

Un resumen de experiencias y el estado de avance en el uso de agentes y sistemas multiagente

Marcelo Luis Errecalde Guillermo Aguirre Alfredo Muchut
Fernando González Diego Devia Cristina Sáez

LIDIC *

Departamento de Informática
Universidad Nacional de San Luis(UNSL)
Ejército de los Andes 950 - Local 106
5700 - San Luis. Argentina

e-mail:{merreca,gaguirre,amuchut,dhdevia,csaez}@unsl.edu.ar

Tel. (02652)-424938. Int. 259

Resumen

Este trabajo describe el estado actual de las tareas de investigación realizadas en la línea de *Agentes y Sistemas Multiagente* del Laboratorio de Investigación y Desarrollo en Inteligencia Computacional (LIDIC) de la Universidad Nacional de San Luis. Esta línea de investigación está centrada en el estudio y desarrollo de sistemas basados en el concepto de *agente*. Los agentes autónomos y los sistemas multiagente consitituyen una forma relativamente nueva de analizar, diseñar e implementar sistemas de software complejos [5]. Existen hoy en día una gran variedad de aplicaciones fundamentadas en la visión basada en agentes. Las dominios de aplicación incluyen, entre otros, a sistemas de filtrados de e-mail, controladores de tráfico aéreo, bibliotecas digitales, sistemas automáticos de planificación de encuentros, robots móviles, etc. El área de agentes y sistemas multiagentes ha sido escenario de un intenso debate sobre la conveniencia del uso de distintos tipos de arquitecturas para la construcción de agentes inteligentes. La experiencia ha demostrado que a excepción de ciertos dominios particulares, en la mayoría de los problemas ningún enfoque *puro* es el más apropiado. Esto ha llevado a un creciente interés en arquitecturas híbridas que incorporan los mejores aspectos de los distintos enfoques. En base a las consideraciones previas, en nuestro grupo de trabajo hemos estudiado y aplicado distintos enfoques para la construcción de agentes inteligentes, sin adherir taxativamente a ninguno en particular. Estos estudios han abarcado agentes que aprenden a partir de refuerzos, agentes que toman sus decisiones utilizando conceptos de votación, robots con controladores basados en lógica difusa, etc. En general se ha puesto un énfasis especial en dotar a los agentes con capacidades de adaptación y aprendizaje. En este trabajo presentamos una breve síntesis de nuestras experiencias en el desarrollo de agentes artificiales y del estado de avance en este área.

Palabras Claves: Agentes Inteligentes, Sistemas Multiagente, Aprendizaje de Máquina.

*El laboratorio es dirigido por el Dr. Raúl Gallard y subvencionado por la UNSL y la ANPCYT (Agencia Nacional para la Promoción de la Ciencia y la Tecnología)

1. Introducción

Existen actualmente una gran variedad de enfoques para la construcción de agentes artificiales. Las propuestas en este sentido, abarcan desde sistemas con agentes reflejos muy elementales, que reaccionan directamente en base a su información perceptual a agentes complejos de alto nivel con modelos simbólicos del mundo y capacidades de razonamiento lógico. Las capacidades de comunicación entre agentes también varían desde la propagación de señales físicas en el ambiente hasta el intercambio de mensajes en lenguajes de comunicación de alto nivel.

Si bien estas diferencias han sustentado un intenso debate sobre las ventajas y limitaciones de cada enfoque, existe actualmente un reconocimiento mayoritario de que ningún enfoque puro resulta adecuado para atacar todos los problemas. Es así que comienzan a recibir un creciente interés distintos enfoques *híbridos* que tratan de capturar las mejores características de las distintas propuestas para la construcción de agentes.

Adhiriendo a esta línea de pensamiento, en nuestro grupo de investigación hemos estudiado y desarrollado agentes artificiales utilizando distintas técnicas. Estos estudios han abarcado agentes que aprenden a partir de refuerzos, agentes que toman sus decisiones en base a conceptos de votación, robots con controladores basados en lógica difusa, etc. Nuestra intención es estudiar y detectar las principales ventajas y falencias de cada uno de ellos. Consideramos que es a partir de un cabal entendimiento de estos factores, que será posible una mejor integración de los distintos enfoques para su aplicación a un espectro de problemas más amplio. En este sentido, nuestros esfuerzos han estado orientados a extender distintas técnicas para el desarrollo de agentes con conceptos y soluciones surgidos de otros enfoques. Por otra parte, en aquellos casos en que resultó conveniente, se ha enfatizado la aplicación de técnicas de aprendizaje para proveer a los agentes con capacidades adaptativas.

El resto del trabajo describe algunas de las principales áreas en que hemos aplicado los conceptos de agentes y sistemas multiagente en nuestro grupo de investigación, con el estado de avance hasta la fecha.

2. Aprendizaje por Refuerzo

El área del Aprendizaje por Refuerzo (AR) ha sido la temática que mayor atención ha recibido desde los orígenes de la línea de investigación. Algunos de los trabajos realizados con este enfoque incluyen el análisis comparativo de distintas técnicas de AR [2], paralelismo en AR [6, 7], AR en ambientes no estacionarios [4], aplicación de técnicas de AR en agentes con sistemas clasificadores [3] y marcos teóricos del AR multiagente [1].

El AR se basa en la idea central del aprendizaje *por prueba y error* [10], un concepto originalmente analizado en estudios relacionados con el comportamiento animal. El AR asume la existencia de un agente que es recompensado o penalizado cuando realiza sus acciones. En base a estos refuerzos el agente aprende una política de control que busca maximizar la suma de los refuerzos que obtiene a lo largo del tiempo. Dentro de este tipo de aprendizaje no se asume ningún conocimiento previo del agente sobre el ambiente o la tarea a resolver. Estas características llevaron a que muchos investigadores plantearan al AR como una solución general para aquellos dominios desconocidos o poco entendidos para el diseñador de un agente artificial.

Más allá de la simplicidad de este tipo de aprendizaje, existen algunas limitaciones para la aplicación directa del AR en dominios complejos del mundo real. La falta de conocimiento previo del ambiente, produce que en los primeros episodios del aprendizaje el agente pueda derivar en

una caminata random en el espacio de estados principalmente cuando recibe los refuerzos en forma demorada. Por otra parte, dado que la información que recibe el agente por sus acciones está centralizada en la señal de refuerzo, esta señal se torna cada vez más compleja en la medida que aumenta la complejidad del problema a resolver.

A nuestro criterio, no es realista pensar que todos los ambientes en que se desempeñará el agente deban ser completamente desconocidos ni que un agente deba aprender exclusivamente a partir de una señal de refuerzo numérica. En este sentido, se ha desarrollado un modelo para el aprendizaje basado en múltiples fuentes de experiencia que permite que un agente pueda aprender no sólo a partir de refuerzos sino también de diversa información disponible durante su ciclo de vida. Este modelo de aprendizaje ha permitido conceptualizar distintos esquemas de exploración utilizados en AR como casos particulares del aprendizaje basado en múltiples fuentes de experiencia. También se han propuesto nuevas formas de exploración permitiendo en uno de los casos, solucionar falencias exhibidas por la exploración de Boltzmann. Por otra parte, estamos trabajando en integrar conceptos de *leyes sociales* [9] en el contexto del aprendizaje por refuerzo multiagente.

3. Agentes y lenguajes de comunicación de agentes

Es indudable que siempre que es posible, la comunicación entre agentes es una herramienta invaluable o incluso indispensable dentro de los sistemas multiagentes. Existen enfoques donde agentes reactivos se comunican entre sí mediante la propagación de señales o rastros dejados en el ambiente. En otros enfoques, agentes de alto nivel se comunican utilizando lenguajes sofisticados de comunicación basados en la teoría de *speech acts*. En nuestro grupo de trabajo hemos estudiado el uso de agentes de software que se comunican utilizando el último enfoque. El lenguaje de comunicación de agentes utilizado fue ACL-FIPA97. La plataforma utilizada para el desarrollo del sistema multiagente fue JADE (Java Agent DEvelopment Framework) el cual provee un marco de trabajo para el desarrollo de agentes que se comunican en base a este standard. Hasta el momento se han desarrollado dos aplicaciones con esta plataforma, las cuales se describen a continuación.

3.1. Sistema multiagente para la administración de links en una LAN

El objetivo con este trabajo fue construir un sistema multiagente que facilite al usuario la tarea de navegar en Internet haciéndole disponible un conjunto unificado de sitios preferidos en un entorno LAN. Dicha tarea es considerada teniendo en cuenta si el trabajo es realizado por un solo usuario o un grupo de usuarios.

Es habitual que los usuarios de diversos navegadores de Internet encuentren que el archivo que contiene los links a sus sitios preferidos se encuentra en una estación de trabajo, que no es la que están usando. Si bien los navegadores permiten especificar el camino a un archivo de favoritos específico, esto requiere realizar varias acciones por lo que normalmente no se hace.

El sistema multiagente desarrollado detecta las modificaciones al archivo de favoritos local en forma automática y difunde la novedad a los otros agentes para que actualicen los correspondientes archivos de favoritos en las restantes estaciones de trabajo. El sistema multiagente permitió mantener la consistencia de la información que un usuario mantiene en las distintas estaciones de trabajo cuando utiliza un navegador particular. En una segunda etapa, el trabajo se extendió para soportar la búsqueda colaborativa de información realizada por un grupo de usuarios.

Cuando se considera la forma habitual de trabajo de un grupo de usuarios que navegan en Internet para investigar sobre una misma temática, se detectan algunas ineficiencias. Es muy posible que varios miembros del grupo recorran los mismos sitios. También está el problema de transmitir a los otros un URL, ya que generalmente se cometen errores al leer o escribir las direcciones. Nuestro sistema multiagente brindó ayuda en estos casos permitiendo que el grupo de usuarios comparta un único archivo de favoritos. Esto se logró organizando el sistema multiagente de acuerdo a lo que se conoce como *sistemas blackboard*. Los sistemas tipo blackboard están caracterizados por contar con una estructura de datos central llamada blackboard, que está generalmente dividida en regiones o niveles. Existe además una colección de procesos independientes, denominados fuentes de conocimiento, que pueden leer y escribir sobre distintos niveles, bajo la supervisión de un *sistema de control* que administra la utilización de los recursos.

3.2. Sistema multiagente para la administración de aulas de la universidad

Este dominio es interesante por varias razones. En primer lugar, es intuitivamente natural utilizar un sistema multiagente para este problema, con agentes que representan los intereses de las cátedras (o profesores) y un agente encargado del aulero. Si bien la interacción aislada entre una cátedra particular y el administrador del aulero no reviste gran complejidad, la situación se torna problemática cuando el aulero debe atender a múltiples requerimientos en forma simultánea y mantener consistente la información general sobre las aulas. Por otra parte, los agentes representantes de las cátedras deberán tomar decisiones sobre distintas alternativas que se le presentan en cuanto a los horarios de clases, ubicación de las aulas, equipamiento de las aulas, etc. En este caso, los agentes deberán balancear las distintas preferencias de los usuarios que representan y deberán contar con mecanismos que permitan resolver estos conflictos.

Un mecanismo interesante para atacar éste último problema, lo constituyen los esquemas de votación, los que además de tener una semántica bien definida, exhiben ciertas garantías formales en cuanto a los resultados obtenidos [8]. En nuestro caso, las decisiones de los agentes que representan a las cátedras fueron realizadas en base al protocolo conocido como *regla de Black* la cual ha demostrado satisfacer varias características deseables para el resultado de una elección social. Este protocolo obtiene el ganador Condorcet entre una serie de alternativas y en caso de no existir un ganador utiliza el protocolo de *cuenta de Borda*.

El sistema permite que las cátedras puedan reservar sus aulas mediante una interfase gráfica o deleguen esta responsabilidad en un agente que toma las preferencias de la cátedra de un archivo y elige las aulas en forma automática en base a este esquema de votación. Si bien actualmente las preferencias de usuario deben ser ingresadas *a mano* por cada una de las cátedras, futuras extensiones de este sistema prevén la posibilidad de que estas preferencias sean aprendidas on-line a partir de la observación del comportamiento de las cátedras a la hora de elegir sus aulas.

4. Aprendizaje en agentes robots

Recientemente hemos comenzado con la aplicación de técnicas de control basadas en lógica difusa y redes neuronales para la navegación de robots móviles. El principal problema que hemos atacado en este caso, es el que se presenta cuando los sensores del robot no permiten hacer distinciones útiles entre estados diferentes del ambiente. Este problema, conocido como *aliasing*

perceptual es uno de los principales problemas que un robot debe enfrentar cuando sólo cuenta con información sensorial de bajo nivel.

Para los estudios hemos utilizado el simulador de un robot Khepera con 8 sensores de proximidad y de distancia y dos motores para sus ruedas laterales. Los estudios se han restringido a la definición de un controlador difuso aumentado con reglas de contexto, el cual fué utilizado para entrenar una red neuronal multicapa. Se han realizado comparaciones de los comportamientos logrados con ambos controladores para medir el grado en que la red neuronal pueda replicar el comportamiento del controlador difuso en la presencia del problema de aliasing perceptual. El trabajo futuro está orientado a que este proceso se realice en forma simultánea y on-line, utilizando un enfoque evolutivo para obtener las reglas difusas y que las mismas sirvan como un *teacher* para la red neuronal que controla el robot.

Referencias

- [1] Marcelo Errecalde. Marcos teóricos del aprendizaje por refuerzo multiagente. In *Proceedings del Workshop de Investigadores en Ciencias de la Computación 2001 - WICC 2001*, pages 77–79, San Luis, Argentina, 2001.
- [2] Marcelo Errecalde, Maria Liz Crespo, and Cecilia Montoya. Aprendizaje por refuerzo: Un estudio comparativo de sus principales métodos. In *Proceedings del Segundo Encuentro Nacional de Computación*, México, 1999.
- [3] Marcelo Errecalde, Ana Garis, and Guillermo Leguizamón. SARSA_BB: Un algoritmo *on policy* para Sistemas Clasificadores. In *Proceedings del VIII Congreso Argentino de Ciencias de la Computación 2002 - CACIC 2002*, pages 389–400, Buenos Aires, Argentina, 2002.
- [4] Marcelo Errecalde and Alfredo Muchut. Exploración dirigida por el objetivo en aprendizaje por refuerzo basado en modelo para ambientes no estacionarios. In *Proceedings del Congreso Argentino de Ciencias de la Computación 2001 - CACIC 2001*, pages 1117–1129, El Calafate, Argentina, 2001.
- [5] Nicholas R. Jennings, Katya Sycara, and Michael Wooldridge. A roadmap of agent research and development. *Autonomous Agents and Multi-Agent Systems*, 1:7–38, 1998.
- [6] Marcela Printista, Marcelo Errecalde, and Cecilia Montoya. Una implementación paralela del algoritmo de q-learning basada en un esquema de comunicación con caché. In *Proceedings del Congreso Argentino de Ciencias de la Computación 2000 - CACIC 2000*, Ushuaia, Argentina, 2000.
- [7] Marcela Printista, Marcelo Errecalde, and Cecilia Montoya. A parallel implementation of Q-learning based on communication with cache. *Journal of Computer Science and Technology, Special issue on Research in Computer Science*, 2(6):43–53, May 2002.
- [8] Tuomas W. Sandholm. Distributed rational decision making. In Gerhard Weiss, editor, *Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence*, chapter 5, pages 201–258. The MIT Press, 1999.
- [9] Yoav Shoham and Moshe Tennenholtz. On social laws for artificial agent societies: Off-line design. *Artificial Intelligence*, 1993.
- [10] Richard S. Sutton and Andrew G. Barto. *Reinforcement learning: an introduction*. The MIT Press, 1998.