



Marcelo França Corrêa

**Modelos Neuro-Fuzzy Hierárquicos com
Aprendizado por Reforço para Multi-Agentes
Inteligentes**

Tese de Doutorado

Tese apresentada ao programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica da PUC-Rio como parte dos requisitos parciais para obtenção do título de Doutor em Engenharia Elétrica.

Orientadora: Profa. Marley Maria Bernardes Rebuszi Vellasco
Co-orientadora: Profa. Karla Tereza Figueiredo Leite

Rio de Janeiro
Agosto de 2011



Marcelo França Corrêa

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Profa. Marley Maria Bernardes Rebuzzi Vellasco
Orientadora
Departamento de Engenharia Elétrica – PUC-Rio

Profa. Karla Tereza Figueiredo Leite
Co-orientadora
UEZO

Prof. Ricardo Tanscheit
Departamento de Engenharia Elétrica – PUC-Rio

Pfrof. Flavio Joaquim de Souza
UERJ

Prof. Fernando Antonio Campos Gomide
UNICAMP/FEEC/DCA

Prof. Adriano Joaquim de Oliveira Cruz
UFRJ

Profa. Roxana Jimenez Contreras
Departamento de Engenharia Elétrica – PUC-Rio

Prof. Bruno Feijó
Departamento de Informática – PUC-Rio

Prof. José Eugenio Leal
Coordenador Setorial do Centro
Técnico Científico - PUC-Rio

Rio de Janeiro, 25 de agosto de 2011

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e da orientadora.

Marcelo França Corrêa

Possui graduação em Informática pela Pontifícia Universidade Católica do Rio de Janeiro (1998), MBA em Finanças pela IBMEC-RJ (2000), Mestrado em Administração de Empresas pela IBMEC-RJ (2004) e Doutorado em Inteligência Computacional Aplicada pela PUC-RJ (2011). Trabalha no setor privado desde 1997, tendo passagens por instituições financeiras e consultorias. Hoje, atua como empresário no setor de Tecnologia

Ficha Catalográfica

Corrêa, Marcelo França

Modelos neuro-Fuzzy hierárquicos com aprendizado por reforço para multi-agentes inteligentes / Marcelo França Corrêa; orientadora: Marley Maria Bernardes Rebuszi Vellasco; co-orientadora: Karla Tereza Figueiredo Leite. – 2011.

157 f.; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2010.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Sistemas multi-agente (SMA). 3. Neuro-fuzzy hierárquico. 4. Agentes inteligentes. 5. Aprendizado por reforço. I. Vellasco, Marley Maria Bernardes Rebuszi. II. Leite, Karla Tereza Figueiredo III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

Agradecimentos

A meus pais,
Agradeço pelo apoio moral e financeiro em toda a minha formação.

Ao CNPq e à PUC-Rio,
Pelo auxílio financeiro e acadêmico prestados para o desenvolvimento deste trabalho.

A minha orientadora,
Pelo auxílio e orientação em todo período de construção da tese.

A Deus,
Pela saúde que sempre me deu para dar continuidade às minhas atividades.

Resumo

Corrêa, Marcelo França; Vellasco, Marley Maria Bernardes Rebuzzi (Orientadora); Leite, Karla Tereza Figueiredo (Co-orientadora). **Modelos Neuro-Fuzzy Hierárquicos com Aprendizado por Reforço para Multi-Agentes Inteligentes**. Rio de Janeiro, 2011. 157p. Tese de Doutorado. Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Os benefícios trazidos pela aplicação de Sistemas Multi-Agentes (SMA) são diversos. Através da computação paralela, agentes podem trabalhar em conjunto para explorar melhor a estrutura descentralizada de uma determinada tarefa e acelerar sua conclusão. Além disso, agentes também podem trocar experiências se comunicando, fornecer alto grau de escalabilidade, através da inclusão de novos agentes quando necessário, e ainda fazer com que agentes assumam as atividades de outros agentes em casos de falha. Vários modelos de agentes desenvolvidos até o momento usam o aprendizado por reforço como algoritmo base no processo de aprendizado. Quando o agente está inserido em ambientes pequenos ou discretos, os resultados obtidos com o uso de métodos como *Q-learning* são satisfatórios. No entanto, quando o ambiente é grande ou contínuo, o uso de métodos de aprendizado por reforço torna-se inviável, devido à grande dimensão do espaço de estados. Nos SMA, este problema é consideravelmente maior, já que a memória necessária passa a crescer exponencialmente com a quantidade de agentes envolvidos na aplicação. Esta tese teve como finalidade o desenvolvimento de um novo modelo de aprendizado autônomo para Sistemas Multi-Agentes (SMA) visando superar estas limitações. O trabalho foi realizado em três etapas principais: levantamento bibliográfico, seleção e implementação do modelo proposto, e desenvolvimento de estudo de casos. O levantamento bibliográfico contemplou o estudo de agentes inteligentes e Sistemas Multi-Agentes, buscando identificar as propriedades e limitações dos algoritmos já desenvolvidos, as aplicações existentes, e as características desejadas em um SMA. A seleção e utilização de um modelo neuro-fuzzy hierárquico da família RL-NFH foi motivada especialmente pela importância de se estender a autonomia e aprendizado de agentes através do quesito inteligência, e pela sua capacidade de superar limitações presentes em algoritmos de aprendizado por reforço tradicionais. Inicialmente, ao modelo anterior foram adicionados os conceitos de satisfatoriedade e não-dominação, com a finalidade de acelerar o processo de aprendizado do algoritmo. Em seguida, o novo modelo multi-agente foi criado, viabilizando o desenvolvimento de aplicações de natureza tanto cooperativa como competitiva, com múltiplos agentes. Os estudos de caso contemplaram situações distintas de cooperação e competição entre agentes autônomos. Foram implementadas três aplicações distintas: uma aplicação *benchmark* do jogo da presa-predador (Pursuit-Game); um leilão energia elétrica, em que os fornecedores de energia fazem ofertas para atender à previsão de demanda em um período de tempo determinado; e uma aplicação na área de gerenciamento de projetos, onde agentes inteligentes são criados com o objetivo de fornecer estimativas de duração de atividades e automatizar alguns processos realizados pelo Gerente de Projetos. Em todos os Estudos de Caso, os resultados foram comparados com técnicas convencionais e/ou com o desempenho de outros Sistemas Multi-Agente. Os resultados alcançados pelo novo modelo se mostraram promissores. Os testes evidenciaram que o modelo teve a capacidade de coordenar as ações entre agentes totalmente autônomos em diferentes situações e ambientes. Além disso, o novo modelo mostrou-se genérico e flexível, podendo ser usado no futuro em outras aplicações envolvendo múltiplos agentes.

Palavras-chave

Sistemas Multi-Agente (SMA); Neuro-Fuzzy Hierárquico; Agentes Inteligentes, Aprendizado por Reforço.

Abstract

Corrêa, Marcelo França; Vellasco, Marley Maria Bernardes Rebuzzi (Advisor); Leite, Karla Tereza Figueiredo (Co-advisor). **Hierarchical Neural Fuzzy Models Based on Reinforcement Learning of Intelligent Agents**. Rio de Janeiro, 2011. 157p. PhD Thesis – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

There are several benefits provided by Multi-Agent Systems (MAS). Through parallel computing, agents can work together to better explore the decentralized structure of a given task and speed up its completion. In addition, agents can also exchange knowledge through communication, provide scalability by adding new agents when appropriate, and replace troubled agents in cases of failures. A great number of existing agent models is based on reinforcement learning algorithms for learning. When the agent works in small or discrete environments, the results obtained with methods such as Q-learning are satisfactory. However, when the environment is large or continuous reinforcement learning methods become unfeasible due to the large state space. In MAS, this problem is considerably greater, since the required memory begins to grow exponentially with the number of agents involved in the application. The main objective of this thesis is to develop a new model of autonomous learning for multi-agents in order to overcome these limitations. The study consisted of three main stages: literature review, new model development and implementation, and case studies. Literature review included the study of intelligent agents and Multi-Agent Systems, seeking to identify the properties and limitations of the algorithms already developed, existing applications, and desired features in the new MAS. The choice of a neuro-fuzzy hierarchical model of the family RL-NFH as a basis was especially motivated by the importance of extending the autonomy and learning of the agents through intelligence. And also, because of its capacity to overcome some of the limitations present in traditional reinforcement learning algorithms. Initially, the concepts of *satisficing* and *non-domination* were incorporated into the previous model to accelerate the learning algorithm. Then, the new multi-agent model was elaborated and implemented, enabling the development of cooperative and competitive applications, with multiple agents. Case studies have covered different situations of cooperation and competition between autonomous agents. Three applications were considered: the Pursuit-Game *benchmark* game, an electricity auction, where energy suppliers make offers to meet forecast demand in a given period of time, and an application in project management area, where intelligent agents are created to provide activity duration estimates and to automate some processes done usually by the Project Manager. In all case studies, results were compared with conventional techniques and/or the performance of other MAS. The results achieved by the new model are encouraging. The tests showed that the new system has the capacity to coordinate actions between fully autonomous agents in different situations and environments. Moreover, the new model is strongly generic and flexible. Due to these properties, it can be used in future in several other applications involving multiple agents.

Keywords

Multi-Agent Systems (MAS); hierarchical neuro-fuzzy; intelligent agents; reinforcement learning.

Sumário

1. Introdução.....	12
1.1. Motivação.....	12
1.2. Descrição do trabalho e contribuição.....	15
1.3. Organização da Tese.....	18
2. Agentes Inteligentes e Sistemas Multi-Agentes.....	20
2.1. Agentes Inteligentes.....	20
2.2. Inteligência.....	21
2.2.1. Base de Conhecimento.....	22
2.2.2. Raciocínio.....	23
2.2.3. Aprendizado.....	23
2.3. Aprendizado por Reforço (Reinforcement Learning - RL).....	25
2.4. Sistemas Multi-Agentes (SMA).....	28
2.4.1. Introdução.....	28
2.4.2. Conceitos e Taxonomia.....	31
2.4.3. Sistemas Multi-Agentes baseados em Reinforcement Learning.....	41
2.4.4. Aplicações de Sistemas Multi-Agentes.....	47
3. Reinforcement Learning Neuro-Fuzzy Hierárquico Politree (RL-NFHP).....	52
3.1. Introdução.....	52
3.2. Particionamento Quadtree/Politree.....	52
3.3. Célula Básica RL-Neuro-Fuzzy Politree.....	53
3.4. Arquitetura RL-NFHP.....	59
3.4.1. Antecedentes das Regras do Modelo RL-NFHP.....	62
3.4.2. Conseqüentes das Regras do Modelo RL-NFHP.....	62
3.5. Algoritmo de Aprendizado.....	64
4. Modelo Reinforcement Learning Neuro-Fuzzy Hierárquico para Múltiplos Agentes – RL-NFHP-MA.....	79
4.1. Introdução.....	79
4.2. Princípios de <i>Satisfatoriedade</i> e <i>Não-Dominação</i>	80
4.3. Sistemas RL-NFHP-MA.....	82
4.3.1. Dinâmica do Aprendizado.....	83
4.3.2. Mecanismo de Coordenação entre os agentes.....	85
4.3.3. Tipos de Sistemas RL-NFHP-MA e Objetivos.....	89
4.4. Algoritmo de Aprendizado.....	90
4.5. Outras Considerações sobre os Sistemas RL-NFHP-MA.....	94
4.5.1. Homogeneidade do Aprendizado.....	94
4.5.2. Percepção do Agente.....	96
5. Estudo de Casos.....	98
5.1. Introdução.....	98
5.2. Seleção e Apresentação dos Estudo de Casos.....	99
5.3. Desenvolvimento dos Estudos de Caso.....	100
5.3.1. Jogo da Presa e Predador.....	100
5.3.2. Leilão de Energia.....	118

5.3.3 Sistema Multi-Agente para Gerenciamento Ágil de Projetos de Softwares em Ambientes Distribuídos	131
6. Conclusões.....	143
7. Referências bibliográficas	146

Lista de Tabelas

Tabela 1: Quadro relacionando os diferentes modelos RL-NFHP-MA com os Estudos de Caso que foram desenvolvidos.....	18
Tabela 2: Principais algoritmos multi-agentes de RL	46
Tabela 3: Exemplo da forma de cálculo de μ_a e μ_r	82
Tabela 4: Quadro com uma síntese dos diferentes modelos RL-NFHP-MA	90
Tabela 5: Quadro com uma síntese dos diferentes modelos RL-NFHP-MA	98
Tabela 6: Quadro relacionando os diferentes modelos RL-NFHP-MA com os Estudos de Caso que foram desenvolvidos.....	100
Tabela 7: Resultados alcançados pela versão modificada do algoritmo RL-NFHP, após a introdução dos conceitos de <i>Satisfatoriedade</i> e <i>Não-Dominação</i>	114
Tabela 8: Resultados comparativos do total de passos necessários para realização de 1.000 capturas, com e sem um mecanismo de coordenação explícito	115
Tabela 9: Resultados comparando o total de passos necessários para realização de 1.000 capturas com a presa inteligente e aleatória	116
Tabela 10: Relação das termoeletricas e suas características	122
Tabela 11: Funções de custo das termoeletricas.....	123
Tabela 12: Resultados do primeiro experimento, com apenas um agente inteligente, competindo contra agentes de estratégias conservadoras.....	126
Tabela 13: Resultados do segundo experimento, em que são utilizados dois agentes inteligentes.....	128
Tabela 14: Resultados do segundo experimento, em que são utilizados dois agentes inteligentes com aprendizado simultâneo.....	129
Tabela 15: Desempenho das equipes de desenvolvimento de software	137
Tabela 16: Desempenho das equipes de desenvolvimento de software, após a implantação e aprendizado do novo SMA.....	141
Tabela 17: Resultados comparativos do desempenho do modelo RL-NFHP-MA com técnicas convencionais	141

Lista de Figuras

Figura 1 – Esquema do modelo Reinforcement Learning	26
Figura 2: Taxonomia das áreas de pesquisa dentro da Inteligência Artificial Distribuída (DAI), de acordo com Stone e Veloso (2000).	30
Figura 3: Categorias de SMA de acordo com o nível de comunicação e heterogeneidade dos agentes (Stone e Veloso, 2000).	33
Figura 4: Resumo de algoritmos multi-agentes de RL e suas técnicas	47
Figura 5: SoccerServer: servidor usado em jogos entre times de robôs	49
Figura 6: SMA de Negociação, onde cada agente possui uma função	50
Figura 7: Exemplo de particionamento Quadtree	52
Figura 8 - Célula Reinforcement Learning Neuro-Fuzzy Quadtree	54
Figura 9: Diagrama simplificado da célula Reinforcement Learning Neuro-Fuzzy Quadtree relativo a figura 8	54
Figura 10: Célula RL-NFP representada sob o formato de rede neuro-fuzzy	55
Figura 11: Divisão em quadrantes realizada pelas FPs alto e baixo	56
Figura 12: Representação em árvore da célula RL-NFP.	57
Figura 13: Exemplo de arquitetura RL-NFHP	59
Figura 14: Árvore <i>Politree</i> referente ao particionamento da figura 13	59
Figura 15: Esquema do processo de aprendizado do agente	62
Figura 16: Interior da célula RL-NFHP com duas entradas (Quadtree)	63
Figura 17: Retropropagação do retorno do ambiente para o modelo RL-NFHP... ..	67
Figura 18: Exemplo de atualização da função de valor Q_{t+1}	73
Figura 19: Função de crescimento	76
Figura 20 – Particionamento da Célula RL-NFP	78
Figura 21: Particionamento da Célula RL-NFP	82
Figura 22: Compartilhamento do conhecimento e exploração do ambiente pelos multi-agentes	83

Figura 23: Sistema RL-NFHP-MA em que os agentes possuem diferentes estruturas de aprendizado	84
Figura 24: Arquitetura com diferentes estruturas e um Agente Central.....	85
Figura 25: Sistema em que agentes usam mesma estrutura de aprendizado	86
Figura 26: Grid ortogonal do Jogo da Presa/Predador.	87
Figura 27: Coordenação realizada por agente central no jogo da presa-predador	87
Figura 28: Jogo da presa-predador sem a figura de um agente central	88
Figura 29: Representação do jogo em que a Presa é um Agente Inteligente.....	89
Figura 30: Algoritmo de aprendizado do modelo RL-NFHP-MA	91
Figura 31: Exemplo de ambiente multi-agente em que agentes possuem comportamentos distintos	95
Figura 32: Representação de diferentes níveis de percepção do agente no jogo da presa-predador	97
Figura 33: Possíveis valores do estado para o agente, quando este se encontra na posição (4, 4).....	102
Figura 34: Quatro possíveis objetivos que os agentes buscavam alcançar para capturar a presa.....	103
Figura 35: Sequência de movimentação dos agentes durante 2ª captura.	105
Figura 36: Número de passos que cada captura levou durante o aprendizado da versão multi-agentes	106
Figura 37: Número de passos que cada captura levou durante o aprendizado da versão original do modelo RL-NFHP.....	113
Figura 38: Perfil horário da demanda da região Sul.....	120
Figura 39: Leilão de Energia multi-agentes, sendo 1 agente RL-NFHP	125
Figura 40: Leilão de Energia multi-agentes, sendo 2 agentes RL-NFHP	127
Figura 41: Desenvolvimento de projetos através de metodologia SCRUM.....	135
Figura 42: Esquema de funcionamento do novo SMA proposto.....	138
Figura 43: Processo de aprendizado do agente ‘Programador’	139
Figura 44: SMA proposto considerando dois Escritórios de Projetos (EGPs)....	139