

Conclusões

Este trabalho apresentou um novo modelo de aprendizado para Sistemas Multi-Agentes (SMA) através de algoritmos neuro-fuzzy hierárquicos da família RL-NFH. A principal motivação para o desenvolvimento desta Tese foi explorar benefícios trazidos pela aplicação de Sistemas Multi-Agentes (SMA), entre eles a computação paralela, que permite que agentes trabalhem em conjunto para explorar melhor uma determinada tarefa e acelerar sua conclusão, e a coordenação e comunicação entre agentes.

A escolha do algoritmo RL-NFH como base do novo modelo, realizada após a etapa de levantamento bibliográfico, 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.

Antes do desenvolvimento da versão para multi-agentes, foram adicionados ao modelo RL-NFH original os conceitos de *satisfatoriedade* e *não-dominância*, com a finalidade de acelerar o processo de aprendizado do algoritmo. Os ganhos no processo de aprendizagem puderam ser observados no primeiro estudo de caso, que contemplou a aplicação *benchmark Pursuit Game*. Neste jogo, um grupo de quatro predadores tem como objetivo perseguir e capturar uma presa em um grid ortogonal.

Após a alteração comentada no parágrafo anterior, o novo modelo multi-agente foi então elaborado. Através do modelo, foi possível o desenvolvimento de aplicações de natureza tanto cooperativa como competitiva, com múltiplos agentes. Para evidenciar esta flexibilidade do modelo, além do jogo *Pursuit Game*, também foram desenvolvidos outros dois estudos de caso: um leilão de 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.

O primeiro estudo de caso mostrou alguns benefícios na utilização de agentes aprendendo em paralelo, acelerando assim o processo de aprendizado. Além disso, também foi possível explorar diferentes formas de coordenação entre os agentes. Primeiramente, os agentes funcionaram através de uma coordenação implícita durante a captura da presa. Em seguida, um mecanismo explícito de coordenação foi introduzido (“agente central”), com o objetivo de sincronizar os objetivos dos agentes predadores a cada rodada do jogo. Os resultados permitiram demonstrar os ganhos trazidos pela criação do mecanismo. Ainda neste estudo de caso, a aplicação foi modificada para que a presa também passasse a ser um agente inteligente RL-NFHP, tornando a aplicação competitiva entre a presa e os predadores, e colaborativa entre os predadores.

No segundo Estudo de Caso foi desenvolvido um sistema multi-agente de natureza competitiva para simular um leilão reverso de energia. Neste tipo de leilão, os fornecedores de energia fazem ofertas para atender uma determinada previsão de demanda durante um período de tempo. Foram criados agentes inteligentes RL-NFHP para atuar como fornecedores, que visavam maximizar o lucro através de ofertas estratégicas. Os resultados alcançados pelos agentes RL-NFHP foram comparados com os resultados obtidos por agentes conservadores e também pelos resultados obtidos em Walter e Gomide (2006). Foi observado que o novo modelo foi capaz de superar estratégias conservadoras utilizando os *bidding* estratégicos gerados pelo algoritmo. Em relação ao modelo GFRBS (Walter e Gomide, 2006), o RL-NFHP-MA obteve resultados similares, sendo superior em algumas situações e inferior em outras. Uma das vantagens apresentadas pelo novo modelo foi a capacidade de realizar um aprendizado paralelo dos agentes.

Já o terceiro e último Estudo de Caso teve como objetivo o desenvolvimento de um novo Sistema Multi-Agente voltado para o Gerenciamento Ágil de Projetos de Softwares. Nesta aplicação, foram criados agentes colaborativos, que representavam diferentes classes de profissionais, com estruturas RL-NFHP independentes. As estruturas independentes dos agentes foram alimentadas e treinadas a partir das experiências acumuladas dos diversos profissionais da mesma classe (ou que exerciam a mesma atividade). O novo SMA teve como objetivos primários o suporte no processo de definição de métricas e estimativas de duração e a automatização de alguns dos principais

processos realizados pelo Gerente de Projetos. Os resultados mostraram que o novo sistema foi capaz de superar técnicas convencionais utilizadas na área de Gerenciamento de Projetos.

As principais contribuições deste trabalho são, portanto:

- melhorias nos algoritmos da família RL-NFH, com a introdução dos novos conceitos de *satisfatoriedade* e *não-dominação*;
- e a proposição e teste de um novo modelo voltado para ambientes multi-agentes, flexível e genérico, que pode vir a ser usado em diversas aplicações e problemas distintos. Isso pode ser observado nos estudos de caso realizados, onde foram abordados problemas em diferentes áreas de natureza competitiva, cooperativa e, ainda, competitiva e cooperativa simultaneamente.

Como contribuição secundária destaca-se um levantamento bibliográfico extenso na área de Sistemas Multi-Agentes, tema recente, promissor e ainda relativamente pouco explorado no Brasil;

Em relação a trabalhos e perspectivas futuras, que podem ser explorados a partir do desenvolvimento desta Tese, podem ser consideradas:

- extensão dos algoritmos da família RL-NFH para trabalhar com duas variáveis de saída;
- criação de mecanismo padronizado genérico de comunicação entre os agentes, através de mensagens e/ou *blackboards*;
- utilização do modelo em outras aplicações multi-agente, como jogos robóticos, controles de navegação, sistemas de negociação e *trading*, gerenciamento de recursos, etc.;
- estender o modelo para explorar as propriedades de escalabilidade e contingência dos SMA, através da introdução e exclusão automática de novos agentes sempre que houver aumento/redução de demanda ou falha nos agentes do sistema; e
- desenvolver aplicações SMA com agentes heterogêneos. Ou seja, agentes utilizando diferentes mecanismos de aprendizagem.