

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL**

IVAN ROSSATO CHRUN

**MAPAS COGNITIVOS FUZZY DINÂMICOS APLICADOS EM VIDA
ARTIFICIAL E ROBÓTICA DE ENXAME**

DISSERTAÇÃO

CURITIBA

2016

IVAN ROSSATO CHRUN

**MAPAS COGNITIVOS FUZZY DINÂMICOS APLICADOS EM VIDA
ARTIFICIAL E ROBÓTICA DE ENXAME**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Ciências” - Área de Concentração: Engenharia de Automação e Sistemas

Orientadora: Profa. Dra. Lúcia Valéria Ramos de Arruda

Coorientador: Prof. Dr. Márcio Mendonça

CURITIBA

2016

Dados Internacionais de Catalogação na Publicação

C557m Chrun, Ivan Rossato
2016 Mapas cognitivos fuzzy dinâmicos aplicados em vida artificial e robótica de enxame / Ivan Rossato Chrun.-- 2016.
129 f. : il. ; 30 cm.

Texto em português, com resumo em inglês
Disponível também via World Wide Web
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Curitiba, 2016
Bibliografia: f. 118-129

1. Sistemas difusos. 2. Lógica difusa. 3. Computadores neurais. 4. Sistemas de suporte de decisão. 5. Teoria dos grafos. 6. Inteligência coletiva. 7. Engenharia elétrica – Dissertações. I. Arruda, Lúcia Valéria Ramos de. II. Mendonça, Márcio. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial. IV. Título.

CDD: Ed. 22 -- 621.3

Biblioteca Central da UTFPR, Câmpus Curitiba

Título da Dissertação Nº. ____

Mapas Cognitivos Fuzzy Dinâmicos Aplicados em Vida Artificial e Robótica de Enxame.

por

Ivan Rossato Chrun

Orientador: Prof^a. Dr^a. Lúcia Valéria Ramos de Arruda (UTFPR)

Coorientador: Prof. Dr. Márcio Mendonça (UTFPR)

Esta dissertação foi apresentada como requisito parcial à obtenção do grau de MESTRE EM CIÊNCIAS – Área de Concentração: **ENGENHARIA DE AUTOMAÇÃO DE SISTEMAS** do Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial – CPGEI – da Universidade Tecnológica Federal do Paraná – UTFPR, às 14h do dia 17 de outubro 2016. O trabalho foi aprovado pela Banca Examinadora, composta pelos professores doutores:

Prof^a. Dr^a. Lúcia Valéria Ramos de Arruda
(Presidente – UTFPR)

Prof. Dr. Ricardo Breganon
(IFPR)

Prof. Dr. João Alberto Fabro
(UTFPR)

Visto da coordenação:

Prof. Jean Carlos Cardozo da Silva, Dr.
(Coordenador do CPGEI)

AGRADECIMENTOS

Agradeço à minha orientadora Profa. Dra. Lúcia Valéria Ramos de Arruda e coorientador Prof. Dr. Márcio Mendonça pelo apoio, contribuições e condução das atividades.

A Deus, aos meus amigos do LASCA e da UTFPR, e a todos da minha família que motivaram e ajudaram superar dificuldades.

RESUMO

Este trabalho propõe o uso de Mapas Cognitivos *Fuzzy* Dinâmicos (DFCM, do inglês *Dynamic Fuzzy Cognitive Maps*), uma evolução dos Mapas Cognitivos Fuzzy (FCM), para o desenvolvimento de sistemas autônomos para tomada de decisões. O FCM representa o conhecimento de forma simbólica, através de conceitos e relações causais dispostas em um grafo. Na sua versão clássica, os FCMs são usados no desenvolvimento de modelos estáticos, sendo inapropriados para o desenvolvimento de modelos temporais ou dinâmicos devido à ocorrência simultânea de todas as causalidades em uma estrutura fixa dos grafos, i.e., os conceitos e suas relações causais são invariantes no tempo. O DFCM utiliza o mesmo formalismo matemático do FCM através de grafos, acrescentando funcionalidades, como por exemplo, a capacidade de auto adaptação através de algoritmos de aprendizagem de máquina e a possibilidade de inclusão de novos tipos de conceitos e relações causais ao modelo FCM clássico. A partir dessas inclusões, é possível construir modelos DFCM para tomada de decisões dinâmicas, as quais são necessárias no desenvolvimento de ferramentas inteligentes em áreas de conhecimento correlatas à engenharia, de modo específico a construção de modelos aplicados em Robótica Autônoma. Em especial, para as áreas de Robótica de Enxame e Vida artificial, como abordados nesta pesquisa. O sistema autônomo desenvolvido neste trabalho aborda problemas com diferentes objetivos (como desviar de obstáculos, coletar alvos ou alimentos, explorar o ambiente), hierarquizando as ações necessárias para atingi-los, através do uso de uma arquitetura para o planejamento, inspirada no modelo clássico de Subsunção de Brooks, e uma máquina de estados para o gerenciamento das ações. Conceitos de aprendizagem de máquina, em especial Aprendizagem por Reforço, são empregadas no DFCM para a adaptação dinâmica das relações de casualidade, possibilitando o controlador a lidar com eventos não modelados a priori. A validação do controlador DFCM proposto é realizada por meio de experimentos simulados através de aplicações nas áreas supracitadas.

Palavras-chave: Mapas Cognitivos *Fuzzy*, Sistemas Inteligentes, Sistema de navegação autônoma, Sistemas de Tomadas de Decisões, Vida Artificial e Robótica de Enxame.

ABSTRACT

This dissertation proposes the use of Dynamic Fuzzy Cognitive Maps (DFCM), an evolution of Fuzzy Cognitive Maps (FCM), for the development of autonomous system to decision-taking. The FCM represents knowledge in a symbolic way, through concepts and causal relationships disposed in a graph. In its standard form, the FCMs are limited to the development of static models, in other words, classical FCMs are inappropriate for development of temporal or dynamic models due to the simultaneous occurrence of all causalities in a permanent structure, i.e., the concepts and the causal relationships are time-invariant. The DFCM uses the same mathematical formalism of the FCM, adding features to its predecessor, such as self-adaptation by means of machine learning algorithms and the possibility of inclusion of new types of concepts and causal relationships into the classical FCM model. From these inclusions, it is possible to develop DFCM models for dynamic decision-making problems, which are needed to the development of intelligent tools in engineering and other correlated areas, specifically, the construction of autonomous systems applied in Autonomous Robotic. In particular, to the areas of Swarm Robotics and Artificial Life, as approached in this research. The developed autonomous system deals with multi-objective problems (such as deviate from obstacle, collect target or feed, explore the environment), hierarchizing the actions needed to reach them, through the use of an architecture for planning, inspired by the Brook's classical Subsumption model, and a state machine for the management of the actions. Learning machine algorithms, in particular Reinforcement Learning, are implemented in the DFCM to dynamically tune the causalities, enabling the controller to handle not modelled event a priori. The proposed DFCM model is validated by means of simulated experiments applied in the aforementioned areas.

Key-words: Fuzzy Cognitive Maps, Intelligent Systems, Autonomous Navigation System, Decision-Making Systems, Artificial Life, Swarm Robotics.

LISTA DE ILUSTRAÇÕES – FIGURAS

Figura 2.1 – Exemplo de um FCM clássico.	25
Figura 2.2 – Classificação de agentes quanto à ênfase dada a alguns atributos primários.....	39
Figura 3.1 – Decomposição tradicional de um sistema de controle de robôs móveis em módulos funcionais.	48
Figura 3.2 – Decomposição de um sistema de controle para um robô móvel baseado em comportamentos para realização de tarefas - Arquitetura de Subsunção de Brooks.....	48
Figura 3.3 – Visão geral da arquitetura.	51
Figura 3.4 – Evolução do FCM para DFCM, aumento dos conceitos e fundamentos.	52
Figura 3.5 – Modelo AR genérico.	56
Figura 4.1 – Arquitetura DFCM para aplicação em Vida Artificial.....	65
Figura 4.2 – Decisões hierárquicas e camadas adaptativas do Golfinho (abordagem bottom-up).	66
Figura 4.3 – Decisões hierárquicas e camadas adaptativas do Predador (abordagem bottom-up).	66
Figura 4.4 –Máquina de estado do Golfinho.	67
Figura 4.5 – Máquina de estado do Predador	68
Figura 4.6 – DFCM para o golfinho.	69
Figura 4.7 – DFCM resultante para o estado de desvio de obstáculos (seleção obstáculo)	72
Figura 4.8 – DFCM do predador.	75
Figura 4.9 – Visão geral do ambiente.....	77
Figura 4.10 – Trilhas de navegação do predador e golfinho – Ambiente com 1 predador.	78
Figura 4.11 – Velocidade do Golfinho e distância relativa entre predador e sua presa– Ambiente com 1 predador	78
Figura 4.12 – Valores do peso W4, PD e VE do Golfinho – Ambiente com 1 predador.....	79
Figura 4.13 – Valores do peso W3, PE e VD do Golfinho – Ambiente com 1 predador.....	79
Figura 4.14 – Visão ampliada das trilhas das criaturas virtuais – Ambiente com 1 predador.	81
Figura 4.15 – Visão ampliada - Trilha do golfinho nos momentos de agrupamento – Ambiente com 1 predador.	81
Figura 4.16 – Trilha das criaturas virtuais no ambiente, onde o predador captura sua presa..	82
Figura 4.17 – Velocidade do Golfinho e distância relativa entre predador e sua presa – Morte do Golfinho.....	82
Figura 4.18 – Valores do peso W4, PD e VE do Golfinho – Morte do Golfinho.	83

Figura 4.19 – Valores do peso W3, PE e VD do Golfinho – Morte do Golfinho.	83
Figura 4.20 – Trilha das criaturas virtuais em um ambiente com dois predadores.	84
Figura 4.21 – Velocidade do Golfinho e distâncias relativas entre os predadores e sua presa – Ambiente com 2 predadores.	85
Figura 4.22 – Valores do peso W4, PD e VE do Golfinho – Ambiente com 2 predadores.	85
Figura 4.23 – Valores do peso W3, PE e VD do Golfinho – Ambiente com 2 predadores.	86
Figura 5.1 – Arquitetura híbrida DFCM para Robótica de Enxame.	89
Figura 5.2 – Hierarquia de ações para a arquitetura de subsunção.....	91
Figura 5.3 – Estratégia de gerenciamento do agente (Sistema de Estados Interno).....	91
Figura 5.4 – Modelo DFCM inicial para navegação reativa.	93
Figura 5.5 – Modelo DFCM completo para navegação reativa e deliberativa.....	95
Figura 5.6 – Modelo DFCM simplificado para processamento de dados no método de compartilhamento de trajetória.....	97
Figura 5.7 – Modelo DFCM simplificado para processamento de dados no método de compartilhamento por feromônio.	99
Figura 5.8 – Visão geral do ambiente simulado.	103
Figura 5.9 – Método de compartilhamento de trajetória: primeira rodada no ambiente com um obstáculo móvel.....	104
Figura 5.10 – Método de compartilhamento de trajetória: Valores dos sensores e pesos do agente principal (ambiente com um obstáculo móvel).....	105
Figura 5.11 – Método de compartilhamento por feromônio: primeira rodada no ambiente com um obstáculo móvel.....	105
Figura 5.12 – Método de compartilhamento por feromônio: Valores dos sensores e pesos do agente principal (ambiente com um obstáculo móvel).....	106
Figura 5.13 – Método de compartilhamento de trajetória: segunda rodada no ambiente com um obstáculo móvel.....	106
Figura 5.14 – Método de compartilhamento de trajetória: Valores dos sensores e pesos do agente principal (segunda rodada e ambiente com um obstáculo móvel).	107
Figura 5.15 – Método de compartilhamento por feromônio: segunda rodada no ambiente com um obstáculo móvel.....	107
Figura 5.16 – Método de compartilhamento de trajetória: Valores dos sensores e pesos do agente principal (segunda rodada e ambiente com um obstáculo móvel).	108
Figura 5.17 – Método de compartilhamento de trajetória: segunda rodada no ambiente com dois obstáculos móveis.....	109

Figura 5.18 – Método de compartilhamento de trajetória: Valores dos sensores e intensidade dos pesos do agente principal (ambiente com dois obstáculos móveis).....	109
Figura 5.19 – Método de compartilhamento por feromônio: segunda rodada no ambiente com dois obstáculos móveis.	110
Figura 5.20 – Método de compartilhamento de trajetória: Valores dos sensores e intensidade dos pesos do agente principal (ambiente com dois obstáculos móveis).....	110

LISTA DE TABELAS

Tabela 3.1 – Etapas de desenvolvimento da DFCM (ontologia).....	55
Tabela 3.2 – Exemplificação de tipos de ações, descrições e exemplos práticos.....	55
Tabela 3.3 – Pseudocódigo para compartilhamento de informação por feromônio.....	58
Tabela 4.1 – Ações modeladas para o Golfinho.....	63
Tabela 4.2 – Ações modeladas para o Predador.....	64
Tabela 4.3 – Conceitos do DFCM para o golfinho.....	70
Tabela 4.4 – Conceitos do DFCM proposto para o predador.....	75
Tabela 5.1 – Comportamento / habilidades / situações / ações executadas pelo agente.	90
Tabela 5.2 – Conceitos do DFCM proposto.....	95
Tabela 5.3 – Conceitos do DFCM para o método de compartilhamento de trajetória.....	98
Tabela 5.4 – Conceitos do DFCM para o método de compartilhamento por feromônio.	99

LISTA DE ABREVIATURAS E SIGLAS

AHP	<i>Analytic Hierarchy Process</i>
IA	Inteligência Artificial
AmI	<i>Ambient Intelligence</i>
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
AR	Aprendizagem por Reforço
ARS	<i>Autonomous Robotic System</i>
BDI	<i>Belief, Desire and Intention</i>
CFCM	<i>Contextual Fuzzy Cognitive Maps</i>
CMMS	<i>Computerized Maintenance Management System</i>
CM	<i>Mapas Cognitivos, ou Cognitive Maps</i>
DFCM	Mapas Cognitivos Fuzzy Dinâmicos, ou <i>Dynamic Fuzzy Cognitive Maps</i>
ER	<i>Evolutionary Robotics</i>
FCM	Mapas Cognitivos Fuzzy, ou <i>Fuzzy Cognitive Maps</i>
FICM	<i>Fuzzy Inference Cognitive Maps</i>
GRN	<i>Gene Regulatory Networks</i>
InteRRAP	<i>Integration of reactive behaviour and rational planning</i>
MANET	<i>Mobile Ad hoc Network</i>
SMA	Sistema Multi-Agente, ou <i>Multi-Agent Systems</i>
PRS	<i>Procedural Reasoning System</i>
RB-FCM	<i>Rule Based – Fuzzy Cognitive Maps</i>
RBFNN	<i>Radial Base Function Neural Network</i>
RCGA	<i>Real-Coded Genetic Algorithm</i>
RNA	Redes Neurais Artificiais
ROS	<i>Robotic Operating System</i>
SAF	<i>Situation Assessment Framework</i>
SW	Robótica de Enxame, ou <i>Swarm Robotics</i>
TAFCM	<i>Timed Automata Fuzzy Cognitive Maps</i>
VA	Vida Artificial

SUMÁRIO

1	INTRODUÇÃO	12
1.1	PROBLEMA A SER PESQUISADO.....	14
1.2	MOTIVAÇÃO.....	17
1.3	OBJETIVOS.....	19
1.3.1	Objetivo Geral.....	19
1.3.2	Objetivos Específicos.....	20
1.4	ORGANIZAÇÃO DO TRABALHO.....	20
2	ESTADO DA ARTE.....	22
2.1	FUNDAMENTAÇÃO TEÓRICA	23
2.1.1	Mapas Cognitivos (CM).....	23
2.1.2	Mapas Cognitivos <i>Fuzzy</i> (FCM)	24
2.1.3	Mapas Cognitivos <i>Fuzzy</i> Dinâmicos (DFCM).....	27
2.2	REVISÃO DE LITERATURA - MODELOS COGNITIVOS EM APLICAÇÕES GENÉRICAS.....	30
2.2.1	Revisão de trabalhos correlatos ao tema de sistemas autônomos e métodos de aprendizagem.....	34
2.3	SISTEMAS MULTI-AGENTES E AGENTES INTELIGENTES	37
2.4	FUNDAMENTOS DE ROBÓTICA DE ENXAME	40
2.5	FUNDAMENTOS DE VIDA ARTIFICIAL.....	43
3	SISTEMA AUTÔNOMO BASEADO EM DFCM.....	46
3.1	ARQUITETURA DE AGENTES	46
3.2	MODELO DFCM.....	52
3.2.1	Ontologia.....	54
3.2.2	Aprendizagem por Reforço - AR	56
3.2.3	Algoritmo para Transmissão de Feromônios	57
3.3	CONCLUSÃO.....	59
4	VIDA ARTIFICIAL.....	61
4.1	ESTRATÉGIA DE CONTROLE	64
4.2	MODELOS (DFCM) COGNITIVOS DAS CRIATURAS	68
4.3	RESULTADOS	76
4.4	CONCLUSÃO.....	86
5	ROBÓTICA DE ENXAME.....	88

5.1 ESTRATÉGIA DE CONTROLE	88
5.2 MODELOS DFCM PARA AMBIENTES COM MÚLTIPLOS ROBÔS	89
5.3 RESULTADOS	102
5.4 CONCLUSÃO.....	111
6 CONCLUSÕES GERAIS	113
6.1 FUTUROS TRABALHOS	114
PUBLICAÇÕES RELACIONADAS AO TRABALHO	116
REFERÊNCIAS	118

1 INTRODUÇÃO

Há na comunidade científica e industrial um crescente interesse no desenvolvimento de robôs móveis e veículos autônomos, também chamados de agentes móveis, ocasionado pela grande diversidade de tarefas que podem ser tratadas por esses, como em aplicações que apresentam perigo à saúde humana e/ou ambientes inóspitos (MAKI *et al.*, 2010; SHAIKH *et al.*, 2013). Especificamente, pode-se citar o trabalho de MANDOW *et al.* (1996), o qual descreve um robô móvel autônomo para uso na agricultura, a fim de substituir o trabalho humano em atividades inóspitas como a pulverização com inseticidas.

A área de Robótica Autônoma tem uma relação com a ficção científica que está enraizada em nosso instinto de compreender a nós mesmos como protagonistas do mundo. De fato, essa área de pesquisa tem como objetivos construir modelos e paradigmas inspirados na biologia dos humanos/animais, desenvolver dispositivos robóticos e equipá-los com ferramentas inteligentes para tomar decisões em substituição aos seres humanos (HEXMOOR, 2013).

A área possui diversas aplicações, como em segurança, exploração de áreas inacessíveis, de difícil acesso ou ambientes perigosos, e em serviços críticos como a pulverização de inseticida citada acima. Como exemplos, podem-se citar trabalhos que descrevem o uso de robôs móveis autônomos para soldagem (SCHROTH *et al.*, 2009), exploração de ambiente (SALAN *et al.*, 2015), ambientes subaquáticos (BROGGI *et al.*, 2008; SPEARS *et al.*, 2014), entre outros. Sendo assim, este é um campo emergente de pesquisa e aplicação da Robótica Autônoma, tal como apresentado por VERNON *et al.* (2007) e expandido por MAKI *et al.* (2010).

O termo "autonomia" em robótica não se refere apenas à capacidade de ação e decisão de um sistema de controle independente de interferência humana, mas também a capacidade de adaptação do mecanismo de tomadas de decisões em face de situações não modeladas ou previstas (SMITHERS, 1997; MATARIC, 2007). Esses sistemas devem ser capazes de guiar os robôs sem nenhuma interferência externa (MAES, 1995; RUSSELL e NORVIG, 2009) e definir ações, como atingir alvos, desviar de obstáculos e explorar ambiente (CALVO, 2007).

Em outras palavras, sistemas autônomos têm a capacidade de realizar tarefas complexas com um elevado grau de sucesso; além disso, um robô, veículo ou agente pode ser considerado

autônomo se ele é total ou parcialmente bem-sucedido em, pelo menos, três diferentes cenários, sem a intervenção humana (MAES, 1995; MATARIC, 2007; RUSSELL e NORVIG, 2009).

Uma das principais áreas que requerem autonomia é a área de sistemas de navegação, devido a necessidade de integração de vários sensores, atuadores e controladores, os quais precisam ser robustos o suficiente para interpretar e reagir a mudanças no ambiente, guiando o agente desde o seu ponto ou região inicial até o seu destino final, ou ao cumprimento da(s) tarefa(s), como por exemplo, desviar de obstáculos, encontrar alvos, gerenciar energia. Em resumo, a inserção da autonomia em sistemas de navegação permite o desenvolvimento de agentes autônomos capazes de tomar decisões sem a intervenção humana.

No entanto, algumas dificuldades permanecem a serem resolvidas para o desenvolvimento de um sistema de navegação autônomo. Os problemas estão relacionados a diferentes domínios, como a percepção (abstração do ambiente para o agente), localização (odometria, ou outros métodos de localização espacial), modelagem ambiental (representação do cenário), tomadas de decisões (decisões comportamentais do agente), controle (métodos e técnicas de desenvolvimento dos controladores), etc. (SHAIKH *et al.*, 2013). Em especial, as diferentes estratégias para a tomada de decisões, abrangendo o gerenciamento das ações a serem executadas pelo agente, e o controle, o qual aborda as ferramentas, técnicas e métodos para desenvolver o controlador do agente serão focos do presente trabalho.

Similar à área de Robótica Autônoma, em especial no que se refere aos conceitos de agentes autônomos, uma criatura artificial pode ser vista como um sistema autônomo, o qual age e interage com o mundo real (criaturas robóticas ou humanos) e com o mundo virtual (criaturas virtuais), quando o ambiente é simulado computacionalmente como acontece nos jogos eletrônicos.

O mundo virtual permite simulações de agentes com comportamentos bio-inspirados em animais ou humanos em um ambiente virtual 2d ou 3d, o qual permite uma melhor análise sobre a interação entre os agentes e um melhor controle sobre as variáveis que influenciam no sistema ou problema. A utilização dessa ferramenta está em ascensão na literatura, especialmente na área de jogos e educação. Pode-se citar trabalhos nessas áreas, como os trabalhos de ALAMAN *et al.* (2016), ANTONIO *et al.* (2015) e TROETSTH *et al.* (2015) em aplicações de jogos focados para educação, KONRAD *et al.* (2015) em sistemas de transporte inteligentes, BORGHESE *et al.* (2013) para reabilitação de pacientes que sofreram derrame. VASUDEVAMURT e USKOV (2015) apresentam uma revisão e análise de algumas ferramentas para jogos (*game engines*) e suas aplicações.

De forma resumida, a inclusão do mundo virtual na área de vida artificial se caracteriza pela reprodução dos processos de vida dentro de um computador; enquanto que a robótica móvel e em especial a robótica de enxame são caracterizadas pela implementação de sistemas de controle descentralizados inspirados no comportamento de insetos sociais para a resolução de problemas, através do uso de vários agentes móveis simples para a execução e distribuição de tarefas em grupo.

Apesar dessas áreas se diferirem em seu conceito, suas implementações possuem muitos pontos semelhantes, devido as características desejadas para os agentes ou criaturas artificiais a serem desenvolvidos, tais como autonomia, tomada de decisões em eventos não esperados, métodos de cooperação, divisão de tarefas, entre outros. Enquanto a área de vida artificial busca dotar as criaturas artificiais de comportamentos ou características animais, e a área de robótica de enxame, busca dotar a robôs móveis com habilidades inteligentes, como, por exemplo, raciocinar e agir sobre o ambiente.

Dessa forma, a implementação de agentes nessas áreas visa a análise da interação entre vários personagens em um ambiente, virtual ou simulado. E, portanto, dado as características desses agentes, esses tipos de aplicações podem ser tratados em um contexto de sistemas multi-agentes. Definido por WOOLDRIDGE (2009) como um sistema de múltiplos agentes, interagindo entre si, capazes de executar ações de forma independente, i.e., sem interferência externa, objetivando o cumprimento de tarefas.

O desenvolvimento de agentes para essas áreas não é uma tarefa trivial e na literatura não existe ainda soluções fechadas para essas aplicações. Nesse contexto, esta dissertação propõe uma metodologia de modelagem baseada em FCM que suporte o desenvolvimento de ambas aplicações.

1.1 PROBLEMA A SER PESQUISADO

Nos últimos anos os problemas de tomadas de decisões em sistemas autônomos são alvo de pesquisa ativa, devido ao seu impacto na solução de diversos sistemas do mundo real. As tomadas de decisões podem ser aplicadas em tarefas de seleções das ações para a solução de um sistema/problema específico. De outro modo, tomar uma decisão implica que existem escolhas alternativas a serem consideradas e ponderadas (NÁPOLES *et al.*, 2016). Para

sistemas de navegação autônomos, pode-se aplicar o conhecimento de especialistas e dados históricos do problema, com o intuito de melhorar o desempenho das tomadas de decisões.

Os sistemas de navegação autônoma devem ser capazes de tomar decisões sequenciais que levem o agente a mover-se através de um ambiente estático ou dinâmico, e se necessário mudar sua trajetória devido a um evento. O sistema deve agregar conhecimento reativo (ações de baixo nível) e deliberativo (ações de gerenciamento ou planejamento). As ações de baixo nível, tais como, as decisões para virar à esquerda ou à direita quando os sensores acusam algum obstáculo e acelerar quando há um caminho livre, são sempre ações de controle válidas em todas as circunstâncias. Já as deliberativas são ações de planejamento ou gerenciamento, como por exemplo, o gerenciamento do nível de energia ou bateria de um robô, podendo inferir no planejamento da trajetória do agente ou robô em busca de um ponto de recarga.

O uso dos conceitos das áreas de conhecimentos apresentados, juntamente com o processamento de dados de sensores, permite extrair objetos de cenários simulados, tais como obstáculos, alvos, trajetórias, etc., em tempo real. Em outras palavras, um agente autônomo deve ser capaz de reconhecer e localizar objetos e, eventualmente, descrevê-los com uma visão mais detalhada, o que lhe possibilita a compreensão do cenário com os objetos relevantes a si mesmo (MAES, 1995; RUSSELL e NORVIG, 2009). Em especial para Sistemas Multi-Agentes, devido à existência de muitos agentes ou criaturas compartilhando o mesmo ambiente, surge ainda a necessidade de comunicação e interação entre agentes (WOOLDRIDGE e JENNINGS, 1995).

No entanto, no desenvolvimento de sistemas Multi-Agentes, de acordo com WOOLDRIDGE (2009) dois problemas devem ser especialmente analisados:

- A construção de agentes capazes de ser independentes e tomar ações autônomas que completem as tarefas que foram delegadas a eles;
- A construção de agentes capazes de interagir (cooperação, coordenação, negociação) com outros agentes de forma a completar as tarefas que foram delegadas a eles de forma satisfatória, não podendo assumir que estes agentes tenham o mesmo objetivo/interesse.

O primeiro problema se refere ao método de construção do agente, e o segundo é relacionado ao *design* da sociedade onde os agentes estarão inseridos. Esses são problemas que ocorrem em sistemas com um ou mais robôs que necessitam de cooperação, como a navegação

de um robô autônomo em um ambiente, no qual outros agentes deverão aprender o caminho tomado de outro robô, no intuito de aprimorar seu trajeto.

Os conceitos de cooperação, coordenação e negociação são geralmente necessários para resolver problemas em ambientes dinâmicos e imprevisíveis. Para lidar com esse tipo de ambientes, a habilidade de aprendizagem do agente é particularmente importante. Além disso, a coexistência de agentes no mesmo cenário, com objetivos iguais ou distintos, exige capacidade individual e/ou do grupo para resolver conflitos e alcançar os objetivos. Nesse contexto, um sistema autônomo dotado de capacidade de tomada de decisões possibilita o gerenciamento destas ações de forma deliberativa, ponderando e priorizando as ações a serem tomadas pelos agentes através das informações extraídas do ambiente.

Na área de robôs autônomos móveis, algumas soluções recentes encontradas na literatura para os problemas citados acima são baseadas em técnicas de inteligência computacional, tais como Árvores de Decisão (PAZIENZA *et al.*, 2007), Sistemas *Fuzzy* (SAFIOTTI, 1997; MITCHELL e COHEN, 2014; TIWARI *et al.*, 2016), Redes Neurais Artificiais (ZHANG *et al.*, 2016), Mapas Cognitivos *Fuzzy* (SUBRAMANIAN e DAGLI, 2003), e outros. Essas técnicas ajudam os agentes em tomadas de decisões de forma independente.

De um modo geral, essas técnicas e/ou métodos procuram emular as habilidades dos seres humanos para lidar com processos complexos para tomadas de decisões, com base em informações imprecisas e / ou aproximadas. No entanto, para a modelagem de sistemas inteligentes, as informações podem também ser obtidas a partir do conhecimento do(s) especialista(s) e/ou dados operacionais do comportamento atual e passado do sistema (PASSINO e YURKOVICH, 1997).

Uma técnica recente que tem sido usada para o desenvolvimento de sistemas autônomos são os Mapas Cognitivos *Fuzzy* Dinâmicos (DFCM – *Dynamic Fuzzy Cognitive Maps*), o qual é utilizado nesta dissertação para o desenvolvimento de um sistema inteligente baseado em conhecimento com aplicação em enxame de robôs e vida artificial. Com essa ferramenta é possível, por um lado, codificar o conhecimento heurístico sobre o sistema a ser modelado, e por outro, incluir funcionalidades computacionais, como a capacidade de efetuar ajustes nos parâmetros do modelo a partir de dados quantitativos do sistema, através de aprendizagem ou treinamento e inferência. Os modelos, assim construídos, refletem as características cognitivas inerentes aos modelos mentais humanos, que os possibilitam controlar sistemas complexos.

Dessa forma, este trabalho objetiva o desenvolvimento de um sistema de navegação autônomo, tendo como base uma evolução dos Mapas Cognitivos *Fuzzy*, denominada DFCM,

do inglês *Dynamic Fuzzy Cognitive Map*. Esta evolução ocorre a partir da agregação de uma máquina de estado ao modelo que determina as ações dos agentes de acordo com o ambiente, construindo uma hierarquia de conhecimento e tomada de decisão que possibilita a cooperação, coordenação e negociação entre diversos agentes em um ambiente. Este sistema autônomo baseado em DFCM irá gerenciar as ações comportamentais do agente, através da adição de novos conceitos (nós) e relações causais (arcos) em um mapa cognitivo (grafo) original, e do uso de técnicas de sintonia fina dos pesos do mapa (arcos do grafo), permitindo uma melhor adaptabilidade do sistema a situações diversas na interação do agente com o ambiente. O DFCM será integrado então em uma arquitetura de subsunção (BROOKS, 1986) que permite o gerenciamento hierárquico de ações reativas e deliberativas. Por fim, a metodologia proposta é aplicada no desenvolvimento de um sistema autônomo nas áreas de Robótica de Enxame e Vida Artificial, mostrando-se como uma solução promissora para a tomada de decisões em Sistemas Multi-Agentes.

1.2 MOTIVAÇÃO

Existem trabalhos na literatura que utilizam conhecimento heurístico para modelar as tomadas de decisões em navegação autônoma através de Mapas Cognitivos *Fuzzy*, uma ferramenta de inteligência computacional que permite expressar o conhecimento de especialistas sobre um determinado domínio por meio de palavras ou expressões de linguagem, interligados por uma simples relação de causa e efeito (PIPE, 1998; SIRAJ *et al.*, 2001; MALHOTRA e SARKAR, 2005; ASTUDILLO *et al.*, 2006; MIN *et al.*, 2006; YEAP *et al.*, 2006).

Os Mapas Cognitivos *Fuzzy* surgiram na literatura com uma proposta de modelos computacionais inteligentes que combinam aspectos de Redes Neurais Artificiais e da Lógica *Fuzzy*. A partir da proposta inicial de KOSKO (1986), diversos problemas em diferentes áreas de conhecimento foram modelados através de FCMs, como por exemplo: séries temporais, navegação autônoma, controle de processos, sistemas sociais, diagnósticos médicos, entre outras. Entretanto, na sua versão clássica os FCMs, conforme proposto por Kosko e formalizado por YUAN e ZHI-QIANG (2000) não são capazes de representar relações temporais dinâmicas ou variantes no tempo, desse modo, diversas propostas de evolução têm sido presentes na literatura, como por exemplo, as redes cognitivas dinâmicas de MIAO *et al.* (1999) e

MENDONÇA e ARRUDA (2015), os mapas cognitivos baseados em regras de CARVALHO e TOME (2000), os autômatas temporais de ACAMPORA e LOIA (2009) e outros. Assim, uma das motivações deste trabalho está na proposta de uma evolução dos Mapas Cognitivos *Fuzzy*, denominada DFCM como uma alternativa para a utilização de FCM na modelagem de sistemas dinâmicos.

Os DFCMs são modelos cognitivos que utilizam conhecimento heurístico para construção dos modelos e dados *on-line* para sua sintonia e adaptação dinâmica. O conhecimento é estruturado e construído na forma de um grafo, que representa o comportamento do sistema a ser modelado. Neste modelo as relações do DFCM são dinamicamente adaptadas por regras que são disparadas pela ocorrência de eventos específicos, alterando o comportamento do modelo. Os DFCMs foram inicialmente propostos por MENDONÇA *et al.* (2013a) para desenvolvimento de um sistema supervisor de um processo de fermentação e em seguida foram aplicados pelos mesmos autores em um misturador industrial (MENDONÇA *et al.*, 2015a) e em um sistema de navegação autônomo (MENDONÇA *et al.*, 2014) que serviu de ponto de partida para os modelos desenvolvidos nesta dissertação.

Como instanciação da ontologia para DFCM proposta em Mendonça *et al.* (2014), o modelo a ser proposto nesse trabalho, desenvolve um controlador inteligente genérico para tomada de decisões dinâmicas aplicadas à área de agentes autônomos. O controlador a ser desenvolvido deve agregar informações, obtidas por meio de sensoriamento e informações oriundas de especialistas através da execução de bases de conhecimento que descrevem as características do problema. Com isto, o sistema de navegação autônoma proposto deve ser capaz de tomar decisões dinâmicas para se mover através do ambiente e, se necessário, mudar a sua trajetória caso ocorra algum evento inesperado ou não, como por exemplo, na aplicação de vida artificial, a presença de um predador. Para isso, o modelo DFCM proposto deve agregar um conhecimento de baixo nível, como as decisões de virar à esquerda ou à direita quando os sensores detectarem obstáculos, e acelerar quando há um caminho livre; e decisões deliberativas, como decidir se a criatura virtual deve buscar comida ou agrupar-se a outras criaturas da mesma espécie.

Além das funcionalidades citadas acima, existem situações específicas, tais como a necessidade de manter uma tendência de movimento, principalmente em manobras de curvas, como, por exemplo, quando o agente está desviando para a esquerda e os sensores acusam um novo obstáculo na mesma direção. Devido à inércia e restrições físicas, o agente não pode mudar de direção bruscamente, e, portanto, este tipo de manobra deve ser cuidadosamente

executado. Outras situações particulares também devem ser modeladas no mapa por relações causais e conceitos, porém só são válidas se resultantes de tomada de decisões causadas por acontecimentos em curso.

O modelo proposto nesta dissertação será aplicado na análise dos comportamentos de agentes virtuais na área de Vida Artificial e Robótica de Enxame. Para a primeira área, os comportamentos instintivos de criaturas virtuais, como a fome, a necessidade de agrupar e escapar de predadores, serão modelados em um ambiente artificial com personagens ou criaturas distintas. Especificamente, esta aplicação tem como objetivo o desenvolvimento de um sistema de comportamento dinâmico de criaturas artificiais em um cenário virtual de duas dimensões, tratando problemas de decisões sequenciais com diferentes objetivos (como desviar de obstáculos, coletar alvos ou alimento, explorar o ambiente). Esta aplicação é inspirada no trabalho original de DICKERSON e KOSKO (1998), no qual, modelos cognitivos de pequenos peixes, golfinhos e tubarões foram inseridos em um ambiente artificial através FCMs clássicos e servirá para validar as DFCMs como evolução dos FCMs.

Para a segunda aplicação, propõe-se o desenvolvimento de um sistema de navegação autônomo, no qual se utiliza o conhecimento abstraído de robôs cooperativos em ambientes simulados, de forma similar a aplicação de Vida Artificial. Esse tipo de problema necessita de decisões sequenciais em ambientes parcialmente ou totalmente desconhecidos com diferentes objetivos. Desse modo, o nível de complexidade desse tipo de problema exige uma arquitetura com capacidade de aprendizado, sintonia, adaptação, gerenciamento de ações e com capacidade de evolução, utilizando, por exemplo, algoritmos inspirados no comportamento de insetos, baseados em conceitos de Robótica de Enxame, ou do inglês *Swarm Robotics*.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

O objetivo principal deste trabalho é o desenvolvimento de uma arquitetura, baseada na ontologia de DFCM proposta por MENDONÇA *et al.* (2014), que suporte a construção de um controlador autônomo com as características de adaptabilidade, cooperação e coordenação, discutidas na motivação. Este controlador será aplicado em duas áreas correlatas à Robótica Autônoma, em específico, Vida Artificial e Robótica de Enxame, através de experimentos

simulados. O DFCM proposto tem como funcionalidade o controle e gerenciamento das ações implementadas, modeladas pelo conhecimento abstraído de especialistas, objetivando um sistema dinâmico para tomadas de decisões.

Para ambas as aplicações, o controlador DFCM deve guiar o agente através de um ambiente desconhecido e atingir os objetivos propostos, desviando de obstáculos, coletando alvos ou alimentos, e inferindo ações comportamentais específicas às suas respectivas aplicações.

1.3.2 Objetivos Específicos

Para se atingir o objetivo acima, os seguintes objetivos específicos devem ser atingidos:

- Desenvolver uma arquitetura híbrida baseada na ontologia de DFCM para criação de agentes autônomos e no uso de máquina de estado para gerenciar a tomada de decisão;
- Construir e aplicar a arquitetura DFCM proposta em Agentes Autônomos, na área específica de Vida artificial;
- Construir e aplicar a arquitetura DFCM em Agentes Autônomos, na área específica de Robótica de Enxame;
- Validar as aplicações por meio de experimentos simulados.

1.4 ORGANIZAÇÃO DO TRABALHO

Os próximos capítulos deste documento são organizados como listado a seguir.

O Capítulo 2 apresenta o estado da arte sobre tópicos afins. Uma fundamentação teórica sobre Mapas Cognitivos, Mapas Cognitivos *Fuzzy* e Mapas Cognitivos *Fuzzy* Dinâmicos é brevemente apresentada. Também, é apresentada uma revisão da literatura, e um breve resumo sobre o estado da arte em Vida Artificial, Robótica de Enxame, Agentes Inteligentes, e Sistemas Multi-Agentes.

O Capítulo 3 aborda tópicos sobre a arquitetura dos Agentes e a técnica de Aprendizagem por Reforço (a qual é utilizada neste trabalho como método de adaptação

dinâmica do controlador autônomo para tomadas de decisões). Uma arquitetura é proposta para o desenvolvimento dos modelos DFCM, abordando sua topologia, de uma forma genérica e mostrando como aplicar a ontologia DFCM na construção de modelos específicos.

O Capítulo 4 relata o desenvolvimento e modelagem da DFCM para a aplicação na área de Vida Artificial. Abordando a arquitetura utilizada para essa aplicação em específico, juntamente com sua máquina de estados, estratégia de controle (planejamento das ações) e o modelo DFCM proposto para VA. E, finalmente, apresenta e discute os resultados simulados com experimentos em ambientes virtuais.

O Capítulo 5 propõe o desenvolvimento de um modelo DFCM aplicado na área de Robótica de Enxame. Apresentando sua arquitetura, estratégia de navegação, máquina de estados, planejamento das ações e gerenciamento das mesmas. Os resultados apresentam o desempenho do DFCM em um ambiente com múltiplos objetivos, e compara dois métodos de compartilhamento de informações.

No Capítulo 6 são apresentadas as conclusões e discussões sobre os resultados obtidos, ressaltando a aplicação de DFCM como um sistema inteligente de navegação autônomo para tomada de decisões.

2 ESTADO DA ARTE

A área de sistemas computacionais inteligentes visa desenvolver métodos que tentam imitar ou aproximar as capacidades dos seres humanos para resolver problemas. Esses são capazes de tomar decisões por meio de aproximações com certo "grau de pertinência" das variáveis envolvidas nas tomadas de decisão. Por exemplo, se utiliza um equipamento de ar condicionado quando está "quente", no "começo da manhã" e quando o ar está "abafado". Estas variáveis linguísticas podem ser melhores descritas e manipuladas num conjunto *Fuzzy*. Assim, a Lógica *Fuzzy* é uma generalização da lógica clássica que permite incluir a imprecisão nos processos decisórios.

O termo "inteligência computacional" foi proposto por ZADEH (1992) para denominar um conjunto de métodos que visam explorar a tolerância às falhas, a imprecisão e a incerteza dos sistemas reais, proporcionando robustez e solução de baixo custo para aplicações de controle, reconhecimento de padrões, aproximação de funções, entre outras, em diversas áreas de conhecimento. Pode-se citar algumas metodologias de inteligência computacional:

- Sistemas *Fuzzy*, os quais utilizam modelos relacionais, sistemas baseados em regras do tipo Mamdani, Takagi-Sugeno-Kang e *Type-2 Fuzzy*;
- Raciocínio Probabilístico, teoria de Dempster-Shafer, Redes Bayesianas, Chow-Liu *tree*;
- Redes Semânticas, Mapas Mentais, *Spatial Networks*;
- Redes Neurais Artificiais, Máquinas de Aprendizado Extremo e *Echo State Networks*;
- Computação Evolutiva (Algoritmos Genéticos, programação evolutiva, programação genética e estratégia evolutiva);
- Agentes Inteligentes (Sistemas Multi-Agentes);
- Sistemas híbridos os quais são combinações de duas ou mais técnicas citadas acima. Essas combinações podem ser sequenciais (duas técnicas em série), auxiliares (técnicas para auxiliar outras técnicas/sistemas, como o uso de técnicas evolutivas para treinar uma rede neural) ou incorporadas (não havendo separação visível entre duas técnicas, como sistemas neuro-fuzzy).

Estes métodos buscam uma emulação da habilidade dos seres humanos de tratar informações de forma imprecisa por meio de termos linguísticos para lidar com processos complexos. Pode-se citar os FCMs como uma ferramenta inteligente para a abstração e modelagem do conhecimento humano, através de termos linguísticos, característica dos Sistemas *Fuzzy*, mas disposta em uma estrutura similar às Redes Neurais Artificiais (RNA), a qual facilita o tratamento de dados e possui capacidade de treinamento e adaptação.

Neste capítulo, as áreas pertinentes, as técnicas e métodos utilizados para o desenvolvimento do controlador proposto serão brevemente apresentados. Uma revisão da literatura focando em aplicações de mapas cognitivos, suas evoluções e adaptações, também é apresentada.

2.1 FUNDAMENTAÇÃO TEÓRICA

2.1.1 Mapas Cognitivos (CM)

Os Mapas Cognitivos (CM – *Cognitive Maps*) foram propostos por AXELROD (1976) para facilitar a visualização das relações causais entre os diversos fatores cognitivos do pensamento humano. Os CMs como proposto por Axerold usam variáveis binárias para modelar conceitos e ligações binárias para modelar as relações causais entre os conceitos, formando assim um grafo. MIAO *et al.* (2006) estabelecem que o CM pode ser visto como uma tupla:

$$(C_i, C_f, w_{if}) \quad (2.1)$$

Onde:

- C_i é o conceito de entrada.
- C_f é o conceito de saída.
- w_{if} é o peso do arco que liga os conceitos de entrada e saída. Com $w_{if} \in \{-1, +1\}$.

Em que -1 indica uma relação causal negativa e +1 representa uma relação causal positiva.

Baseado nas entradas casuais, a função de decisão dada em (2.2) altera o estado do conceito; entretanto, em CM, não há diferenciação entre intensidade das relações causais (os pesos são sempre unitários), o que o torna inadequado para aplicações de sistemas complexos.

$$f_{c_1}(u) = f_{c_1}\left(\sum_{j=1}^n w_{ij} * x_j\right) \quad (2.2)$$

2.1.2 Mapas Cognitivos *Fuzzy* (FCM)

Os Mapas Cognitivos *Fuzzy* (FCM – *Fuzzy Cognitive Maps*), introduzidos por KOSKO (1986), aparecem então como uma solução para o problema apresentado acima. Esse herda os conceitos dos CM adicionando valores *Fuzzy* para a distinção de intensidade das relações causais, isto é, os valores dos pesos em (2.1) são resultantes de um sistema *Fuzzy*.

Com essa evolução do CM, o FCM é capaz de modelar razoavelmente bem vários sistemas reais, tendo assim sua utilização em várias áreas, como entretenimento, automação, defesa e sistemas sociais. Porém, MIAO *et al.* (1999) apontam que o FCM tem dificuldade em modelar relações de causa e efeito em sistemas dinâmicos ou temporais, e, portanto, pode haver inferências contraditórias no FCM quando há uma modelagem de um sistema real complexo.

Assim como os Mapas Cognitivos de AXELROD (1976), o FCM representa palavras, ideias, tarefas ou outros itens ligados a um conceito central e dispostos radialmente em volta deste conceito, representando conexões entre informação sobre um tema ou tarefa. Os elementos são arranjados intuitivamente de acordo com a importância dos conceitos, organizados em grupos, ramificações ou áreas.

De outro modo, um FCM é um modelo de conhecimento representando a cognição dos seres humanos sobre o mundo externo. Essa ferramenta representa fatores como nós / vértices e suas relações causais como links / arcos entre os nós. A força das ligações causais é modelada com pesos. Cada fator pode ter um conjunto binário / ternário de estados, ou um conjunto de valores múltiplos de estados (YUAN e ZHI-QIANG, 2000). De fato, um FCM é um mapa do conhecimento, em que fatores de um problema são causalmente ligados para facilitar a tomada de decisão humana, e representados por grafos ponderados e direcionados (dígrafos), em que as variáveis envolvidas são números *Fuzzy* (KOSKO, 1986).

Um exemplo de um FCM é mostrado na Figura 2.1, o grafo identifica as respectivas conexões causais e os conceitos do mapa. Sua respectiva matriz de pesos é apresentada na equação (2.3).

$$W = \begin{bmatrix} 0 & w_{12} & 0 & w_{14} & 0 & w_{16} & w_{17} & w_{18} \\ w_{21} & 0 & w_{23} & w_{24} & 0 & w_{26} & w_{27} & 0 \\ w_{31} & w_{32} & 0 & 0 & 0 & 0 & 0 & 0 \\ w_{41} & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ w_{51} & w_{52} & 0 & 0 & 0 & 0 & 0 & 0 \\ w_{61} & w_{62} & 0 & 0 & 0 & 0 & 0 & 0 \\ w_{71} & w_{72} & 0 & 0 & 0 & 0 & 0 & 0 \\ w_{81} & w_{82} & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (2.3)$$

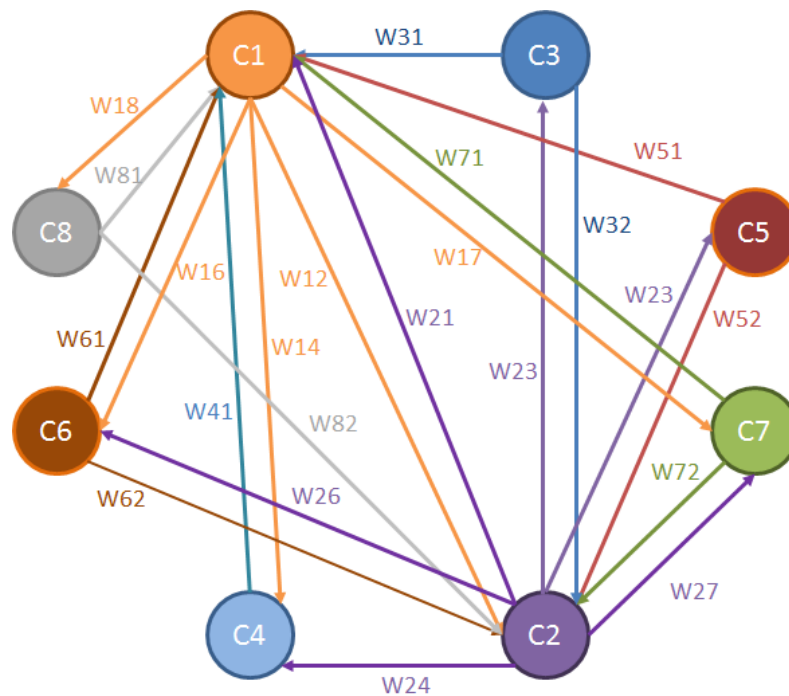


Figura 2.1 – Exemplo de um FCM clássico.
Fonte: (MENDONÇA *et al.*, 2015d)

De um modo geral, pode-se definir que o FCM é uma metodologia baseada na abstração do conhecimento para modelar a causalidade em sistemas complexos de decisão, originado a partir da combinação de Lógica *Fuzzy* e Mapas Cognitivos. Um FCM descreve o comportamento de um sistema desconhecido em termos de conceitos, cada conceito representa uma entidade, um estado, uma variável, ou uma característica do sistema (KOSKO, 1992).

Os Mapas Cognitivos *Fuzzy* usam uma representação simbólica para descrever e modelar um sistema, a qual utiliza conceitos para ilustrar diferentes comportamentos,

integrando a experiência de especialistas na construção do modelo. As construções dos FCMs podem ser feitas de forma manual, através do conhecimento dos especialistas, ou automática, através de técnicas de treinamento para o ajuste dos pesos (GLYKAS, 2010).

O trabalho de YESIL *et al.* (2013) sugere que um FCM não pode ser desenvolvido de forma manual quando:

- Não há um especialista para definir os conceitos da FCM;
- Há discrepância entre o conhecimento adquirido de vários especialistas, causando diferentes grafos para a modelagem por FCM;
- Quando houver um grande número de conceitos com relações causais entre eles, dificultando uma modelagem correta/precisa do grafo FCM;

Ressalta-se que para este trabalho, todos os FCMs desenvolvidos são manuais. A partir desses FCMs serão evoluídos os DFCM utilizando a ontologia proposta em MENDONÇA *et al.* (2014).

Como uma técnica computacional para modelagem do conhecimento causal, os FCMs são capazes de modelar sistemas complexos e podem ser aplicados em uma ampla gama de problemas de engenharia e áreas correlatas (PAPAGEORGIOU, 2012).

Nesse trabalho, é adotada uma representação formal do FCM apresentado por PEDRYCZ *et al.* (2005), no qual o Mapa Cognitivo *Fuzzy* é uma tupla, dada na equação (2.4), enquanto $K=[-1,1]$ e $L=[0,1]$.

$$(C, W, S, f) \tag{2.4}$$

$C = \{C_1, C_2 \dots C_n\}$ é o conjunto de n conceitos formando os nós de um grafo.

$W: (C_i, C_{jf}) \rightarrow w_{ij}$ É o peso que liga os conceitos de entrada e saída. Em FCM, w_{ij} é uma variável *Fuzzy* representando uma relação causal; $w_{ij} < 0$ indica uma relação causal negativa; $w_{ij} > 0$ indica uma relação causal positiva, e $\|w_{ij}\|$ é a intensidade da relação causal. Assim $W(CxC) = (w_{i,j}) \in K^{n \times n}$ é a matriz de conexões.

$S: C_i \rightarrow S_i$ é o grau de ativação de um conceito tal que $S(0)$ é o vetor inicial especificando os valores de todos os nós dos conceitos, e $S(t) \in L^n$ é um vetor de estados na “t” iteração.

$f: R \rightarrow L_i$ é a função de decisão, a qual inclui a relação recorrente de $t \geq 0$ entre $S(t+1)$ e $S(t)$.

A tomada de decisão do FCM ou função de inferência por nó é definida por f , apresentada pelas equações (2.5) e (2.6).

$$f(x_i) = f_c \left(\sum_{j=1}^n w_{ij} * x_j \right) \quad (2.5)$$

$$f_c(u) = \frac{1}{1 + e^{-\lambda u}} \quad (2.6)$$

Onde: f_c é a função de ativação do nó; x_j é o valor do conceito j ; w_{ij} é a relação causal ligando os conceitos “ i ” e “ j ”; λ é a taxa de aprendizado.

O uso de funções sigmoide que são continuamente diferenciáveis como em (2.5) e (2.6) definidas em um intervalo L garantem a estabilidade dos FCMs desenvolvidos (BOUTALIS *et al.* (2009). Uma análise sobre a estabilidade desse tipo de grafos foi apresentada no trabalho de BOUTALIS *et al.* (2008), usando a teoria de contração de mapeamento. De outra maneira, Kosko também examinou a estabilidade dos Mapas Associativos determinando uma função Lyapunov associada aos estados (KOSKO, 1988; MARTCHENKO *et al.*, 2003) do FCM. Como os modelos DFCMs utilizam o mesmo formalismo matemático do FCM, mas com sintonia dinâmica, a questão de estabilidade discutida se mantém. Assim, demonstrar a estabilidade dos modelos obtidos está além do escopo deste trabalho. No entanto resultados experimentais de simulação nos capítulos 4 e 5 sugerem a estabilidade dos modelos propostos.

A diferença fundamental entre um FCM e outras técnicas inteligentes que também podem ser consideradas grafos tais que redes neurais ou redes bayesianas é que todos os nós do grafo FCM têm uma semântica forte, os quais são definidos na modelagem dos conceitos. Em comparação, por exemplo, as Redes Neurais, onde os nós de entradas e saídas possuem uma semântica fraca, definidas apenas por relações matemáticas (RODIN *et al.*, 2009).

2.1.3 Mapas Cognitivos *Fuzzy* Dinâmicos (DFCM)

De forma resumida, os Mapas Cognitivos foram apresentados pela primeira vez por AXELROD (1976) usando um termo concebido por TOLMAN (1948), a fim de expressar as relações de causa e efeito dos elementos com valores binários em um ambiente. Por sua vez,

Mapas Cognitivos *Fuzzy* foram propostos por KOSKO (1986) para modelar eventos, valores e objetivos como um conjunto de conceitos interconectados por meio de relações causais *Fuzzy*, como uma ferramenta para construir modelos cognitivos,

Em uma forma gráfica, os FCMs são normalmente grafos ponderados *Fuzzy* e direcionados, geralmente envolvendo feedbacks, construídos através de conceitos (“nós”) e relações causais (“arcos”). Os nós representam conceitos comportamentais descritivos do sistema e os arcos representam relações de causa-efeito entre os conceitos.

Sua aplicação em diversas áreas do conhecimento, os quais são discutidos nas próximas subseções, juntamente com as características e vantagens herdadas de suas técnicas primárias sugerem que a modelagem FCM fornece métodos para abstração do conhecimento de uma forma simples e necessária para sua implementação em sistemas complexos.

Na última década, o FCM tem sido usado para resolver problemas de tomadas de decisões, incluindo problemas de tomadas de decisões robóticas que são caracterizados pela sua distributividade, necessidade de paralelismo e heterogeneidade (PAPAGEORGIU e SALMERON, 2013). Existem trabalhos que utilizam Mapas Cognitivos *Fuzzy* para desenvolver sistemas de navegação autônomos, em especial, podem-se citar os trabalhos de PIPE (1998), VASCAK e MADARASZ (2010), MENDONÇA *et al.* (2012), MOTLAGH *et al.* (2012a); MOTLAGH *et al.* (2012b) e PAL'A e MIZENKO (2012), que são diretamente relacionados à robótica móvel. Também se destaca o trabalho de SUBRAMANIAN e DAGLI (2003), que desenvolve um sistema baseado em FCM para robôs limpadores que trabalham cooperativamente, usando conhecimento heurístico para organizar e distribuir as tarefas a serem executadas, entre eles.

Um ponto comum dos trabalhos citados acima é que todos os modelos FCM propostos usam um mecanismo de aprendizagem para adaptação, levando em consideração às mudanças ambientais ou eventos inesperados. Neste contexto, essas variações do FCM com conceitos e relações variantes no tempo são Mapas Cognitivos *Fuzzy* Dinâmicos, ou adaptativos, na literatura citada.

Como uma evolução do FCM, o DFCM funciona de acordo com a complexidade do problema modelado. Para decisões em que ambiguidades estão envolvidas, mas sem uma precedência temporal entre eles, essa ferramenta se comporta como um FCM clássico em que as relações causais são conceitos *Fuzzy*, mas ainda considerando que todas as causalidades ocorrem simultaneamente. Um modelo DFCM pode dinamicamente mudar os valores das relações causais entre seus conceitos e / ou alterar a estrutura do grafo representando o sistema.

Além disso, também é possível adicionar ou excluir relações causais entre conceitos. Essas características torna o DFCM uma ferramenta sofisticada para a modelagem de sistemas dinâmicos não-lineares (MENDONÇA *et al.*, 2013a).

Como resultado dessas modificações, a matriz W da tupla (2.1) de um DFCM, é agora uma matriz variante no tempo em que os valores são calculados de acordo com a importância (nível) da característica modelada e com o tipo de relação. Cada peso nesta matriz pode também ser modelado como uma tupla:

$$(N, C_i, C_o, r, U, B_r) \quad (2.7)$$

Onde:

- N identifica a camada ou nível em que as relações pertencem, isto é, uma relação causal pura tem $N = 0$, uma vez que esta pertence ao menor nível da camada;
- C_i são os conceitos de entrada;
- C_o são os conceitos de saída;
- r é o tipo de relação, sendo uma relação causal, relação causal variante no tempo, relação *Fuzzy* ou uma relação de seleção (resultante da execução de uma base de regras);
- U descreve o universo discurso da relação, podendo representar um valor numérico, um intervalo (como no trabalho de PEDRYCZ *et al.* (2005)) ou uma variável linguística;
- B_r é o índice que representa a base de regras relevantes para a relação, assim uma relação puramente causal ou variante no tempo tem $B_r = 0$.

Deste modo, é possível identificar a partir do DFCM uma lista de atributos que indicam o papel de cada relacionamento do modelo, permitindo assim a construção formal do modelo. O seu desenvolvimento, mesmo para pequenos sistemas, requer uma grande quantidade de conceitos e relações que precisam ser estabelecidos, os quais dificultam um desenvolvimento manual do modelo. Para simplificar esse processo e permitir uma análise coerente dos mapas, estes modelos devem ser desenvolvidos de forma incremental, de acordo com os tipos de conexões de causa-efeito modelados, como proposto por CHAUVIN *et al.* (2008).

Nesse contexto, a modelagem através dos Mapas Cognitivos *Fuzzy* Dinâmicos oferece possibilidades mais amplas na gestão de estruturas e na modelagem de sistemas que apresentam não linearidades fortes e fenômenos temporais acentuados. Os valores das relações causais de um DFCM variam no tempo, de acordo com alguma função, permitindo a construção de modelos cognitivos dinâmicos naturalmente adaptativos, diferentemente do FCM em que os valores de pesos associados aos arcos são fixos.

Portanto, os DFCMs são mapas cognitivos que consideram os seguintes aspectos de uma relação causal:

1. A força da relação de causalidade;
2. A força da causa;
3. O grau de efeito.

Deste modo, as relações de causalidade em DFCMs diferem não apenas na duração do efeito provocado por uma determinada causa, mas também sobre como a causa gera o efeito. Os DFCMs têm a capacidade de modelar e gerenciar comportamentos não-lineares dependentes do tempo, muitas vezes em tempo real; porém, não existe uma solução fechada e ainda há um amplo espaço para modificações e atualizações dessa ferramenta ou de outras correlatas.

2.2 REVISÃO DE LITERATURA - MODELOS COGNITIVOS EM APLICAÇÕES GENÉRICAS

Desde o trabalho de KOSKO (1986), que incluiu a lógica *Fuzzy* nos Mapas Cognitivos de AXELROD (1976), várias aplicações do FCM são encontradas na literatura aplicados em diversas áreas, como vida artificial (DICKERSON e KOSKO, 1993; 1998), tomada de decisão (PERUSICH, 1996; LEE e LEE, 2003; PAPAGEORGIOU *et al.*, 2007) detecção de pontos em imagens geradas por sistema de câmeras estéreo (PAJARES e CRUZ, 2006), estudos sociais (JETTER e SCHWEINFORT, 2011; NEOCLEOUS e SCHIZAS, 2012; PRATT *et al.*, 2012), modelagem de emoções (JUN *et al.*, 2012), assistência médica (PAPAGEORGIOU *et al.*, 2007; AMIRKHANI *et al.*, 2012; GROUMPOS e ANNINO, 2012; PAPAGEORGIOU e FROELICH, 2012; WANG *et al.*, 2012; DOUALI *et al.*, 2013), comércio (SALOMON *et al.*, 2012; TABATABAYI *et al.*, 2012) e gestão (HAOLI e MINGJUN, 2012; GRAY *et al.*, 2013;

HWANG e LEE, 2013). Observa-se que, estes trabalhos também apresentam variações semânticas da proposta original de FCM, adaptando a estrutura do FCM de acordo com o problema tratado.

Um Mapa Cognitivo *Fuzzy* diferente do FCM de Kosko é apresentado em ZHI-QIANG e SATUR (1999) e denominado *Contextual Fuzzy Cognitive Maps* (CFCM). O modelo CFCM emprega dados de um sistema de informações geográfico e conhecimento qualitativo de especialistas. Essa arquitetura emprega relações modeladas por funções *Fuzzy* no mecanismo de inferência para auxílio em tomada de decisões em um sistema de predição geográfica.

O modelo de FCM apresentado em CARVALHO e TOME (2000) utiliza base de regras para a inferência *Fuzzy* entre as relações causais. Esta arquitetura é denominada RB-FCM (*Rule Based FCM*). De acordo com o autor, somente as relações causais entre os conceitos restringem a aplicação de FCM em sistemas dinâmicos. O uso de regras de inferência (SE-ENTÃO) entre as relações permite a tomada de decisões, alterando conceitos para diferentes pontos de operação ou para conectar vários FCM em diferentes níveis hierárquicos. Além disso, um autômato celular é utilizado para transição entre diferentes tipos de regras *Fuzzy* em diferentes cenários de um sistema dinâmico.

Um exemplo de evolução do FCM é apresentado no trabalho de JONES *et al.* (2004), no qual um sistema ANFIS (*Adaptive Neuro-Fuzzy Inference System*) é adicionado para inferência na modelagem das relações causais de um FCM. O FICM (*Fuzzy Inference Cognitive Maps*) emprega dois tipos de conceitos diferentes. Os conceitos e relações causais comumente utilizados na construção de FCMs e acrescenta conceitos auxiliares para a tomada de decisão.

No trabalho de MAKRINOS *et al.* (2007), é proposto uma abordagem clássica do FCM para desenvolver um modelo de simulação para a agricultura de precisão, o qual pode ser implementado para tomada de decisões, analisando três diferentes cenários para determinar a categoria da safra do algodão. O modelo é aplicado em três casos, e os resultados das simulações são comparadas com medições reais.

O controle hierárquico de um sistema de radioterapia, que calcula e decide a dosagem de radiação em pacientes com câncer é proposto em PAPAGEORGIU *et al.* (2007). O FCM de baixo nível é responsável pelo cálculo de três variáveis de saídas (fatores e seletores), as quais devem ser analisadas no nível superior. O FCM de alto nível atua como um sistema de tomada de decisão. As diferentes opções de ajuste entre os parâmetros dos fatores e seletores são feitas através de regras de decisão simples do tipo SE-ENTÃO. Observa-se que as inferências alteram os valores dos conceitos e não das relações causais previamente ajustadas de acordo com o conhecimento empírico do processo.

BUCHE *et al.* (2010) utilizam um FCM como ferramenta para modelar o comportamento de atores virtuais improvisando em interações livres, em um cenário com um pastor, um cão e ovelhas. O FCM modela o estado emocional de cada agente (como medo, satisfação, amor, ódio), e as ações são tomadas de acordo com o estado emocional e estímulos externos. Cada agente possui um mundo virtual e um imaginário, onde no mundo imaginário o ator tenta prever as ações dos outros atores, e então os pesos da FCM são refinados através de Aprendizagem por Reforço. O FCM usado neste trabalho é clássico, e possui um algoritmo diferencial adaptado de Aprendizagem de Hebb.

Em JETTER e SCHWEINFORT (2011), um FCM é utilizado para a construção de cenários, combinando técnicas intuitivas de mapeamento cognitivo com análise quantitativa; objetivando a auxiliar o planejamento de cenários através da integração do conhecimento qualitativo e parcial de múltiplos indivíduos, superando as limitações do processamento de informações. São apresentados dois cenários, ou estudos de caso, sobre painéis fotovoltaicos para casas residenciais.

No trabalho de ACAMPORA e LOIA (2011) é apresentado uma adaptação formal do FCM original de Kosko. Essa nova ferramenta é designada como TAFCM (*Timed Automata Fuzzy Cognitive Maps*) e depende de um modelo de granularidade temporal de duas camadas, onde a camada de baixo nível é baseada nos mecanismos temporais do FCM, como o *base time* (*B-time*), introduzida por CARVALHO (2002), enquanto que a camada superior propõe um novo mecanismo temporal denominado *top time* (*T-time*). Este age como um mecanismo de supervisão que explora os conceitos da camada inferior para suprir o FCM com novos mecanismos de temporização.

Um novo *framework* para a construção de FCM combinando diretrizes e o conhecimento de especialistas, e a partir de dados, através do uso de métodos de extração de regras, a fim de gerar regras *Fuzzy* significativas, é proposto por PAPAGEORGIOU (2011) para auxiliar nas tomadas de decisões na área médica. Esta ferramenta é aplicada a dois estudos de caso, radioterapia conformacional e tratamento de câncer de próstata.

FROELICH *et al.* (2012) aplicaram um FCM para a predição de câncer de próstata, considerando parâmetros que possibilita a predição em um horizonte longo. O FCM prediz o estado do paciente, após um período de tempo, seguindo um plano de tratamento sugerido para o indivíduo. O FCM é clássico, e, também, é proposta uma nova fórmula para o cálculo dos erros de predição, com o objetivo de melhorar a predição em longo prazo; o treinamento do FCM é feito por um RCGA (*Real-Coded Genetic Algorithm*).

Em seu trabalho, MOTLAGH *et al.* (2012a) utilizam um mecanismo de inferência causal baseado em Mapas Cognitivos *Fuzzy* (FCM) para controlar um robô móvel para resolver problemas de localização, levando em conta erros sequenciais e derrapagem das rodas. O trabalho busca apresentar também as vantagens do sistema FCM em relação às outras técnicas baseadas em regras. O sistema desenvolvido foi implementado em uma plataforma Pioneer. Os resultados e as comparações com os trabalhos relacionados são dados usando simulação ActivMedia e uma ferramenta de simulação desenvolvida para o FCM. Uma técnica de estimativa de erro é usada para medir o erro entre o real (FCM embarcado no robô móvel Pioneer) e os resultados simulados.

No trabalho de MENDONÇA *et al.* (2013a), um DFCM é aplicado a supervisão do controle de um reator de fermentação alcoólica. O DFCM possui um algoritmo de Aprendizagem por Reforço para sintonia dinâmica dos pesos, e gera dinamicamente os *setpoints* de operação para o controlador PID em resposta às mudanças nas variáveis do processo, em condições normais e críticas. Simulações são apresentadas comparando o sistema supervisorio proposto e um controle PID clássico.

O trabalho de KOTTAS *et al.* (2015) apresenta uma FCN (*Fuzzy Cognitive Networks*), uma evolução de FCM, para o controle de uma pequena *smart grid*, termo caracterizado para uma rede elétrica moderna usando sistemas computacionais de controle remoto e automação. Essa rede é composta por dois painéis fotovoltaicos, um banco de baterias, um gerador eólico e cinco cargas. A rede FCN objetiva a previsão e execução das ações necessárias para o fornecimento de diferentes serviços auxiliares à rede, tais como rápida compensação da potência ativa, tensão e regulação de frequência, *back-up* de alimentação; usando dados meteorológicos e estimando uma previsão de 15min da potência que os geradores terão de fornecer.

A aplicação de um FCM para a avaliação de riscos da terceirização da manutenção, é apresentado no trabalho de JAMSHIDI *et al.* (2015), como uma ferramenta de suporte para decisão, auxiliando na terceirização da manutenção, considerando as inter-relações entre os fatores de riscos (como cronograma, qualidade, flexibilidade, entre outros) e suas consequências.

No trabalho de MENDONÇA *et al.* (2015d) um FCM é modelado por meio de conhecimento de especialistas para avaliar quantitativamente o nível de satisfação dos discentes de uma universidade, considerando características como capacitação, estrutura, moradia, limpeza, entre outros.

O trabalho de MENDONÇA e ARRUDA (2015) inspirou a construção do modelo de uma DCN, evolução do clássico FCM, como uma ferramenta inteligente que utiliza uma base de conhecimento qualitativa com tomadas de decisões, através de bases de regras e relações de causa e efeito. Em um trabalho correlato, uma DCN, é desenvolvida por MENDONÇA *et al.* (2015c) para aplicação em navegação autônoma. Um algoritmo de Aprendizagem por Reforço é utilizado para sintonizar os pesos da DCN, o qual controla e gerencia as ações de um agente móvel em um ambiente parcialmente desconhecido, desviando de obstáculos e capturando alvos.

Os trabalhos citados acima apresentam diferentes propostas de evolução para os Mapas Cognitivos *Fuzzy* e/ou combinações destes com outros modelos/técnicas, buscando o desenvolvimento de uma ferramenta eficiente para criação de modelos cognitivos inteligentes para o auxílio e/ou tomada de decisões em ambientes dinâmicos ou não. Nesse contexto, essa dissertação propõe o uso de uma arquitetura de controle, inspirada na arquitetura de subsunção proposta por BROOKS (1986), para a hierarquização das ações tomadas pela inferência FCM, através da adição de novos tipos de conceito no modelo cognitivo FCM original.

2.2.1 Revisão de trabalhos correlatos ao tema de sistemas autônomos e métodos de aprendizagem

Os trabalhos citados a seguir são exemplos de FCM aplicados em navegação cooperativa, tomada de decisões, navegação robótica, entre outros tópicos relacionados ao presente trabalho.

AZOUAOUI *et al.* (2005) apresentam uma abordagem para navegação autônoma em grupo baseado em Aprendizagem por Reforço, e implementado em simulações para o controle de múltiplos robôs autônomos (*ARS – Autonomous Robotic Systems*) para navegação em formação de círculo.

No trabalho de CALVO (2007) é apresentada uma arquitetura híbrida inteligente para um sistema de navegação autônomo. Esse sistema tem como objetivo alcançar alvos, ou pontos metas, em ambientes desconhecidos. Sua arquitetura é baseada em Redes Neurais Artificiais e lógica *Fuzzy*, juntamente com um Aprendizado por Reforço (AR), baseado na lei de Hebb, que pondera os comportamentos inatos conflitantes ajustando os pesos sinápticos das redes neurais nos instantes de captura do alvo e colisão. Seu sistema é validado através de simulações em

ambiente real através da implementação desse sistema no simulador *Saphira*, ambiente de simulação que acompanha o robô Pioneer I.

Para controlar um time de futebol de robôs, NASCIMENTO e BRITO (2007) emprega Redes de Petri para abordar as estratégias utilizadas nos controles desses agentes cooperativos. As estratégias de um futebol de robôs são divididas em três grandes estratégias básicas: goleiro, defesa e ataque. Um sistema *Fuzzy* mapeado como Rede de Petri, decide o tipo de estratégia que irão adotar, onde a ação de cada agente depende tanto da reação de outro agente, quanto da cooperação dos demais.

O trabalho de COSTA e GOUVEA (2010) destaca a importância do aprendizado para navegação autônoma e propõe dois métodos de Aprendizado por Reforço, *Q-Learning* e *Q-Learning with heuristic*. Sua proposta tem como objetivo otimizar a performance do agente em consideração as tarefas dadas a ele.

No trabalho de GOLMOHAMMADI *et al.* (2006) é utilizado um FCM para controlar as ações tomadas por um time de robôs autônomos. Esse FCM possui uma adaptação do Algoritmo de Hebb para sintonizar os pesos do FCM, auxiliando na tomada de decisões dos agentes. Este método proposto (ARMAN modificado) foi comparado a dois outros métodos (ARMAN original e ARIA) através de simulações na plataforma *RoboCup 3D Simulated Soccer League*.

O trabalho de MOHAN e PONNAMBALAM (2009) apresenta uma revisão de diversos sistemas inteligentes bio-inspirados para controle e cooperação de robôs autônomos em diversas aplicações. Em MENDONÇA *et al.* (2012) foi desenvolvido um sistema de navegação autônoma utilizando Mapas Cognitivos *Fuzzy* (FCM). Uma nova variante do FCM, chamado *Event DriveFuzzy Cognitive Maps* é proposta para modelar tarefas de decisão e / ou fazer inferências em navegação autônoma a partir da ocorrência de eventos. Um sistema de navegação baseado em *Fuzzy* é usado como uma referência para avaliar o desempenho do sistema de navegação autônoma proposto.

O trabalho GANGANATH *et al.* (2013) propõe um Mapa Cognitivo *Fuzzy* (FCM) com base na avaliação da situação (SAF - *Situation Assessment Framework*) para a detecção de um alvo para um robô móvel. Um determinado objetivo de navegação é descrito com várias submetas utilizando conhecimento prévio. Com base nessas submetas, a SAF proposta opera de forma recursiva sobre a meta de navegação para verificar e selecionar essas submetas. O sistema de tomada de decisão combina informação sensorial a partir de múltiplos sensores para verificar as submetas. O FCM é usado como um motor de raciocínio de alto nível. Resultados experimentais demonstram que o quadro proposto pode decidir com precisão as metas de

navegação em ambientes desconhecidos com base na informação sensorial e conhecimento especializado (GANGANATH *et al* 2013).

Uma comparação entre duas abordagens, HD-FCM (*Hybrid Dynamic-Fuzzy Cognitive Maps*) e HWF (*Hierarchical Weighted Fuzzy*), aplicados em sistemas de navegação autônomo é apresentado por MENDONÇA *et al.* (2015b). A primeira possui dois modelos cognitivos, ambos implementados com um algoritmo de Aprendizagem de Hebb; já a segunda é composta por bases de regras *Fuzzy* para navegação. Em ambas abordagens, uma máquina de estados controla a comutação entre os dois modelos cognitivos, ou base de regras.

GONG *et al.* (2016) apresentam uma abordagem para modelar a tomada de decisões na ultrapassagem de veículos em uma autoestrada, objetivando sua aplicação na condução autônoma. As tomadas de decisões são processadas por uma Máquina de Estados Hierárquico (HSM – *Hierarchy State Machine*) através de informações recebidas por sensores, como mapa da estrada, distâncias e velocidades relativas aos veículos nas proximidades. Juntamente com uma RBFNN (*Radial Base Function Neural Network*) para determinar a intenção de ultrapassar, treinado a partir de dados de condutores humanos.

Uma comparação entre métodos de treinamento para FCM aplicados em navegação autônoma é apresentado por VASCAK e MADARASZ (2010). Esses métodos de treinamento são baseados em adaptações da Aprendizagem de Hebb, *Least Mean Squares* e por especialistas. A comparação destes são feitas através da análise do desempenho da implementação dos FCMs no simulador ODE (*Open Dynamics Engine*) para guiar um agente móvel a um ponto final (ou alvo) no ambiente.

O trabalho de revisão de PAPAGEORGIU (2012) discute as várias técnicas de aprendizagem para FCMs, categorizando-as em três grandes grupos com base em seus paradigmas de aprendizagem: aprendizado de Hebb, sistema populacional e sistemas híbridos, que combinam algoritmos dos dois grupos anteriores.

VASSILIKI e GROUMPOS (2016) aplicam um FCM com um método de treinamento que é uma adaptação da Aprendizagem de Hebb não-linear, para automatizar o controle de um prédio, objetivando a adequação satisfatória de um ambiente a seus usuários e a diminuição do consumo de energia do mesmo.

O trabalho de ACAMPORA e LOIA (2011), no qual utiliza um FCM com conceitos de Sistemas Multi-Agentes aplicados em sistemas AmI (*Ambient Intelligence*), os quais são *frameworks* computacionais capazes de integrar computação em um ambiente com vida, a fim de permitir que as pessoas/agentes desse ambiente, possam se movimentar e interagir com o mesmo de uma forma mais natural do que já fazem atualmente.

O trabalho de SALMERON (2012) propõe um Mapa Cognitivos *Fuzzy* (FCM) como ferramenta para a previsão de emoções artificiais em sistemas autônomos, imersos em ambientes complexos com elevado grau de incerteza. A saída desse FCM é mapeada pelo modelo emocional de Thayer (análise do humor como um conceito biopsicológico), dentro de um espaço emocional. Esse modelo define as categorias de emoção em um plano cartesiano de coordenadas de acordo com a sua valência e excitação.

Dos trabalhos expostos acima, existem diferentes métodos de treinamento, de aprendizagem de máquina e/ou técnicas inteligentes que podem ser combinadas ao modelo clássico FCM, objetivando atenuar ou mesmo eliminar suas restrições e permitindo uma adaptação do modelo cognitivo. Dessa forma, para essa dissertação, um método de aprendizado é implementado para a sintonia dinâmica dos pesos do FCM e inclusão de novos tipos de regras ao mesmo. Com isto, o modelo cognitivo é capaz de adaptar-se dinamicamente e aprender com sua interação com o meio ambiente.

2.3 SISTEMAS MULTI-AGENTES E AGENTES INTELIGENTES

RODIN *et al.* (2009), em seu trabalho, relataram que os primeiros estudos de Sistemas Multi-Agentes (SMA) são datados dos anos 80. Os quais foram justificados pela seguinte observação “Existem sistemas na natureza, que são capazes de realizar tarefas complexas e de forma coletiva em um ambiente dinâmico sem controle externo ou coordenação centralizada” (TISSEAU, 2001).

De acordo com WOOLDRIDGE e JENNINGS (1995), um "agente" é definido como sendo um sistema de computador que está situado em um ambiente, e que este agente é capaz de tomar decisões e inferir ações, sem interferência externa, a fim de completar as tarefas delegadas a eles. No entanto, dificilmente um agente terá o completo controle sobre seu ambiente. Do ponto de vista do agente, se uma mesma ação ocorrer duas vezes sobre iguais circunstâncias, os resultados poderão ser inteiramente diferentes, podendo levar ao não cumprimento de seu objetivo. Além disto, um agente deve estar preparado para a possibilidade de falha até em ambientes triviais. De modo resumido, um agente deve ter capacidade de agir e tomar decisões, independente de um programador ou do usuário, considerando as condições do ambiente em que está inserido. Para realizar tal feito, estes autores definiram dois tipos de atributos ou habilidades para um agente: fracos e fortes. Primeiramente, os atributos fracos são:

- **Autonomia:** agentes operam sem a intervenção direta dos seres humanos ou outros sistemas, e possuem algum tipo de controle sobre suas ações e estados internos;
- **Iniciativa:** agentes não só agem em resposta aos seus ambientes, mas são capazes de exibir comportamento orientado a objetivos;
- **Habilidade social:** comunicação direta ou indireta entre agentes;
- **Reatividade:** percepção de seu ambiente e respostas às mudanças que ocorrem no ambiente.

Em segundo lugar, os atributos fortes são:

- **Mobilidade:** a capacidade de um agente para se movimentar no cenário;
- **Benevolência:** a suposição de que os agentes não têm objetivos conflitantes, e que cada agente vai sempre tentar fazer o que é pedido dele;
- **Racionalidade:** a suposição de que um agente vai agir, a fim de atingir os seus objetivos, e não agir de forma a evitar os objetivos a serem alcançados;
- **Adaptabilidade:** a capacidade de um agente para se adaptar a mudanças inesperadas no cenário, enquanto age para atingir seus objetivos;
- **A colaboração:** a capacidade de um agente para transmitir informação direta ou indiretamente a outro agente.

Da teoria de sistemas autônomos, a autonomia entre agentes cooperativos é uma das características principais dos sistemas multi-agentes (SMA), ou seja, a capacidade do agente para execução de tarefas de forma isolada e/ou em grupo para alcançar seus objetivos sem intervenção humana. Em complemento, BRAGA e PEREIRA (2001) destacam que se além da capacidade de autonomia e cooperação, um agente possuir a habilidade de aprender com a interação com o ambiente, atributo este que vai além da adaptabilidade, um agente pode ser considerado inteligente. Na Figura 2.2, ilustra-se como um agente inteligente, denominado por estes autores de agentes de aprendizado colaborativo são classificados em relação aos demais agentes.

De um modo geral, os agentes inteligentes executam continuamente três funções: percebem as condições dinâmicas do ambiente, agem alterando as condições do ambiente e

raciocinam de modo a interpretar percepções, resolver problemas, fazer inferências e determinar ações (GUDWIN, 2002).

Além dos atributos acima citados, o termo "inteligência coletiva" tem sido encontrado na literatura de Sistemas Multi-agentes (SMA) e refere-se a comportamentos coletivos sofisticados que podem surgir a partir da combinação de múltiplos agentes com comportamento e ações relativamente simples, cada um operando de forma autônoma.

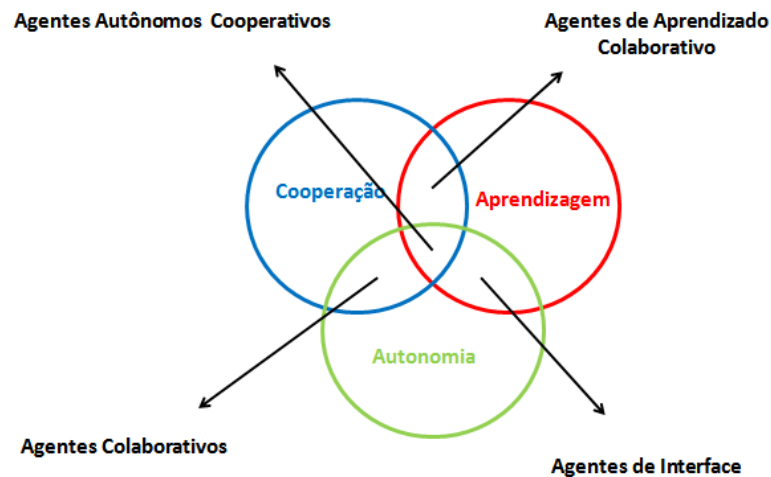


Figura 2.2 – Classificação de agentes quanto à ênfase dada a alguns atributos primários
Fonte: adaptado de (BRAGA e PEREIRA, 2001)

Porém, dotar agentes com inteligência não é uma tarefa trivial. Robôs e / ou agentes treinados com baixo nível de capacidade cognitivas não podem lidar com tarefas sofisticadas que requerem o uso intensivo da representação do conhecimento. Para superar esses desafios, novas metodologias surgem conciliando diferentes técnicas e ferramentas, possibilitando que estes agentes apresentem capacidades cognitivas.

O desenvolvimento de Sistemas Multi-Agentes, incluindo múltiplos robôs com inteligência coletiva, é uma nova área de pesquisa denominada como *Swarm Robotics*, ou Robótica de Enxame (ESPELOSÍN *et al.*, 2012). Este difere dos SMAs clássicos devido às suas estruturas de comando e controle, não-hierárquica e não-centralizada. No entanto, assim como Sistemas Multi-Agentes, os sistemas de Robótica do Enxame são distribuídos, auto organizados e podem ser inspirados pelo comportamento coletivo de colônias de insetos sociais e outros animais (BONABEAU *et al.*, 1999).

2.4 FUNDAMENTOS DE ROBÓTICA DE ENXAME

Robótica de Enxame, ou *Swarm Robotics*, é uma abordagem para a coordenação de vários robôs de funcionamento relativamente simples. De acordo com BAYINDIR e SAHIN (2007) esta abordagem tem como inspiração um sistema de nível funcional de uma comunidade de insetos, os quais demonstram três características desejadas para Sistemas Multi-Agentes:

- **Robustez:** Pode ser definido como o grau no qual o sistema pode operar na presença de falhas parciais ou outras condições anormais. Comunidades de insetos são altamente robustas e seu sistema auto organizável funciona mesmo após a perda de vários dos seus componentes ou a mudança considerável de parâmetros ambientais nos quais estão inseridos;
- **Flexibilidade:** É a capacidade de adaptação ao novo, diferente ou mudança nos requerimentos do ambiente. Flexibilidade e robustez têm definições parcialmente contraditórias. Quando um problema surge, o sistema tem que ser suficientemente flexível (e não robusto) para mudar seu comportamento a fim de resolver este novo problema. Os sistemas biológicos têm esse nível de flexibilidade e podem mudar seu comportamento quando há problemas. Por exemplo, as colônias de formigas possuem uma boa flexibilidade, os quais podem resolver o problema de forrageamento, recuperar alimento e de formação de cadeias, com o mesmo mecanismo base auto-organizado;
- **Escalabilidade:** Pode ser definida como a habilidade de expansão do sistema para suportar um maior ou menor número de indivíduos sem afetar significativamente o desempenho deste sistema. Embora não haja um intervalo no qual a comunidade realiza seus objetivos em um nível de desempenho aceitável, é preferido que este intervalo seja o maior possível.

Em seu trabalho, DE CASTRO (2007) relata que o comportamento coletivo de insetos sociais tem semelhança com uma composição de simples agentes (formigas, abelhas, vespas, cupins entre outros). O comportamento coletivo pode aumentar a capacidade desses insetos na solução de tarefas mais sofisticadas ou mais complexas, como a determinação de um caminho para busca de alimentos, onde somente um inseto pode não ter sucesso. Enquanto que com o compartilhamento de informações uma solução pode ser encontrada. Essa é uma clássica argumentação de inteligência coletiva, na qual a capacidade de vários agentes é potencializada e permite soluções mais complexas.

De acordo com MOHAN e PONNAMBALAM (2009), pode-se observar as seguintes características quanto à implementação de *Swarm Robotics*:

- Algumas tarefas podem ser inerentemente mais complexas a ponto de não serem resolvidas por um único agente;
- Benefícios de desempenho podem ser amplificados quando se utiliza um time de robôs. Como por exemplo, a coleta de lixo pode ser muito mais rápida caso seja executada por um grupo de robôs e não somente um agente;
- O progresso da robótica móvel nos últimos anos facilitou a implementação de grupos de robôs;
- A área de pesquisa voltada para a vida artificial também se utiliza dos conceitos biológicos de cooperação e comportamento coletivo, em especial vida social de insetos.

As ações coletivas que podem ser executadas sem intervenção humana por um enxame robótico, inserido em um ambiente dinâmico e imprevisível, podem ser sintetizadas em três áreas principais: a organização espacial, navegação e tomadas de decisões coletivas.

As ações de organização espacial estão relacionadas com a agregação ou agrupamento de tarefas (TRIANNI *et al.*, 2003), formação de padrões (SHUCKER e BENNETT, 2007) e formação de cadeia (SPERATI *et al.*, 2011).

As ações de navegação consideram a exploração coletiva (DUCATELLE *et al.*, 2011), o movimento coordenado (CAMPO *et al.*, 2006) e o transporte coletivo (KUBE e BONABEAU, 2000). E finalmente, as tomadas de decisões coletivas estão relacionadas com a obtenção de consenso (OCA *et al.*, 2010) e alocação de tarefas (PINI *et al.*, 2011).

Geralmente, a consolidação de uma inteligência coletiva de um enxame robótico depende do compartilhamento bem-sucedido de informações sobre o problema, o ambiente e / ou as tarefas a serem executadas entre os agentes (ESPELOSÍN *et al.*, 2012). Esse compartilhamento pode ser tratado de forma centralizada, onde a informação é gravada em uma memória primária que seja acessível aos outros agentes. Também, pode ser tratada de uma forma descentralizada, em que cada agente possui uma memória (ou experiência) independente e compartilha essas informações através de protocolos específicos.

Portanto, quando uma tarefa requer cooperação, há uma necessidade de alguma forma de comunicação entre os agentes. Na literatura, dois tipos de distinções são feitos relacionados

ao tipo de comunicação, implícito e explícito. O método implícito de comunicação é feito através de forma indireta, como, por exemplo, através de uma memória comum disponível no ambiente.

Na comunicação explícita o agente transmite a informação diretamente para outro agente e/ou para um operador. MCPARTLAND *et al.* (2005) comparam o compartilhamento de informações de forma implícita e explícita, aplicando-os em dois sistemas de navegação cooperativo, baseado no tempo de exploração. O trabalho HAYES *et al.* (2003) descreve um algoritmo distribuído para localização de odores, e mostra que o desempenho do grupo utilizando comunicação explícita, pode ser maior que a de um único agente.

Outros trabalhos relacionados à Robótica de Enxame podem ser encontrados na literatura, como por exemplo, o trabalho de BARTH (2003), que desenvolve um algoritmo dinâmico baseado em um método de busca e captura que fornece regras locais para a navegação entre agentes, tendo como objetivo a localização de um alvo fixo em um ambiente complexo desconhecido, através de relés fixos de marcação.

O trabalho de PAYTON *et al.* (2001) apresenta uma técnica para coordenação de ações de um grande grupo de pequenos robôs, com o objetivo de alcançar maiores resultados, podendo ser utilizado nas áreas de segurança, reconhecimento, detecção de lugares perigosos e encontrar trajetórias. Eles exploram um conceito inspirado na noção biológica de “feromônio virtual”, utilizando *transceivers* montados no topo de cada robô, os quais são equipados com 8 transmissores e 8 emissores infravermelho. Isso permite que os grupos de robôs se tornem uma malha de computação distribuída dentro do próprio ambiente, ao mesmo tempo atuando como uma personificação física da interface do usuário. Essa metodologia é embarcada em vários robôs autônomos que tem como tarefa encontrar o caminho entre duas coordenadas do ambiente. Para a simulação do feromônio, três informações são codificadas e transmitidas, o tipo de feromônio, o qual determina o tipo de relação do agente com o ambiente, quantidade de retransmissões, informando quantas vezes o feromônio foi retransmitido, e dado do ambiente, podendo ser usado para transmitir alguns bytes de informações.

LABELLA *et al.* (2006) analisaram o comportamento de um grupo de robôs envolvidos na tarefa de recuperação de um objeto, onde o modelo do sistema de controle é inspirado no comportamento de forrageamento das formigas. As tarefas designadas para os robôs foram extraídas de comportamentos simples da colônia de formigas, tais como busca, recuperação, retorno e descanso. De modo similar, PAYTON *et al.* (2003) e CAZANGI *et al.* (2005) usam feromônios para modelar um mecanismo de comunicação entre robôs.

TOMLINSON e BLUMBERG (2002) desenvolveram um SMA virtual interativo baseado no comportamento da matilha de lobos cinzas (*Canis lupus*). Os lobos virtuais são capazes de se relacionar com outros lobos virtuais através de um mecanismo de formação de relações sociais que abrange o comportamento de emoções, percepção e aprendizado.

No trabalho de FONG *et al.* (2002), uma proposta de modelagem de robôs baseada na interação social humana foi apresentada, juntamente com uma revisão sobre a sociabilidade entre robôs.

Outro exemplo de comunicação pode ser encontrado no trabalho de DUCATELLE *et al.* (2011), que é baseado em algoritmos de navegação cooperativa para *Swarm Robotics*. O sistema de navegação utiliza algoritmos de roteamento similar às redes móveis *ad hoc* (MANET – *Mobile Ad hoc Network*). A ideia geral é que os robôs do enxame, ou grupo, possuam uma tabela com dados de navegação sobre todos os robôs conhecidos no ambiente, similar aos nós da rede MANET, para manter a tabela de roteamento atualizada. Cada robô, periodicamente, transmite o conteúdo da sua tabela para os seus vizinhos, para que a informação se espalhe através de todo o enxame. São utilizadas duas situações para validar sua proposta, guiar um robô até um ponto específico e a navegação dos robôs entre dois alvos.

Neste contexto, este trabalho desenvolve um controlador inteligente para tomadas de decisões aplicadas em navegação autônoma, apresentando capacidade de aprendizagem, sintonia online, auto-adaptação e gestão de comportamentos. Esse sistema de navegação deve suportar o desenvolvimento de aplicações em Robótica de Enxame. Para isso, uma estratégia de controle descentralizada é implementada, de modo a que cada agente possua um controlador independente capaz de inferir com informações compartilhadas de outros agentes, a fim de emular uma inteligência coletiva. Algoritmos Bio-inspirados são utilizados para o compartilhamento de informações, possibilitando aos agentes uma melhor realização das tarefas ou objetivos.

2.5 FUNDAMENTOS DE VIDA ARTIFICIAL

Os avanços de sistemas inteligentes, computação gráfica e tecnologia de hardware (tais como maior capacidade de processamento e memória) permitiram um rápido desenvolvimento da área de animação computacional, podendo ser aplicado na indústria de entretenimento, jogos, realidade virtual, e também na área de educação, como ferramentas para o ensino de

biologia, o treinamento do esporte e simulação do comportamento de Vida Artificial (um dos escopos deste trabalho) através de simulações computacionais.

De modo geral, Vida Artificial (LANGTON, 1997; BEDAU, 2007), Robótica Cognitiva (NOLFI e FLOREANO, 2000), *Animals* (DEAN *et al.*, 1998), Neuroetologia Computacional (CLIFF, 2002) e Etiologia Sintética (MACLENNAN, 2002) são as principais áreas envolvidas na síntese de criaturas artificiais / atores em sistemas sintéticos. Em pesquisas recentes, a Robótica Evolucionária (*Evolutionary Robotics - ER*) investiga a aplicação de evolução artificial para a síntese de robôs com comportamentos autônomos (NELSON, 2014).

Neste contexto, a Vida Artificial requer metodologias rigorosas e explícitas para representação do conhecimento e planejamento para tomadas de decisões. Outro desafio dessa área está relacionado com o realismo físico dos agentes, os quais não podem ser garantidos (BAN *et al.*, 2009). Existem diferentes estudos que abordam os processos naturais que caracterizam a vida, abordagens *bottom-up* tentam criar processos emergentes que podem ser identificados com o conceito de vida (LANGTON, 1997).

Existem também abordagens *top-down* que buscam inspiração em criaturas vivas para modelar sistemas artificiais em que a Vida Artificial pode ser sintetizada (DEAN *et al.*, 1998). Métodos de VA são usados para simular muitos dos processos naturais que caracterizam os seres vivos, como o crescimento, reprodução, evolução, morfogênese, adaptação, percepção, aprendizagem e cognição (CHARNIAK e MCDERMOTT, 1985; BENTLEY, 1999). Especialmente, as simulações em um ambiente virtual contribuem para o estudo de VA em diversos tópicos, permitindo que através de recursos visuais sofisticados e interativos, uma melhor compreensão dos processos. Assim, os personagens podem ser capazes de evoluir e reproduzir artificialmente, aprender, comunicar e tomar decisões de forma autônoma.

Outros exemplos podem ser encontrados na literatura, como o trabalho de NACHÁZEL (2015), o qual apresenta a modelagem de um controlador para criaturas virtuais em um ambiente multi-agente. Os comportamentos da criatura abrangem comida, água, perigo e fuga. Um FCM com AHP (*Analytic Hierarchy Process*) é desenvolvido para o controle do comportamento, de forma independente. O FCM é utilizado para inferir as ações a serem executadas pela criatura, enquanto o AHP gerencia as tomadas de decisões, escolhendo qual comportamento deve ser executado.

Nesse contexto, a metodologia para o desenvolvimento do controlador DFCM proposto deve suportar aplicações na área de Vida Artificial, no qual possui pontos semelhantes à Robótica de Exame (apresentado na subseção anterior), sendo que para ambas aplicações os

agentes ou criaturas devem navegar de forma autônoma, tomando decisões sequenciais para atingir os objetivos.

3 SISTEMA AUTÔNOMO BASEADO EM DFCM

Este capítulo apresenta arquitetura implementada para o desenvolvimento do sistema de navegação autônomo baseado em DFCM, a qual é disposta em forma de camadas hierárquicas para o gerenciamento de ações do agente, inspirado na Arquitetura de subsunção de BROOKS (1986). Também, é abordado os passos para o desenvolvimento do um DFCM seguindo a ontologia proposta por MENDONÇA e ARRUDA (2015). Para uma melhor adaptação do sistema de uma forma dinâmica, visando contornar as dificuldades inerentes do FCM clássico, um método de aprendizado de máquina é apresentado para a sintonia dos pesos da DFCM ao longo do tempo. Também é apresentado a metodologia, através de um pseudocódigo, para compartilhar informações, implementado na aplicação de robótica de enxame.

3.1 ARQUITETURA DE AGENTES

Um tópico importante correlato ao desenvolvimento de sistemas Multi-Agentes está nos diferentes tipos de arquiteturas que podem ser idealizadas para a implementação, gerenciamento e controle dos agentes no ambiente. Entende-se que a arquitetura do SMA em geral e a arquitetura dos agentes propriamente ditos, é um conjunto de especificações e técnicas utilizadas para a definição funcional deste.

Um sistema de controle para um agente autônomo deve realizar o processamento de várias informações complexas e a arquitetura em que ele é implementado deve suportar tal processamento. O agente opera em um ambiente onde as condições limites podem mudar rapidamente, como detecção de um obstáculo móvel se aproximando enquanto o agente executa manobras para coleta de um alvo na mesma direção, inferindo assim decisões contraditórias. Uma das abordagens para o desenvolvimento de um sistema de controle autônomo para agentes móveis é a decomposição do problema em uma série de subproblemas, sua ordenação em camadas (hierárquicas ou não), e resolução de cada subproblema. Este tipo de arquitetura é denominado de Subsunção e foi proposta por BROOKS (1986).

A Figura 3.1 apresenta essa decomposição do problema em módulos funcionais, de um sistema autônomo genérico para um robô móvel. Os módulos funcionais são dispostos em níveis de planejamento ou funcionamento do robô móvel autônomo, formando uma cadeia de informação que segue do ambiente para o robô, através do sensoriamento, e do robô para o

ambiente, através de ações, fechando o *loop* de controle do agente. Pode-se então, como descrito acima, decompor o problema de acordo com os comportamentos, ou um sub-conjunto destes, desejados para um agente (como comportamentos simples: desviar de obstáculos, coletar alvos, e navegar; e comportamentos mais complexos: explorar, identificar objetos para coleta, entre outros) e organizá-los em níveis de competência (ou prioridade).

O objetivo na hierarquização dos comportamentos do agente é permitir o desenvolvimento de camadas de controle, correspondentes a cada nível de prioridade, e adicionar uma nova camada sobre a anterior, seguindo de comportamentos mais simples para comportamentos mais sofisticados, no qual as camadas de níveis superiores possam gerenciar e/ou interferir nas de níveis inferiores. De forma resumida, o desenvolvimento do agente ou robô autônomo passa a ser de forma incremental, implementando primeiramente comportamentos reativos, camadas de baixo nível, em direção aos deliberativos, camadas de alto nível.

Dessa forma, a arquitetura de subsunção permite a representação, modelagem, e implementação do comportamento e ações de controles do sistema de forma hierárquica, com as seguintes características (MENDONÇA *et al.*, 2013b):

- As tarefas são priorizadas de acordo com a heurística de operação do sistema;
- A heurística de controle é baseada na situação-ação do agente; gerenciamento de um conjunto de ações necessárias para o cumprimento dos objetivos ou tarefas;
- Gerenciamento das ações de forma paralela, ou seja, dois ou mais comportamentos podem ser acionados simultaneamente, necessitando de um mecanismo de escolha para decidir qual ação deverá realmente ser executada.

Portanto, a hierarquização dos comportamentos possibilita o planejamento e resolução de ações conflitantes de uma forma simples, permitindo que as camadas de baixo nível inibam as camadas de alto nível.

A Figura 3.2 apresenta uma decomposição baseada em comportamentos do robô ou agente para o mesmo sistema autônomo da Figura 3.1. As tomadas de decisões para uma arquitetura baseada em comportamentos devem funcionar em paralelo, e o sistema deve ser capaz de tomar decisões relacionadas a comportamentos humanos como “raciocinar sobre o comportamento de objetos” e “explorar” o ambiente.

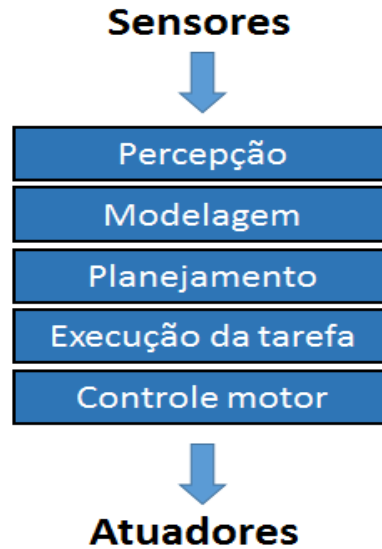


Figura 3.1 – Decomposição tradicional de um sistema de controle de robôs móveis em módulos funcionais.
Fonte: Adaptado de BROOKS (1986)

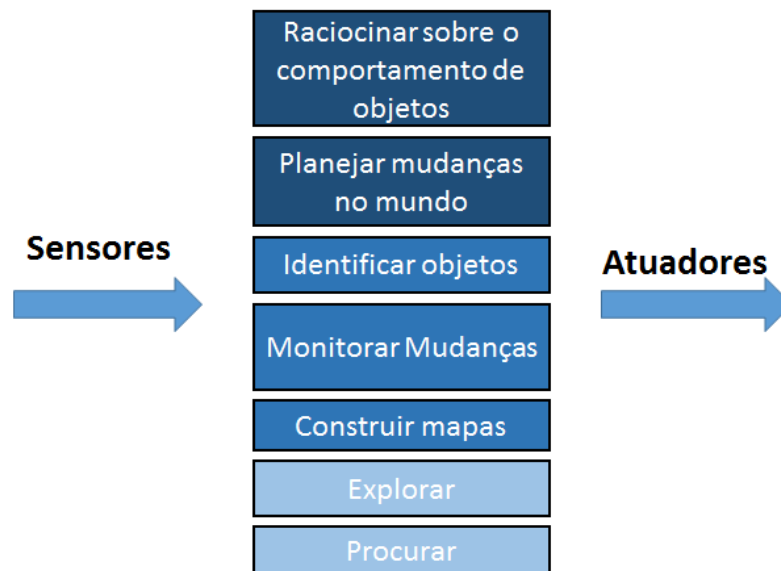


Figura 3.2 – Decomposição de um sistema de controle para um robô móvel baseado em comportamentos para realização de tarefas - Arquitetura de Subsunção de Brooks.
Fonte: Adaptado de BROOKS (1986)

Em geral, a arquitetura de um SMA define a funcionalidade dos agentes. Neste trabalho, os agentes devem combinar características das arquiteturas clássicas, por exemplo, subsunção (apenas reativa), com arquiteturas tipo BDI (*Belief, Desire and Intention*), os quais consideram três estados mentais: a crença, desejo e intenção (WOOLDRIDGE, 1999); os quais estão relacionados com estados comportamentais do agente. Ressalta-se que a uma das características de uma arquitetura puramente reativa, como a de subsunção de Brooks, é que estas não apresentam capacidade de aprendizado (MATARIC, 2007).

O modelo proposto nesta dissertação para agentes é uma DFCM capaz de representar os comportamentos correspondentes às ações reativas e deliberativas. Cada comportamento corresponde a uma visão da DFCM (modificações do grafo original) e estes comportamentos são organizados em camadas de acordo com uma estratégia hierárquica como na Figura 3.2, na qual as camadas inferiores têm prioridade. Em geral, as diferentes camadas não são completamente independentes. No entanto, o sistema pode ser capaz de lidar com mais do que um comportamento (ou objetivo ou ainda tarefa) de forma paralela, apesar de sua dependência. Conseqüentemente, a arquitetura de subsunção fornece mecanismos pelos quais as camadas mais elevadas, ou competentes, podem observar o estado das camadas mais baixas, podendo inibir suas saídas e substituir suas entradas, assim, ajustando seu comportamento (BROOKS e STEIN, 1994). Para isso, cada criatura ou agente tem uma arquitetura inspirada nas funcionalidades da arquitetura de subsunção de Brooks.

De outro modo, a arquitetura de subsunção pode ser brevemente resumida em uma composição de malhas de controle hierárquico, onde cada ciclo modela o comportamento de percepção-ação ou causa-efeito. Na abordagem proposta neste trabalho, essas malhas de controle simples são Mapas Cognitivos *Fuzzy* combinados de forma dinâmica em camadas incrementais e hierárquicas, trabalhando com uma abordagem *bottom-up* em direção a sistemas mais complexos.

Nesse contexto, a arquitetura desenvolvida neste trabalho usa a mesma arquitetura de subsunção que suporta modelagem por DFCM proposta em MENDONÇA *et al.* (2013a), acrescentando novos métodos e ou protocolos que permitam o desenvolvimento de agentes inteligentes.

Outra característica interessante herdada da modelo clássico de Subsunção de Brooks é o paralelismo, onde muitos comportamentos podem ser simultaneamente ativados. Neste caso, tem-se então a necessidade de um mecanismo de escolha para selecionar o que deve realmente ser acionado (GOERICK, 2011). Para este trabalho, o nível de gestão é modelado como uma Máquina de Estados que coordena as várias decisões que devem ser tomadas de acordo com uma hierarquia de tarefas. Esta arquitetura agrega alguns outros recursos, além das características herdadas da arquitetura de subsunção de Brooks, e são explicados ao longo do capítulo.

A Figura 3.3 mostra uma visão geral da arquitetura usada no desenvolvimento dos agentes neste trabalho. Os agentes por sua vez são modelados como um DFCM. Esta arquitetura é genérica e pode ser adaptada para outras aplicações baseadas em DFCM.

A arquitetura na Figura 3.3 possui seis blocos/módulos: Sistema de Percepção, Sistema de Estados Interno, Sistema Comportamental, Sistema de Aprendizagem, Sistema Motor e Memória. Esta representação em bloco auxilia na compreensão da arquitetura como um todo. Ressalta-se que o bloco “ambiente” não é parte da arquitetura em si; no entanto, serve para mostrar quais blocos da arquitetura interagem com o ambiente. O bloco em linhas pontilhadas em laranja representa os blocos que são abrangidos pelo modelo DFCM.

O Sistema de Percepção modela a percepção do agente sobre o meio ambiente definindo seu status operacional ou comportamento. Os sensores (sistema de percepção) dos agentes (no modelo cognitivo) não serão discutidos nessa dissertação, no entanto, assume-se que o modelo de percepção dos agentes pode reconhecer os personagens/objetos e suas respectivas distâncias no cenário. De acordo com a Figura 3.3, observa-se que o Sistema de Percepção influencia diretamente no Sistema de Estados Interno, no Sistema Comportamental e no Sistema de Aprendizagem.

O Sistema Motor é responsável pela realização do movimento do agente no ambiente de acordo com seu estado atual, e é sintonizado dinamicamente pelo bloco do Sistema de Aprendizagem.

O Sistema de Aprendizagem é definido por um algoritmo de Aprendizagem por Reforço (AR). Este bloco é responsável pela adaptação do agente através de dados fornecidos pelo Sistema de Percepção. O algoritmo de AR é utilizado para minimizar de forma dinâmica a incerteza em ações de baixo nível, intensificando ou atenuando as relações causais das ações, como virar à esquerda e/ou direita, de acordo com uma política de punição e bônus devido às mudanças no ambiente. O algoritmo utilizado neste trabalho é o *Q-learning* adaptado por regras. No entanto, outros algoritmos de aprendizagem, como por exemplo, o Aprendizado de Hebb, pode ser utilizada para adaptar os pesos do FCM (PAPAGEORGIU, 2012).

O Sistema Comportamental consiste, neste exemplo, em dois subsistemas: homeostase e motivação. A homeostase é a capacidade ou a tendência de um organismo para manter o seu equilíbrio interno, ajustando os seus processos fisiológicos. Isto é influenciado pelos sensores internos, tais como o tempo nas criaturas artificiais ou a carga na bateria em um robô móvel. “Fome” e “medo”, para a aplicação de Vida Artificial, são considerados como estados interno. Outros possíveis estados de homeostase, não modelado neste trabalho, podem ser relacionados com a “fadiga” ou o “desgaste de peças”. O subsistema de motivação é o básico “desejo / querer” do agente virtual, dados pelas ações deliberativas, como desviar de possíveis objetos/obstáculos ou situações perigosas (como por exemplo, a fuga do predador ou uma colisão iminente, para as aplicações de Vida Artificial e Robótica de Enxame, respectivamente).

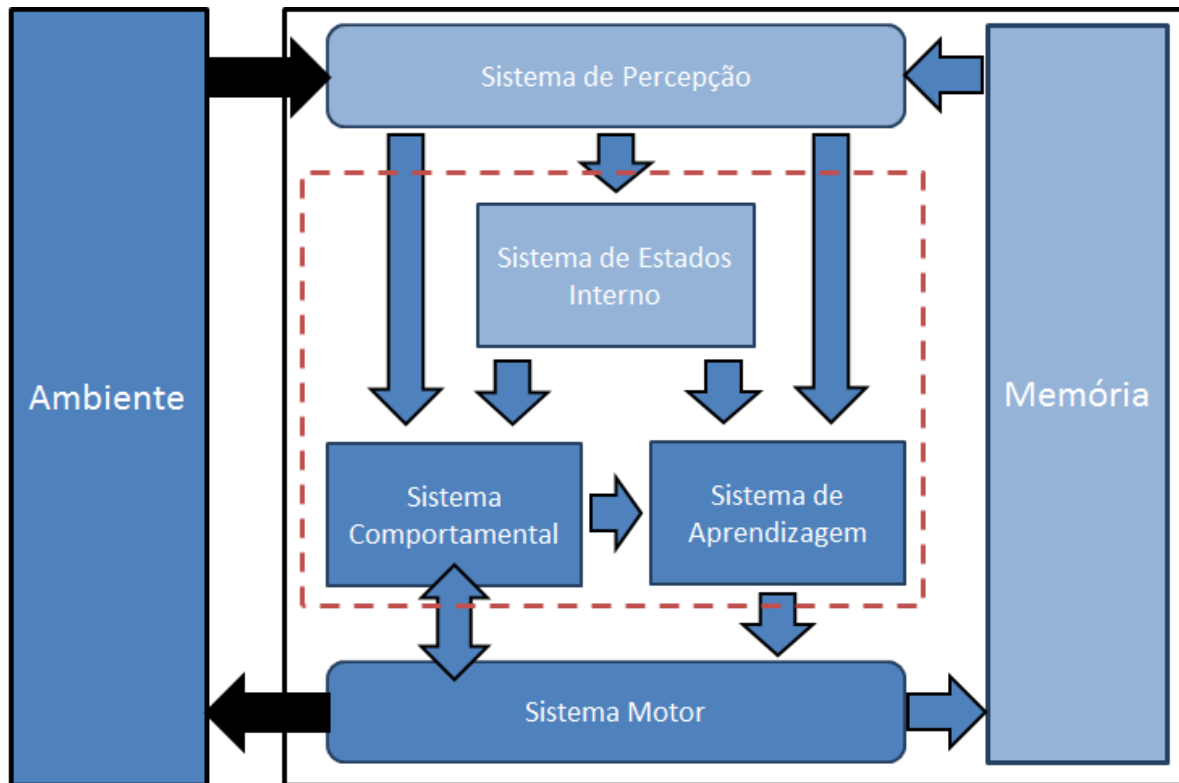


Figura 3.3 – Visão geral da arquitetura.
Fonte: MENDONÇA et al. (2015b)

O bloco do Sistema de Estados Interno representa a capacidade de tomar decisões e alterar comportamentos dos agentes. Este bloco é implementado por uma Máquina de Estados em ambas as aplicações dessa dissertação. O comportamento do agente em cada instante é baseado em informações recebidas pelo Sistema de Percepção e o Sistema de Estados Interno. E, finalmente, o sistema de Memória representa a estratégia ou técnica de comunicação e compartilhamento das informações com outros agentes.

Ressalta-se que existem outras propostas conhecidas na literatura para construção de agentes, como a Máquina de Turing (COPELAND, 2004), InteRRAP – *Integration of reactive behaviour and rational planning* (MÜLLER e PISCHEL, 1993) e PRS - *Procedural Reasoning System* (MYERS, 1997). Todavia, optou-se por se utilizar a arquitetura de subsunção, já que esta foi originalmente idealizada para a utilização em robôs móveis autônomos capazes de realizar o processamento de informações complexas em tempo real (CHONG et al., 2007).

3.2 MODELO DFCM

Os Mapas Cognitivos *Fuzzy* clássicos, como definidos na seção anterior, não são capazes de considerar causalidades temporais e não possuem habilidade de auto ajuste, especialmente de uma forma dinâmica.

Para superar estas limitações, novas abordagens têm surgido na literatura buscando conciliar tomadas de decisões de baixo nível e de alto nível como discutido no capítulo 2. Entre essas abordagens encontram-se os DFCM (Mapas Cognitivos *Fuzzy* Dinâmicos) apresentados em MENDONÇA *et al.* (2014) que são uma evolução do FCM clássico, adicionando conceitos e fundamentos das áreas de SMA e Aprendizagem de Máquinas. A Figura 3.4 apresenta uma representação visual em bloco dos conceitos citados para a evolução da ferramenta. Neste trabalho o DFCM será usado para construir modelos de agentes dotados de adaptação, autonomia e cooperação capazes de solucionar problemas com múltiplos objetivos, como exigido para as aplicações modeladas neste trabalho.

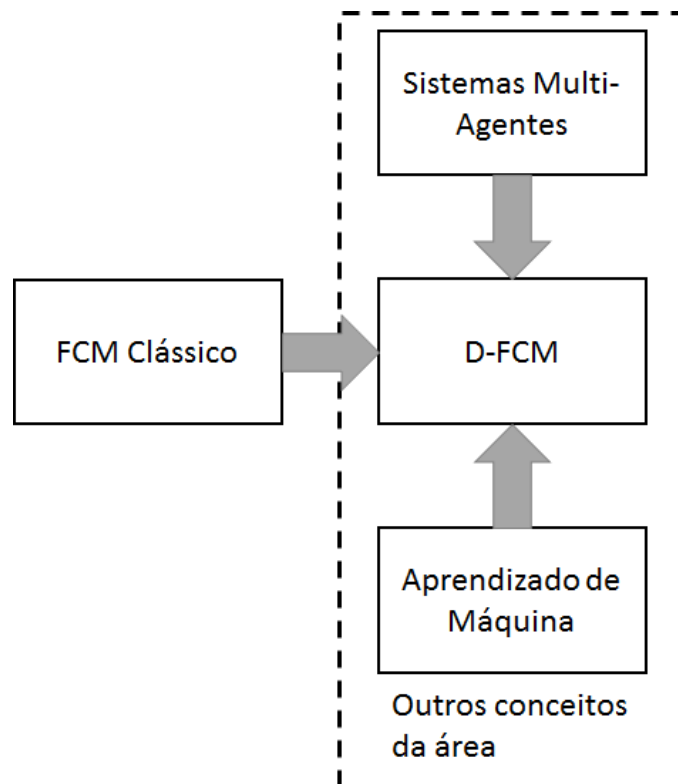


Figura 3.4 – Evolução do FCM para DFCM, aumento dos conceitos e fundamentos.
 Fonte: Adaptado de MENDONÇA *et al.* (2016)

De acordo com MENDONÇA *et al.* (2014), um DFCM admite os seguintes tipos de conceitos e relações:

- Conceitos de entrada/saída: conceitos relacionados a entrada e saída do sistema, responsável pela interface entre o controlador e o ambiente;
- Conceitos de memória: esses conceitos armazenam valores anteriores de outros conceitos;
- Conceitos Fator: esse conceito insere um operador de multiplicação, ponderando os conceitos ligados à saída do DFCM;
- Relações causais: representam as relações de causa e efeito entre dois conceitos;
- Relações variantes no tempo: representam as relações de causa e efeito entre dois conceitos do DFCM, as quais são modeladas por uma função variante no tempo ou sintonizadas por técnicas de aprendizado de máquina;
- Relações de seleção: essas relações modelam a ocorrência de eventos através de regras do tipo se-então, identificando quais relações causais são válidas em um dado tempo. Essas relações só são disparadas quando há a ocorrência de uma determinada situação modelada a priori;
- Relações *Fuzzy*: adiciona ao modelo DFCM um raciocínio lógico *Fuzzy* e não monotônico, no qual dois ou mais conceitos afetam um outro conceito por meio de funções *Fuzzy*.

Essas modificações conferem aos DFCMs uma semântica forte para os conceitos e relações do modelo cognitivo as quais podem ser organizadas em ontologias. E, portanto, adotando uma construção manual dos FCM a partir do conhecimento de vários especialistas (MIAO, 2014) e utilizando o método proposto por LEE e LEE (2015) para construção de FCM baseada na combinação de ontologias, os modelos desenvolvidos nesta dissertação utilizam a ontologia apresentada a seguir.

3.2.1 Ontologia

A construção de um DFCM (Tabela 3.1) inicialmente segue os mesmos passos do desenvolvimento de Mapas Cognitivos e Mapas Cognitivos *Fuzzy*. No entanto, a estratégia para a construção de um modelo com tomadas de decisões deve acrescentar mais etapas ou passos no desenvolvimento de DFCM; mais informações podem ser encontradas no trabalho de MENDONÇA *et al.* (2013a), no qual o desenvolvimento de um Mapa Cognitivo *Fuzzy* Dinâmico é apresentado e aplicado a supervisão de um processo de fermentação alcoólica.

A ontologia para a modelagem de sistemas dinâmicos na Tabela 3.1, pode sofrer pequenas alterações dependendo do tipo de problema a ser modelado (sistemas de supervisão controle, robótica, mundo virtual, tomadas de decisões, etc.). Por exemplo, pode não ser necessário usar relações *Fuzzy* ou conceitos com variação temporal. Ou até mesmo, métodos de treinamento ou aprendizagem podem não ser necessários para modelar ou adaptar o sistema. Além disso, os algoritmos usados em cada fase podem ser diferentes. Um dos passos mais importantes na qualidade do modelo obtido é realização das etapas 1 e 2. Por conseguinte, a abstração do conhecimento necessário para realizar estes passos não é uma tarefa simples e se qualquer informação relevante sobre o comportamento do sistema não for modelada, poderá afetar os outros passos da construção do DFCM. O desenvolvimento de um modelo DFCM é feito de forma gradual, ou seja, é construído um DFCM inicial, semelhante a um FCM, e em seguida são adicionados outras funções, seleções e / ou outras estratégias de controle à DFCM (MENDONÇA *et al.*, 2013b).

Sendo assim, o desenvolvimento de um modelo DFCM pode ser feito em duas partes distintas; em primeiro lugar, um DFCM inicial é desenvolvido através das etapas 1, 2 e 3, ou seja, identificar os conceitos e suas relações, obter os dados e definir as relações causais usando números *Fuzzy*. Nestes passos, o DFCM resultante é um FCM clássico cuja topologia pode incluir todos os conceitos e relacionamentos apresentados no problema modelado.

A partir deste DFCM inicial, as etapas 4, 5 e 6 podem ser realizadas, ou seja, a criação da base de regras, algoritmos de aprendizado, adaptação e otimização do modelo, a implementação de outros conceitos / relações, entre outros. O DFCM final é agora uma FCM cujos conceitos e relacionamentos de topologia são determinados de forma dinâmica pelas regras projetadas na etapa 6. E, finalmente, na etapa 7, a validação do modelo é realizada, podendo ser utilizados para cada nível da DFCM, ou para o DFCM completo.

Tabela 3.1 – Etapas de desenvolvimento da DFCM (ontologia).

Descrição	
Etapa 1:	Identificação de conceitos elementares, suas funções (suas entradas, saídas, níveis, decisões) e suas correlações; determinando sua natureza causal (positiva, negativa, neutra).
Etapa 2:	Configuração inicial dos conceitos e relações causais. Os valores de estados iniciais do mapa (nós/arcos) podem ser adquiridos através do conhecimento de especialistas, análise de dados históricos e/ou simulação do sistema.
Etapa 3:	Determinação da influência semântica entre os conceitos. Concepção dos diferentes pontos de vista do sistema.
Etapa 4:	Para cada ponto de vista do sistema, projetar uma base de regra <i>Fuzzy</i> e funções variantes no tempo para o cálculo dos valores dos pesos das relações causais da DFCM.
Etapa 5:	Processamento da informação, adaptação e sintonização do modelo DFCM, ajustando suas respostas aos valores desejados de saída. Se necessário, um método de treinamento de máquina (Aprendizagem por Reforço, Aprendizado de Hebb, Algoritmos Evolutivos, ou outras técnicas de Aprendizagem de Máquina) pode ser utilizado para sintonia dinâmica do modelo.
Etapa 6:	A modelagem do nível de gestão correspondendo ao desenvolvimento da base de regras associadas aos conceitos de fatores e relações de seleção; a implementação do algoritmo de aprendizado online (caso necessário).
Etapa 7:	Teste final e validação do modelo desenvolvido.

Fonte: MENDONÇA e ARRUDA (2015)

Tabela 3.2 – Exemplificação de tipos de ações, descrições e exemplos práticos.

Tipo de ação	Descrição	Exemplos
Reativa	Ações de baixo nível.	Virar à esquerda, virar à direita, acelerar ou desacelerar.
Deliberativa	Ações de alto nível, planejamento e/ou gerenciamento.	Explorar o ambiente, andar em linha reta, identificar obstáculos, coletar alvos.
Inteligente	Ações de alto nível, e ações relacionadas ao aprimoramento do modelo.	Aprendizagem, adaptação, aquisição de conhecimento, cooperação.

Fonte: Autoria própria

Olhando de forma mais objetiva, focando sobre os conceitos de Sistemas Multi-Agentes e seguindo a ontologia da Tabela 3.1, as ações de baixo nível correspondem a relações de causa-efeito simples e assim podem ser modeladas como um FCM clássico. As ações deliberativas (ações de planejamento ou gerenciamento) estão relacionadas com decisões do agente e correspondem a relações de seleção e/ou relações *fuzzy*. As ações inteligentes são ações relacionadas à adaptação/ajuste do controlador e a cooperação, seja esta, por exemplo, através de técnicas de aprendizagem do agente ou métodos de transmissão de informações. A Tabela 3.2 exemplifica alguns tipos dessas ações; ressalta-se que as ações exemplificadas são focadas na aplicação de Robótica Móvel, porém podem ser generalizadas para as outras áreas, com suas respectivas ações válidas.

3.2.2 Aprendizagem por Reforço - AR

Um dos diferenciais dessa pesquisa em comparação com o trabalho original de DICKERSON e KOSKO (1998), é a inclusão da capacidade de auto-adaptação dos agentes através da utilização de Aprendizagem por Reforço para a sintonia dinâmica. Este algoritmo permite ajustes para uma melhor adaptação em parâmetros do controlador, devido às mudanças possíveis no ambiente e / ou a dinâmica do agente ou criatura, como mudança de aderência no piso ou peças desgastadas do robô para aplicações em robótica móvel (COSTA e GOUVEA, 2010).

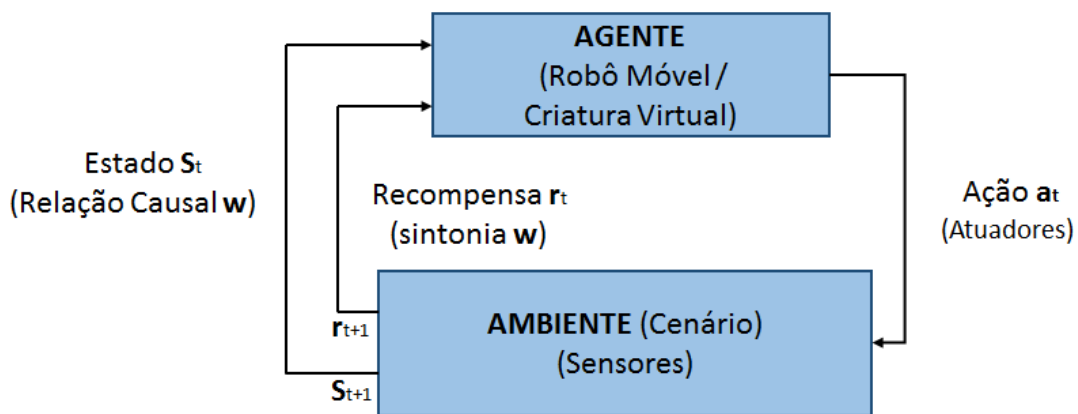


Figura 3.5 – Modelo AR genérico.
Fonte: Adaptado de MENDONÇA e ARRUDA (2015)

Um algoritmo de Aprendizagem por Reforço, semelhante ao *Q-learning* e baseado em aprendizagem heurística, é implementado. Para essa dissertação, uma política de mapeamento dos estados é usada, para determinar qual ação deve ser realizada quando o agente está em um estado “s(t)”, assim, definindo o comportamento do agente ao longo do tempo. Este algoritmo utiliza a experiência de cada transição de estado para atualizar o custo $Q(s, a)$ de uma ação “a” tomada que aciona o sistema a partir do estado real “s(t)” para o próximo estado “s(t + 1)”; o algoritmo realiza a atualização e recebe uma recompensa “r(t + 1)”, a gestão das sanções é feita por uma política de regras, como mostrado na equação (3.1).

Esta atualização é realizada por meio da regra:

$$Q(s, a, t + 1) = Q(s, a, t) + \alpha * \left[r + \gamma * \max_a Q(s', a') - Q(s, a, t) \right] \quad (3.1)$$

Onde α é o fator de aprendizagem, γ é o fator de desconto, r é o valor da recompensa ou punição, e $\max Q(s', a')$ é uma previsão de recompensa no próximo estado s' . Sob condições apropriadas, este algoritmo converge ao estabelecer uma política que aplica recompensas e punições de acordo com mudanças ambientais (SUTTON e BARTO, 1998).

As ações de recompensa e punição implementadas no algoritmo são obtidas a partir de regras heurísticas que descrevem o ambiente. Por exemplo, numa situação mais realista, uma mudança na corrente da água poderia interferir com a dinâmica de navegação do agente (velocidade de nado do golfinho no cenário de vida artificial). Assim, não há período de treinamento e, ao invés, um auto ajuste das relações causais, dentro de um intervalo previamente estabelecido pelos especialistas.

De forma resumida, a regra de Aprendizagem por Reforço descrita pela equação (3.1) é usada nesse trabalho para adaptar dinamicamente os pesos das relações causais do DFCM. No entanto, a adaptação deve ser cuidadosamente planejada para evitar a ocorrência de mudanças drásticas nos valores dos pesos; a inclusão de valores mínimo e máximo, para as relações causais, foi a solução encontrada. Os valores dos pesos das relações causais são adaptados de acordo com regras heurísticas.

As regras que determinam a mudança heurística da política do estado através de recompensa e punição é o termo " r " da equação (3.1), descrito no algoritmo *Q-learning*. A aplicação da equação (3.1) para o cálculo dos pesos leva a equação (3.2):

$$w_i(k) \leftarrow w_i(k-1) + \alpha * [r + \gamma * W_{lim} - w_i(k-1)] \quad (3.2)$$

Onde: w_i é o peso, ou matriz de pesos da DFCM; α é o fator de aprendizagem; γ é o fator de desconto; r é o valor da recompensa ou punição; e W_{lim} é o valor máximo desejado para o peso da relação causal. A equação (3.2) aplica-se diretamente a experiência do agente na sua interação com o ambiente. No entanto, os valores limites de bônus ($W_{lim} = W_{fmax}$) e punição ($W_{lim} = W_{fmin}$) são delimitados dentro de faixas definidas pelos especialistas.

3.2.3 Algoritmo para Transmissão de Feromônios

Essa dissertação, como objetivo secundário, propõe o desenvolvimento e aplicação de um método de compartilhamento de informação para a aplicação de Robótica de Enxame. Esse

método é inspirado no trabalho de PAYTON *et al.* (2003), que descreve um “feromônio virtual” como um mecanismo de interação local difusora para comunicação e coordenação de robôs, baseado no comportamento de forrageamento das formigas que apresentam uma sequência de características comportamentais para a procura e coleta de alimento.

Uma formiga operária forrageira ao encontrar uma fonte de alimento retorna ao ninho, marcando seu caminho através da liberação de odores químicos específicos a sua colônia, denominados de feromônio, para que outras formigas possam utilizar essas marcações para navegar até a fonte de alimento encontrada; essas formigas, após a encontrar o alimento, o transportam para a colônia e reforçam a trilha de feromônios.

Um método de compartilhamento de informações inspirado no comportamento citado acima, objetiva uma transmissão de informações de forma implícita, através da liberação de feromônios no ambiente. A informação liberada será utilizada por outros agentes para auxiliar as tomadas de decisões durante sua navegação.

No algoritmo desenvolvido neste trabalho, cada agente autônomo possui um mecanismo para liberação dos feromônios no ambiente que é modelado na DFCM na forma de um conceito e de um conjunto de regras de seleção. Para garantir a periodicidade dessa liberação, um contador é adicionado, o qual decresce de acordo com dados de sensoriamento dos agentes. Em outras palavras, quanto mais próximo de um obstáculo o agente estiver, maior será o valor decrementado do contador, favorecendo ou antecipando assim manobras de desvios executadas no ambiente.

A Tabela 3.3 apresenta o pseudocódigo para a implementação desse método de compartilhamento.

Para utilizar essa informação disponível no ambiente, um conceito de entrada é adicionado o modelo cognitivo do agente, para fazer o sensoriamento dos feromônios como alvos secundários, cujas capturas não são obrigatórias.

Tabela 3.3 – Pseudocódigo para compartilhamento de informação por feromônio

```

Início
Contador = valor;
  enquanto (agente navegar no ambiente)
    Leitura de dados dos sensores;
    Decrescimento do contador;
    se Contador =< Condição (base de regras)
      Liberar feromônio;
      Resetar valor do contador para “valor”;
    fim_se
  fim_enquanto
Fim

```

Fonte: Autoria própria

3.3 CONCLUSÃO

A arquitetura apresentada nesse capítulo explora a capacidade de abstração do conhecimento estruturado, com diferentes fontes de conhecimento. Podendo estas fontes ter ou não a mesma origem, possibilitando a construção de métodos ou estratégias para tomadas de decisões de baixo nível, ações reativas, e de alto nível, ações deliberativas, ou seja, estados e comportamentos a serem modelados, trabalhando de modo simultâneo ou não (*White board*) (COPPIN, 2004). O conhecimento abstraído possibilita um mapeamento direto da situação a ação, ou seja, é possível atribuir ações de controle para cada situação ou estado modelado referente ao comportamento a ser implementado pelo sistema ou agente, os quais estão dispostos em camadas hierárquicas. Geralmente, as diferentes camadas não são completamente independentes e o sistema pode ser capaz de lidar com mais do que uma ação ou tarefa em paralelo.

A arquitetura proposta para o SMA, inspirada nas funcionalidades da Subsunção, para gerenciar esses estados fornece mecanismos pelos quais as camadas mais altas ou mais competentes possam observar o estado das camadas inferiores, possibilitando que estas inibam suas saídas e entradas, assim, ajustando seu comportamento (BROOKS e STEIN, 1994). Os agentes são modelados por uma DFCM, incrementalmente construída, que representam seus diversos comportamentos

Além das características supracitadas, uma técnica de aprendizagem de máquina é utilizada para adaptação ao ambiente, o Aprendizado por Reforço. O uso desta técnica proporciona ao agente (ou sistema) uma melhor adaptação a eventos não planejados a priori, através do uso de regras heurísticas que descrevem o ambiente.

Um método de compartilhamento de informações, inspirado no forrageamento das formigas, foi apresentado para auxiliar nas tomadas de decisões dos agentes, em específico para a aplicação de Robótica de Enxame, objetivando o aprimoramento da trajetória de navegação dos agentes autônomos.

Em resumo, podem-se citar algumas características deste tipo de arquitetura:

- Utiliza uma hierarquia que prioriza funções de acordo com a heurística de operação do processo;
- É baseada em ação-situação;

- As decisões dos agentes são realizadas através de um conjunto de comportamentos direcionados a tarefas a cumprir;
- Tem inspiração na neurobiologia, em especial, na sinergia que existe entre a sensação e a atuação de insetos.

A arquitetura apresentada é genérica e, de acordo com as suas funcionalidades, ela pode ser estendida a uma gama de aplicações, por exemplo, agentes robóticos, sistemas de supervisão, Vida Artificial, entre outros.

4 VIDA ARTIFICIAL

O Sistema Multi-Agente virtual proposto permite simular comportamentos autônomos individuais e coletivos (como explorar, desviar de obstáculos, recolher alimentos, agrupar, e escapar de um ou mais predadores naturais) com apenas o conhecimento de baixo nível (como virar à esquerda ou à direita) e a ocorrência de eventos (como fome, percepção de predadores, e outros).

O ambiente de VA (Vida Artificial) desenvolvido corresponde a uma arquitetura com capacidade de planejamento e mecanismos para controlar a mudança de estados de acordo com a ocorrência de eventos. As criaturas virtuais são modeladas por um DFCM e as suas mudanças de comportamento são gerenciados por uma Máquina de Estados, a qual impõe a presença / ausência e intensidade das relações causais no DFCM. O algoritmo de aprendizagem utilizado neste trabalho é o Aprendizado por Reforço com regras (as punições e recompensas são feitas por regras de comportamento), o qual é usado para ajuste fino do modelo cognitivo para desvio de obstáculos da criatura artificial.

Este ambiente virtual é composto dos seguintes atores:

- Golfinho: personagem principal, agente ativo ou criatura artificial do ambiente virtual. O DFCM desta criatura é o mais desenvolvido, com ajuste dinâmico, e diversas habilidades tais que capacidade de fuga, fome, agrupamento e navegação (desvio de obstáculos, busca por alimentos e por outras criaturas da mesma espécie);
- Tubarão: o predador também é um agente ativo. No entanto, neste trabalho, o predador tem objetivos mais simples do que o golfinho. Sendo esse limitado a caça ao golfinho e navegação;
- A comida (peixes pequenos), por simplicidade, são agentes passivos, criaturas praticamente estáticas nos ambientes simulados, oscilando em torno de um ponto fixo.

Olhando de forma mais objetiva, as ações reativas de ambas as criaturas (golfinho e predador) correspondem às relações de causa-efeito, implementadas como relações clássicas do FCM, e participam do nível mais baixo da arquitetura proposta.

Por outro lado, as ações deliberativas estão relacionadas com decisões da criatura e não podem ser hierarquizadas. Assim, um processamento paralelo é necessário para que estas ações coexistam na arquitetura, embora elas não possam ocorrer simultaneamente; em geral, a ação escolhida é disparada pela ocorrência de eventos, tais como a detecção de um obstáculo ou a presença de um predador. Essas ações deliberativas correspondem aos níveis mais altos da arquitetura, e a tomada de decisões é implementada por uma Máquina de Estados, onde cada estado é resultante de uma ação deliberativa. Além disso, essas ações deliberativas correspondem a diferentes tipos de relações DFCM, como por exemplo: uma relação causal variante no tempo, uma relação *Fuzzy* ou uma relação de seleção.

Em resumo, o desenvolvimento de um modelo DFCM para Vida Artificial começa a partir da observação do problema, e as suas características são adicionadas gradualmente à medida que os comportamentos dinâmicos de um ou mais agentes, ou atores, são analisados.

Como já mencionado, o senso de percepção, reconhecimento dos atores (Golfinho, Tubarão e peixes pequenos), e os modelos reais dinâmicos não serão abordados nesta dissertação. No entanto, presume-se que os conceitos cinemáticos de distância relativa e velocidade relativa de cada criatura são inseridos em seus respectivos conceitos nos modelos da DFCM. Tendo assim, como objetivo desta seção, a exploração da construção de uma arquitetura inteligente para emular o comportamento de animais virtuais, os quais são inspirados no comportamento de golfinhos e tubarões.

A DFCM desenvolvida para o comportamento e sentidos do golfinho, visa a modelagem das seguintes habilidades ou comportamentos:

- Agrupamento: quando o golfinho encontra um ou mais elementos da sua espécie e não está sob qualquer ameaça, ou se alimentando de peixes pequenos ou ainda desviando de obstáculos, ele se agrupará com o outro de sua espécie;
- Ameaça: na presença de um predador, o golfinho acelera, aumentando a sua velocidade de nado na tentativa de preservar sua própria vida;
- Busca por alimento: se houver a detecção de alimentos, sem ameaças, o golfinho caçará a sua presa, os peixes pequenos, e se alimentará;
- Nado livre: quando nenhuma das situações acima ocorrer, o golfinho nadará em linha reta preocupando-se somente em evitar os obstáculos em seu caminho.

Em comparação, o comportamento do predador é relativamente simples: se o predador encontra o golfinho, o predador irá aumentar sua velocidade no intuito de perseguir o golfinho, senão nadará em linha reta, desviando de obstáculos.

As Tabelas 4.1 e 4.2 apresentam as ações a serem tomadas pelo golfinho e predador, respectivamente, de acordo com a situação em que se encontram no ambiente, o tipo de comportamento modelado e sua capacidade estratégica de navegação e planejamento.

As manobras, neste trabalho, são consideradas deliberativas visto que os ambientes são dinâmicos. Em contrapartida, agentes puramente reativos (reagem somente a estímulos) dificilmente atingiriam os objetivos propostos. Neste contexto, ressalta-se a importância da capacidade de adaptação do golfinho para mudanças no ecossistema sintético, especialmente para as várias tarefas inicialmente propostas para este agente ou criatura.

Tabela 4.1 – Ações modeladas para o Golfinho.

Comportamento	Capacidade	Situação	Ação
Reativo	Navegação	Presença de um obstáculo do lado direito do agente	Virar à esquerda
Reativo	Navegação	Presença de um obstáculo do lado esquerdo do agente	Virar à direita
Reativo	Navegação	Trajatória livre de obstáculos e alimentos	Acelerar / Desacelerar
Deliberativo	Planejamento	Trajatória livre de obstáculos e alimentos	Navegação em linha reta (Nado livre)
Deliberativo	Planejamento	Presença de Alimento na proximidade	Virar à esquerda ou direita em direção ao alimento
Deliberativo	Planejamento	Trajatória livre de obstáculos e predadores	Buscar por alimento
Deliberativo	Planejamento	Presença de um predador	Fuga do predador
Deliberativo	Planejamento	Presença de outro agente de sua espécie	Tomar ações para agrupar com este
Inteligente	Adaptação	Adaptar a mudanças ambientais	Usar um procedimento de aprendizagem para adaptação dinâmica (somente para desvio de obstáculos)

Fonte: Autoria própria

Tabela 4.2 – Ações modeladas para o Predador.

Comportamento	Capacidade	Situação	Ação
Reativa	Navegação	Presença de um obstáculo do lado direito do agente	Virar à esquerda
Reativa	Navegação	Presença de um obstáculo do lado esquerdo do agente	Virar à direita
Reativa	Navegação	Presença da presa (golfinho)	Acelerar / Desacelerar
Deliberativa	Planejamento	Trajectoria livre de obstáculos e alimento (golfinho)	Navegação em linha reta (Nado livre)
Deliberativa	Planejamento	Trajectoria livre de obstáculos	Buscar por alimento
Deliberativa	Planejamento	Presença da presa (golfinho)	Perseguir o golfinho

Fonte: Autoria própria

4.1 ESTRATÉGIA DE CONTROLE

Para esta aplicação, a arquitetura utilizada para o desenvolvimento e planejamento das ações é a mesma arquitetura apresentada no capítulo anterior, na Figura 3.3. Porém, não se faz necessário o uso do bloco de Memória já que a aplicação em Vida Artificial não possui métodos ou técnicas para o compartilhamento de informações, como apresentado pela Figura 4.1.

Essa arquitetura apresenta cinco blocos: Sistema de Percepção, Sistema de Estados Interno, Sistema Comportamental, Sistema de Aprendizagem e Sistema Motor.

O Sistema de Percepção modela a percepção sensorial das criaturas virtuais com o meio ambiente, sendo representado também como os conceitos de entrada da DFCM. O Sistema Comportamental representa quais comportamentos o agente possui, e suas necessidades. Os estados modelados, para esta dissertação, são: nado, fome, evitar obstáculos, fugir de predadores e agrupar com outros golfinhos. Estes estados são gerenciados por uma Máquina de Estados, implementado na arquitetura como o Sistema de Estados interno e apresentadas nas Figuras 4.4 e 4.5, para o golfinho e o predador, respectivamente.

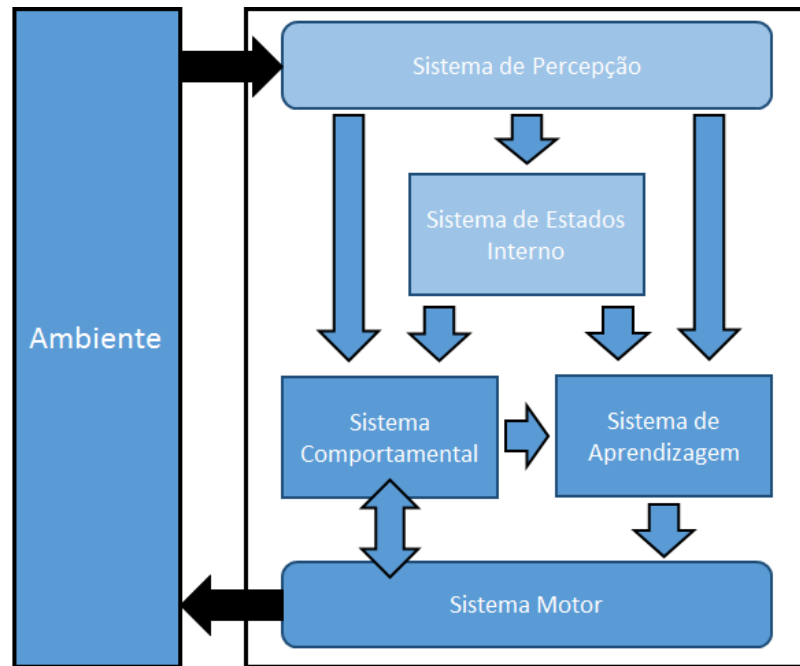


Figura 4.1 – Arquitetura DFCM para aplicação em Vida Artificial.
 Fonte: MENDONÇA *et al.* (2015b)

O Sistema de aprendizado refere-se ao algoritmo de Aprendizagem por Reforço implementado para a sintonia dinâmica dos pesos da DFCM. E finalmente, o Sistema Motor é responsável pelas inferências no movimento da criatura.

O desenvolvimento da arquitetura do controlador DFCM segue a ontologia mostrada na Seção 3.2.1. Para a aplicação em Vida Artificial, os DFCMs resultante dos passos 1 a 3 da ontologia, correspondem a FCMs clássicos modelando todas as ações reativas para ambas as criaturas. A arquitetura apresentada na Figura 4.1 e os níveis hierárquicos de cada criatura (Figuras 4.2 e 4.3) são usados para executar os passos 4 a 7 da ontologia proposta. Como resultado, a arquitetura altera a configuração cognitiva do DFCM dos agentes de acordo com a Máquina de Estados. A transição do estado pode ser resultado de eventos inesperados ou mudança do estado interno. A configuração cognitiva dos agentes é modificada dinamicamente pelos seguintes procedimentos:

- Incluir/retirar conceitos;
- Incluir/retirar relações causais;
- Aumentar / reduzir a força das relações causais;
- Gerenciar a prioridade das ações de baixo e alto nível, ou ações reativas e deliberativas.

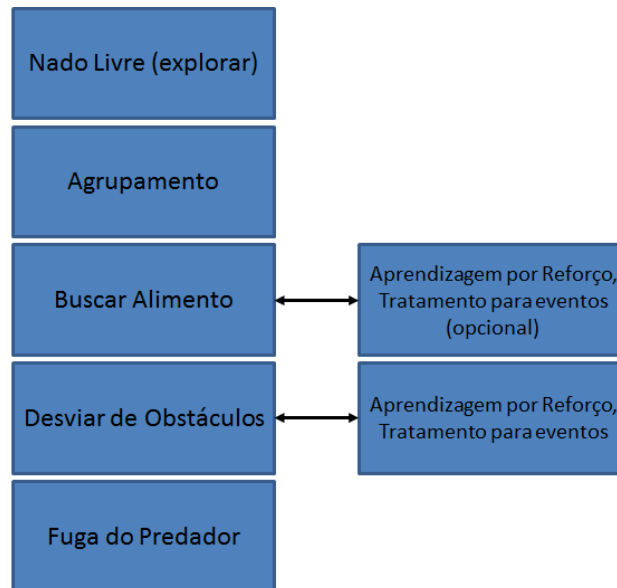


Figura 4.2 – Decisões hierárquicas e camadas adaptativas do Golfinho (abordagem *bottom-up*).

Fonte: Autoria Própria

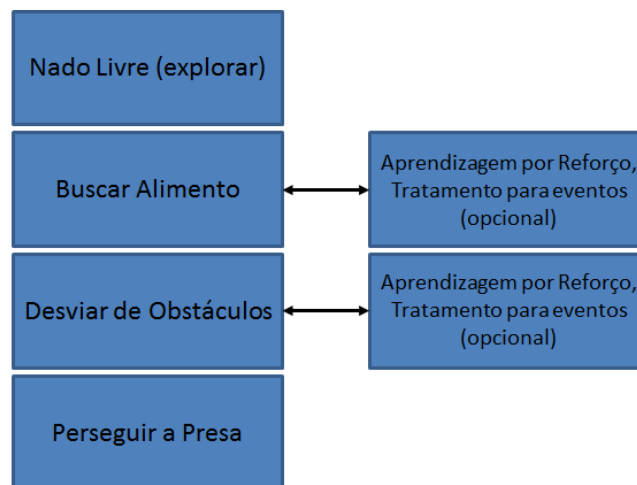


Figura 4.3 – Decisões hierárquicas e camadas adaptativas do Predador (abordagem *bottom-up*).

Fonte: Autoria Própria

Analisando a Tabela 4.1 pode-se estabelecer uma hierarquia de ações do golfinho (Figura 4.2) utilizando-se de uma abordagem *bottom-up*. A criatura artificial tem como prioridade: Fuga do predador, desviar de obstáculos, buscar alimento, agrupar com criaturas da mesma espécie e explorar o ambiente. Essa explicação pode ser estendida para a hierarquia de ações do predador, mostrada na Figura 4.3, com seus comportamentos descritos na Tabela 4.2.

Ressalta-se que, como apresentado na Figura 4.2, o algoritmo de adaptação dinâmica age somente sobre o estado de desvio de obstáculo. E o predador não possui o tratamento de sintonia dinâmica dos pesos.

De acordo com a arquitetura apresentada, cada agente, golfinhos e tubarão (predador), tem um conjunto diferente de objetivos e, portanto, possuem Máquinas de Estados e DFCM distintos.

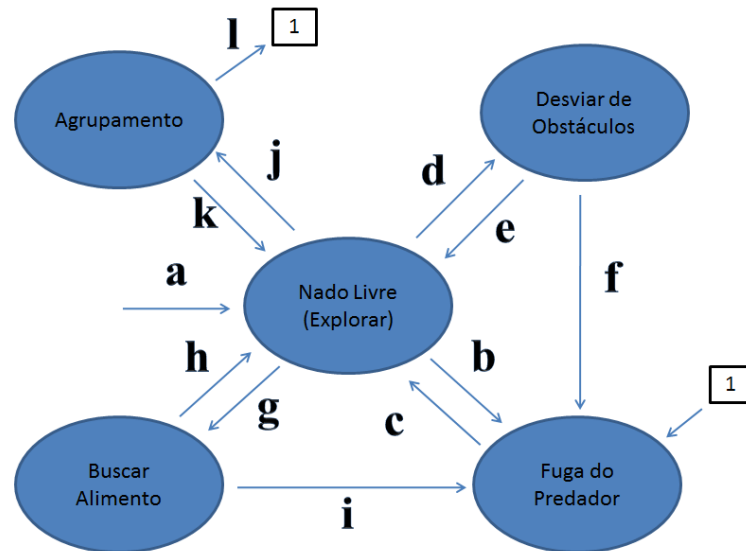


Figura 4.4 –Máquina de estado do Golfinho.
Fonte: Autoria Própria

O vocabulário da Máquina de Estados do golfinho, representada na Figura 4.4, é:

- a. Estado inicial e padrão da criatura: explorar o ambiente ou nado livre;
- b. A percepção de um predador em sua proximidade ativa um estado de fuga, que corresponde a um aumento na velocidade de nado (ação de baixo nível);
- c. Depois de uma fuga com êxito, o golfinho retorna ao seu estado inicial;
- d. A percepção de obstáculos próximos dispara o estado de desvio de obstáculos (ação de baixo nível);
- e. Depois de desviar do obstáculo, o golfinho retorna ao seu estado inicial;
- f. Se um predador for detectado durante uma manobra de desvio de obstáculos, o estado de fuga é acionado;
- g. A percepção de alimento leva ao estado de forrageamento, no qual o golfinho tentará capturar sua presa (peixes pequenos);
- h. Após a captura do alimento, retorna ao seu estado inicial;
- i. A percepção de um predador enquanto o golfinho está em um estado de captura de alimentos, também dispara o estado de fuga;
- j. A percepção de outro ser da mesma espécie dispara o estado agrupamento;

- k. A percepção dos alimentos, enquanto em um estado agrupamento dispara o estado de forrageamento;
- l. A percepção de um predador enquanto em um estado agrupamento dispara o estado de fuga.

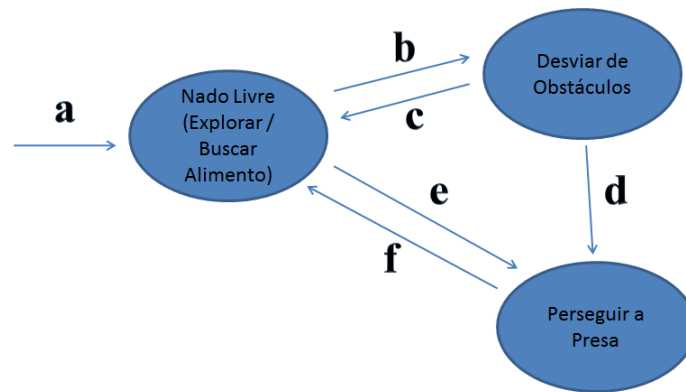


Figura 4.5 – Máquina de estado do Predador
Fonte: Autoria Própria

O vocabulário da Máquina de Estados do predador, mostrado na Figura 4.5, é:

- a. Estado inicial e padrão da criatura: explorar o ambiente ou nado livre;
- b. A percepção de um obstáculo próximo dispara o estado obstáculo desvio;
- c. Depois do desvio do obstáculo, retorna ao seu estado inicial;
- d. A percepção de uma presa enquanto no estado de desvio de obstáculo dispara o estado de perseguição;
- e. A percepção de uma presa dispara o estado de perseguição;
- f. Depois da tentativa de capturar sua presa, com sucesso ou não, retorna ao seu estado inicial.

4.2 MODELOS (DFCM) COGNITIVOS DAS CRIATURAS

A fim de enfrentar situações não modeladas (contingências), mas considerando um planejamento a priori, novos conceitos e relações são introduzidos no DFCM, além dos necessários para modelar comportamentos reativos. Conceitos do tipo fator são associados à intensidade de movimento e é afetado pelas decisões da criatura de agrupar ou fugir. De outra

forma, as relações que descrevem estes eventos são relações de seleção e são representados por pesos “Ws” no modelo cognitivo do DFCM. Seus valores são calculados pela aplicação de regras do tipo SE-ENTÃO (implicações linguísticas).

Estas regras representam a importância de algumas decisões, como por exemplo, a razão pela qual a criatura está virando à direita, se é porque o agente detectou um obstáculo à sua esquerda, ou porque percebeu um alimento a ser coletado à sua direita (MENDONÇA e ARRUDA, 2015). Se nenhuma regra é acionada para um determinado relacionamento, então o valor do peso associado ao conceito de fator (C_9) é nulo.

O modelo completo do DFCM, para o golfinho, é apresentado na Figura 4.6, e sua relação de conceitos na Tabela 4.3. As relações de causa e efeito do DFCM ($W_1 - W_{12}$), herdado do FCM clássico, é responsável pelas ações de baixo nível. O sistema de percepção é composto por PE, PF e PD; os quais são conceitos clássicos, e de entrada do modelo DFCM. VE e VD também são conceitos clássicos, e são inferências de saída do DFCM. O conceito Fator (C_9), tal como discutido acima, limita a influência dos conceitos Agrupamento (C_7) e Fuga (C_4), para garantir que estes conceitos não possam prevalecer sobre os estados de procura de alimentos e de desvio de obstáculos.

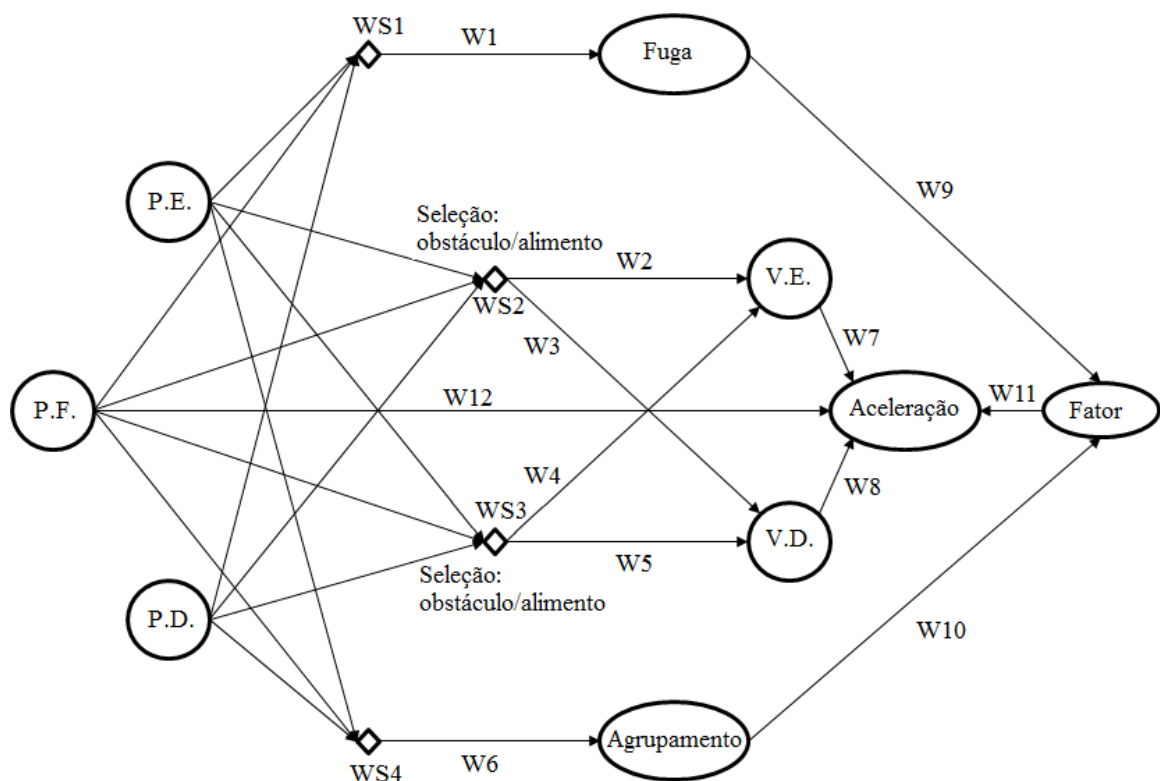


Figura 4.6 – DFCM para o golfinho.
Fonte: Autoria Própria

Tabela 4.3 – Conceitos do DFCM para o golfinho.

Conceito	Descrição
C1	P.E. – Percepção Esquerda
C2	P.F. – Percepção Frontal
C3	P.D. – Percepção Direita
C4	Fuga
C5	V.E. – Virar à Esquerda
C6	V.D. – Virar à Direita
C7	Agrupamento
C8	Aceleração
C9	Fator

Fonte: Autoria própria

Note-se que na Figura 4.6 não há representação dos pesos entre os conceitos de entrada $\{C_1, C_2 \text{ e } C_3\}$ e as seleções $\{W_{s1}, W_{s2}, W_{s3} \text{ e } W_{s4}\}$, devido a uma simplificação visual no modelo cognitivo para facilitar a compreensão da funcionalidade do DFCM em forma de grafo.

Entretanto, existem 12 relações causais entre os conceitos $\{C_1, C_2, C_3\}$ e $\{C_4, C_5, C_6, C_7\}$. Essas relações causais são ativadas somente quando os seus respectivos estados são acionados, por exemplo, W_1 representa as três relações causais entre as entradas e o estado em fuga (conceito C_4), similarmente W_6 representa o conjunto de pesos entre a percepção e o estado de agrupamento (conceito C_7); esta explicação pode ser estendida para os conjuntos de pesos W_2 e W_5 , os quais representam as relações causais entre a percepção e $\{C_5, C_6\}$ quando o estado de busca por alimentos (no grafo como a seleção: alimento, Figura 4.6) é disparado.

Da mesma forma para W_3 e W_4 quando o estado de desvio de obstáculos (seleção: obstáculo, Figura 4.6) é disparado. A diferença entre estes estados é a influência dos conceitos de entrada nos conceitos de saída, quando a seleção de "alimento" é ativada, os conceitos C_1 e C_3 inferem sobre os conceitos C_5 e C_6 , respectivamente; e quando a seleção de "obstáculo" é disparada, os conceitos C_1 e C_3 inferem sobre os conceitos C_6 e C_5 , respectivamente. Em outras palavras, se o agente percebe um obstáculo à sua direita, ele vai reagir virando à esquerda; se o objeto percebido é um alimento em vez de um obstáculo, o agente vai virar à direita, aproximando-se do alimento. Isto também pode ser visto nas suas respectivas tuplas, apresentadas nas equações (4.5) - (4.10).

Cada relação de seleção é disparada por seu respectivo valor de estado na Máquina de Estados. Em outras palavras, o estado de Agrupamento irá ativar a seleção W_{s4} e, conseqüentemente, os conceitos e os pesos relativos a esta relação de seleção: conceitos C_7 e

C_9 e pesos W_6 e W_{10} . Similarmente, o estado de Fuga irá ativar W_{S1} e seus seguintes conceitos e pesos; o estado de desvio de obstáculo ativará W_{S2} e W_{S3} , os conceitos relacionados a estes e os pesos W_3 e W_4 . O estado de busca por alimento dispara W_{S2} e W_{S3} , seus seguintes conceitos e os pesos W_2 e W_5 ; e finalmente, o estado de nado livre permite que a criatura se mova em linha reta.

Para exemplificação, no caso do DFCM do golfinho, enquanto as relações de seleção W_{S1} e W_{S4} não são acionadas, os pesos W_1 e W_6 não participam nas inferências do DFCM e, conseqüentemente, nem os conceitos C_4 e C_7 e os pesos W_9 e W_{10} . Em outras palavras, quando a criatura está no estado de desvio de obstáculo, apenas a percepção (conceitos de entrada) e os conceitos de saída são inferidos, como pode ser visto na Figura 4.7. Desta maneira o modelo cognitivo do DFCM muda dinamicamente de acordo com a Máquina de Estados.

As relações de seleção W_{S1} , W_{S2} , W_{S3} e W_{S4} para tomada de decisões são definidas de acordo com a estratégia da Máquina de Estados e a seguinte base de regras do tipo SE-ENTÃO:

- (W_{S1}) **SE** o golfinho percebe a presença de um predador **ENTÃO** W_1 é o conjunto de pesos da relação causal entre a percepção e o conceito Fuga (C_4).
- (W_{S2}) **SE** o golfinho percebe um obstáculo **ENTÃO** W_4 é o conjunto de pesos entre a percepção e o conceito VD (C_6).
- (W_{S2}) **SE** o golfinho percebe um alimento **ENTÃO** W_2 é o conjunto de pesos entre a percepção e o conceito VE (C_5).
- (W_{S3}) **SE** o golfinho percebe um obstáculo **ENTÃO** W_3 é o conjunto de pesos entre a percepção e o conceito VE (C_5).
- (W_{S3}) **SE** o golfinho percebe um alimento **ENTÃO** W_5 é o conjunto de pesos entre a percepção e o conceito VD (C_6).
- (W_{S4}) **SE** o golfinho percebe uma criatura da mesma espécie **ENTÃO** W_6 é o conjunto de pesos da relação causal entre a percepção e o conceito Agrupamento (C_7).

O modelo DFCM para tomada de decisões (Figura 4.6) proporciona a criatura virtual os seguintes comportamentos:

- A criatura virtual se move em um ambiente desconhecido, desde o ponto de origem até um ponto final (conhecidos a priori) dentro de uma região estimada;

- Se um obstáculo ou alimento é detectado à frente, esquerda e/ou direita da criatura, ela deve decidir um novo caminho para desviar, caso seja um predador, ou capturá-la, no caso de um alimento;
- O comportamento de nado padrão é em linha reta com velocidade constante, isto é, movimentos laterais são utilizados apenas como resultado de detecção de obstáculos, alimentos ou outras criaturas;
- Quando a criatura virtual está em movimento e seus sensores não percebem qualquer obstáculo ou alimento, ele acelera suavemente e, em seguida, permanece em uma velocidade constante;
- A tendência de movimento corresponde a uma média entre os valores do movimento em curso e os valores no instante anterior, o que impede qualquer alteração drástica no seu comportamento de nado;
- Quando a criatura virtual está virando à esquerda e o sensor oposto também detecta um obstáculo, a tendência de movimento é mantida.

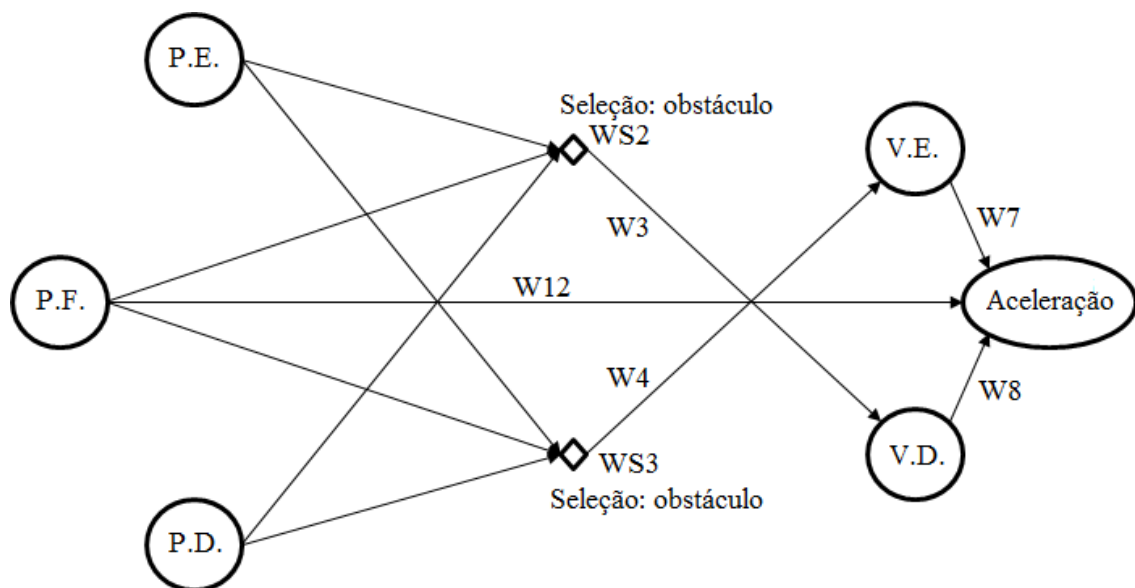


Figura 4.7 – DFCM resultante para o estado de desvio de obstáculos (seleção obstáculo)
Fonte: Autoria Própria

A Figura 4.7 apresenta o grafo do DFCM resultante para o estado de desvio de obstáculos. Este serve como uma exemplificação geral do seu funcionamento, relacionada com a atuação do processo de seleção. Enquanto não houver detecção de alimentos, predador ou criaturas da mesma espécie, as relações causais relacionados a esses conceitos são nulos, ou seja, esses conceitos não influenciarão no processo de tomada de decisão no estado de desvio

de obstáculos. No entanto, o modelo cognitivo pode trocar para outro estado, de acordo com a estratégia da Máquina de Estados, reorganizando-se.

Assim, o DFCM é um modelo cognitivo dinâmico, modificado pela Máquina de Estados por meio de relações de seleção. Estes novos tipos de relacionamentos podem ser descritos com modelos matemáticos simplificados apresentados pelas equações (4.1) - (4.4) (ressalta-se que estes modelos são referentes ao DFCM da Figura 4.6).

Função de seleção: desvio de obstáculos

$$desvio_{obstáculos} = \sum_{i=1}^n f(W_i * x_j) \mid i = \{3,4,7,8,12\} \text{ e } j = \{1,2,3,5,6,8\} \quad (4.1)$$

Função de seleção: busca por alimento

$$busca_{alimento} = \sum_{i=1}^n f(W_i * x_j) \mid i = \{2,5,7,8,12\} \text{ e } j = \{1,2,3,5,6,8\} \quad (4.2)$$

Função de seleção: fuga do predador

$$fuga_{predador} = \sum_{i=1}^n f(W_i * x_j) \mid i = \{1,9,11\} \text{ e } j = \{1,2,3,4,9\} \quad (4.3)$$

Função de seleção: Agrupamento

$$agrupamento = \sum_{i=1}^n f(W_i * x_j) \mid i = \{6,10,11\} \text{ e } j = \{1,2,3,7,9\} \quad (4.4)$$

Onde: f é a função relacionada a inferência do DFCM para o cada estado; W_i é o conjunto “i” de pesos das relações causais conectadas aos conceitos “ x_j ”, de acordo com o estado atual do agente.

As equações (4.5) - (4.20) realizam, de acordo com o formalismo apresentado na Seção 2.1, o cálculo dos pesos relacionados ao nível do conceito e do tipo de relação. Além disso, estas equações fornecem uma melhor compreensão de cada relação utilizada no desenvolvimento do DFCM.

$$W_1 = (1, [C1, C2, C3], C4, \text{causal}, [-1,1], 0) \quad (4.5)$$

$$W_2 = (1, [C1, C2], C5, \text{causal}, [-1,1],0) \quad (4.6)$$

$$W_3 = (1, [C2, C3], C5, \text{causal: sintonizado dinamicamente}, [-1,1],0) \quad (4.7)$$

$$W_4 = (1, [C1, C3], C6, \text{causal: sintonizado dinamicamente}, [-1,1],0) \quad (4.8)$$

$$W_5 = (1, [C2, C3], C6, \text{causal}, [-1,1],0) \quad (4.9)$$

$$W_6 = (1, [C1, C2, C3], C7, \text{causal}, [-1,1],0) \quad (4.10)$$

$$W_7 = (0, C5, C8, \text{causal}, [-1,1],0) \quad (4.11)$$

$$W_8 = (0, C6, C8, \text{causal}, [-1,1],0) \quad (4.12)$$

$$W_9 = (0, C4, C9, \text{causal}, [-1,1],0) \quad (4.13)$$

$$W_{10} = (0, C7, C9, \text{causal}, [-1,1],0) \quad (4.14)$$

$$W_{11} = (0, C9, C8, \text{causal}, [-1,1],0) \quad (4.15)$$

$$W_{12} = (0, C2, C8, \text{causal: sintonizado dinamicamente}, [-1,1],0) \quad (4.16)$$

Os pesos de navegação e sobrevivência:

$$W_{S1} = (2, [C1, C2, C3], C4, \text{Seleção}, [0,1],1) \quad (4.17)$$

$$W_{S2} = (2, [C1, C2], [C5, C6], \text{Seleção}, [0,1],2) \quad (4.18)$$

$$W_{S3} = (2, [C1, C3], [C5, C6], \text{Seleção}, [0,1],2) \quad (4.19)$$

$$W_{S4} = (2, [C1, C2, C3], C7, \text{Seleção}, [0,1],1) \quad (4.20)$$

A Figura 4.8 apresenta DFCM do predador, e a Tabela 4.4 apresenta sua relação de conceitos. O seu funcionamento é semelhante ao DFCM do golfinho, de uma forma simplificada. Este tomador de decisões DFCM possibilita o predador desviar de obstáculos e procurar alimento (caçar a presa, neste ambiente virtual), e está em conformidade com a estratégia da Máquina de Estado do Predador (Figura 4.5). Onde: PE, PF e PD são os conceitos de percepção (entrada), e VE e VF são conceitos de saída. As relações causais e seleção são semelhantes às do golfinho, assim como sua Máquina de Estados dispara as relações causais e seus respectivos conceitos e pesos.

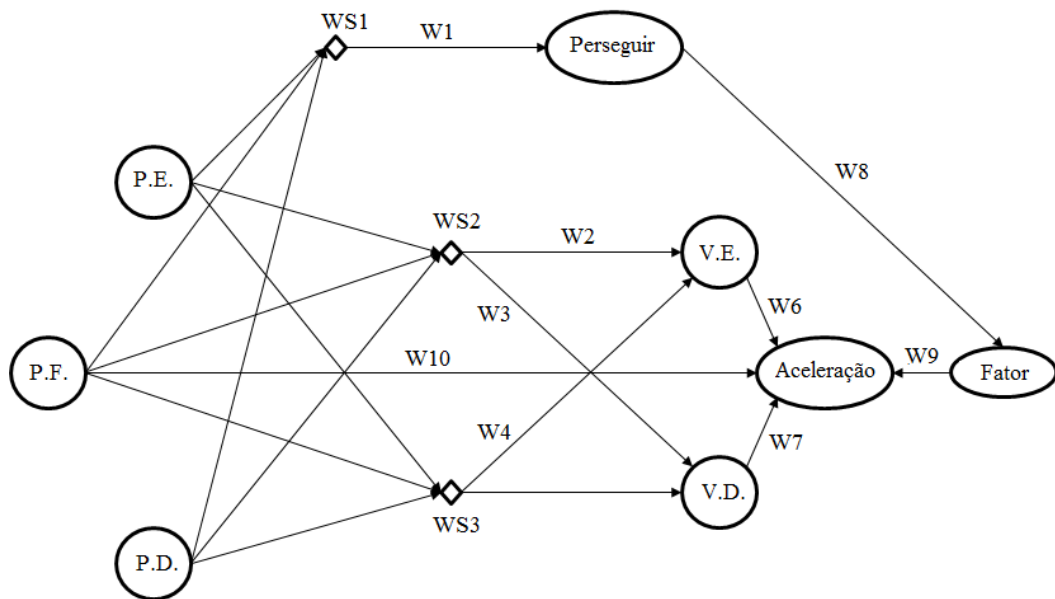


Figura 4.8 – DFCM do predador.

Fonte: Autoria Própria

Tabela 4.4 – Conceitos do DFCM proposto para o predador.

Conceito	Descrição
C1	P.E. – Percepção Esquerda
C2	P.F. – Percepção Frontal
C3	P.D. – Percepção Direita
C4	Perseguir
C5	V.E. – Virar à Esquerda
C6	V.D. – Virar à Direita
C7	Aceleração
C8	Fator

Fonte: Autoria Própria

Uma vez que os modelos DFCM (conjunto de pesos e conceitos válidos em cada instante de tempo e/ou estados) para o golfinho e tubarão são definidos pelo sistema de estados interno, os pesos podem ser afinados pelo algoritmo de Aprendizagem por Reforço, apresentado na Seção 3.2.2. Esta adaptação do modelo DFCM deve ser desenvolvida com acurácia para evitar a ocorrência de alterações drásticas nos valores dos pesos.

Para isso, os valores das relações causais são adaptados de acordo com regras heurísticas, onde valores limites de máximo e mínimo são estabelecidos para cada peso. Cita-se como exemplo a regra de W_3 :

- **SE** intensidade do sensor frontal (PF) é maior que limite máximo **ENTÃO** W_{lim} aplicado no ajuste de W_3 é o valor máximo W_{Fmax} .

Estas regras determinam a mudança heurística da política do estado através de recompensas e punições correspondente ao termo "r" da equação (3.2), como descrito na Seção 3.2.2, para sintonia fina dos pesos da DFCM. Essa equação aplica diretamente a experiência do agente em sua interação com o ambiente.

4.3 RESULTADOS

Geralmente, um ambiente virtual permite a simulação de criaturas interagindo no mesmo. Neste trabalho, o ambiente simulado apresenta dois golfinhos, sendo o primeiro o ator ou criatura principal do ecossistema com um ou dois predadores, em diferentes experimentos, e finalmente, para maior riqueza de detalhes do ambiente, alguns peixes menores (alimento para o golfinho). Ambos, predador e golfinho podem aumentar ou diminuir a sua velocidade de nado, dependendo da situação. O golfinho, quando ameaçado por predadores, aumentará sua velocidade na tentativa de escapar e sobreviver, e quando não há mais ameaça, retorna à sua velocidade e estados normais. O predador, quando percebe a presença de sua presa aumentará sua velocidade, a fim de caçá-la e capturá-la. Como resultado, é possível controlar a velocidade do predador através da alteração de sua "fome", assim afetando o seu desempenho para capturar o golfinho.

Um ecossistema simulado 2-D animado também foi desenvolvido para testar o modelo cognitivo DFCM para tomada de decisões em Vida Artificial. Uma visão geral do ambiente simulado é apresentada na Figura 4.9, onde os sinais "+" simbolizam os obstáculos estáticos; "*" representa o alimento; "o" representa a criatura virtual, o golfinho; e, finalmente, "▲" simboliza o predador; nas simulações a trilha com três cores simboliza um golfinho e as trilhas em azul e vermelho representam os predadores. As falhas na trajetória representam o aumento na velocidade de nado.

Nas figuras apresentadas nessa seção de resultados, é mostrado o caminho tomado pelo golfinho em toda a simulação, o momento em que o golfinho aumenta sua velocidade uma vez que nenhum alimento / obstáculo é detectado. Nestas simulações o golfinho coleta o alimento em seu caminho, escapa do predador, e encontra outra criatura da mesma espécie, realizando

assim o agrupamento. Em particular, ressalta-se a capacidade do agente para se adaptar e para compensar a incerteza ou conhecimento parcial do ecossistema,

Na Figura 4.10, um caminho ou trilha é usado para exibir a sequência de ações tomadas pelas criaturas durante as simulações, como as mudanças de direção e aceleração em suas trajetórias. O golfinho parte do ponto (15,5) em coordenadas cartesianas, e logo após se depara com um obstáculo a sua frente e um alimento a sua esquerda, decidindo virar à esquerda em direção ao alimento. Em seguida, o golfinho percebe o predador na sua esquerda, e, em frente, um obstáculo à direita, no qual decide aumentar sua velocidade para escapar do predador manobrando para a esquerda, desviando assim de ambos, continuando sua navegação em direção a um outro alimento à sua esquerda. Após a captura desse alimento e dois outros a frente, em especial o segundo localizado no ponto (-5,200), o qual está próximo a um obstáculo, exigindo que o controlador tome decisões contraditórias (se distanciar do obstáculo ou se aproximar do alimento), o golfinho encontra outro ser de sua espécie e decide agrupar. Os quais seguem agrupados até o termino da simulação.

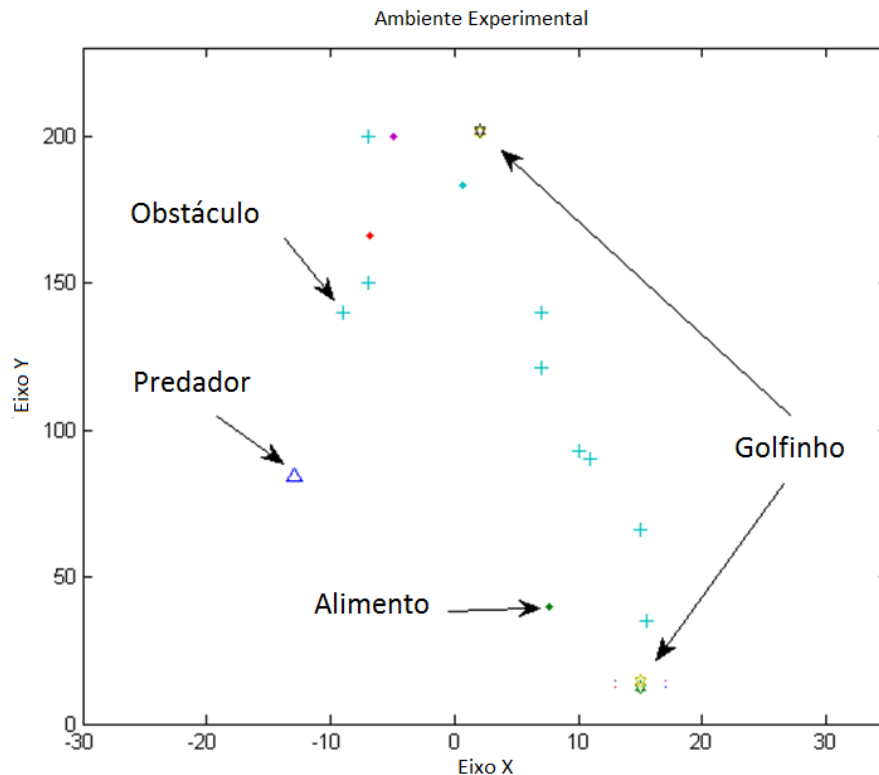


Figura 4.9 – Visão geral do ambiente.
Fonte: Autoria Própria

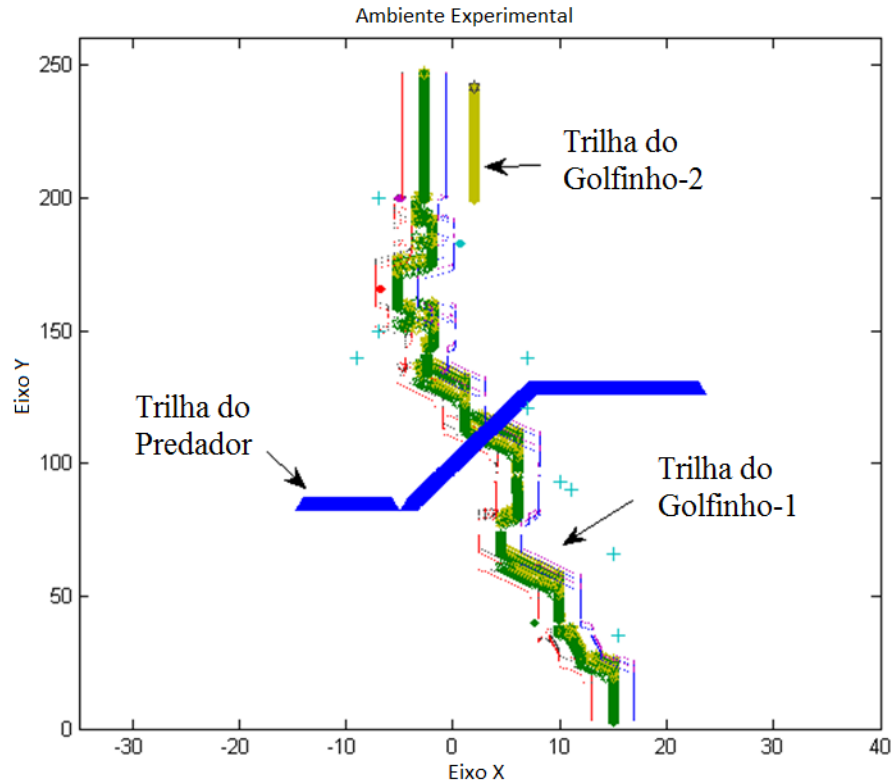


Figura 4.10 – Trilhas de navegação do predador e golfinho – Ambiente com 1 predador.
Fonte: Autoria Própria




Figura 4.11 – Velocidade do Golfinho e distância relativa entre predador e sua presa– Ambiente com 1 predador
Fonte: Autoria Própria




Figura 4.12 – Valores do peso W_4 , PD e VE do Golfinho – Ambiente com 1 predador.
Fonte: Autoria Própria




Figura 4.13 – Valores do peso W_3 , PE e VD do Golfinho – Ambiente com 1 predador.
Fonte: Autoria Própria

As Figuras 4.11, 4.12 e 4.13 apresentam os valores dos conceitos do DFCM do golfinho, referente ao ambiente com 1 predador (Figura 4.10). A variável no eixo x destes gráficos é dada em ciclos da simulação e correspondem ao tempo em que o golfinho leva para atravessar o ambiente, chegando a seu destino final. Um ciclo corresponde a uma iteração do DFCM em que os conceitos do grafo recebem valores, interagem entre si e param em um ponto de

estabilização. As linhas verdes apresentam a variação dos pesos relacionados a inferência do movimento do agente no ambiente, W3 e W4 para Virar à Direita e Virar à Esquerda, respectivamente; sendo possível, também, a visualização da sintonia dinâmica da Aprendizagem por Reforço atuando nestes pesos, relacionados aos conceitos de entrada PE e PD, respectivamente.

Na Figura 4.11, é apresentada a velocidade do golfinho e a distância relativa entre a criatura e o predador. Pode-se notar que há um aumento significativo na velocidade do golfinho quando o predador está próximo, durante os ciclos 270 a 340 no eixo x. Ressalta-se que há um valor default de velocidade de 0.5 escolhido pelos especialistas, o AR apenas causa variações acima ou abaixo deste offset. Com isto a velocidade normal de nado do golfinho é sempre representada na figura por 0.5. Essa explicação também é válida para as Figuras 4.17 e 4.21.

Nas Figuras 4.12 e 4.13 são apresentados os conceitos relacionados à percepção do agente principal, o golfinho. Nestas figuras é possível visualizar se as ações tomadas pelo golfinho são referentes ao desvio de obstáculo ou para capturar o alimento; juntamente com a ação de sintonia dinâmica dos pesos relacionados aos conceitos de Virar à Esquerda e Virar à Direita, respectivamente. Essa explicação pode ser estendida para as Figuras 4.18, 4.19, 4.22 e 4.23.

A Figura 4.14 destaca as ações tomadas pelo predador e pelo golfinho, quando suas presenças são mutuamente percebidas; ambos aumentam suas velocidades de movimento; o golfinho tentando fugir, e o predador em sua tentativa de capturar sua presa, como apresentado na Figura 4.11 para o golfinho. A Figura 4.15 apresenta as medidas tomadas pelo golfinho, em uma visão ampliada, quando este encontra outro ser de sua espécie, agrupando com ele.

O modelo cognitivo do tubarão é relativamente simples, com apenas três estados, nado livre, evitar obstáculos e caçar a presa. A mudança de estado ocorre quando uma presa (golfinho) é percebida, assim, o predador entra no estado perseguição (caça), e sua velocidade é aumentada de acordo com sua fome. Neste contexto, a Figura 4.16 mostra a trajetória das criaturas no ambiente virtual para a segunda simulação em que o predador captura a sua presa; o conceito de fome do predador teve um aumento de 30%, em relação a simulação anterior (Figura 4.10), possibilitando assim que o predador persiga e capture sua presa com sucesso.

As Figuras 4.17, 4.18 e 4.19 apresentam os dados da percepção do golfinho para ambiente da Figura 4.16. Nessas figuras é possível visualizar as ações tomadas pelo golfinho em seu curto trajeto; ressalta-se que quando o golfinho é capturado pelo predador, seus valores de percepção, pesos e conceitos passam a ser zero, pois este agente não existe mais nesse ambiente.

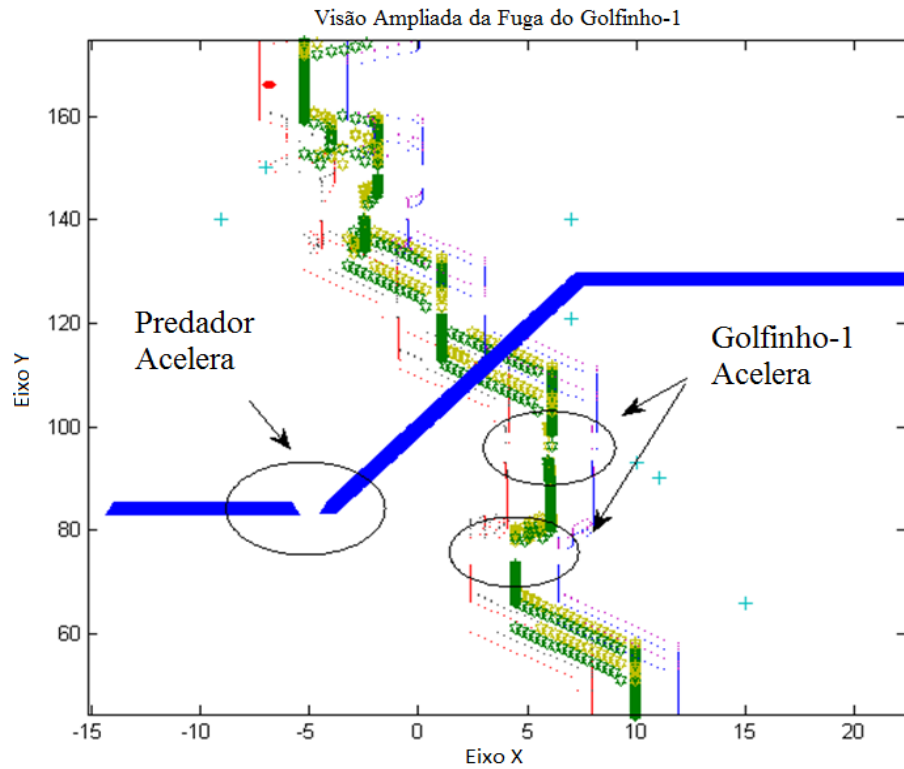


Figura 4.14 – Visão ampliada das trilhas das criaturas virtuais – Ambiente com 1 predador.
Fonte: Autoria Própria

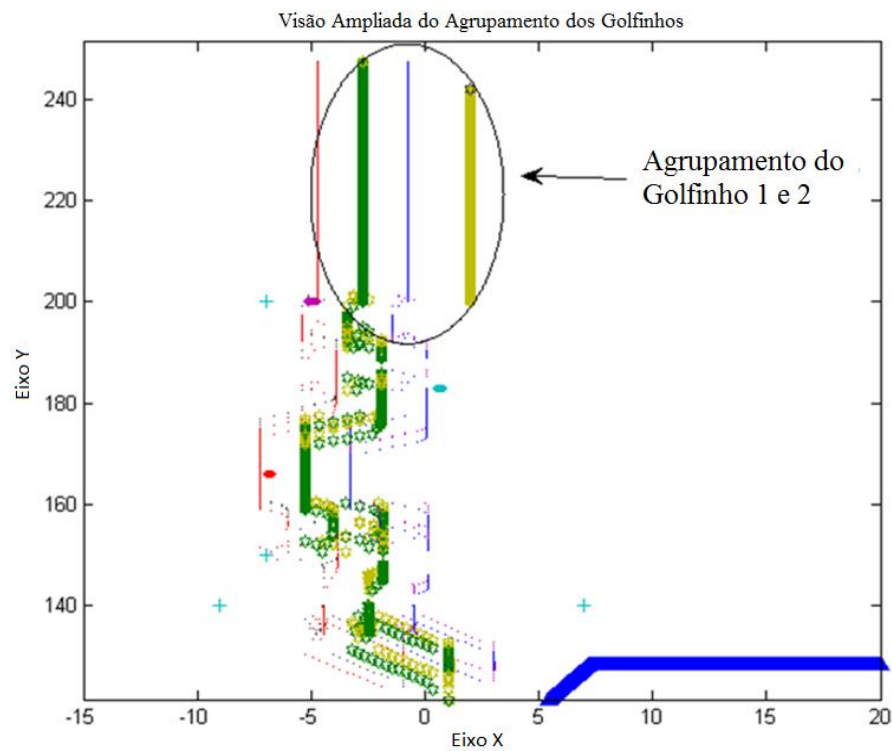


Figura 4.15 – Visão ampliada - Trilha do golfinho nos momentos de agrupamento – Ambiente com 1 predador.
Fonte: Autoria Própria

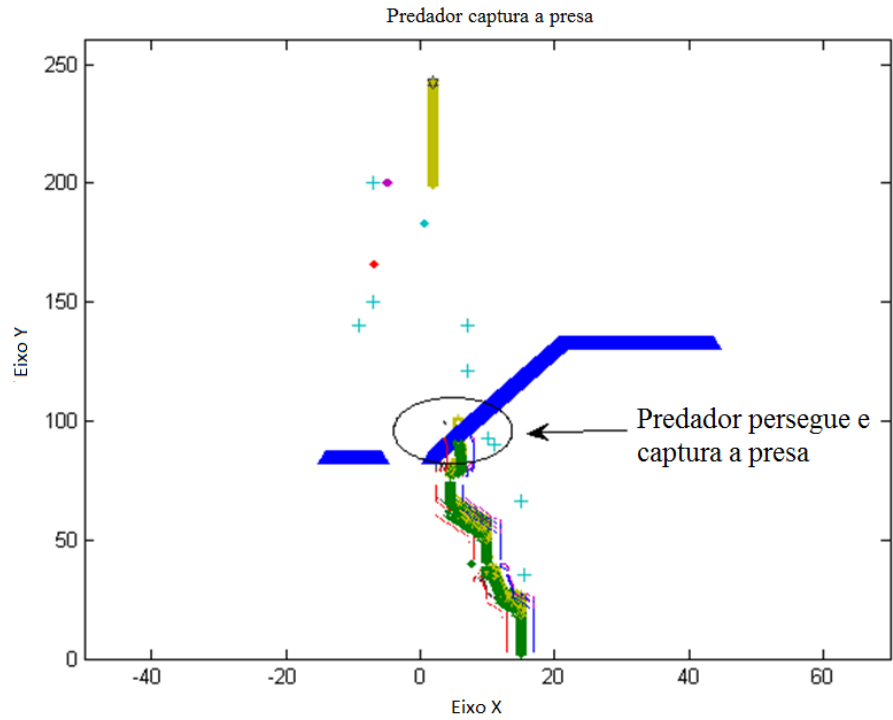


Figura 4.16 – Trilha das criaturas virtuais no ambiente, onde o predador captura sua presa.
Fonte: Autoria Própria

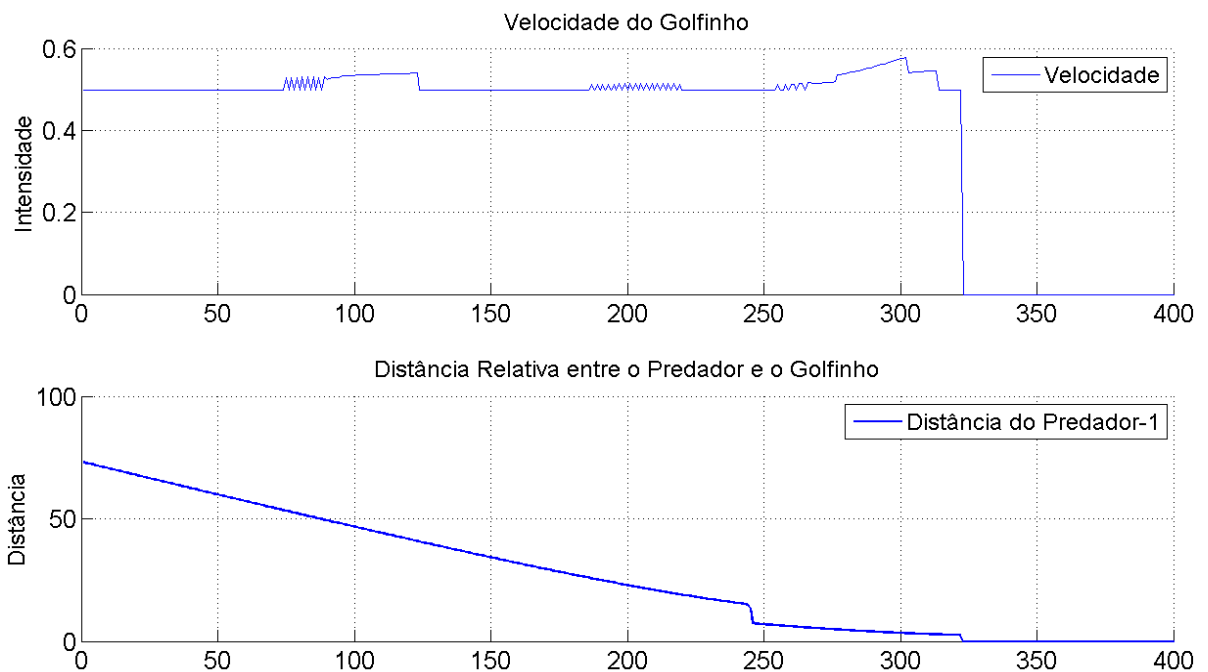


Figura 4.17 – Velocidade do Golfinho e distância relativa entre predador e sua presa – Morte do Golfinho
Fonte: Autoria Própria

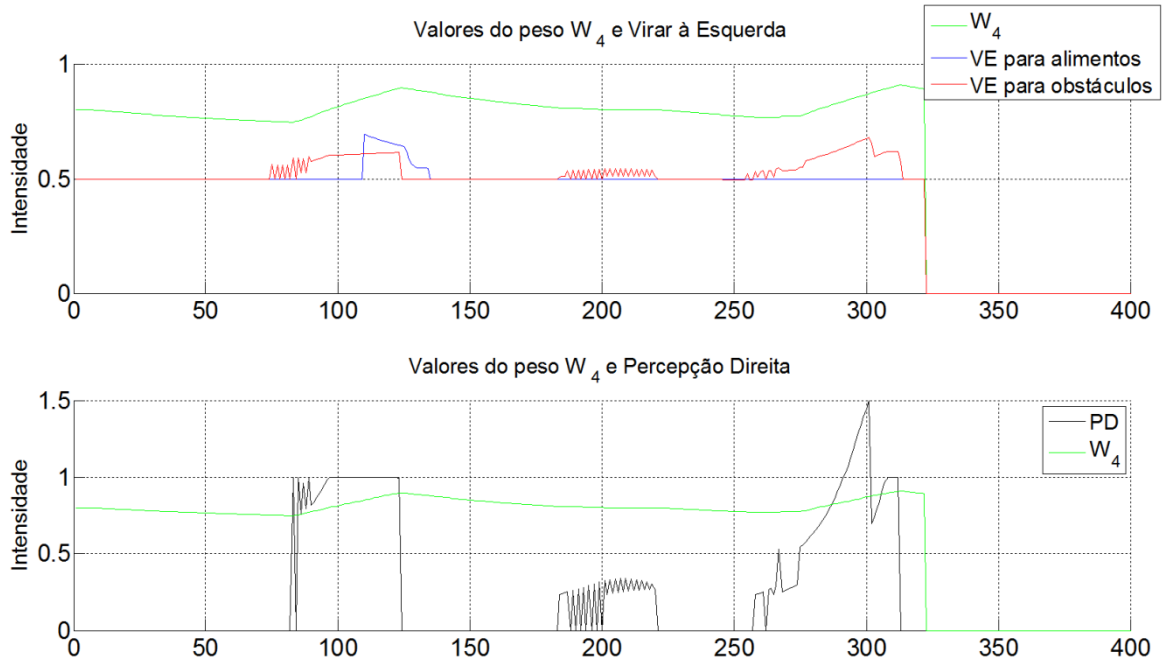


Figura 4.18 – Valores do peso W_4 , PD e VE do Golfinho – Morte do Golfinho.
Fonte: Autoria Própria

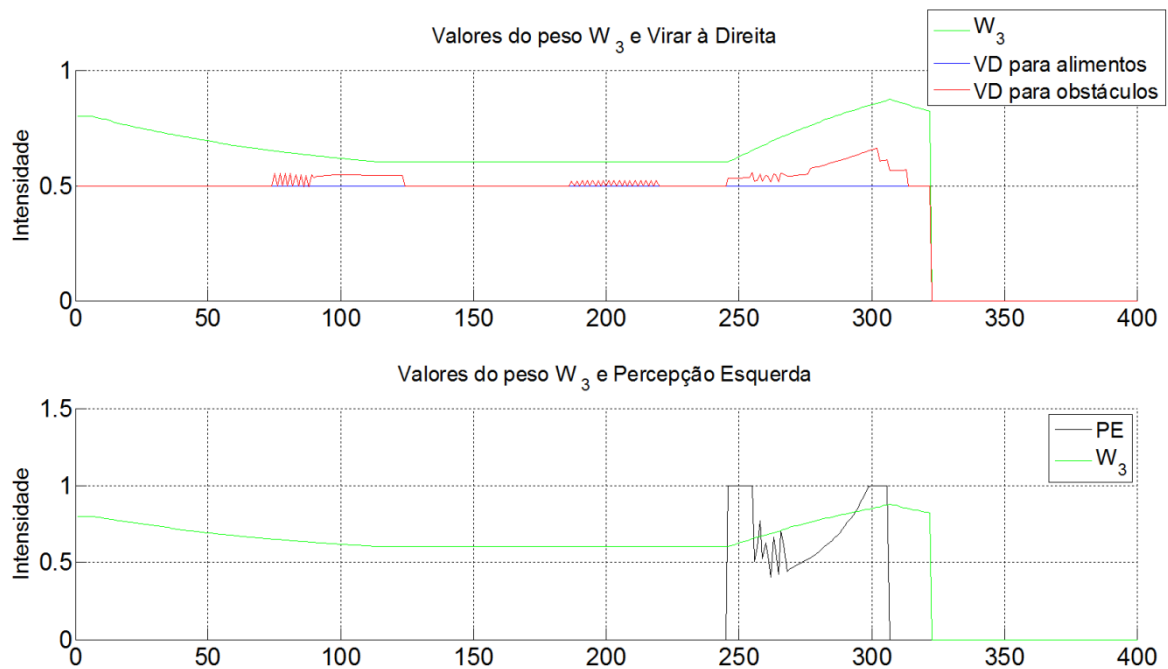
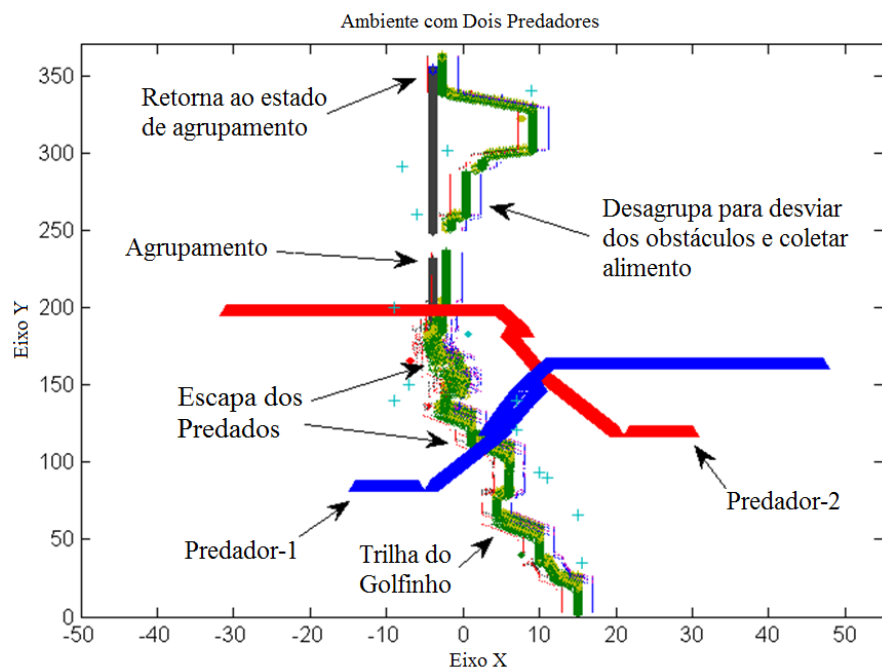


Figura 4.19 – Valores do peso W_3 , PE e VD do Golfinho – Morte do Golfinho.
Fonte: Autoria Própria

A Figura 4.20 mostra as criaturas artificiais num ambiente mais complexo, com dois predadores. Nesta figura, correspondente a terceira simulação, o segundo predador é representado pela trilha de cor vermelha, e o segundo golfinho pela cor cinzenta. O primeiro

golfinho consegue escapar de ambos os predadores e agrupar com outra criatura, em seguida, o golfinho tem de tomar a decisão de permanecer agrupado ou evitar um obstáculo, e, imediatamente após, um alimento é percebido; depois de se desviar do obstáculo e recolher o alimento, ele retorna ao estado de agrupamento. Ressalta-se que o golfinho através da execução dos movimentos para escapar do predador-2, não coleta o alimento na posição (0.5,183); este fato é devido à prioridade das ações modeladas para este agente, no qual a ação de escapar do predador tem uma maior importância do que a ação de coleta de alimento, corroborando assim, com sua estratégia modelada para a hierarquia de decisões, como mostrado na Figura 4.2.

As Figuras 4.21, 4.22 e 4.23 apresentam os dados da percepção e dos pesos referentes às saídas, similarmente as outras figuras já apresentadas. Pode-se visualizar, na Figura 4.21, as ações do golfinho, alterando sua velocidade de nado, para escapar do predador, durante os ciclos, de 270 a 340 para o predador-1, e 550 a 650 para o predador-2.



**Figura 4.20 – Trilha das criaturas virtuais em um ambiente com dois predadores.
Fonte: Autoria Própria**

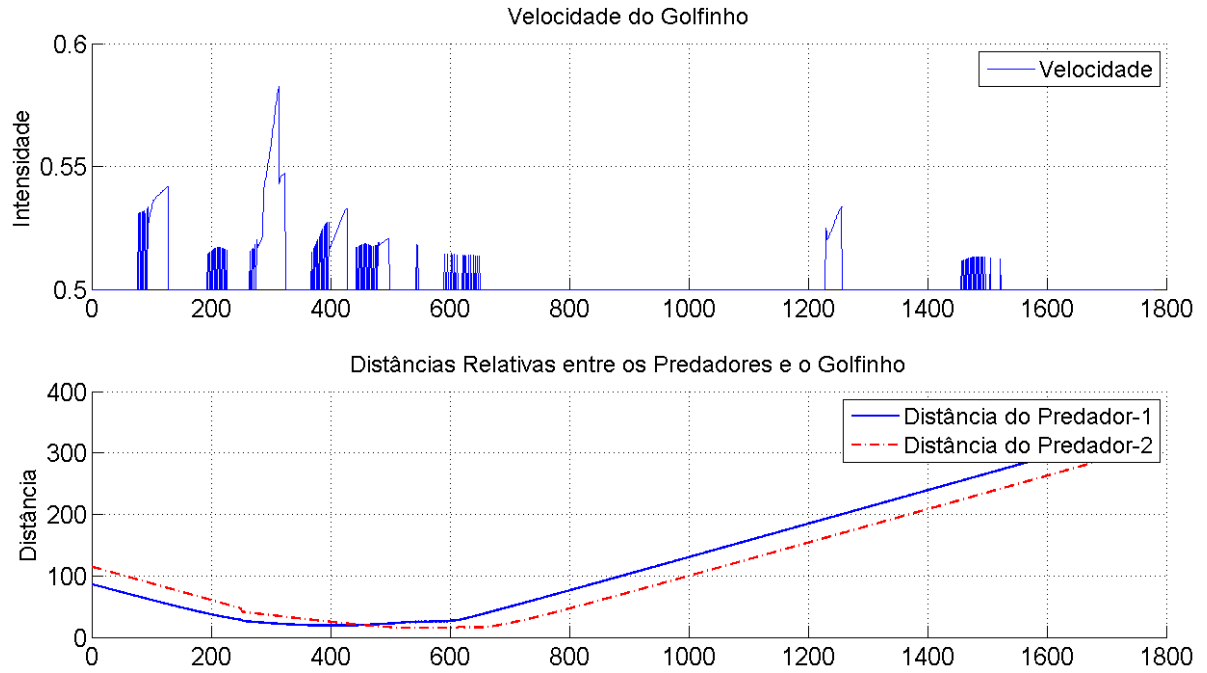


Figura 4.21 – Velocidade do Golfinho e distâncias relativas entre os predadores e sua presa – Ambiente com 2 predadores.
Fonte: Autoria Própria

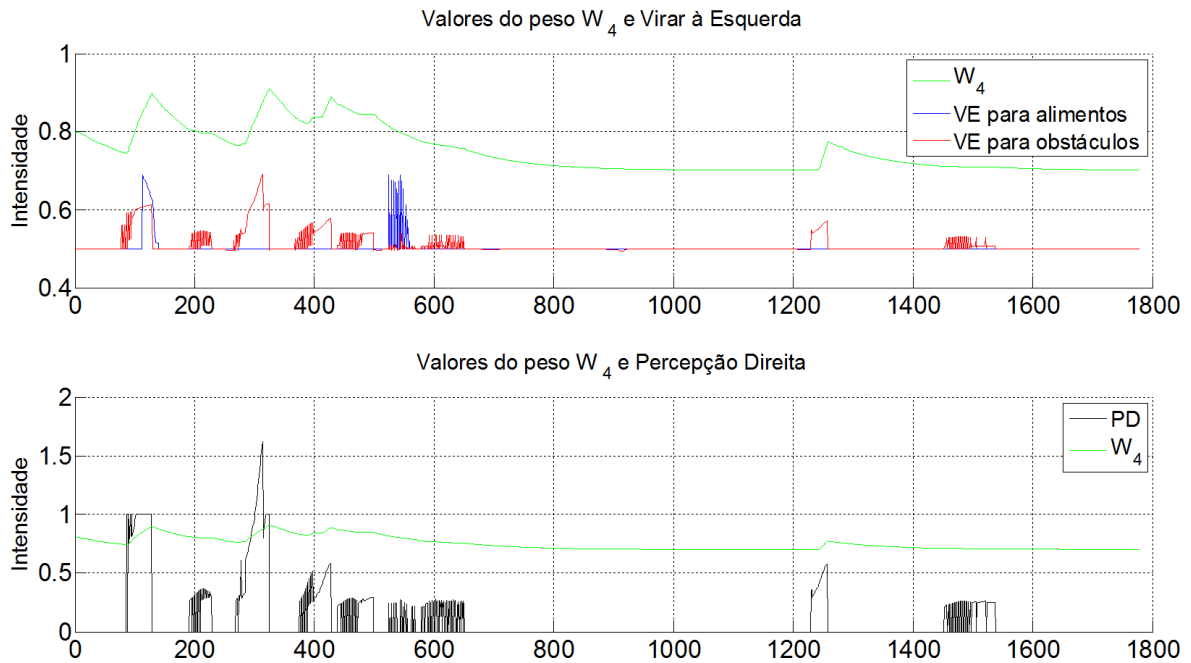


Figura 4.22 – Valores do peso W_4 , PD e VE do Golfinho – Ambiente com 2 predadores.
Fonte: Autoria Própria

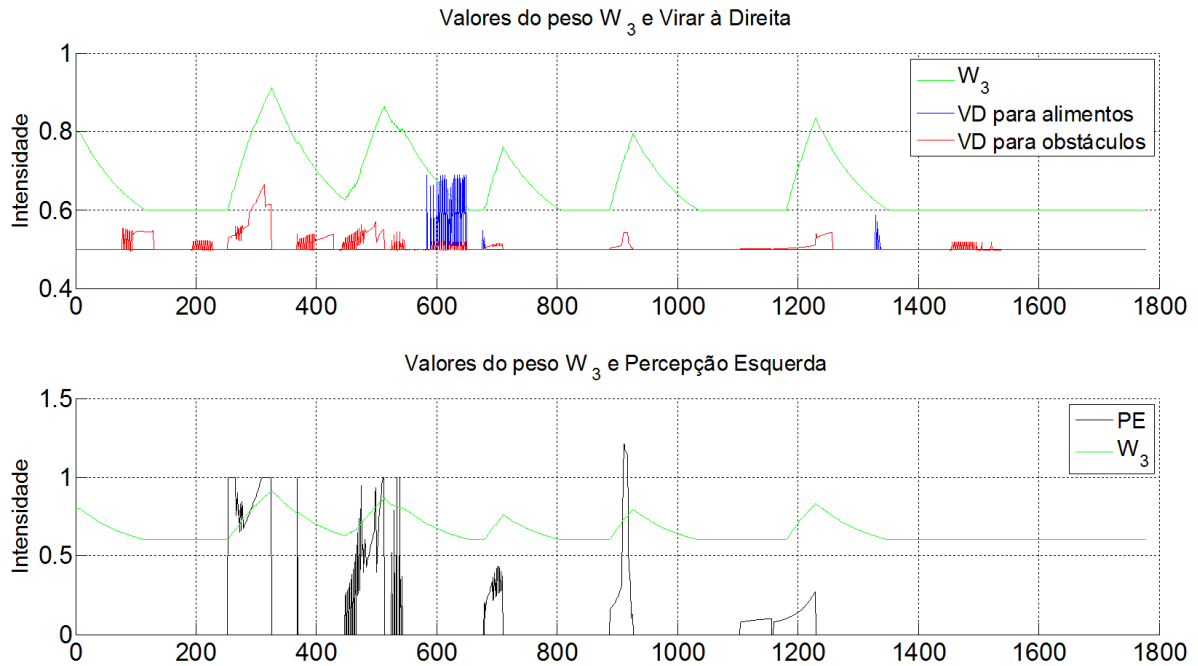


Figura 4.23 – Valores do peso W_3 , PE e VD do Golfinho – Ambiente com 2 predadores.
Fonte: Autoria Própria

4.4 CONCLUSÃO

Este capítulo abordou o desenvolvimento de um modelo DFCM autônomo para aplicação na área de Vida Artificial, através do uso de conhecimento heurístico para planejamento das ações, inspiradas em um ecossistema marítimo, no comportamento de golfinhos e tubarões, e no gerenciamento das mesmas por uma Máquina de Estados.

Os resultados dos experimentos simulados mostram dois comportamentos distintos no ambiente virtual. Mais especificamente, é possível observar o evento no qual o golfinho é morto quando o predador é mais rápido, devido ao aumento de seu conceito de fome. No entanto, quando o predador tem uma velocidade mais lenta, o golfinho é capaz de escapar.

Ressalta-se também o comportamento do golfinho no ambiente com dois predadores, no qual este agente, de forma a garantir sua sobrevivência, decide não capturar um alimento para desviar do segundo predador, de acordo com a hierarquização das ações planejadas e modeladas a ele.

Essas criaturas desempenharam suas funções em conformidade com a estrutura DFCM proposta, atingindo os objetivos dados e improvisando contra as limitações de ambiente. Desse modo, os atores implementados com DFCMs não são apenas sensíveis, mas também

perceptivos, ou seja, o seu comportamento depende de sua percepção e interação no ambiente. No entanto, nenhum comportamento emergente ou inesperado foi observado nas simulações, ou seja, todas as ações executadas pelas criaturas eram esperadas. Um comportamento emergente pode ser, por exemplo, quando o golfinho encontra outra da mesma espécie e decide não agrupar. Esta habilidade deve ser investigada em trabalhos futuros.

Uma dificuldade do desenvolvimento de modelos DFCM, está na abstração do conhecimento para a geração de mapas relacionando as variáveis que descrevem o problema, através de conceitos, e as causalidades entre elas. Esta dificuldade pode levar a mapas irrealis, principalmente quando os especialistas discordam entre si na extração do conhecimento sobre o problema. Porém, após a construção do mapa, sua interpretação é simples, pois cada conceito possui uma semântica forte, diferentemente de algumas outras técnicas inteligentes, como por exemplo as redes neurais.

O uso da arquitetura proposta permite o desenvolvimento, de uma forma simples, das camadas de controle do DFCM, pois sua construção é feita de forma incremental abordando comportamentos mais simples nas camadas inferiores, e incrementalmente adicionando camadas mais complexas ao modelo, agregando novos conceitos e relações ao modelo cognitivo de forma gradativa.

A ferramenta proposta pode ser generalizada para a aplicação em outras áreas através do uso da ontologia e a da arquitetura proposta, por meio do desenvolvimento de camadas de controle de forma hierárquica utilizando o conhecimento abstraído do problema e dispostos em forma de grafos.

5 ROBÓTICA DE ENXAME

Uma arquitetura para Sistemas Multi-Agentes (SMA) baseado na modelo clássico de Subsunção (BROOKS, 1986) é proposta nesta dissertação para gerir comportamentos de agentes inteligentes. O formalismo do conhecimento para representar, modelar e implementar diversos comportamentos dos agentes é baseado em Mapas Cognitivos *Fuzzy* Dinâmicos. Esta arquitetura conforme apresentada no Capítulo 3 utiliza a capacidade de evolução do agente para auxiliar nas tomadas de decisões. A evolução é conceitualmente diferente de aprendizagem, dado que um agente só pode evoluir se este herda o conhecimento de outro agente, enquanto que durante a aprendizagem o agente só precisa de si mesmo (DE CASTRO, 2007).

O sistema de navegação autônomo cooperativo desenvolvido é capaz de resolver problemas de navegação com decisões sequenciais em ambiente parcialmente ou totalmente desconhecido com múltiplos objetivos. Para isso, duas estratégias diferentes, inspiradas em colônias de formigas (DORIGO e STÜTZLE, 2004), são usadas para compartilhar informações (memória de navegação) entre os agentes. Na primeira estratégia, uma memória do trajeto de navegação é, a priori, compartilhada com os outros agentes; o agente, em posse dessa informação, usa a percepção, por meio da leitura dos seus sensores, e a memória de navegação do trajeto de um agente anterior. Portanto, cada novo agente adquire parte do conhecimento de todos os agentes anteriores e, assim, a cada novo ciclo, a memória de navegação é reforçada.

Na segunda estratégia, o agente navegará através do ambiente liberando feromônios, os quais geram uma trilha para os próximos agentes. Este caminho de feromônios é intensificado pelo número de agentes que navegaram pelo mesmo cenário, que também liberam seus feromônios. Estas duas estratégias são comparadas e o desempenho do sistema de navegação autônoma é avaliado por meio de um ambiente simulado.

5.1 ESTRATÉGIA DE CONTROLE

A arquitetura proposta, para esta aplicação, possui 6 blocos ou subsistemas, como mostrado na Figura 5.1. Cada bloco representa uma parte específica do problema. O Sistema de Percepção simboliza os sensores e o Sistema de Estados Interno corresponde à Máquina de Estados que gerencia o comportamento do agente. O Sistema Comportamental reúne os

modelos DFCM. O Sistema de Aprendizagem implementa os algoritmos de aprendizagem e evolução. O Sistema Motor é a saída do sistema responsável pelas inferências no movimento do agente no ambiente. E, finalmente, o Sistema de Memória contém a estratégia de comunicação e compartilhamento das informações com outros agentes.

Como discutido no Capítulo 3, o bloco do meio ambiente não é parte da arquitetura em si; no entanto, serve para mostrar quais blocos interagem com o mesmo. Note que apenas os Sistemas de Percepção e Motor interagem com o Ambiente, isto significa que o planejamento não é parte do ciclo percepção-ação, agindo apenas quando qualquer resultado relevante (eventos, como a percepção de um obstáculo) é inferido, exigindo assim uma decisão do agente.

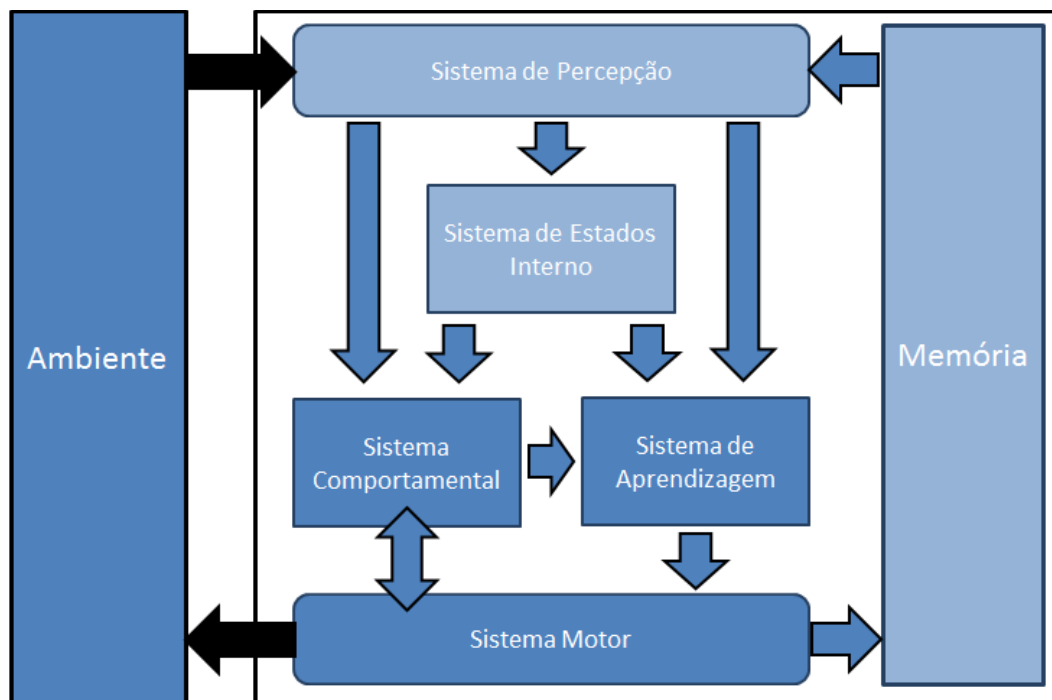


Figura 5.1 – Arquitetura híbrida DFCM para Robótica de Enxame.
 Fonte: Adaptado de MENDONÇA *et al.* (2015b)

5.2 MODELOS DFCM PARA AMBIENTES COM MÚLTIPLOS ROBÔS

O desenvolvimento do modelo DFCM para navegação autônoma em ambientes com múltiplos robôs começa pela compreensão dos comportamentos e ações de agentes em diversas situações. Estes comportamentos e ações estão listados na Tabela 5.1, de acordo com a situação e estratégia de navegação, tipo de comportamento e as habilidades do agente.

Neste trabalho, existem duas tarefas que deverão ser realizadas pelos robôs: obter os alvos localizados em pontos previamente conhecidos e evitar obstáculos desconhecidos com base em medições de sensores (ambiente parcialmente conhecido).

Tabela 5.1 – Comportamento / habilidades / situações / ações executadas pelo agente.

Comportamento	Habilidade	Situação	Ação
Reativo	Navegação	Presença de obstáculo (s) no lado direito do robô	Virar à esquerda
Reativo	Navegação	Presença de obstáculo (s) no lado esquerdo do robô	Virar à direita
Reativo	Navegação	Trajetória livre de obstáculos	Ir em frente (acelerar ou desacelerar)
Reativo	Navegação	Presença de obstáculo (s) na frente do robô	Virar à direita ou à esquerda
Deliberativo	Navegação	Colisão iminente (a aparência súbita de um obstáculo)	Acionar a ré e continuar
Deliberativo	Planejamento	Explorar o ambiente	Andar em linha reta
Deliberativo	Planejamento	Mapear o ambiente	Identificar e memorizar obstáculos
Deliberativo	Planejamento	Execução de tarefas	Coletar alvos
Inteligente	Adaptação	Adaptar a mudanças ambientais	Usar um procedimento de aprendizagem para adaptação dinâmica
Inteligente	Cooperação	Adquirir conhecimento	Usar a experiência de navegação de outros agentes para evolução do modelo
Inteligente	Aprendizagem	Auto adaptação	Usar sua própria memória de navegação para evolução do modelo
Inteligente	Cooperação	Compartilhar informação	Criar uma trilha de feromônios
Inteligente	Aprendizagem	Adquirir conhecimento	Usar a trilha de feromônios para evolução do modelo

Fonte: Autoria própria

Ao analisar as várias situações na Tabela 5.1, pode-se estabelecer uma hierarquia de ações (Figura 5.2). Os robôs móveis adotam uma abordagem *bottom-up* para as ações (blocos azuis). Por conseguinte, tomar decisões para desvio de obstáculos em especial acionar a ré em caso de colisão eminente, encontrar alvos (os feromônios são considerados como alvos secundários) e explorar o cenário. As outras ações (blocos brancos) estão relacionadas com gerenciamento do comportamento do robô e elas estão sempre atuando de forma paralela. Em

outras palavras, a adaptação do modelo, evolução e algoritmos de ajuste agem de acordo com as premissas estabelecidas (comportamento inteligente) independentemente da decisão / ações relacionadas com comportamentos reativos e/ou deliberativos.

A fim de dinamicamente evoluir o agente, a Máquina de Estados apresentada na Figura 5.3 administra a estratégia de gestão do agente e corresponde ao Sistema de Estados Interno.

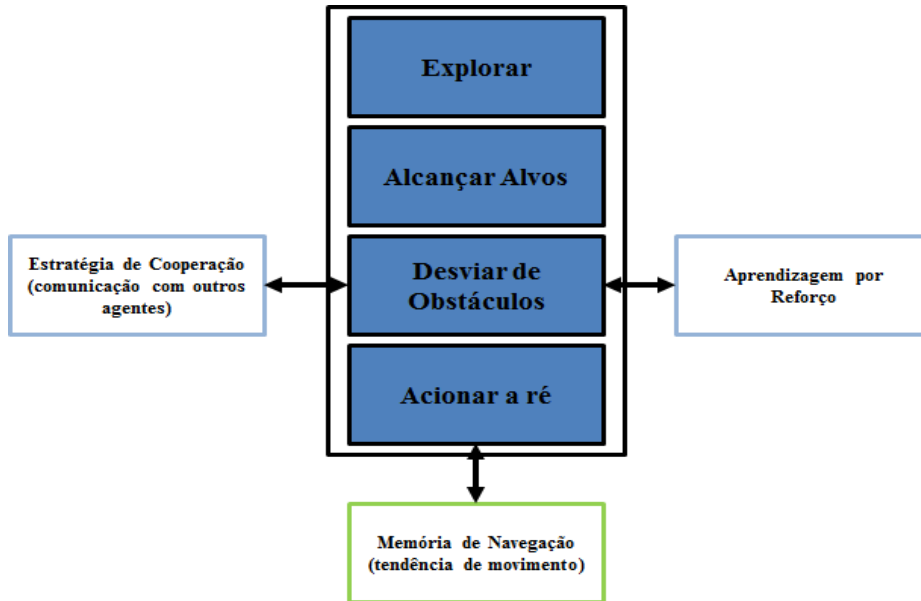


Figura 5.2 – Hierarquia de ações para a arquitetura de subsunção.
Fonte: Autoria Própria

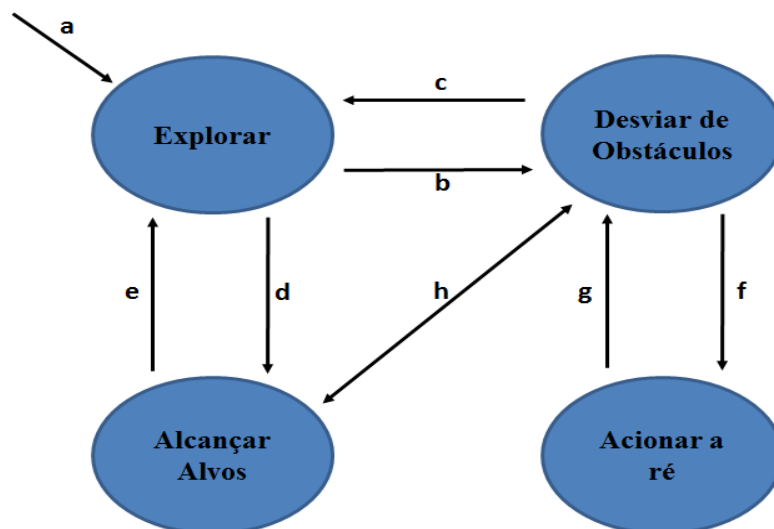


Figura 5.3 – Estratégia de gerenciamento do agente (Sistema de Estados Interno).
Fonte: Autoria Própria

Nesta figura, os nós do grafo são as ações de gestão e os arcos representam os eventos que são acionados por regras de decisão. Estes valores de arcos são tomados a partir de um alfabeto, mostrado a seguir:

- a. Estado inicial: o agente navega em linha reta para explorar o ambiente;
- b. Detecção de obstáculos: desviar do obstáculo;
- c. Caminho livre: retorna ao estado inicial;
- d. Detecção de alvo (sem obstáculos): tomadas de ações para se mover até ao alvo e coletá-lo;
- e. Alvo coletado: retorna ao estado inicial;
- f. Detecção de colisão: ações de controle para desviar do obstáculo, através do acionamento da ré;
- g. Detecção de posição segura: retorna ao estado inicial;
- h. Algumas situações podem levar do estado de Desvio de obstáculos para o estado de alcançar alvos e vice-versa.

Cada ação de gestão associada aos estados da Máquina de Estados requer a reconfiguração do modelo DFCM do agente, como será explicado a seguir.

Inicialmente, os quatro comportamentos reativos (Tabela 5.1), necessários para a navegação, são mapeados para conceitos. Eles estão relacionados com a descrição do ambiente, tais como, a presença (ou ausência) de obstáculos e a posição dos obstáculos em relação (esquerda, direita ou frontal do agente) ao caminho seguido pelo robô.

Esses conceitos formam o conjunto de conceitos elementares da ontologia dada na Tabela 3.1. Três ações que descrevem os movimentos do robô também estão listadas na Tabela 5.1: virar à esquerda, virar à direita e seguir em frente. As três entradas assumem valores a partir das medições de três sensores colocados no lado esquerdo, direito e a frontal do robô.

O mapa cognitivo resultante a partir deste conhecimento é mostrado na Figura 5.4, na qual os conceitos de entrada SD (sensor direito), SF (sensor frontal) e SE (sensor esquerdo) estão ligados por arcos aos conceitos de decisão que representam a ação de aceleração (conexão positiva) e de frenagem (conexão negativa).

Assim, as três decisões de movimento são originalmente modeladas resultando em três conceitos de movimentos: OE, OD e OUTFrente. O conceito OE resulta da decisão: se os sensores acusam um obstáculo no lado esquerdo, o robô deve virar para o lado direito. Por outro

lado, o conceito OD responde à premissa: se os sensores acusam um obstáculo no lado direito então o robô deve virar para a esquerda. A decisão de mudança na direção implica em uma desaceleração suave do robô. A terceira decisão diz respeito a um ambiente livre de obstáculos; neste caso, o robô segue em linha reta com uma aceleração suave e é representada pelo conceito OUTFrente.

A partir da Figura 5.4, os pesos (W1 a W9) conectando esses conjuntos de conceitos ({SE, SD, SF} a {OE, OD, OUTFrente}) correspondem a relações causais puras. Seus valores são inicialmente aprendidos por meio de simulações com um método heurístico inspirado em recozimento simulado, (“*simulated annealing*”) (GHAZANFARI *et al.*, 2007). De modo específico, todos os arcos são inicializados com 0,5 (positivos ou negativos dependendo da sua causalidade), na sequência, os novos valores são incrementados ou decrementados de uma maneira sistemática e ao acaso, até que o modelo atinja o comportamento dinâmico desejado.

Este modelo também usa uma memória temporária para induzir uma tendência de movimento durante a trajetória em evolução e para impedir o movimento de zig-zag. Como resultado, dois conceitos do tipo memória (OE (-1) e OD (-1)) associados aos movimentos de virar à direita / esquerda anteriores são adicionados ao DFCM na Figura 5.4.

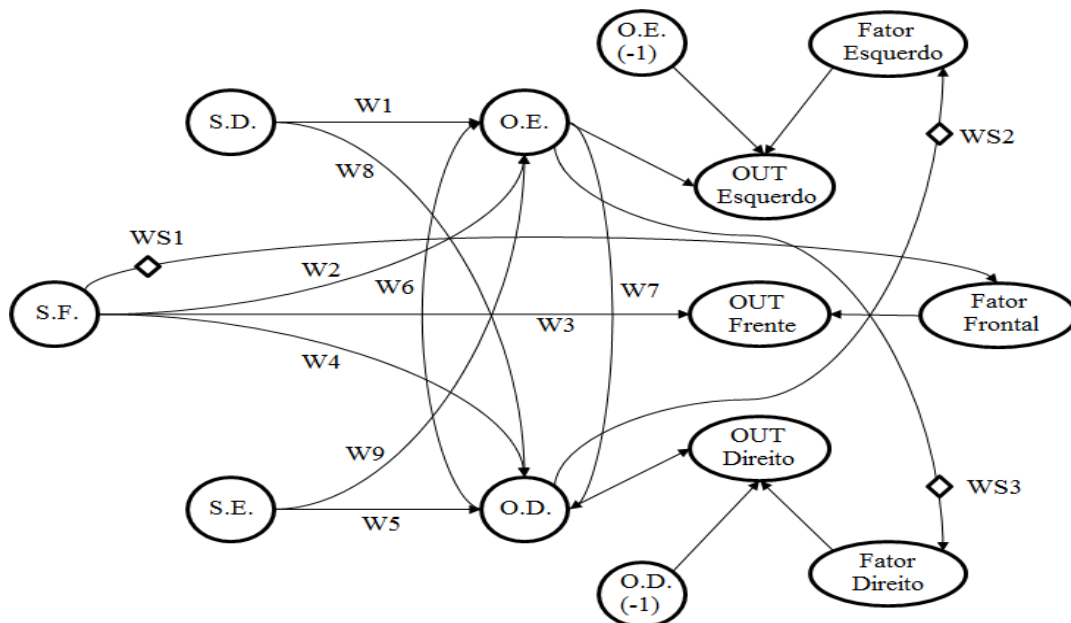


Figura 5.4 – Modelo DFCM inicial para navegação reativa.
Fonte: Autoria Própria

Já o comportamento deliberativo na quarta linha da Tabela 5.1 deve ser incluído a seguir. A ação do robô subsequente é resultante da pergunta: a decisão de movimento (seguir em frente, virar à esquerda ou à direita) é um movimento seguro? Este é modelada por meio de

relações de seleção (WS1, WS2 e WS3) considerando a posição real do robô, os sensores (conceitos OD e OE) e os conceitos de fator (Fator Esquerdo, Fator Frontal e Fator Direito; referentes aos conceitos de entrada). Os conceitos do fator são utilizados para interromper os movimentos que podem danificar o robô. Por exemplo, quando virar à direita para obter um alvo, o robô colide com um obstáculo inesperado nesta posição.

As relações de seleção (arcos WS) e conceitos de fatores são resultantes da inferência da Máquina de Estados. Eles representam a ligação entre o Sistema Comportamental e Sistema de Estados Interno na arquitetura da Figura 5.1.

Finalmente, os conceitos de saída que representam as ações de controle enviadas para as rodas do robô são OUTEsquerda, OUTDireita e OUTFrente. Os valores finais são devidos a decisão de movimento (conceitos OE, OD e OUTFrente), a tendência de movimento (conceitos OE (-1) e OD (-1)) e ao planejamento de segurança de movimento (conceitos Fator esquerdo, Fator frente e Fator direita).

No modelo DFCM na Figura 5.4, o algoritmo de Aprendizagem por Reforço (AR), apresentado na Seção 3.2.2, é utilizado para a sintonia dinâmica dos pesos do DFCM, para o desvio de obstáculos. As ações de recompensa e punição implementadas no algoritmo de AR são obtidas a partir de regras heurísticas que descrevem o cenário. O objetivo é a sintonização dinâmica das relações causais, a fim de fornecer uma melhor adaptação do modelo para possíveis mudanças na dinâmica do robô e / ou cenário, tais como um possível desgaste das peças e / ou mudança de aderência no chão. Similarmente como utilizado na aplicação de Vida Artificial, os valores limites são calculados com uma base de regra formada por seis regras heurística, similares às regras para aplicação de VA, como por exemplo a seguinte regra para o peso W_3 :

- **SE** a intensidade do sensor frontal é maior que um limiar médio **ENTÃO** W_{lim} usado para calcular W_3 é o valor máximo W_{fmax} .

Maiores detalhes dessa base de regra e a implementação do algoritmo de Aprendizagem por Reforço pode ser encontrado em MENDONÇA *et al.* (2012).

Em resumo, o DFCM na Figura 5.4 modela o comportamento e habilidades do robô para navegação em um ambiente desconhecido. Este é um mapa de movimento que permite a locomoção do robô como um comportamento puramente reativo.

A próxima camada a ser adicionada no sistema de navegação está relacionada ao conhecimento deliberativo correspondente às situações de planejamento na Tabela 5.1. As ações e tarefas planejadas como se mover para a posição final, coletar o alvo e evitar colisão são modelados. O modelo DFCM que faz o mapeamento comportamentos / ações é mostrado na Figura 5.5, o qual é uma extensão da DFCM na Figura 5.4. Os seus conceitos estão listados na Tabela 5.2 e sua representação em tupla é apresentada nas equações (5.1) - (5.15).

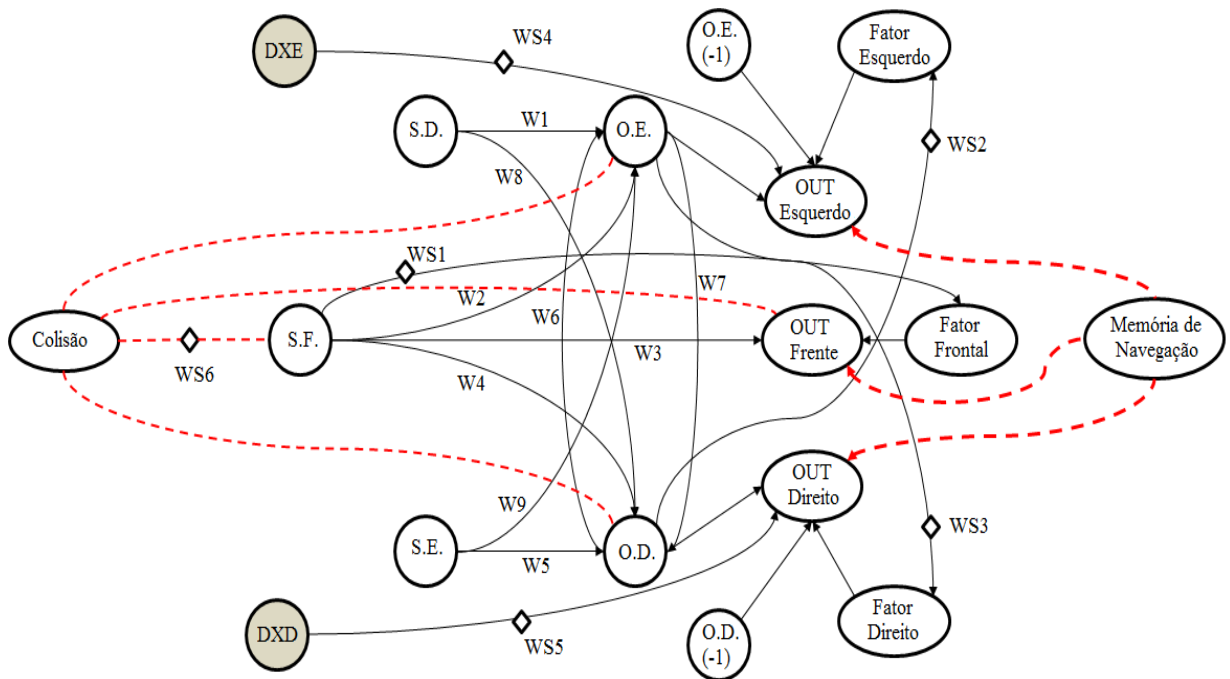


Figura 5.5 – Modelo DFCM completo para navegação reativa e deliberativa.
Fonte: Autoria Própria

Tabela 5.2 – Conceitos do DFCM proposto.

Conceito	Descrição	Conceito	Descrição
C1	S.D. – Sensor Direito	C10	OUTDireito
C2	S.F. – Sensor Frontal	C11	Fator Esquerdo
C3	S.E. – Sensor Esquerdo	C12	Fator Direito
C4	O.E.	C13	Fator Frontal
C5	O.D.	C14	DXE
C6	O.E. (-1)	C15	DXD
C7	O.D. (-1)	C16	Colisão
C8	OUTEsquerdo	C17	Memória de Navegação
C9	OUTFrente		

Fonte: Autoria própria

Na Figura 5.5, dois conceitos de decisão (DXD e DXE) e duas relações de seleção (WS4 e WS5) são adicionados para modelar a tarefa “alcançar o alvo”. Uma vez que o robô deve capturar o alvo cujas coordenadas são previamente atribuídas no ambiente, os conceitos DXE e DXD medem, em tempo de navegação, as distâncias entre a posição atual do robô e as coordenadas alvo.

Também na Figura 5.5, a funcionalidade de segurança necessária para evitar colisões é refinada. Quando um evento de colisão é detectado, uma sequência de ações de controle é realizada como se segue: o robô móvel freia e faz um movimento reverso, e, em seguida, ele corrige ligeiramente a sua trajetória e continua a navegação. Este comportamento é modelado por um conceito de decisão (Colisão) e uma relação de seleção (WS6). Esta relação desencadeia uma tarefa para evitar a colisão quando o sensor frontal acusa um nível muito elevado de leitura.

O valor limiar do sensor frontal é calculado de modo a garantir que o robô possa implementar a complexa manobra como descrito acima. Quando um novo caminho seguro é alcançado, o robô retorna para a sua estratégia de navegação inicial, a qual foi interrompida pela ocorrência de uma colisão iminente. As linhas tracejadas ligadas aos conceitos OE e OD na Figura 5.5 sugerem que a estratégia de controle inicial de virar à esquerda, à direita ou andar em linha é retomada.

Finalmente, a capacidade de adaptação (auto-sintonia, auto-aprendizagem) a partir da experiência, e de cooperação são adicionados por meio de um conceito de memória de navegação, tal como mostrado na Figura 5.5. Os valores dos arcos de conexão deste conceito para os conceitos de saída (OUTEsquerdo, OUTDireito e OUTFrente) são calculados pela heurística do controlador. Este controlador analisa o estado atual do robô e toma uma decisão sobre o próximo movimento com base nas tarefas dadas pela hierarquia de subsunção na Figura 5.2 e a Máquina de Estado mostrada na Figura 5.3.

O conceito de memória de navegação Figura 5.5 é um diferencial do modelo genérico de DFCM, o qual corresponde às duas estratégias diferentes para compartilhar e utilizar informações sobre a experiência de navegação dos robôs.

Para ambas as estratégias, um agente move-se inicialmente através do ambiente e deixa uma memória de navegação armazenada. Assim, o próximo agente usa essa "experiência de navegação" na sua tomada de decisão. Intuitivamente estas estratégias melhoram as decisões sobre manobras tomadas pelo agente, especialmente as manobras drásticas. A principal diferença entre estas estratégias de cooperação é o método de como a informação é transmitida para o outro agente.

A primeira estratégia, denominada método de compartilhamento de trajetória, objetiva explorar a memória de navegação adquirida pelo agente anterior sobre todo o seu percurso. Os dados de navegação são armazenados em uma matriz e transmitidos para o próximo agente. Esse agente irá ponderar esta informação com os valores de movimento (OUTEsquerdo, OUTDireito e OUTFrente) obtidos pelo DFCM na Figura 5.5 , utilizando apenas 1% das informações compartilhadas dos agentes anteriores, para ajudar a sua tomada de decisão sobre o movimento a ser implementado.

A Figura 5.6 mostra o modelo DFCM correspondente ao método de compartilhamento de trajetória cujos conceitos estão na Tabela 5.3. Nesta figura, os conceitos VF, VE e VD estão relacionados com a decisão dos movimentos de ir em frente, virar à esquerda e virar à direita, respectivamente. Eles são as conexões com a DFCM na Figura 5.5 : VF tem os mesmos valores de conceito OUTFrente, VE corresponde a OE, e VD a OD. Em resumo, eles recebem e enviam dados da/para DFCM. Os pesos entre W10 a W16 representam as relações causais entre os conceitos. Sua representação em tupla pode ser vista nas equações (5.16) - (5.22).

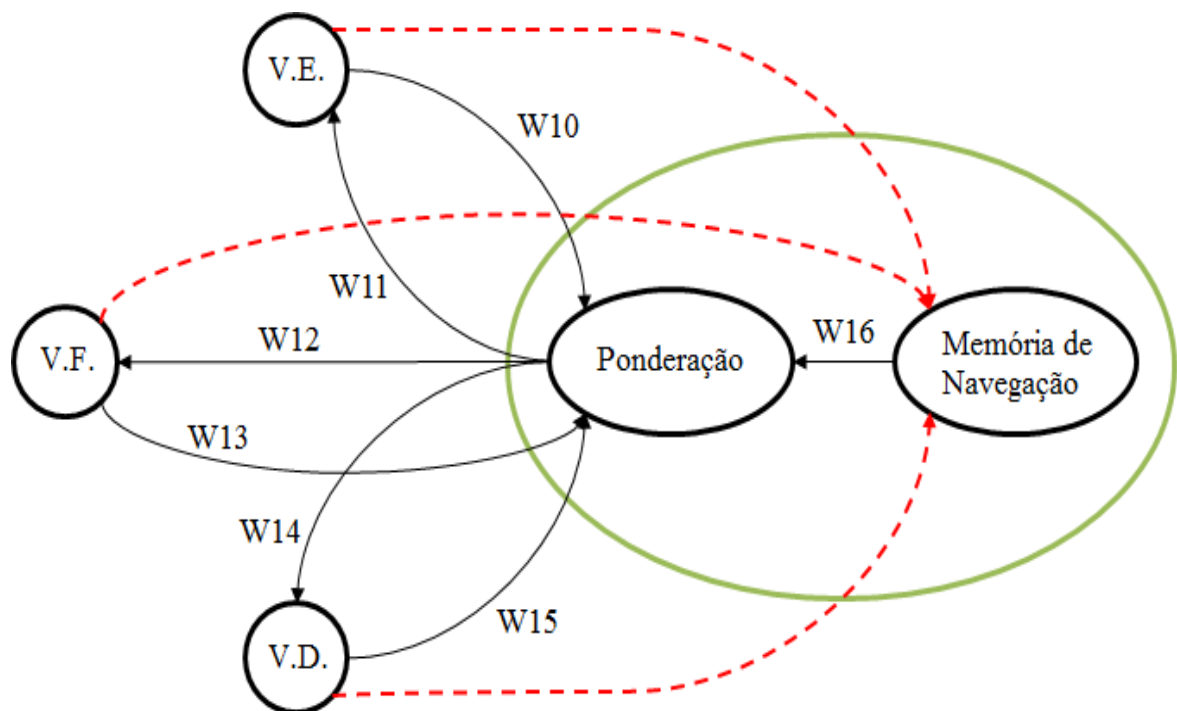


Figura 5.6 – Modelo DFCM simplificado para processamento de dados no método de compartilhamento de trajetória.

Fonte: Autoria Própria

Tabela 5.3 – Conceitos do DFCM para o método de compartilhamento de trajetória.

Conceito	Descrição
C18	V.E.
C19	V.F.
C20	V.D.
C21	Ponderação
C22	Memória de Navegação

Fonte: Autoria própria

Para este método, dois novos conceitos são considerados: a Ponderação (C21) e Memória de Navegação (C22). O conceito C21 trata e pesa as informações das entradas VF, VE e VR com C22. Após esta ponderação ser feita, VF, VE e VD recebem novos valores que são enviados para o modelo DFCM na Figura 5.5 . O conceito C22 armazena os dados de navegação e os compartilha. Nota-se que não existe qualquer relação de causalidade entre os conceitos de entrada VF, VE e VD e C22. A linha pontilhada vermelha indica apenas que os dados são guardados na memória.

A segunda estratégia é inspirada no forrageamento das colônias de formigas, em que as formigas liberam um produto químico (chamado feromônio) para demarcar o caminho percorrido, transmitindo e recebendo dados de forma implícita da trajetória tomado pela colônia. Em outras palavras, o agente irá navegar através do cenário e deixar demarcações (feromônios) ao longo de sua trajetória, e outro agente interpretará este feromônio e irá usá-lo para auxiliar na sua tomada de decisão. Para implementar esta estratégia, denominada de método de compartilhamento por feromônio, um novo DFCM, mostrado na Figura 5.7 e baseado nos conceitos da Tabela 5.4, é desenvolvido. Nesta figura, os conceitos de Ponderação (C21), VF, VE e VD desempenham o mesmo papel que no método de compartilhamento de trajetória. Além desses, dois novos conceitos, Liberação do feromônio (C22) e Detecção do feromônio (C23), são adicionados e duas novas relações de seleção WS7 e WS8 também são estabelecidas. As equações (5.23) - (5.31) mostram a representação em forma de tupla para o DFCM desta estratégia de cooperação.

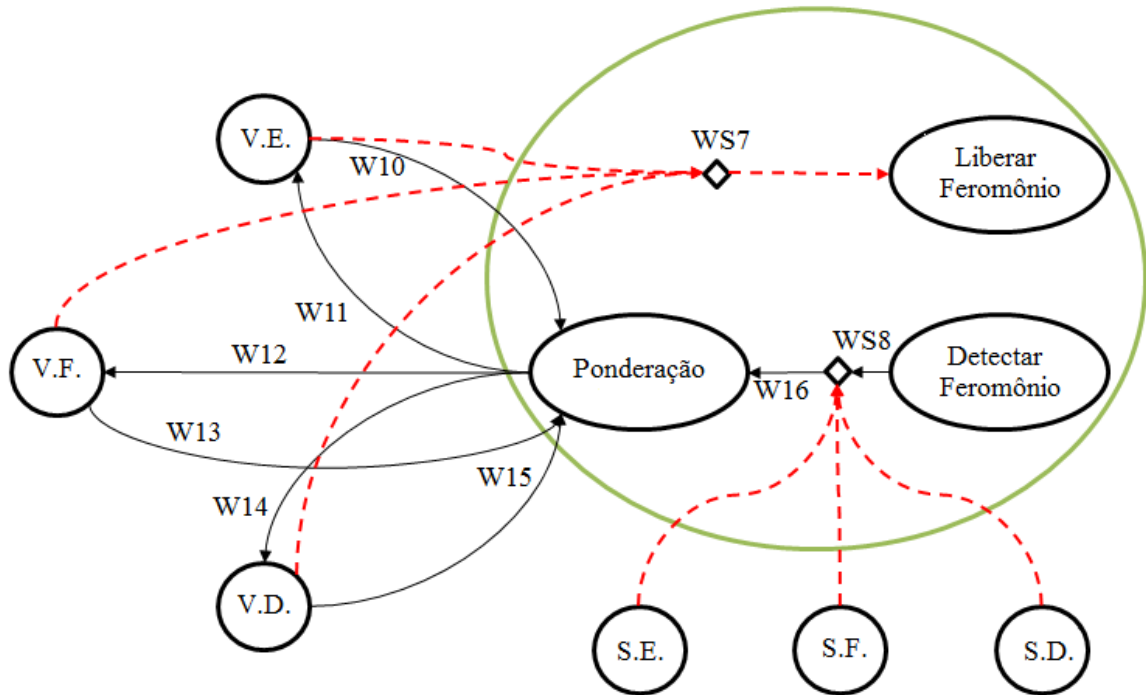


Figura 5.7 – Modelo DFCM simplificado para processamento de dados no método de compartilhamento por feromônio.
Fonte: Autoria Própria

Tabela 5.4 – Conceitos do DFCM para o método de compartilhamento por feromônio.

Conceito	Descrição
C18	V.E.
C19	V.F.
C20	V.D.
C21	Ponderação
C22	Liberar Feromônio
C23	Detectar Feromônio
C1	S.D. – Sensor Direito (Figura 5.5)
C2	S.F. – Sensor Frontal (Figura 5.5)
C3	S.E. – Sensor Esquerdo (Figura 5.5)

Fonte: Autoria própria

Na Figura 5.7, os conceitos SE, SF e SD estão relacionados às leituras do sensor esquerdo, frontal e direito, respectivamente (conceitos C1, C2 e C3 da Figura 5.5). Estas medições são utilizadas como premissas na base de regras que dispara a relação de seleção WS8. As linhas pontilhadas vermelhas implicam em valores de conceitos que só são usados para inferir a ocorrência de eventos (alvo ou obstáculo detectado) em tempo real.

O conceito C22 gere os feromônios a serem liberado pelo agente, se os critérios de seleção forem atendidos por WS7. Um contador também é inserido em WS7, especificamente para auxiliar quando o estado de libertação de feromônios é disparado, conferindo uma periodicidade a essa liberação. Esse contador decrescerá em valores que estão diretamente relacionados com a intensidade das saídas VE e VD. Em outras palavras, o valor subtraído do contador será maior quando VE e VD são altos, e menor quando VE e VD são baixos. Isso é necessário para enfatizar as mudanças de direção ao longo do trajeto do robô. Um exemplo da base de regras de WS7 é:

- **SE** (VE e VD são altos **E** contador é baixo) **OU** (contador é muito baixo) **ENTÃO** Liberação do feromônio é disparado.

O conceito C23 é uma nova variável de “entrada” para o modelo DFCM, semelhante a um sensor de entrada. Este sensor virtual detecta os feromônios deixados por outros agentes. Estes feromônios são considerados como alvos secundários e suas capturas não são obrigatórias. No entanto, essa captura auxilia no processo de tomada de decisões, antecipando manobras de desvio de obstáculo e em captura de alvos primários. Uma relação de seleção WS8 conectando os conceitos C21 e C22 irá alterar a relação de causalidade entre estes. Os valores de W16, referidos a sua intensidade, são dados pelas regras disparadas na base de regras de WS8:

- **SE** um obstáculo é detectado **ENTÃO** o peso W_{16} é médio;
- **SE** um alvo é detectado **ENTÃO** o peso W_{16} é baixo;
- **SE** nenhum alvo ou obstáculo são detectados **ENTÃO** o peso W_{16} é alto.

Finalmente, a ligação entre o modelo DFCM na Figura 5.5 a um dos outros modelos DFCM na Figura 5.6 ou 5.7 constitui o sistema de navegação autônomo proposto que é baseado em Mapas Cognitivos *Fuzzy* Dinâmicos. Como discutido acima, esta arquitetura é baseada em subsunção e é construída de forma incremental com base no comportamento do robô. Este desenvolvimento foi facilitado pelo uso de uma ontologia, que facilmente mapeia o conhecimento sobre o comportamento do robô em um grafo. Este tradutor simples de comportamento para grafo é uma das vantagens da modelagem FCM (MENDONÇA, 2014).

Ao contrário de outras abordagens baseadas no conhecimento, como modelos *Neurofuzzy*, modelos FCM não exigem um grande conjunto de dados ou longas horas de treinamento. Além disso, são simples de incorporar um novo conhecimento sobre situações não modeladas no sistema de navegação, modelando o comportamento correspondente do robô com um novo, pequeno FCM e vinculando esse novo FCM com o antigo sistema de navegação por meio de conceitos comuns.

As equações abaixo apresentam as tuplas do DFCM:

$$W_1 = (1, C1, C4, \text{causal: sintonizado dinamicamente}, [-1,1],0) \quad (5.1)$$

$$W_2 = (1, C2, C4, \text{causal}, [-1,1],0) \quad (5.2)$$

$$W_3 = (1, C2, C9, \text{causal: sintonizado dinamicamente}, [-1,1],0) \quad (5.3)$$

$$W_4 = (1, C2, C5, \text{causal}, [-1,1],0) \quad (5.4)$$

$$W_5 = (1, C3, C5, \text{causal: sintonizado dinamicamente}, [-1,1],0) \quad (5.5)$$

$$W_6 = (1, C5, C4, \text{causal}, [-1,1],0) \quad (5.6)$$

$$W_7 = (1, C4, C5, \text{causal}, [-1,1],0) \quad (5.7)$$

$$W_8 = (1, C1, C5, \text{causal}, [-1,1],0) \quad (5.8)$$

$$W_9 = (1, C3, C4, \text{causal}, [-1,1],0) \quad (5.9)$$

$$W_{S1} = (2, C2, C13, \text{Seleção}, [0,1],1) \quad (5.10)$$

$$W_{S2} = (2, C5, C11, \text{Seleção}, [0,1],1) \quad (5.11)$$

$$W_{S3} = (2, C4, C12, \text{Seleção}, [0,1],1) \quad (5.12)$$

$$W_{S4} = (2, C14, C8, \text{Seleção}, [0,1],1) \quad (5.13)$$

$$W_{S5} = (2, C15, C10, \text{Seleção}, [0,1],1) \quad (5.14)$$

$$W_{S6} = (2, C2, C16, \text{Seleção}, [0,1],1) \quad (5.15)$$

Método compartilhamento de trajetória

$$W_{10} = (1, C18, C21, \text{causal}, [-1,1],0) \quad (5.16)$$

$$W_{11} = (1, C21, C18, \text{causal}, [-1,1],0) \quad (5.17)$$

$$W_{12} = (1, C21, C19, \text{causal}, [-1,1],0) \quad (5.18)$$

$$W_{13} = (1, C19, C21, \text{causal}, [-1,1],0) \quad (5.19)$$

$$W_{14} = (1, C21, C20, \text{causal}, [-1,1],0) \quad (5.20)$$

$$W_{15} = (1, C20, C21, \text{causal}, [-1,1],0) \quad (5.21)$$

$$W_{16} = (1, C22, C21, \text{causal}, [-1,1],0) \quad (5.22)$$

Método compartilhamento de feromônio

$$W_{10} = (1, C18, C21, \text{causal}, [-1,1], 0) \quad (5.23)$$

$$W_{11} = (1, C21, C18, \text{causal}, [-1,1], 0) \quad (5.24)$$

$$W_{12} = (1, C21, C19, \text{causal}, [-1,1], 0) \quad (5.25)$$

$$W_{13} = (1, C19, C21, \text{causal}, [-1,1], 0) \quad (5.26)$$

$$W_{14} = (1, C21, C20, \text{causal}, [-1,1], 0) \quad (5.27)$$

$$W_{15} = (1, C20, C21, \text{causal}, [-1,1], 0) \quad (5.28)$$

$$W_{16} = (1, C23, C21, \text{causal}, [-1,1], 0) \quad (5.29)$$

$$W_{S7} = (2, \{C18, C19, C20\}, C22, \text{Seleção}, [0,1], 2) \quad (5.30)$$

$$W_{S8} = (2, [C23, \{C1, C2, C3\}], C21, \text{Seleção}, [0,1], 3) \quad (5.31)$$

5.3 RESULTADOS

Um cenário simulado em animação 2-D foi desenvolvido para testar o sistema de navegação cooperativo proposto, similar ao utilizado na aplicação de Vida Artificial. Nesse ambiente simulado, a trilha com três cores simboliza o robô móvel. Os sinais “+” em azul claro representam os obstáculos estáticos que podem ser conhecidos ou inesperados, o sinal “*” na cor azul escuro representa o obstáculo móvel e os sinais “.” simbolizam os feromônios deixados pelo agente. Eles são representados por duas cores, amarelo para os feromônios liberados por outros agentes, e verde para os feromônios liberados (lançamento) pelo próprio agente. O “▲” representa os alvos. Na simulação, uma faixa ou trilha azul é usado para mostrar a trajetória de um obstáculo dinâmico cruzando o cenário. A Figura 5.8 mostra uma visão geral do ambiente, com obstáculos fixos, inesperados e um obstáculo móvel.

Em todas as figuras seguintes, o gráfico mostra uma cena no plano XY com o ponto de partida (15, 0) e o ponto final (0, 205) da trajetória do robô. Estes gráficos também mostram o caminho dinâmico efetuado pelo agente. As falhas na trajetória representam o aumento na velocidade, quando os sensores não detectam quaisquer obstáculos ou alvos e o robô acelera. Em todos os experimentos o robô atinge o ponto de destino dentro de um intervalo [-8, 8]

centrado na posição desejada. As figuras mostram o ponto de vista de um único robô, denominado de robô principal.




Figura 5.8 – Visão geral do ambiente simulado.
Fonte: Autoria Própria

Desse modo, os outros robôs são vistos como obstáculos móveis e os feromônios são considerados alvos. Todas as simulações são realizadas em duas rodadas, as quais são caracterizadas pela navegação completa do agente no cenário, ou seja, do ponto inicial até o ponto final. Na primeira rodada o robô principal não possui memória sobre as tarefas e caminhos, e o seu objetivo é atravessar o ambiente enquanto coleta alvos e desvia de obstáculos. Na segunda rodada, um novo robô principal também deve cruzar o cenário com os mesmos objetivos. No entanto, agora, este novo robô principal pode usar o conhecimento sobre alvos, obstáculos estáticos e caminho percorrido pelo robô principal na primeira rodada.

No primeiro cenário (Figuras 5.9 a 5.16), há apenas um obstáculo móvel, isto é, existem dois robôs que viajam no ambiente. Este obstáculo inesperado e dinâmico aparece no cenário quando o robô principal navega nas proximidades das coordenadas (-6, 88) e intercepta sua trajetória. Além disso, todos os obstáculos fixos são conhecidos e há vários alvos a serem recolhidos ao longo do trajeto do robô. As Figuras 5.9, 5.10, 5.13 e 5.14 apresentam o desempenho de um robô guiado pelo método de compartilhamento de trajetória e as figuras

5.11, 5.12, 5.15 e 5.16 apresentam o desempenho de um robô guiado pelo método de compartilhamento por feromônio para esse cenário.

Visto que ambas as estratégias utilizam o mesmo DFCM, diferenciando-se no método de cooperação, a primeira simulação é idêntica para ambos os agentes (Figuras 5.9 e 5.11), já que eles não possuem informações de agentes anteriores.

A Figura 5.10 mostra a intensidade dos sensores (linhas nas cores pretas, vermelhas e azuis) e a sintonia dinâmica dos pesos da DFCMs (linha verde) através da Aprendizagem por Reforço do agente na Figura 5.9. Nesta figura, o sensor frontal (conceito SF) é relacionado com W3; o sensor de direito (conceito SD) está relacionada com a W1 e sensor esquerdo (conceito SE) para W5. Esta explicação pode ser estendida para as Figuras 5.12, 5.14, 5.16, 5.18 e 5.20.




Figura 5.9 – Método de compartilhamento de trajetória: primeira rodada no ambiente com um obstáculo móvel.

Fonte: Autoria Própria

A segunda rodada introduz um novo robô principal no mesmo cenário. No entanto, este robô principal tem acesso à informação compartilhada do agente anterior e implementa um menor número de manobras para desviar de obstáculos do que o primeiro robô. Este fato pode ser visto comparando as duas trajetórias nas Figuras 5.9 e 5.13 e a intensidade dos sensores nas Figuras 5.10 e 5.14 para o robô usando o método de compartilhamento de trajetória. Da mesma forma, pode-se comparar as trajetórias das Figuras 5.11 e 5.15 e a intensidades dos sensores nas Figuras 5.12 e 5.16 para o robô usando o método de compartilhamento por feromônio. Além

disso, as Figuras 5.10 e 5.12, em comparação com as Figuras 5.14 e 5.16, sugerem que os robôs/agentes navegam a uma distância maior dos obstáculos, uma vez que as variações dos pesos são suavizadas.

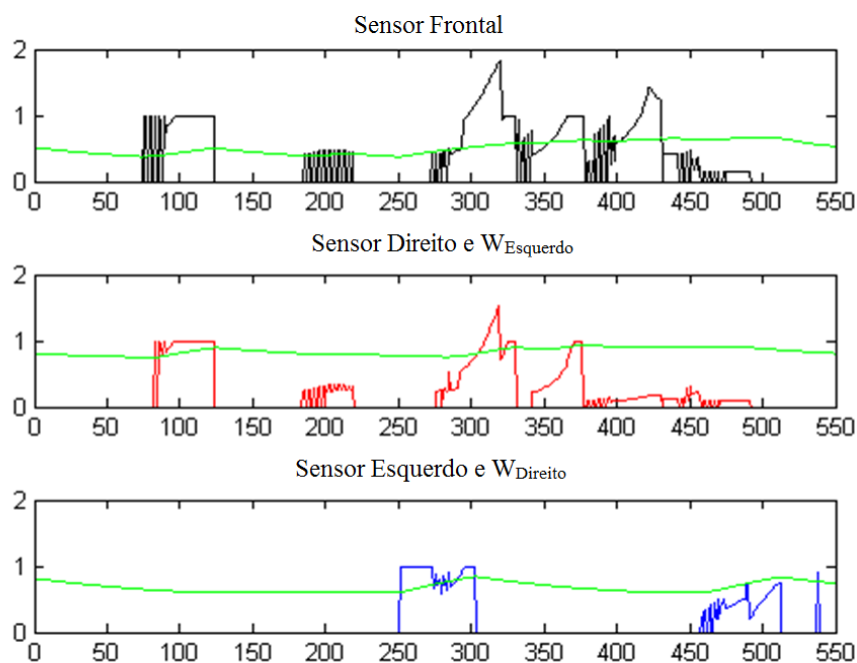


Figura 5.10 – Método de compartilhamento de trajetória: Valores dos sensores e pesos do agente principal (ambiente com um obstáculo móvel).
Fonte: Autoria Própria

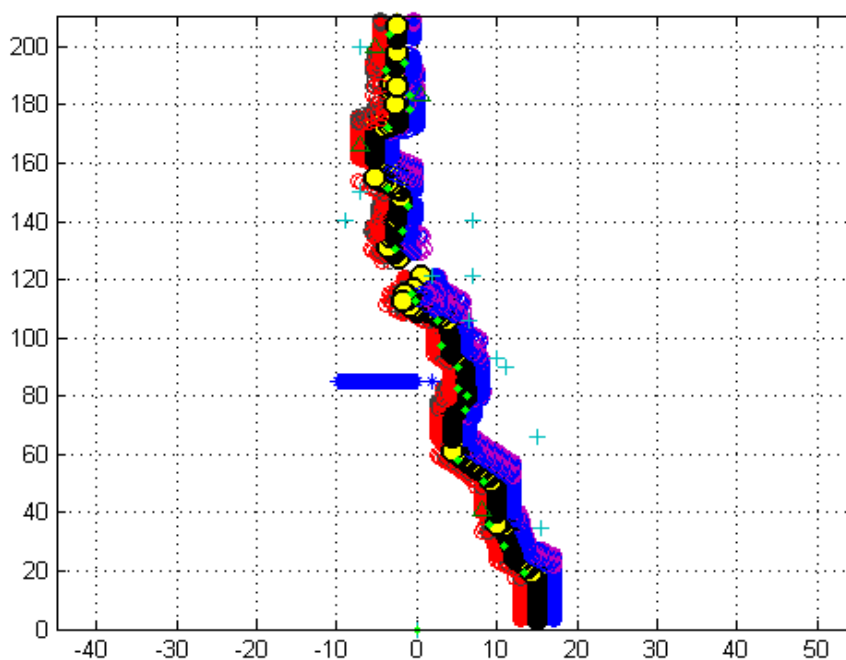


Figura 5.11 – Método de compartilhamento por feromônio: primeira rodada no ambiente com um obstáculo móvel.
Fonte: Autoria Própria

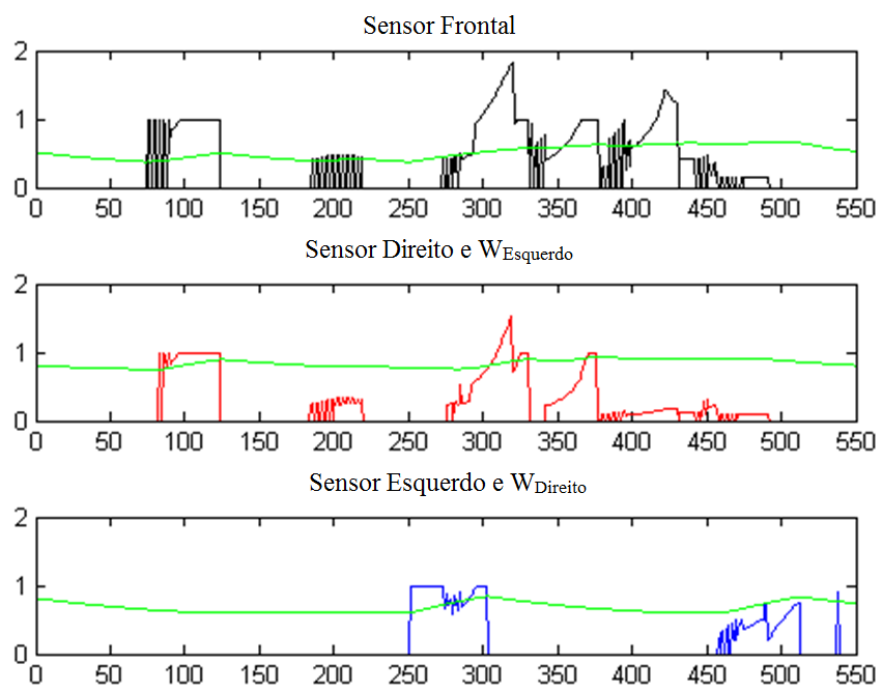


Figura 5.12 – Método de compartilhamento por feromônio: Valores dos sensores e pesos do agente principal (ambiente com um obstáculo móvel).

Fonte: Autoria Própria




Figura 5.13 – Método de compartilhamento de trajetória: segunda rodada no ambiente com um obstáculo móvel.

Fonte: Autoria Própria




Figura 5.14 – Método de compartilhamento de trajetória: Valores dos sensores e pesos do agente principal (segunda rodada e ambiente com um obstáculo móvel).

Fonte: Autoria Própria




Figura 5.15 – Método de compartilhamento por feromônio: segunda rodada no ambiente com um obstáculo móvel.

Fonte: Autoria Própria




Figura 5.16 – Método de compartilhamento de trajetória: Valores dos sensores e pesos do agente principal (segunda rodada e ambiente com um obstáculo móvel).

Fonte: Autoria Própria

Na segunda rodada (Figuras 5.17 a 5.20), três agentes navegam no ambiente e a ocorrência súbita de obstáculos fixos é possível, representando pontos não mapeados do cenário. O agente principal irá navegar com a informação compartilhada pelos agentes anteriores (adquiridos a partir de primeiro experimento), e terá que combinar os dados compartilhados com as mudanças no meio ambiente.

As Figuras 5.17 e 5.18 apresentam o desempenho de um robô guiado pelo método de compartilhamento de trajetória e as Figuras 5.19 e 5.20 apresentam o desempenho com o robô utilizando o método de compartilhamento por feromônio, para o cenário discutido no parágrafo acima.

Através da análise dessas figuras, e considerando que esta é uma terceira rodada da primeira simulação, nota-se que os dois robôs principais melhoraram o seu desempenho. Ambos os trajetos desenvolvidos passam longe dos obstáculos fixos, desviando com sucesso dos obstáculos dinâmicos; isso pode ser visto pela comparação das leituras dos sensores. Além disso, mesmo com a ocorrência repentina de obstáculos o algoritmo de AR não impõe variações drásticas nos pesos (Figuras 5.18 e 5.20).




Figura 5.17 – Método de compartilhamento de trajetória: segunda rodada no ambiente com dois obstáculos móveis.
Fonte: Autoria Própria




Figura 5.18 – Método de compartilhamento de trajetória: Valores dos sensores e intensidade dos pesos do agente principal (ambiente com dois obstáculos móveis).
Fonte: Autoria Própria




Figura 5.19 – Método de compartilhamento por feromônio: segunda rodada no ambiente com dois obstáculos móveis.

Fonte: Autoria Própria

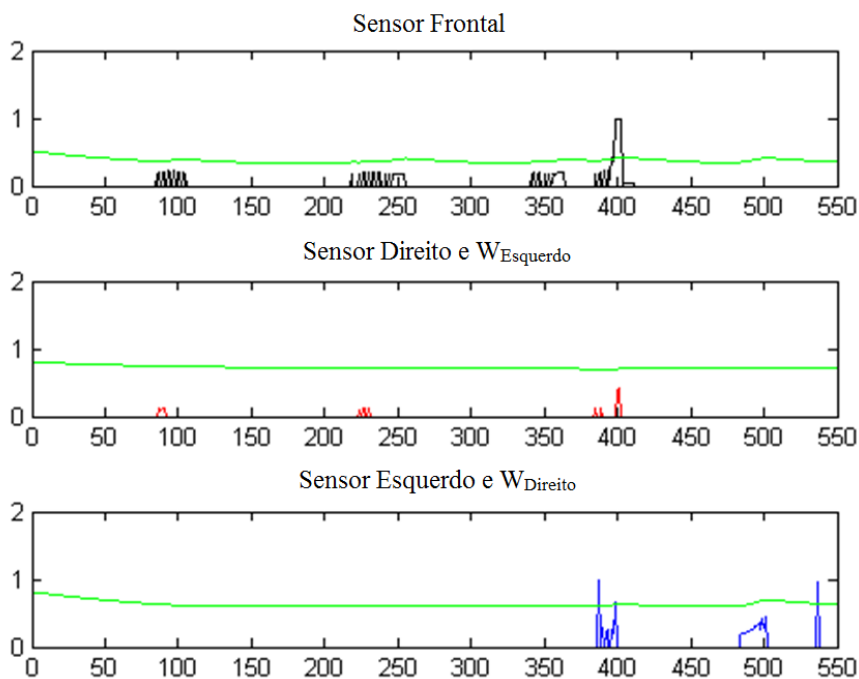


Figura 5.20 – Método de compartilhamento de trajetória: Valores dos sensores e intensidade dos pesos do agente principal (ambiente com dois obstáculos móveis).

Fonte: Autoria Própria

5.4 CONCLUSÃO

Este capítulo apresentou o desenvolvimento de um sistema de navegação autônomo baseado em DFCM aplicado em Robótica de Enxame. O método de cooperação implementado é inspirado no comportamento de forrageamento das formigas. Nesse contexto, duas estratégias de compartilhamento foram implementadas, a qual possibilitou aos agentes a compartilhar sua experiência adquirida na navegação pelo cenário. A primeira, utilizou de informações do trajeto de navegação de um agente, e a segunda, implementou um método de comunicação implícita através da liberação de feromônios no cenário. Ambas as estratégias objetivaram auxiliar na tomada de decisões dos agentes e melhorar o trajeto percorrido por estes, isso pode ser visto comparando os dados sensoriais nos ambientes sem e com a compartilhamento de suas experiências.

Os agentes, em ambas estratégias, apresentaram os comportamentos esperados no decorrer das simulações, de acordo com o planejamento das ações, como desviar de obstáculos, alcançar alvos e compartilhar informações de navegação do cenário com outros agentes. Ambos agentes, através da cooperação, atingiram os objetivos propostos, tomando as decisões necessárias para tal.

Ressalta-se a capacidade de exploração, ou navegação do agente, como supracitado, sugere que quando existe uma colaboração entre agentes, suas habilidades e/ou eficácia tendem a aumentar.

O uso da arquitetura proposta permitiu a construção de agentes autônomos de forma incremental, ou seja, primeiramente foi desenvolvido um FCM para navegação reativa, camada de nível baixo, e em seguida novas funcionalidade foram implementadas pela adição de mais camadas de controle, tratando de ações de planejamento ou deliberativas, e por último o método de compartilhamento de informações.

Dessa forma, outras habilidades podem ser facilmente incluídas no sistema através da adição de novos FCM ou camadas de controle ao controlador desenvolvido, como por exemplo andar em pelotão, recarga da bateria, entre outros.

Como a abstração do conhecimento é relativa ao tipo de problema ou sistema, essa arquitetura pode ser generalizada para outras aplicações, através do uso da ontologia proposta e a metodologia proposta de construção do DFCM, hierarquizando as ações e desenvolvendo o controlador de modo incremental. A adição de um método de treinamento de máquina e novos

conceitos e relações ao FCM clássico permite que a DFCM lide com processos dinâmicos e/ou temporais, abrangendo as áreas que necessitem esse tipo de controle.

Porém, os modelos baseados em DFCM sofrem a dificuldade de abstração inicial do mapa de causalidades entre os vários conceitos que deve ser feito de forma manual, utilizando-se do conhecimento de especialistas. Muitas vezes, os conhecimentos abstraídos de vários especialistas podem gerar mapas cognitivos diferentes, com intensidades e conceitos distintos dos outros, já que esse mapa está sujeito a subjetividade do especialista.

6 CONCLUSÕES GERAIS

Esta dissertação propôs uma arquitetura para desenvolvimento de sistemas Multi-Agentes contendo agentes inteligente com capacidade de tomada de decisões dinâmicas. A arquitetura proposta foi utilizada para desenvolvimento de um sistema de navegação autônomo com aplicações em Robótica de Enxame e Vida Artificial. A arquitetura do sistema é baseada no modelo clássico de Subsunção, possibilitando a tomada de decisões de forma hierárquica em um ambiente dinâmico, englobando três diferentes camadas de mapeamento, os quais modelam tipos diferentes de conhecimento: reativo, ação e reação a estímulos ambientais, deliberativo, ações de planejamento e gerenciamento, e cooperativo, aplicando metodologias para comunicação entre agentes.

Estas camadas trabalham em paralelo, mas respeitam a prioridade (hierarquia) de ações para atingir os objetivos propostos. Além disso, ajustes empíricos são utilizados para mudar dinamicamente o modelo cognitivo DFCM. Um algoritmo de Aprendizagem por Reforço é utilizado para sintonia dinâmica do modelo e uma Máquina de Estados gerencia o comportamento dos agentes, possibilitando que o modelo DFCM se adapte a complexidade do problema a ser modelado.

Essa arquitetura apresentou capacidade de tomadas de decisões dinâmicas em ambientes parcialmente desconhecidos, os quais são necessárias para o desenvolvimento de sistemas para a área de Robótica Autônoma e correlatas. Isso pode ser visto analisando o comportamento e decisões tomadas pelos agentes nos experimentos simulados apresentados.

A modelagem de sistemas complexos dinâmicos norteados pelo uso de uma ontologia para desenvolvimento de Mapas Cognitivos Dinâmicos *Fuzzy*, tem como vantagens:

- Representação do conhecimento abstraído em forma de grafo, de fácil “leitura” e compreensão, em comparação a outras técnicas, como Redes Neurais Artificiais;
- Modelagem do conhecimento estruturado através do conhecimento empírico e prático dos especialistas;
- Melhor adaptação do modelo através da inclusão de diferentes tipos de relações causais e técnicas de aprendizagem de máquina;
- Arquitetura com disposição das ações de forma hierárquica, possibilitando a priorização das mesmas;

- Aplicações bem-sucedidas em diversas áreas do conhecimento implicam claramente na eficácia dessas metodologias e técnicas de aprendizagem dedicada a estas áreas.

No entanto, têm-se algumas dificuldades para esse tipo de modelagem: os modelos desenvolvidos por especialistas são vulneráveis a subjetividade das crenças dos mesmos e podem ser difíceis de serem desenvolvidos para problemas complexos que envolvem dezenas de conceitos. Embora os mapas desenvolvidos por especialistas possam fornecer uma análise estática precisa do modelo cognitivo, eles podem levar a uma análise dinâmica imprecisa. Estas limitações motivaram pesquisadores no sentido da utilização de algoritmos de aprendizagem para fornecer modelos com uma representação mais precisa do sistema FCM. Portanto, novas abordagens são necessárias para o treinamento eficaz dessa ferramenta, possibilitando um aumento no potencial de sua aplicação na prática. Também, ressalta-se que não se pode garantir uma solução ótima para o problema, assim como as outras técnicas de inteligência computacional.

Finalmente, podemos concluir que a arquitetura baseada em DFCM proposta é capaz de implementar tarefas de navegação, modelando comportamentos reativos, deliberativos e de cooperação em diferentes cenários e até mesmo na presença de alterações desconhecidas nos ambientes, e, portanto, pode ser utilizada em aplicações que necessitam de tomadas de decisões dinâmicas de forma autônoma.

6.1 FUTUROS TRABALHOS

Os tópicos aqui apresentados norteiam a aplicação dessa metodologia em outras áreas, assim como o aprimoramento da mesma.

- A introdução de ruídos nos sensores de entrada nos sistemas de navegação, para uma melhor análise e estimação, a fim de implementar esse sistema de navegação em aplicação com robôs reais;
- Inclusão de mais agentes ou criaturas para análise da interação comportamental entre os agentes;
- Desenvolver e implementar outras técnicas de aprendizagem e / ou métodos de desenvolvimento para inclusão / remoção de conceitos para adaptação do modelo do controlador para tomadas de decisões;

- Modelar via DFCM outras aplicações, como sistemas supervisórios de controle de processos;
- Aprimorar o ambiente de simulação, acrescentando protocolos de comunicação, inclusão do modelo dinâmico para um maior realismo dos agentes, em especial para a área de Robótica de Enxame, e aumento das funcionalidades agregadas as criaturas e aos agentes, como fadiga, para os golfinhos e tubarões, e nível de carga, para os agentes robóticos móveis;
- Expandir a ferramenta para aplicações em jogos, modelando as tomadas de decisões ou ações relacionadas ao comportamento de personagens em ambientes dinâmicos;
- Aplicar a abordagem em robôs móveis reais, em ambientes mais complexos, para avaliar sua aplicabilidade na área de Robótica de Enxame.

PUBLICAÇÕES RELACIONADAS AO TRABALHO

- ARRUDA, L. V. R.; MENDONÇA, M.; CHRUN, I. R.; NEVES-Jr, F. A Cooperative Architecture For Swarm Robotic Based on Dynamic Fuzzy Cognitive Maps, **Engineering Applications of Artificial Intelligence**, submetido para publicação, já em segunda revisão.
- MENDONÇA, M.; ARRUDA, L. V. R.; NEVES-JR, F.; CHRUN, I. R.; PAPAGEORGIOU, E. Artificial life environment modeled by dynamic fuzzy cognitive maps. **IEEE Transactions on Cognitive and Developmental Systems**, submetido para publicação, já em terceira revisão.
- MENDONÇA, M.; GONÇALVES, L.F.M.; ARRUDA, L. V. R.; CHRUN, I. R. **Controllers Based in Subsumption Architecture and Swarm Robotics for Cooperative Autonomous Agents**. International Journal of Science and Advanced Technology, vol 5, n 2, 2015.
- MENDONÇA, M.; SILVA, E S.; CHRUN, I. R.; ARRUDA, L. V. R. **Hybrid Dynamic Fuzzy Cognitive Maps and Hierarchical Fuzzy Logic controllers for Autonomous Mobile Navigation**. FUZZ-IEEE 2016 - IEEE World Congress on Computational Intelligence, Vancouver, Canada. 2016.
- MENDONÇA, M.; ARRUDA, L.V.R.; SILVA, E. S.; CHRUN, I. R. **Hybrid navigation system autonomous using a dynamic fuzzy cognitive maps evolution**. In: The Eleventh International Conference on Autonomic and Autonomous Systems ICAS 2015, 2015, Roma. ICAS 2015, 2015.
- MENDONÇA, M.; ARRUDA, L. V. R.; CHRUN, I. R.; SILVA, E. S.; ALMEIDA, J. P. L. S. **Hybrid dynamic fuzzy cognitive maps for autonomous navigation system in semi-unknown environments**. In: Simpósio Brasileiro de Automação Inteligente (SBAI), 2015, Natal-RN. SBAI 15, 2015. v. 1. p. 1-6.

- MENDONÇA, M.; ARRUDA, L.V.R.; CHRUN, I. R.; ALMEIDA, J. P. L. S. **Sistemas multi-agentes cooperativos inspirados em robótica de enxame**. In: Simpósio Brasileiro de Automação Inteligente (SBAI), 2015, Natal. 2015. v. 1. p. 1-6.
- MENDONÇA, M.; CHRUN, I. R.; SILVA, E. S.; FINOCCHIO, M. A. F. **Comparative of two hybrid dynamic fuzzy cognitive maps for autonomous navigation system**. In: COBEM, 2015, Rio De Janeiro. COBEM 2015, 2015. v. 1. p. 0-6.
- ARRUDA, L.V. R.; PAPAGEORGIU, E.; CHRUN, I. R.; MENDONÇA, M.; COCO, B. **Dynamic fuzzy cognitive maps applied in development of techniques inspired in swarm robotics**. In: Congresso Brasileiro de Automática, 2014, Belo Horizonte, MG, 2014.

REFERÊNCIAS

- ACAMPORA, G.; LOIA, V. A dynamical cognitive multi-agent system for enhancing ambient intelligence scenarios. *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on, 2009, 20-24 Aug. 2009.* p.770-777.
- ACAMPORA, G.; LOIA, V. On the Temporal Granularity in Fuzzy Cognitive Maps. **IEEE Transactions on Fuzzy Systems**, v. 19, n. 6, p. 1040-1057, 2011.
- ALAMAN, X. et al. Designing virtual world educational applications. 2016 IEEE Global Engineering Education Conference (EDUCON), 2016, 10-13 April 2016. p.1134-1137.
- AMIRKHANI, A. et al. A novel fuzzy cognitive map based method for the differentiation of intraductal breast lesions. *Biomedical Engineering and Informatics (BMEI), 2012 5th International Conference on, 2012, 16-18 Oct. 2012.* p.6-11.
- ANTONIO, C. P. et al. Remote experiments and 3D virtual world in education. 2015 3rd Experiment International Conference (exp.at'15), 2015, 2-4 June 2015. p.65-70.
- ASTUDILLO, L. et al. Intelligent Control of an Autonomous Mobile Robot using Type-2 Fuzzy Logic **Engineering Letters**, v. 13, n. 2, 2006.
- AXELROD, R. **Structure of Decision: The Cognitive Maps of Political Elites.** Princeton Univ. Press, 1976.
- AZOUAOUI, O. et al. Reinforcement learning based group navigation approach for multiple autonomous robotic system. *IEEE International Conference Mechatronics and Automation, 2005.* p.1539-1544 Vol. 3.
- BAN, X. et al. A self-adaptive control algorithm of the artificial fish formation. *Fuzzy Systems, 2009. FUZZ-IEEE 2009. IEEE International Conference on, 2009, 20-24 Aug. 2009.* p.1903-1908.
- BARTH, E. J. A dynamic programming approach to robotic swarm navigation using relay markers. *American Control Conference, 2003. Proceedings of the 2003, 4-6 June 2003.* p.5264-5269 vol.6.
- BAYINDIR, L.; SAHIN, E. A Review of Studies in Swarm Robotics. **Turk J Elec Enng**, v. 15, n. 2, 2007.
- BEDAU, M. A. Artificial Life. In: (Ed.). **Handbook of the Philosophy of Science:** Elsevier, v.3, 2007.
- BENTLEY, P. J. **Evolutionary Design by Computers.** Morgan Kauffmann, 1999.
- BONABEAU, E. et al. **Swarm intelligence: from natural to artificial systems.** Oxford University Press, 1999.

BORGHESE, N. A. et al. An intelligent game engine for the at-home rehabilitation of stroke patients. *Serious Games and Applications for Health (SeGAH)*, 2013 IEEE 2nd International Conference on, 2013, 2-3 May 2013. p.1-8.

BOUTALIS, Y. et al. On the existence and uniqueness of solutions for the concept values in Fuzzy Cognitive Maps. *Decision and Control, 2008. CDC 2008. 47th IEEE Conference on*, 2008, 9-11 Dec. 2008. p.98-104.

BOUTALIS, Y. et al. Adaptive Estimation of Fuzzy Cognitive Maps With Proven Stability and Parameter Convergence. **IEEE Transactions on Fuzzy Systems**, v. 17, n. 4, p. 874-889, 2009.

BRAGA, B. T. R.; PEREIRA, J. L. A. **Agentes Inteligentes – Conceitos, Características e Aplicações**. Belém: Universidade da Amazônia 2001.

BROGGI, A. et al. Intelligent Vehicles. In: SICILIANO, B. e KHATIB, O. (Ed.). **Springer Handbook of Robotics**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008. p.1175-1198.

BROOKS, R. A robust layered control system for a mobile robot. **IEEE Journal on Robotics and Automation**, v. 2, n. 1, p. 14-23, 1986.

BROOKS, R. A.; STEIN, L. A. Building Brain for Bodies. **Autonomous Robots**, v. 1, 1994.

BUCHE, A. C. et al. Fuzzy cognitive maps for the simulation of individual adaptive behaviors. **Comput. Animat. Virtual Worlds**, v. 21, n. 6, p. 573-587, 2010.

CALVO, R. **Arquitetura híbrida inteligente para navegação autônoma de robôs**. 2007. (Master). USP, São Carlos.

CAMPO, A. et al. Negotiation of Goal Direction for Cooperative Transport. In: DORIGO, M.; GAMBARDELLA, L. M., *et al* (Ed.). **Ant Colony Optimization and Swarm Intelligence**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006. p.191-202.

CARVALHO, J. B. **Mapas Cognitivos Baseados em Regras Difusas: Modelação e simulação da dinâmica de sistemas qualitativos**. 2002. (PhD). Dept .Electr. Comput. Eng., Univ. Tecnica de Lisboa, Lisbon.

CARVALHO, J. P.; TOME, J. A. B. Rule based fuzzy cognitive maps-qualitative systems dynamics. *Fuzzy Information Processing Society*, 2000. NAFIPS. 19th International Conference of the North American, 2000. p.407-411.

CAZANGI, R. R. et al. **Autonomous navigation system applied to collective robotics with ant-inspired communication**. Proceedings of the 7th annual conference on Genetic and evolutionary computation. Washington DC, USA: ACM: 121-128 p. 2005.

CHARNIAK, E.; MCDERMOTT, D. **Introduction to Artificial Intelligence**. Addison-Wesley, 1985.

CHAUVIN, L. et al. Ontological Cognitive Map. 2008 20th IEEE International Conference on Tools with Artificial Intelligence, 2008, 3-5 Nov. 2008. p.225-232.

CHONG, H.-Q. et al. Integrated cognitive architectures: a survey. **Artificial Intelligence Review**, v. 28, n. 2, p. 103-130, 2007.

CLIFF, D. Computational Neuroethology. In: (Ed.). **The Handbook of Brain Theory and Neural Networks**,; the MIT press, v.2, 2002. p.737-741.

COPELAND, J. **The Essential Turing: Seminal Writings in Computing, Logic, Philosophy, Artificial Intelligence, and Artificial Life plus The Secrets of Enigma**. Clarendon Press (Oxford University Press), 2004.

COPPIN, B. **Artificial Intelligence Illuminated**. Jones & Bartlett Learning; Computer ed. edition, 2004. 739.

COSTA, E. D. S.; GOUVEA, M. M. Autonomous Navigation in Dynamic Environments with Reinforcement Learning and Heuristic. Machine Learning and Applications (ICMLA), 2010 Ninth International Conference on, 2010, 12-14 Dec. 2010. p.37-42.

DE CASTRO, L. N. Fundamentals of natural computing: an overview. **Physics of Life Reviews**, v. 4, n. 1, p. 1-36, 2007.

DEAN, T. et al. Solving Planning Problems with Large State and Action Spaces. Proceedings of the Fourth International Conference on Artificial Intelligence Planning Systems (AIPS), 1998.

DICKERSON, J. A.; KOSKO, B. Virtual Worlds as Fuzzy Cognitive Maps. Virtual Reality Annual International Symposium, 1993., 1993 IEEE, 1993, 18-22 Sep 1993. p.471-477.

DICKERSON, J. A.; KOSKO, B. Virtual Worlds as Fuzzy Dynamical Systems. In: (Ed.). **Multimedia Technology for Applications**: Wiley-IEEE Press, 1998. cap. 18, p.567-603.

DORIGO, M.; STÜTZLE, T. **Ant colony optimization**. The MITI press, 2004.

DOUALI, N. et al. New Semantic Web rules and new medical reasoning framework. 2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), 2013, 6-9 May 2013. p.1332-1335.

DUCATELLE, F. et al. Self-organized cooperation between robotic swarms. **Swarm Intelligence**, v. 5, n. 2, p. 73-96, 2011.

ESPELOSÍN, J. et al. Robot navigation in simulated pedestrian areas based on swarm intelligence. Control & Automation (MED), 2012 20th Mediterranean Conference on, 2012, 3-6 July 2012. p.140-144.

FONG, T. W. et al. **A survey of socially interactive robots: Concepts, design, and applications**. Robotics Institute. 2002

FROELICH, W. et al. Application of evolutionary fuzzy cognitive maps to the long-term prediction of prostate cancer. **Applied Soft Computing**, v. 12, n. 12, p. 3810-3817, 2012.

GANGANATH, N. et al. Fuzzy Cognitive Map Based Situation Assessment Framework for Navigation Goal Detection. 2013 IEEE International Conference on Systems, Man, and Cybernetics, 2013, 13-16 Oct. 2013. p.1444-1449.

GHAZANFARI, M. et al. Comparing simulated annealing and genetic algorithm in learning FCM. **Applied Mathematics and Computation**, v. 192, n. 1, p. 56-68, 9/1/ 2007.

GLYKAS, M. **Fuzzy Cognitive Maps: Advances in Theory, Methodologies, Tools and Applications**. Springer Publishing Company, Incorporated, 2010. 200.

GOERICK, C. Towards an Understanding of Hierarchical Architectures. **IEEE Transactions on Autonomous Mental Development**, v. 3, n. 1, p. 54-63, 2011.

GOLMOHAMMADI, S. K. et al. Action Selection in Robots Based on Learning Fuzzy Cognitive Map. 2006 4th IEEE International Conference on Industrial Informatics, 2006, 16-18 Aug. 2006. p.731-736.

GONG, J. et al. Decision-making model of overtaking behavior for automated driving on freeways. 2016 IEEE International Conference on Vehicular Electronics and Safety (ICVES), 2016, 10-12 July 2016. p.1-6.

GRAY, S. A. et al. Mental Modeler: A Fuzzy-Logic Cognitive Mapping Modeling Tool for Adaptive Environmental Management. System Sciences (HICSS), 2013 46th Hawaii International Conference on, 2013, 7-10 Jan. 2013. p.965-973.

GROUMPOS, P. P.; ANNINO, A. P. A theoretical mathematical modeling of Parkinson's disease using Fuzzy Cognitive Maps. Bioinformatics & Bioengineering (BIBE), 2012 IEEE 12th International Conference on, 2012, 11-13 Nov. 2012. p.677-682.

GUDWIN, R. **Semiônica: Uma Proposta de Contribuição à Semiótica Computacional**. 2002. Departamento de Engenharia de Computação e Automação Industrial, Universidade Estadual de Campinas, Campinas.

HAOLI, R.; MINGJUN, W. A study on self-organization system based on Fuzzy Cognitive Map method. Computer Science and Automation Engineering (CSAE), 2012 IEEE International Conference on, 2012, 25-27 May 2012. p.609-612.

HAYES, A. T. et al. Swarm robotic odor localization: Off-line optimization and validation with real robots. **Robotica**, v. 21, n. 4, p. 427-441, 2003.

HEXMOOR, H. **Essential Principles for Autonomous Robotics: Synthesis Lectures on Artificial Intelligence and Machine Learning**. Morgan & Claypool Publishers, 2013.

HWANG, J.; LEE, K. C. Exploring Potentials of Personality Matching between Users and Target Systems by Using Fuzzy Cognitive Map. System Sciences (HICSS), 2013 46th Hawaii International Conference on, 2013, 7-10 Jan. 2013. p.417-424.

JAMSHIDI, A. et al. Dynamic risk modeling and assessing in maintenance outsourcing with FCM. Industrial Engineering and Systems Management (IESM), 2015 International Conference on, 2015, 21-23 Oct. 2015. p.209-215.

JETTER, A.; SCHWEINFORT, W. Building scenarios with Fuzzy Cognitive Maps: An exploratory study of solar energy. **Futures**, v. 43, n. 1, p. 52-66, 2011.

JONES, P. M. et al. Modelling physical systems using fuzzy inference cognitive maps. *Fuzzy Information*, 2004. Processing NAFIPS '04. IEEE Annual Meeting of the, 2004, 27-30 June 2004. p.533-538 Vol.2.

JUN, L. et al. A FCM based approach for emotion prediction in educational game. *Computing and Convergence Technology (ICCCCT)*, 2012 7th International Conference on, 2012, 3-5 Dec. 2012. p.980-986.

KONRAD, S. G. et al. The use of game engines and virtual models to build a simulator for Intelligent Transportation Systems. 2015 XVI Workshop on Information Processing and Control (RPIC), 2015, 6-9 Oct. 2015. p.1-6.

KOSKO, B. Fuzzy cognitive maps. **Int. J. Man-Machine Studies**, v. 24, n. 1, p. 65-75, 1986.

KOSKO, B. Bidirectional associative memories. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 18, n. 1, p. 49-60, 1988.

KOSKO, B. **Neural Networks and Fuzzy Systems: ADynamical Systems Approach to Machine Intelligence**. New York: Prentice Hall, 1992.

KOTTAS, T. et al. New operation scheme and control of Smart Grids using Fuzzy Cognitive Networks. *PowerTech*, 2015 IEEE Eindhoven, 2015, June 29 2015-July 2 2015. p.1-5.

KUBE, C. R.; BONABEAU, E. Cooperative transport by ants and robots. **Robotics and Autonomous Systems**, v. 30, n. 1-2, p. 85-101, 1/31/ 2000.

LABELLA, T. H. et al. Division of labor in a group of robots inspired by ants' foraging behavior. **ACM Trans. Auton. Adapt. Syst.**, v. 1, n. 1, p. 4-25, 2006.

LANGTON, C. G. **Artificial Life: An Overview**. A Bradford Book, 1997.

LEE, D. H.; LEE, H. Construction of holistic fuzzy cognitive maps using ontology matching method. **Expert Systems with Applications**, v. 22, p. 5954-5962, 2015.

LEE, K. C.; LEE, S. A cognitive map simulation approach to adjusting the design factors of the electronic commerce web sites. **Expert Systems with Applications**, v. 24, n. 1, p. 1-11, 2003.

MACLENNAN, B. Synthetic Ethology. In: (Ed.). **The Cognitive Animal: empirical and theoretical perspectives on animal cognition**: the MIT press, 2002.

MAES, P. Artificial life meets entertainment: lifelike autonomous agents. **Commun. ACM**, v. 38, n. 11, p. 108-114, 1995.

MAKI, T. et al. Autonomous detection and volume determination of tubeworm colonies from underwater robotic surveys. *OCEANS 2010 IEEE - Sydney*, 2010, 24-27 May 2010. p.1-8.

MAKRINOS, A. et al. **Introducing Fuzzy Cognitive Maps for decision making in precision agriculture**. 6th European Conference on Precision Agriculture 2007.

MALHOTRA, R.; SARKAR, A. Development of a fuzzy logic based mobile robot for dynamic obstacle avoidance and goal acquisition in an unstructured environment. Proceedings, 2005 IEEE/ASME International Conference on Advanced Intelligent Mechatronics., 2005, 24-28 July 2005. p.1198-1203.

MANDOW, A. et al. The autonomous mobile robot AURORA for greenhouse operation. **IEEE Robotics & Automation Magazine**, v. 3, n. 4, p. 18-28, 1996.

MARTCHENKO, A. S. et al. **Investigating Stability Analysis issues for Fuzzy Cognitive Maps**. MED'03, T. M. C. O. C. A. A.-. 2003.

MATARIC, M. J. **The Robotics Primer**. The MIT press, 2007.

MCPARTLAND, M. et al. Emergence of communication in competitive multi-agent systems: a pareto multi-objective approach. GECCO '05 Proceedings of the 7th annual conference on Genetic and evolutionary computation, 2005, Washington, DC. p.51-58.

MENDONÇA, M. et al. Autonomous navigation system using Event Driven-Fuzzy Cognitive Maps. **Applied Intelligence**, v. 37, n. 2, p. 175-188, 2012.

MENDONÇA, M. et al. A dynamic fuzzy cognitive map applied to chemical process supervision. **Engineering Applications of Artificial Intelligence**, v. 26, n. 4, p. 1199-1210, 2013a.

MENDONÇA, M. et al. A Subsumption Architecture to Develop Dynamic Cognitive Network-Based Models With Autonomous Navigation Application. **Journal of Control, Automation and Electrical Systems**, v. 24, n. 1, p. 117-128, 2013b.

MENDONÇA, M. et al. Cooperative Autonomous Agents Based on Dynamical Fuzzy Cognitive Maps. In: PAPAGEORGIOU, I. E. (Ed.). **Fuzzy Cognitive Maps for Applied Sciences and Engineering: From Fundamentals to Extensions and Learning Algorithms**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. p.159-175.

MENDONÇA, M.; ARRUDA, L. V. R. **A Contribution to the Intelligent Systems Development Using DCN**. Scholars' Press, 2015.

MENDONÇA, M. et al. **Dynamic fuzzy cognitive maps and fuzzy logic controllers applied in industrial mixer**. XII Simpósio Brasileiro de Automação Inteligente (SBAI). Natal - RS 2015a.

MENDONÇA, M. et al. Hybrid Dynamic Fuzzy Cognitive Maps Evolution for autonomous navigation system. Fuzzy Systems (FUZZ-IEEE), 2015 IEEE International Conference on, 2015b, 2-5 Aug. 2015. p.1-7.

MENDONÇA, M. et al. Controller Based in Subsumption Architecture And Swarm Robotics for Cooperative Autonomous Agents. **International Journal of Science and Advanced Technology**, v. 5, n. 2, 2015c.

MENDONÇA, M. et al. Fuzzy Cognitive Maps Applied to Student Satisfaction Level in an University. **IEEE Latin America Transactions**, v. 13, n. 12, p. 3922-3927, 2015d.

MENDONÇA, M. et al. **Hybrid Dynamic Fuzzy Cognitive Maps and Hierarchical Fuzzy Logic controllers for Autonomous Mobile Navigation** FUZZ-IEEE 2016 - IEEE World Congress on Computational Intelligence. Vancouver, Canada 2016.

MIAO, Y. Fuzzy cognitive map for domain experts with no artificial intelligence expertise. Control Automation Robotics & Vision (ICARCV), 2014 13th International Conference on, 2014, 10-12 Dec. 2014. p.486-492.

MIAO, Y. et al. Dynamical cognitive network-an extension of fuzzy cognitive map. Tools with Artificial Intelligence, 1999. Proceedings. 11th IEEE International Conference on, 1999, 1999. p.43-46.

MIAO, Y. et al. The Equivalence of Cognitive Map, Fuzzy Cognitive Map and Multi Value Fuzzy Cognitive Map. 2006 IEEE International Conference on Fuzzy Systems, 2006, 0-0 0. p.1872-1878.

MIN, H. Q. et al. Probability Fuzzy Cognitive Map for Decision-Making in Soccer Robotics. 2006 IEEE/WIC/ACM International Conference on Intelligent Agent Technology, 2006, 18-22 Dec. 2006. p.321-325.

MITCHELL, S.; COHEN, K. Fuzzy logic decision making for autonomous robotic applications. 2014 IEEE 6th International Conference on Awareness Science and Technology (iCAST), 2014, 29-31 Oct. 2014. p.1-6.

MOHAN, Y.; PONNAMBALAM, S. G. An extensive review of research in swarm robotics. Nature & Biologically Inspired Computing, 2009. NaBIC 2009. World Congress on, 2009, 9-11 Dec. 2009. p.140-145.

MOTLAGH, O. et al. An expert fuzzy cognitive map for reactive navigation of mobile robots. **Fuzzy Sets Syst.**, v. 201, p. 105-121, 2012a.

MOTLAGH, O. et al. An FCM modeling for using a priori knowledge: application study in modeling quadruped walking. **Neural Comput. Appl.**, v. 21, n. 5, p. 1007-1015, 2012b.

MÜLLER, J. P.; PISCHEL, M. **The Agent Architecture InteRRaP Concept and Application**. German Research Center for Artificial Intelligence. 1993

MYERS, K. L. **User Guide for the Procedural Reasoning System**. SRI International. Menlo Park, CA. 1997

NACHÁZEL, T. Optimization of Decision-Making in Artificial Life Model Based on Fuzzy Cognitive Maps. Intelligent Environments (IE), 2015 International Conference on, 2015, 15-17 July 2015. p.136-139.

NÁPOLES, G. et al. Rough Cognitive Networks. **Knowledge-Based Systems**, v. 91, p. 46-61, 2016.

NASCIMENTO, T. P.; BRITO, L. Modelagem de Estratégia para Controle de Agentes Cooperativos. **Diálogos & Ciência (Online)**, v. 10, 2007.

NELSON, A. L. Embodied artificial life at an impasse can evolutionary robotics methods be scaled? , *Evolving and Autonomous Learning Systems (EALS)*, 2014 IEEE Symposium on, 2014, 9-12 Dec. 2014. p.25-34.

NEOCLEOUS, C.; SCHIZAS, C. N. Modeling socio-politico-economic systems with time-dependent fuzzy cognitive maps. *Fuzzy Systems (FUZZ-IEEE)*, 2012 IEEE International Conference on, 2012, 10-15 June 2012. p.1-7.

NOLFI, S.; FLOREANO, D. **Evolutionary Robotics: The Biology, Intelligence, and Technology**. MIT Press, 2000. 320.

OCA, M. A. M. D. et al. Opinion Dynamics for Decentralized Decision-Making in a Robot Swarm. In: DORIGO, M.; BIRATTARI, M., *et al* (Ed.). **Swarm Intelligence: 7th International Conference, ANTS 2010, Brussels, Belgium, September 8-10, 2010. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p.251-262.

PAJARES, G.; CRUZ, J. M. D. L. Fuzzy Cognitive Maps for stereovision matching. **Pattern Recognition**, v. 39, n. 11, p. 2101-2114, 2006.

PAL'A, M.; MIZENKO, L. **Mobile Robot Navigation using Adaptive Fuzzy Cognitive Maps**. SCYR 2012 – 12th Scientific Conference of Young Researches 2012.

PAPAGEORGIU, E. et al. Novel Architecture for supporting medical decision making of different data types based on Fuzzy Cognitive Map Framework. 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2007, 22-26 Aug. 2007. p.1192-1195.

PAPAGEORGIU, E. I. A new methodology for Decisions in Medical Informatics using fuzzy cognitive maps based on fuzzy rule-extraction techniques. **Applied Soft Computing**, v. 11, n. 1, p. 500-513, 2011.

PAPAGEORGIU, E. I. Learning Algorithms for Fuzzy Cognitive Maps - A Review Study. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 42, n. 2, p. 150-163, 2012.

PAPAGEORGIU, E. I.; FROELICH, W. Application of Evolutionary Fuzzy Cognitive Maps for Prediction of Pulmonary Infections. **IEEE Transactions on Information Technology in Biomedicine**, v. 16, n. 1, p. 143-149, 2012.

PAPAGEORGIU, E. I.; SALMERON, J. L. A Review of Fuzzy Cognitive Maps Research During the Last Decade. **IEEE Transactions on Fuzzy Systems**, v. 21, n. 1, p. 66-79, 2013.

PASSINO, K. M.; YURKOVICH, S. **Fuzzy Control**. Addison-Wesley Longman Publishing Co., Inc., 1997.

PAYTON, D. et al. Pheromone Robotics. **Autonomous Robots**, v. 11, n. 3, p. 319-324, 2001.

PAYTON, D. et al. Compound behaviors in pheromone robotics. **Robotics and Autonomous Systems**, v. 44, n. 3–4, p. 229-240, 9/30/ 2003.

PAZIENZA, G. E. et al. Decision Trees and CBR for the Navigation System of a CNN-based Autonomous Robot. In: CASTILLO, O.;MELIN, P., *et al* (Ed.). **Hybrid Intelligent Systems: Analysis and Design**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p.181-201.

PEDRYCZ, W. et al. Genetic learning of fuzzy cognitive maps. **Fuzzy Sets and Systems**, v. 153, n. 3, p. 371-401, 2005.

PERUSICH, K. Fuzzy cognitive maps for policy analysis. Technology and Society Technical Expertise and Public Decisions, 1996. Proceedings., 1996 International Symposium on, 1996, 21-22 Jun 1996. p.369-373.

PINI, G. et al. Task partitioning in swarms of robots: an adaptive method for strategy selection. **Swarm Intelligence**, v. 5, n. 3, p. 283-304, 2011.

PIPE, A. G. An architecture for building "potential field" cognitive maps in mobile robot navigation. Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference on, 1998, 11-14 Oct 1998. p.2413-2417 vol.3.

PRATT, S. F. et al. Rebel with many causes: A computational model of insurgency. Intelligence and Security Informatics (ISI), 2012 IEEE International Conference on, 2012, 11-14 June 2012. p.90-95.

RODIN, V. et al. Multi-Agents System to Model Cell Signalling by Using Fuzzy Cognitive Maps. Application to Computer Simulation of Multiple Myeloma. Bioinformatics and BioEngineering, 2009. BIBE '09. Ninth IEEE International Conference on, 2009, 22-24 June 2009. p.236-241.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3rd Edition. Pearson, 2009.

SAFIOTTI, A. Fuzzy logic in autonomous robotics: behavior coordination. Fuzzy Systems, 1997., Proceedings of the Sixth IEEE International Conference on, 1997, 1-5 Jul 1997. p.573-578 vol.1.

SALAN, S. et al. Minimum-Energy Robotic Exploration: A Formulation and an Approach. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 45, n. 1, p. 175-182, 2015.

SALMERON, J. L. Fuzzy cognitive maps for artificial emotions forecasting. **Applied Soft Computing**, v. 12, n. 12, p. 3704-3710, 2012.

SALOMON, R. et al. Bio-inspired optimization of Fuzzy Cognitive Maps for their use as a means in the pricing of complex assets. 2012 IEEE Conference on Computational Intelligence for Financial Engineering & Economics (CIFER), 2012, 29-30 March 2012. p.1-8.

SCHROTH, G. et al. A cognitive system for autonomous robotic welding. 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2009, 10-15 Oct. 2009. p.3148-3153.

SHAIKH, M. H. et al. The state-of-the-art intelligent navigational system for monitoring in mobile autonomous robot. Information and Communication Technology (ICoICT), 2013 International Conference of, 2013, 20-22 March 2013. p.405-409.

SHUCKER, B.; BENNETT, J. K. Scalable Control of Distributed Robotic Macrosensors. In: ALAMI, R.;CHATILA, R., *et al* (Ed.). **Distributed Autonomous Robotic Systems 6**. Tokyo: Springer Japan, 2007. p.379-388.

SIRAJ, A. et al. Fuzzy cognitive maps for decision support in an intelligent intrusion detection system. IFSA World Congress and 20th NAFIPS International Conference, 2001. Joint 9th, 2001, 25-28 July 2001. p.2165-2170.

SMITHERS, T. Autonomy in Robots and Other Agents. **Brain and Cognition**, v. 34, n. 1, p. 88-106, 1997.

SPEARS, A. et al. Design and development of an under-ice autonomous underwater vehicle for use in Polar regions. 2014 Oceans - St. John's, 2014, 14-19 Sept. 2014. p.1-6.

SPERATI, V. et al. Self-organised path formation in a swarm of robots. **Swarm Intelligence**, v. 5, n. 2, p. 97-119, 2011.

SUBRAMANIAN, H.; DAGLI, C. H. Cooperative Cleaning for distributed Autonomous robot systems using Fuzzy Cognitive Maps. Fuzzy Information Processing Society, 2003. NAFIPS 2003. 22nd International Conference of the North American, 2003, 24-26 July 2003. p.287-290.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. A Bradford Book, 1998.

TABATABAYI, F. et al. Simulating Online Consumer Satisfaction Using Fuzzy Cognitive Mapping. Information Technology: New Generations (ITNG), 2012 Ninth International Conference on, 2012, 16-18 April 2012. p.540-547.

TISSEAU, J. **Virtual reality – in virtuo autonomy**. 2001. (PhD). University of Rennes 1, Renne, France.

TIWARI, K. N. et al. Single input fuzzy logic controller tuning for steering control of autonomous underwater vehicle: Genetic algorithm approach. 2016 Indian Control Conference (ICC), 2016, 4-6 Jan. 2016. p.335-340.

TOLMAN, E. C. Cognitive maps in rats and men. **Psychological Review**, v. 55, n. 4, p. 189-208, 1948.

TOMLINSON, B.; BLUMBERG, B. Using Emotional Memories to Form Synthetic Social Relationships. Proceedings of AAMAS 02, 2002, Bologna, Italy.

TRIANNI, V. et al. Evolving Aggregation Behaviors in a Swarm of Robots. In: BANZHAF, W.; ZIEGLER, J., *et al* (Ed.). **Advances in Artificial Life: 7th European Conference, ECAL 2003, Dortmund, Germany, September 14-17, 2003. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2003. p.865-874.

TROETSTH, A. et al. A Prototype of a Virtual World with Collaborative Games for the Study of the Periodic Table of Elements. **IEEE Latin America Transactions**, v. 13, n. 2, p. 476-482, 2015.

VASCAK, J.; MADARASZ, L. Adaptation of Fuzzy Cognitive Maps – a Comparison Study. **Acta Polytechnica Hungarica**, v. 7, n. 3, 2010.

VASSILIKI, M.; GROUMPOS, P. P. A revised approach in modeling fuzzy cognitive maps. 2016 24th Mediterranean Conference on Control and Automation (MED), 2016, 21-24 June 2016. p.350-354.

VASUDEVAMURT, V. B.; USKOV, A. Serious game engines: Analysis and applications. 2015 IEEE International Conference on Electro/Information Technology (EIT), 2015, 21-23 May 2015. p.440-445.

VERNON, D. et al. A Survey of Artificial Cognitive Systems: Implications for the Autonomous Development of Mental Capabilities in Computational Agents. **IEEE Transactions on Evolutionary Computation**, v. 11, n. 2, p. 151-180, 2007.

WANG, S. et al. Activity Density Map Visualization and Dissimilarity Comparison for Eldercare Monitoring. **IEEE Transactions on Information Technology in Biomedicine**, v. 16, n. 4, p. 607-614, 2012.

WOOLDRIDGE, M. Intelligent Agents. In: (Ed.). **Multiagent Systems - A Modern Approach to Distributed Artificial Intelligence**: the MIT press, 1999.

WOOLDRIDGE, M. **An Introduction to MultiAgent Systems**. John Wiley & Sons, 2009.

WOOLDRIDGE, M.; JENNINGS, N. Intelligent Agents: Theory and Practice. **Knowledge Engineering Review**, v. 10, n. 2, 1995.

YEAP, W. K. et al. **Initial experiments with a mobile robot on cognitive mapping**. Proceedings of the 2006 international symposium on Practical cognitive agents and robots. Perth, Australia: ACM: 221-230 p. 2006.

YESIL, E. et al. Fuzzy cognitive maps learning using Artificial Bee Colony optimization. Fuzzy Systems (FUZZ), 2013 IEEE International Conference on, 2013, 7-10 July 2013. p.1-8.

YUAN, M.; ZHI-QIANG, L. On causal inference in fuzzy cognitive maps. **IEEE Transactions on Fuzzy Systems**, v. 8, n. 1, p. 107-119, 2000.

ZADEH, L. A. **An Introduction to Fuzzy Logic Applications in Intelligent Systems** Springer US, 1992.

ZHANG, T. et al. Learning deep control policies for autonomous aerial vehicles with MPC-guided policy search. 2016 IEEE International Conference on Robotics and Automation (ICRA), 2016, 16-21 May 2016. p.528-535.

ZHI-QIANG, L.; SATUR, R. Contextual fuzzy cognitive map for decision support in geographic information systems. **IEEE Transactions on Fuzzy Systems**, v. 7, n. 5, p. 495-507, 1999.