in Cognitive Sciences**, Cambridge, MA, v. 2, n. 11, p. 455-462, 1998.

O'REILLY, R. C. ; MUNAKATA Y. **Computational explorations in cognitive neuroscience**: understanding the mind by simulating the brain. Cambridge: MIT Press, 2000.

PIAGET, J. Cognitive development in children: development and learning. **Journal of Research in Science Teaching**, New York, v. 2, n. 3, p. 176-86, Sept. 1964. pt. 1

PICARD, R. **Affective Computing**. Cambridge: MIT Press, 1997.

PLUTCHIK, R. A general psychocvolutionary theory of emotion. In: PLUTCHIK, R. ; KELLERMAN, H. (Eds). **Emotion**: theory, research, and experience. New York: Academic Press, 1980. p. 3-33. (Vol. 1. Theories of emotion). .

PORR, B. ; WÖRGÖTTER F. Fast heterosynaptic learning in a robot food retrieval task inspired by the limbic system, **BioSystems**, Amsterdam, v. 108, n.1-3, p. 294-299, May-June 2007.

SHAHMIRZADI, D. **Computational modeling of the brain limbic system and its application in control engineering**, 2005. (Maste's Thesis) - Texas A&M University, Texas, 2005.

SQUIRE, L. R. **Memory and brain**. New York: Oxford University Press, 1987

STERNBERG, R. J. **Psicologia cognitiva**. Porto Alegre: Artmed, 2000.

VARELLA, A. V. S. **Uma abordagem computacional e connexionista sobre o sistema de memória emocional**. 2006. 120 f. Dissertação (Mestrado em Informática) – Núcleo de

Computação Eletrônica, Instituto de Matemática, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2006.