

Javier Béjar, Ulises Cortés, Miquel Sànchez-Marrè

Secció d'Intel·ligència Artificial. Dept. de Llenguatges i Sistemes Informàtics. Universitat Politècnica de Catalunya.

{bejar,ia,miquel}@lsi.upc.es

## 1. Introducción

Actualmente la mayor de las distinciones que se pueden trazar entre un humano y un mecanismo de resolución de problemas es que los humanos son capaces de mejorar su actuación en un amplio conjunto de tareas como resultado de haber "solucionado" un problema y aplicar ese conocimiento a la solución de problemas semejantes. El aprendizaje puede considerarse como una de las características más "apreciables" en un sistema inteligente.

Se asume de forma común que un agente autónomo debe tener la capacidad de realizar, si es posible, una misma tarea de varias maneras dependiendo de las circunstancias. El sistema debe ser capaz de tomar decisiones sobre cuál es el curso más apropiado que debe seguir la resolución de un problema y modificar estas decisiones cuando las condiciones así lo requieran. Por esto, uno de los objetivos centrales de la Inteligencia Artificial es construir sistemas que sean capaces de adaptarse, dinámicamente y sin un entrenamiento previo, a situaciones nuevas y aprender como resultado de resolver el problema (o problemas) que estas situaciones presentan.

El aprendizaje automático, también llamado **aprendizaje artificial**, es un área de interés que ha aunado a una gran cantidad de investigadores en inteligencia artificial, dado el carácter versátil y adaptativo que es capaz de introducir en cualquier programa. Este área surge inspirada en otras áreas afines como la biología [gene], la psicología cognitiva [Smith81] y la filosofía que han estado ininteresados desde sus comienzos en investigar la naturaleza de la habilidad de aprender referida tanto al hombre como a sistemas biológicos en general.

Pese a los avances conseguidos, comprender el aprendizaje natural (sobre todo si se trata de aprendizaje humano) de manera suficiente que permita reproducir aspectos de dicha conducta utilizando un ordenador, es una meta muy ambiciosa. Aún cuando algunos investigadores se han restringido explorando la posibilidad de utilizar como modelo otros seres vivos, los resultados todavía son insuficientes. Dadas estas perspectivas, el área de aprendizaje automático no solo incluirá la búsqueda de modelos automáticos del aprendizaje natural sino también todo mecanismo que permita ser calificado como aprendizaje, en el sentido de aumento de capacidades.

El término aprendizaje abarca un área muy amplia, denota la forma, o formas, en la cual una entidad (natural o artificial)

## Aprendizaje Automático

aumenta su conocimiento y mejora sus capacidades de actuación en un entorno. De esta manera el proceso de aprendizaje puede ser visto como un generador de cambios en el sistema que aprende, que por otra parte ocurren lentamente, adaptativamente, y que pueden ser revocados o ampliados. Estos cambios se refieren no sólo a la mejora de las capacidades y habilidades para realizar tareas sino que también pueden implicar modificaciones en la representación de hechos conocidos y de las propias creencias que posee el sistema.

A través de los años, los temas de investigación ha ido variando en intensidad y empleando diferentes aproximaciones con énfasis en diferentes metas, pero con un objetivo común: desarrollar sistemas capaces de mejorar su funcionamiento sin que el constructor tuviera que modificarlos, es decir que aprendieran.

En este contexto, se dice que **un sistema que aprende** (o **Aprendiz**) es un programa (o un conjunto de algoritmos) que para resolver problemas toma decisiones basadas en la experiencia acumulada, para mejorar su actuación. Esta experiencia la ha podido adquirir de diferentes maneras, ya sea viendo ejemplos de resoluciones, o sacando conclusiones de resoluciones que haga el mismo sistema, o experimentando con el entorno y observando sus efectos, etc.

Para permitir que estos sistemas sean capaces de trabajar en entornos reales se ha de incluir como problemas a resolver la capacidad de tratar un rango muy amplio de tipos de datos de entrada, que pueden incluir datos incompletos, inciertos, ruido, inconsistencias, etc.

Así pues, el problema al que se enfrentan los investigadores en el área de aprendizaje automático incluye un amplio abanico de temas que han de confluir hacia una caracterización de como un sistema artificial debe mejorar las capacidades que ya tiene para resolver problemas de una manera mas efectiva, problemas en los que el constructor del sistema no tiene por que haber previsto.

Dos enfoques diferentes han dividido el área de aprendizaje automático dependiendo de las suposiciones sobre el tipo de conocimiento del que se ha de partir en el proceso de aprendizaje, perspectivas que no son incompatibles y que tienden a colaborar.

Una primera perspectiva es la que considera que el aprendizaje se puede iniciar a partir de la adquisición de conjuntos de ejemplos seleccionados por un "profesor" que correspon-

den a uno o más conceptos que se pretenden aprender. Podríamos decir que este tipo de aprendizaje parte de un nivel de abstracción de conocimiento "bajo".

En principio no se supone que deba haber ningún conocimiento adicional para apoyar el proceso de aprendizaje, y el objetivo es conseguir una representación del concepto objetivo de manera que se predigan correctamente los ejemplos presentados y también los que se puedan presentar en el futuro.

La diferencia entre las líneas de investigación que siguen esta filosofía radica en que formalismo de representación es el más adecuado para realizar el proceso de aprendizaje y como conseguir encontrar cual de los posiblemente infinitos conceptos que ese formalismo puede representar es el que estamos buscando. Las respuestas a estas preguntas han sido inspiradas desde ámbitos muy diferentes.

Una segunda perspectiva consiste en partir de una representación del problema a un nivel de abstracción más alto, aprovechando todo el conocimiento sobre el dominio que se pueda conseguir. En este caso el número de ejemplos del concepto a aprender disminuye drásticamente bastando incluso un único ejemplo. En este caso el objetivo es aprender una descripción del concepto objetivo que sea consistente con el conocimiento que se posee.

También son múltiples las respuestas a como realizar un aprendizaje de este tipo, pues la forma de tratar y representar ese conocimiento de base puede favorecer el aprendizaje de diferentes capacidades.

Antes de comentar las diferentes líneas de investigación que pretenden responder a todas estas preguntas es adecuado ver como han ido surgiendo a lo largo de la historia del área.

## 2. Reseña histórica

Una forma de comprender porque han surgido todas las áreas que se preocupan del aprendizaje automático es echar un vistazo a la evolución histórica que ha seguido.

### 2.1. Entusiasmo inicial (1955 - 1965)

La idea de crear sistemas capaces de aprender aparece en los primeros momentos de la inteligencia artificial. En este momento el área se nutre de los primeros desarrollos en algoritmos de resolución de problemas y búsqueda. Podemos citar como líneas principales: Aprendizaje sin conocimiento de respaldo, *Neural Modeling* y Aprendizaje evolutivo.

Entre los hitos más significativos de este período se hallan los perceptrones [Minsky67,percep], las nociones de autoorganización, autoestabilización y el cotejamiento de patrones como herramientas básicas en los procesos de aprendizaje. Los sistemas desarrollados en esta época se caracterizan por la falta, casi absoluta, de conocimiento de respaldo o conocimiento inicial. Los pobres resultados que se obtuvieron respecto a las expectativas despertadas hicieron que muchas de estas líneas sufrieran casi un abandono total. Este estancamiento se hace más patente aún en el área de apren-

dizaje no simbólico, al descubrirse las grandes limitaciones de los modelos que se habían propuesto hasta la fecha.

### 2.2. Etapa oscura (1965 - 1976)

En la segunda época los problemas estudiados se trasladaron esencialmente a la obtención de esquemas de representación con el fin de asegurar la correcta adquisición de nuevos conocimientos (*i.e.* saber cuales son los elementos de conocimiento tras un proceso de aprendizaje). Asociado a esta tendencia se diseñaron nuevas estructuras de representación del conocimiento que permitían la descripción de estructuras jerárquicas, para organizar los conceptos que poseía un sistema. Durante toda esta época cobró gran fuerza el uso de representaciones basadas en la lógica como contraste a las representaciones no simbólicas de la época anterior. A esta época corresponden los trabajos pioneros de Winston [Wi2] que plantea por primera vez el aprendizaje de estructuras simbólicas a partir de un conjunto de ejemplos positivos y de cuasiejemplos (ejemplos negativos con una diferencia mínima con los ejemplos positivos). La mayor parte de los sistemas de aprendizaje simbólico estarán en mayor o menor medida influenciados por este trabajo.

### 2.3. Renacimiento (1976 - 1986)

En este periodo, muy activo, se desarrollan los diferentes campos de investigación que perduran en la actualidad, apareciendo muchas perspectivas nuevas. De estas podemos destacar, dentro del aprendizaje simbólico, la generación de reglas a partir ejemplos, área donde aparece el sistema **ID3** [Quinlan83], que aun perdura como paradigma de sistema de generación de reglas [Quinlan93].

Como aproximación a las teorías desarrolladas en Psicología Cognitiva sobre la formación de los conceptos en el aprendizaje humano [Smith81] aparece todo un área de aprendizaje simbólico que no asume que haga falta un maestro que indique que es lo que hay que aprender (aprendizaje simbólico no supervisado), de este área se puede destacar el sistema **COBWEB** [Fisher91], que ya empieza a incluir representaciones no basadas en la lógica en el aprendizaje simbólico.

Como aproximaciones basadas en la lógica aparecen los modelos que se integran en arquitecturas de resolución de problemas que buscan el descubrimiento de reglas de control que mejoren la eficiencia de esos sistemas [Mitchell83].

En esta época empieza a resurgir con fuerza el aprendizaje no simbólico, encontrándose nuevos modelos en aprendizaje neuronal [Kohonen84] que disipan las dudas sobre su potencia y que permitiran una explosión de aplicaciones en la siguiente época. También surgen los modelos inspirados en la selección natural y en la genética que empiezan a ser aplicados al área del aprendizaje despues de comprobar su eficacia en otros áreas como la búsqueda o la optimización [Holland75].

Como estudio teórico de la capacidad y posibilidad de los algoritmos de aprendizaje, surge el área denominada *aprendizabilidad valiant*, que intenta dar un fundamento teórico al área, que practicamente en su totalidad se habia basado en estudios empíricos.

## 2.4. Desarrollo (1986 - Actualidad)

En la actualidad todos los modelos aparecidos tienen un gran número de líneas de trabajo, tanto aplicada como de investigación básica. No ha aparecido ningún modelo que se demuestre netamente superior en global, por lo que ahora se está apostando por enfoques híbridos en los que se intenta aunar las mejores cualidades de diferentes métodos.

Cabe destacar el despegue definitivo de los métodos no simbólicos [Hecht90,Goldberg89] en los que han aparecido múltiples aplicaciones. Una influencia también destacada en el área ha tenido el desarrollo del área de agentes [Maes91], que ha permitido llevar a la práctica muchas de las investigaciones que se están desarrollando.

Las áreas de investigación se han diversificado bastante, y muchas se están preocupando de encontrar aplicaciones que demuestren sus beneficios y ventajas. Así no es de extrañar que en la actualidad aparezcan líneas de trabajo muy centradas en aplicaciones inmediatas. Una enumeración no exhaustiva de las áreas con mayor esfuerzo de investigación es:

- Modelos neurales y genéticos [arbib,Brooks91,Back96]
- Modelos computacionales teóricos [Kearns94]
- Sistemas basados en agentes [Maes91]
- Aprendizaje inductivo Bayesiano [Spirtes93]
- Aproximaciones híbridas [Mooney93,Towell94]
- Programación lógica inductiva [Lavrac94]
- Algoritmos de descubrimiento de conocimiento (Data Mining) [Fayyad97]

Como centro de referencia sobre la mayoría de las áreas que se desarrollan en la actualidad en aprendizaje automático, y como método de contacto para toda la comunidad del área, se ha creado una página en el WWW mantenida por David Aha (un destacado investigador en aprendizaje simbólico inductivo) (<http://www.aic.nrl.navy.mil/~aha/research/machine-learning.html>).

## 3. Paradigmas del aprendizaje automático

Hacer una clasificación de las áreas de aprendizaje en estos momentos en que se tiende a crear aproximaciones que combinen diferentes metodologías resulta bastante artificial. No obstante se pueden dividir las diferentes áreas según la influencia que las inspiró en sus comienzos. Buenas introducciones a todas estas áreas se pueden encontrar en [Mitchell97,Langley96,Zhongzhi92].

### 3.1. Aprendizaje inductivo

Se trata del paradigma más estudiado dentro del aprendizaje automático, aunque se suele asociar únicamente a aproximaciones simbólicas, las aproximaciones no simbólicas también son inductivas. Su base es partir de un gran número de ejemplos que corresponden a uno o varios conceptos y construir una representación de estos, que permitan hacer predicciones al ver nuevos ejemplos, sin utilizar apenas otro conocimiento más que los propios ejemplos.

La debilidad de este aprendizaje es que no tiene una base exclusivamente heurística, las reglas que permiten crear

descripciones generales a partir de ejemplos no están basados en mecanismos fundamentados lógicamente. Por lo tanto, es posible que la aparición de nuevos ejemplos invalide el nuevo conocimiento que se ha generado. No obstante, la mayor del aprendizaje que realiza un ser humano es de naturaleza inductiva, es imposible disponer de todos los ejemplos posibles de un concepto para intentar definirlo.

La representación que se puede generar a partir de los ejemplos es muy variada, ello ha hecho que el número de algoritmos desarrollados sea bastante grande, dependiendo de la representación elegida. Esta puede ser en forma de jerarquía [Quinlan83], grafo [Spirtes93] o reglas en algún tipo de lógica [Quinlan93,Lavrac94].

Este área ha estado fundamentalmente guiada hacia aprendizaje en el que siempre hay un concepto objetivo conocido de antemano. No obstante, surgió una división en la que se consideró que esta restricción no tenía por que mantenerse. Esto marcó las líneas de aprendizaje supervisado (con un maestro) y no supervisado (sin maestro). El área de aprendizaje inductivo no supervisado obtuvo su apoyo en las teorías desarrolladas en Psicología cognitiva [Smith81,Fisher91]. Esto marcó el desarrollo de modelos computacionales del aprendizaje inductivo para el aprendizaje humano, aspecto bastante dejado de lado por las aproximaciones supervisadas, y el uso de conocimiento del dominio en el proceso de aprendizaje.

Actualmente, están apareciendo aplicaciones prácticas en este área encaminadas al descubrimiento de información en bases de datos [Fayyad97], como una posibilidad de aprovechar el conocimiento que se puede obtener mediante métodos inductivos fuera del entorno de la mejora de capacidades de un agente inteligente.

### 3.2. Aprendizaje analítico o deductivo

Los métodos usados en este tipo de aprendizaje intentan reformular el conocimiento que posee un sistema a base de generalizaciones a partir analizar las resoluciones obtenidas por algún mecanismo de resolución de problemas incluido en el propio sistema.

La base de este aprendizaje no es pues la generación de nuevo conocimiento, sino hacer más eficiente el que ya se posee. En estos términos se ha criticado este tipo de aprendizaje, considerando que no es aprendizaje real dado que no genera nuevo conocimiento. No obstante, si lo es en función de que permite mejorar el rendimiento del sistema que lo utiliza.

En contraste con el aprendizaje inductivo, la base del proceso será el uso de grandes cantidades de conocimiento del dominio, que asociado con ejemplos de resolución de problemas permitirán reformular el conocimiento del sistema. Estas reformulaciones darán como resultado tanto, nuevas formas de expresar el conocimiento que ya se posee en términos más sencillos, como el desarrollo de conocimiento que indique la forma más efectiva para resolver un problema, o que condiciones permiten descartar posibles formas de resolución por ser probablemente erróneas o inútiles [Mitchell83].

El mayor problema de este método de aprendizaje consiste

en decidir cuando se debe incorporar este nuevo conocimiento al sistema, ya que incluir todo lo que es posible aprender, puede hacer que las nuevas resoluciones sean menos eficientes, al tener que revisar el nuevo conocimiento adquirido.

Otro problema está en que el conocimiento del dominio que se posee no siempre es completo y consistente, por lo que a veces es necesario combinar este aprendizaje con el aprendizaje inductivo para completarlo [Mooney93].

### 3.3. Aprendizaje analógico

Este tipo de aprendizaje intenta emular algunas de las capacidades humanas más sorprendentes: poder entender una situación por su parecido con situaciones anteriores conocidas, poder crear y entender metáforas o poder resolver un problema notando su posible semejanza con problemas vistos anteriormente y adaptando de forma conveniente la solución que se encontró para esos problemas. Este tipo de sistemas requieren una gran cantidad de conocimiento previo y mecanismos para generar y explorar relaciones útiles [Carb86]. Se les puede ver como un paso más allá del aprendizaje basado en la deducción lógica.

### 3.4. Aprendizaje genético

Los algoritmos genéticos [Goldberg89] están inspirados en la reproducción biológica y en la selección natural. La metáfora de la que parten, consiste en suponer que la combinación de las características de individuos capaces de resolver bien una tarea, da como resultado individuos más capaces. Esta combinación se realiza siguiendo las pautas de la reproducción biológica (combinación de carácter y mutación espontánea). La medida de la adaptación de la combinación de soluciones a la tarea es el punto más problemático, y depende de cada problema, esta medida de adaptación se utiliza como método de selección, solo los individuos mejor adaptados sobreviven en la siguiente generación.

El problema sobre el que se han aplicado los algoritmos genéticos trata del descubrimiento de reglas mediante la combinación de pequeños elementos y la comprobación de como de eficientes son a la hora de resolver una tarea específica, en este caso el objeto del aprendizaje. Esta tarea puede ser, por ejemplo, el distinguir un conjunto de observaciones que pertenecen a un concepto de otras que no pertenecen.

La base de funcionamiento está en que la combinación de los elementos de las reglas más adecuadas convergerá al mejor conjunto de reglas posibles. Se trata pues de aprovechar las capacidades de búsqueda de los algoritmos genéticos para realizar aprendizaje [Goldberg89, Holland75].

### 4. Aprendizaje conexionista

Otra manera de concebir un sistema de aprendizaje automático es el denominado enfoque conexionista [Arbib, Brooks91, Hecht90]. Este enfoque se inspira en la arquitectura del cerebro, elementos básicos interconectados entre sí que se transmiten impulsos activándose y desactivándose en función de su estado.

Por supuesto la mayoría de estos modelos son una simplificación bastante drástica del modelo real, pero con resultados bastante sorprendentes y efectivos. En esta aproximación el sistema que realiza el aprendizaje es una red de nodos interconectados, que tiene asociada una regla de propagación de valores y una serie de pesos asociados a las conexiones.

Ante un conjunto de estímulos (que puede ser un conjunto de ejemplos) el sistema reacciona modificando los pesos de las conexiones. Se dice que el sistema aprende si adapta los pesos de tal manera que le lleven a dar la salida correcta ante todas (o la mayoría) de las entradas que se le ofrezcan.

Este mecanismo de aprendizaje se ha mostrado muy efectivo en problemas de aproximación de funciones y como método del procesamiento de señales procedentes de sensores.

La mayor crítica que reciben es la dificultad de interpretación de sus resultados, ya que de los pesos que surgen del entrenamiento de una red difícilmente se puede extraer un conocimiento interpretable en función de información simbólica. No obstante se están haciendo esfuerzos considerables en esa línea.

Otras líneas de trabajo que buscan reconciliar este tipo de aprendizaje con los trabajos realizados en el aprendizaje simbólico como una manera de dotar de mayor interpretabilidad a los resultados y compensar las deficiencias de estos últimos métodos.

## 5. Conclusiones

El aprendizaje es un proceso cognitivo mediante el cual un agente adquiere conocimiento. Este puede ser entendido como una tarea orientada a la creación y mantenimiento de un modelo interno del mundo. En general, esta tarea tiene dimensiones gigantescas pero, afortunadamente, existen variantes muy simples que pueden ser estudiadas sin perder generalidad.

La labor del aprendizaje automático ha de ir en ambas líneas, crear por un lado modelos computacionales de los mecanismos naturales del aprendizaje como un método para poder comprenderlos mejor, y por otro, crear algoritmos que basados en diferentes visiones del aprendizaje permitan introducir esta característica dentro de sistemas para asmejorar su funcionamiento.

La respuesta a preguntas como, de que forma se ha de realizar el aprendizaje, cual es el método de representación más adecuado, que papel juega el conocimiento sobre el dominio del problema, cuales son los ejemplos más adecuados para aprender cierto concepto, etc. no es única.

La experiencia desarrollada durante todo el tiempo que se lleva trabajando en este área, ha demostrado que no existe una solución general, y que todas las soluciones aportadas tienen algunas ventajas sobre las otras, pero también tienen sus propias deficiencias. Un enfoque que integre y combine lo mejor de cada área de trabajo será un tema que tendrá un fuerte desarrollo en el futuro.

Los múltiples temas de trabajo y los diferentes paradigmas que han aparecido han contribuido a una amplia diversidad de investigaciones que ha sido muy enriquecedora, y ha dado como fruto muchos sistemas que han resultado muy efectivos. La relativa juventud de este área hace pensar que en el futuro estos resultados serán mayores.

## 6. Bibliografía

- [**arbib**] **Arbib, M.:** Neural computing perspective, *Applied Artificial Intelligence* 5. 1991.
- [**Back96**] **Back, T.:** *Evolutionary algorithms in theory and practice.* Oxford University Press. 1996.
- [**Beer90**] **Beer, R.D.:** *Intelligence as Adaptive Behavior, Perspectives in Artificial Intelligence.* Academic Press. 1990.
- [**Brooks91**] **Brooks R.A. (1991):** Intelligence without representation, *Artificial Intelligence* 47, pags. 139- 159, Elsevier. 1991.
- [**carb86**] **Carbonell, J.:** Analogy in Problem solving. En *Machine Learning: An artificial Intelligence Approach.* Morgan-Kaufmann. 1986.
- [**gene**] **Dawkins, R.:** *The selfish gene,* Oxford University Press. 2ª edición. 1989.
- [**Fayyad97**] **Fayyad, U. M., Piatetski-Shapiro, G., Smyth, P., Uthurusamy, R.:** Advances in Knowledge Discovery and Data Mining, *The MIT Press.* 1996.
- [**Fisher91**] **Fisher, D.H., Pazzani, M.J. & Langley, P.:** *Concept formation: knowledge and experience in unsupervised learning.* Morgan Kaufmann. 1991.
- [**Goldberg89**] **Goldberg, D.:** *Genetic Algorithms in search, optimization and machine learning.* Addison-Wesley. 1989.
- [**Hecht90**] **Hecht-Nielsen, R.:** *Neurocomputing.* Addison-Wesley. 1990.
- [**Holland75**] **Holland, J. H.:** *Adaptation in Natural and Artificial Systems,* University of Michigan Press, 1975.
- [**Kearns94**] **Kearns, M. J., Vazirani, U. V.:** An introduction to computational learning. *MIT Press.* 1994.
- [**Kohonen84**] **Kohonen, T.:** *Self-organization and asociative memory.* Springer-Verlag. 1984.
- [**Langley96**] **Langley, P.:** *Elements of Machine Learning,* Morgan Kaufmann. 1996.
- [**Lavrac94**] **Lavrac, N., Dzeroski, S.:** *Inductive logic programming: Techniques and applications.* Ellis Horwood. 1994.
- [**luger**] **Luger, G.F., Stubblefield, W.A.:** *Artificial Intelligence. Structures and strategies for complex problem solving.* Addison-Wesley, 1997.
- [**Maes91**] **Maes P.:** Designing Autonomous Agents. Ed. P.Maes, *The MIT Press* (1991).
- [**Minsky67**] **Minsky, M.:** *Computation. Finite and Infinite Machines.* Prentice-Hall. 1967.
- [**percep**] **Minsky, M. & Papert, S.:** Perceptrons: An Introduction to Computational Geometry. *MIT Press,* 1969.
- [**Minsky85**] **Minsky, M.:** *The Society of Mind.* Simon & Schuster, New York. (1985)
- [**Mitchell83**] **Mitchell, T. M.:** Learning and problem-solving. *Proceedings de la 8ª International Joint Conference on Artificial Intelligence.* Morgan Kaufmann. 1983.
- [**Mitchell97**] **Mitchell, T. M.:** *Machine Learning.* McGraw Hill. 1997.
- [**Mooney93**] **Mooney, R.:** Induction over the unexplained: Using overly-general domains theories to aid concept learning. *Machine Learning* 10(1). 1993.
- [**Newe82**] **Newell, A.:** The Knowledge Level. *Artificial Intelligence,* 18, pp-87-127, 1982.
- [**Newell90**] **Newell A. (1990):** Unified Theories of Cognition. Harvard University Press.
- [**Pearl88**] **Pearl, J.:** *Probabilistic reasoning in intelligent systems: Networks of plausible inference.* Morgan Kaufmann. 1988.
- [**Quinlan83**] **Quinlan, J. R.:** *Learning efficient classification procedures and their application to chess end games. Machine learning: An AI approach.* Morgan Kaufmann. 1983.
- [**Quinlan93**] **Quinlan, J.R.:** *C4.5: Programs for Machine Learning.* Morgan-Kaufmann. 1993.
- [**Smith81**] **Smith, E. E., Medin, D.:** *Categories and Concepts.* Harvard University Press. 1981.
- [**Spirtes93**] **Spirtes, P., Glymour, C., Scheines, R.:** *Causation, prediction and search.* Springer Verlag. 1993.
- [**Towell94**] **Towell, G., Shavlik, J.:** Knowledge-Based artificial neural networks. *Artificial Intelligence,* 70 (1-2) 119-165. 1994.
- [**valiant**] **Valiant, L.:** A theory of the learnable. *Communications of the ACM,* 27(11). 1984.
- [**Wi2**] **Winston, P.H.:** Learning new principles from precedents and exercises, *Artificial Intelligence* 19, pp. 321-350, 1982.
- [**Zhongzhi92**] **Zhongzhi, S.:** *Principles of Machine Learning,* International Academic Publishers, 1992.