

# APRENDIZAJE INCREMENTAL A PARTIR DE EJEMPLOS EN UN CONTEXTO RUIDOSO DE RESOLUCIÓN DE PROBLEMAS

Eugenio Alberdi\*  
LBEIN, Grupo IDEIA  
Cuesta de Olabeaga 16  
48013 Bilbao  
Email: eugenio@labein.es

Tel: (94) 441 93 00

Helena Matute  
Dpto. de Psicología Básica  
Universidad de Deusto  
Apartado 1  
48080 Bilbao

Tel: (94) 445 31 00

**Palabras clave:** Aprendizaje a partir de ejemplos, Condicionamiento, Asignación de pesos, Incrementalidad, Ruido Aleatorio, "Concept drift", Juegos.

## RESUMEN

En el presente artículo se exponen los resultados de un experimento en que se exploran algunos aspectos relevantes de la adquisición inductiva de conceptos en entornos reactivos de resolución de problemas. Se propone un algoritmo de aprendizaje, IKASLE, que combina el procesamiento simbólico característico de los sistemas de aprendizaje a partir de ejemplos con mecanismos de asignación de pesos inspirados en teorías psicológicas asociativas. De esta forma se pretenden simular algunas de las propiedades adaptativas bien estudiadas en procesos más elementales del aprendizaje humano y animal. IKASLE ha sido evaluado en el dominio del juego del *mus* donde es capaz de adquirir incrementalmente conceptos útiles para sus decisiones de apuesta a partir de datos con altos niveles de ruido aleatorio.

## ABSTRACT

This paper describes the results of an experiment in which relevant aspects of inductive concept acquisition are explored in reactive problem solving environments. A learning algorithm is proposed, IKASLE, which combines the characteristic symbolic processing of learning from examples systems with weighting mechanisms inspired in psychological associative theories. This way IKASLE tries to simulate some adaptive abilities long tested in more elementary processes of human and animal learning. The system has been evaluated in the domain of *mus*, a cards game similar to poker, where it is capable of incrementally acquiring useful concepts for its betting decisions from data with high levels of random noise.

\* Nueva dirección a partir de Octubre de 1991:

Department of Computing Science, University of Aberdeen, King's College, Old Aberdeen, AB9 2UB, Escocia (Reino Unido).

## PUBLICADO EN:

"Actas del IV Congreso de la Asociación Española para la Inteligencia Artificial (AEPIA-91)".  
Madrid, AEPIA, 1991 (p. 273-283)

## 1.- INTRODUCCIÓN

A diferencia de los sistemas que adquieren conceptos de forma aislada (a menudo meros clasificadores), los sistemas de aprendizaje que cooperan con un *problem solver* no cuentan con un tutor benévolo que les provea de los ejemplos de entrenamiento necesarios y debidamente etiquetados como positivos y negativos. Cuando se aprende a partir de la experiencia, las situaciones en las que habrá de basarse el entrenamiento del módulo de aprendizaje vendrán dadas por el *feedback* recibido del medio en función de la ejecución del sistema y la mayor o menor corrección de las soluciones aportadas en cada caso.

La simbiosis con el sistema que toma las decisiones se completa al aportar el programa aprendiz un conocimiento que será de utilidad a la hora de optimizar el comportamiento de aquél en términos de velocidad y calidad, o bien de evitar errores cometidos con anterioridad.

En unas condiciones de aprendizaje mínimamente realistas, se dan situaciones de información imperfecta y mal delimitada, ruido y variabilidad que imponen la necesidad de un procesamiento provisional de los datos. La incrementalidad y la tolerancia al ruido son dos de los aspectos más importantes que se han querido potenciar en IKASLE, el algoritmo que describimos en el presente artículo, y en su implementación en un entorno interactivo de resolución de problemas, el juego del *mus*.

IKASLE (Incremental Knowledge-independent Associative and Symbolic Learning from Examples) es un algoritmo de aprendizaje a partir de ejemplos que se enmarca en la tradición simbólica de las técnicas de adquisición inductiva de conceptos que crean reglas de clasificación generalizando a partir de un conjunto de instancias positivas y negativas.

Al mismo tiempo, en IKASLE se contemplan las aportaciones de una tendencia reciente de investigación cognitiva centrada en estudiar el papel que pueden desempeñar procesos de aprendizaje más elementales a la hora de entender algunos aspectos implicados en la adquisición de conceptos (ver [Schlimmer, Granger, 86a], [Schlimmer, Granger, 86b], [Gluck, Bower, 88], [Pearce, 89]). IKASLE incorpora un mecanismo de asignación de pesos inspirado en teorías psicológicas asociativas propuestas para dar cuenta de fenómenos de condicionamiento y para explicar muchas de las propiedades adaptativas del aprendizaje. Los resultados de este enfoque psicológico han solido ser ignorados en la investigación en aprendizaje humano y raramente están contempladas en las técnicas simbólicas de aprendizaje. Sin embargo, el reciente auge del conexionismo está renovando un interés por los enfoques asociativos a la hora de tratar procesos importantes de la cognición humana que IKASLE trata de simular en un ámbito simbólico de adquisición de conceptos.

Dado que en IKASLE se da importancia a los procesos inductivos de la formación de conceptos, el algoritmo es independiente del conocimiento ("knowledge-independent"). Está guiado por los datos ("data-driven") y diseñado para aprender en situaciones de incertidumbre. En virtud de la asignación de pesos asociativos mencionada, IKASLE es capaz de realizar un aprendizaje incremental incluso en presencia de inconsistencias o ruido.

## 2.- INCREMENTALIDAD, RUIDO Y "CONCEPT DRIFT"

Como ya se ha sugerido en la introducción, la adquisición de conceptos siempre tiene lugar en un contexto de ejecución (por ejemplo, tareas de toma de decisiones o de resolución de problemas), lo cual conlleva una visión incremental del aprendizaje (ver [Iba, Wogulis, Langley, 88] y [Gennari, Langley, Fisher, 89]).

La incrementalidad ha sido tradicionalmente un aspecto problemático para las técnicas inductivas artificiales, especialmente a la hora de tratar el ruido, y la mayoría de los algoritmos desarrollados han solido ser no incrementales (ver [Schlimmer, Fisher, 86]). Sin embargo un renovado énfasis en la naturaleza progresiva del aprendizaje (véanse las versiones incrementales de algoritmos

inductivos clásicos como el ID3, [Utgoff, 89], o el AQ11, [Michalski, Mozetic, Hong, Lavrac, 86]) está motivando que se preste atención a aspectos incrementales más complejos como, por ejemplo, el "concept drift". Con esta expresión, Schlimmer y Granger [Schlimmer, Granger, 86a] hacen referencia a los cambios que sufre la definición de un concepto con el paso del tiempo. Este tipo de evolución tiene lugar, por ejemplo, en conceptos relacionados con las modas, el avance científico, etc.

Schlimmer y Granger desarrollaron un algoritmo llamado STAGGER que al igual que IKASLE posee mecanismos de asignación de pesos basados en teorías psicológicas del condicionamiento [Schlimmer, Granger, 86b]. Aunque los modelos psicológicos concretos en que se inspiran ambos algoritmos son diferentes<sup>1</sup>, tanto IKASLE como STAGGER son capaces de tolerar el ruido y el "concept drift", realizando un procesamiento incremental de los datos. No obstante, STAGGER sólo puede tratar un tipo de ruido, el que Schlimmer y Granger llaman "ruido sistemático", es decir aquellos casos en que el ruido se da sólo en las instancias positivas o se da sólo en las instancias negativas. Por el contrario, IKASLE es capaz también de aprender incrementalmente en los casos de "ruido aleatorio" ("random noise"), donde tanto los ejemplos como los contraejemplos pueden estar erróneamente clasificados.

### 3.- IKASLE Y SU IMPLEMENTACIÓN EN EL JUEGO DEL *MUS*

IKASLE ha sido implementado en el dominio del juego del *mus*. La elección de este dominio de aplicación está justificada no sólo por la larga tradición de sistemas artificiales de aprendizaje en contextos de juego ([Samuel, 63], [Waterman, 69], [Mostow, Hayes-Roth, 79], [Quinlan, 83], [Shapiro, 87]) sino especialmente por su idoneidad para evaluar muchas de las características de IKASLE.

En su implementación en el juego del *mus*, la función de IKASLE consiste en adquirir los conceptos que definen las configuraciones de cartas que son suficientemente buenas para arriesgar una apuesta.

El juego del *mus* es una tarea interactiva en la que un sujeto debe estar continuamente tomando decisiones basándose en el aprendizaje recién realizado. Como consecuencia de sus decisiones, el jugador recibe nueva evidencia que da lugar a una actualización de su conocimiento previo. Dicha evidencia, que determina la corrección de las predicciones generadas, consiste en un *feedback* inmediato pero impreciso que informa si una decisión de apuesta ha tenido éxito o no.

Dado que el *mus* es un juego de información imperfecta en el que el azar y factores psicológicos son muy importantes, las instancias recibidas por el sistema (combinaciones de cuatro cartas) son altamente ruidosas. En algunos casos, cartas reconocidas como muy buenas pueden dar lugar a pérdidas importantes al igual que bazas que un experto consideraría malas o mediocres pueden ganar una apuesta. Se puede decir, por tanto, que en el *mus* se da ruido aleatorio.

El "concept drift" se hará patente cuando la personalidad del oponente o los requisitos inmediatos del juego cambien e impongan una preferencia por configuraciones de cartas diferentes. En el *mus* no hay un concepto predefinido y fijo que represente la configuración de "cartas suficientemente buenas".

A continuación, después de describir las estrategias de aprendizaje características de IKASLE (la conservación de hipótesis antiguas, los mecanismos de asignación de pesos y la creación de una versión negativa del concepto) damos cuenta de los resultados de la implementación del algoritmo en el *mus*.

---

<sup>1</sup> STAGGER se basa en la teoría de la contingencia [Rescorla, 68]. Sin embargo, IKASLE se inspira en una adaptación que Dickinson y Shanks [Dickinson, Shanks, 85] realizaron del modelo asociacionista de Rescorla-Wagner [Rescorla, Wagner, 72]. Este modelo se propuso en su momento como una alternativa con la que se querían superar algunas de las limitaciones del modelo de contingencia (ver [Papini, Bitterman, 1990]). En la sección 3.2. se trata con más detalle el modelo de Dickinson y Shanks, implementado en IKASLE a través de sus mecanismos de asignación de pesos.

### 3.1. Conservación de Versiones Antiguas del Concepto

IKASLE caracteriza un concepto con un conjunto de hipótesis que llamaremos H. Siguiendo un criterio relativamente común los conceptos adquiridos por IKASLE estarán definidos por la disyunción de varias conjunciones que forman el conjunto de hipótesis plausibles [Mitchell, Utgoff, Banerji, 83], [Michalski, 87].

El conjunto H está constituido, a su vez, por dos subconjuntos de hipótesis:  $H_0$  y  $H_1$ .  $H_1$  representa el estado actual de conocimiento y contiene las descripciones adquiridas en la última generalización.  $H_1$  se actualizará cada vez que una de sus hipótesis no incluya a una instancia positiva. Esta hipótesis será sustituida por sus generalizaciones más específicas y será transferida a  $H_0$ .

$H_0$  se asemeja a una memoria a largo plazo en la que el sistema podrá encontrar hipótesis fiables o útiles, cuando la presencia de inconsistencias en los datos provoque un bloqueo en la ejecución del sistema e imponga un *backtracking*.

Para que el sistema pueda reconocer las descripciones más predictivas de  $H_0$  se hace necesario tener en cuenta información adicional. IKASLE obtiene esta información a través de un mecanismo de asignación de pesos. Los pesos informarán de la evidencia que apoya o contradice las diferentes descripciones y ayudará a eliminar las que no son efectivas.

### 3.2. Asignación de Pesos

En los métodos convencionales de aprendizaje inductivo (v.g., el espacio de versiones de Mitchell [Mitchell, 77]) basta que una hipótesis sea contradicha por una única instancia para que dicha hipótesis sea rechazada. Esto no puede hacerse en un dominio ruidoso; de lo contrario el sistema podría perder información valiosa contenida en descripciones que, siendo potencialmente útiles y predictivas, son inconsistentes con instancias eventualmente mal clasificadas.

Una hipótesis no se rechazará hasta que no se haya adquirido suficiente evidencia en su contra. En IKASLE esta evidencia está representada por un número real positivo, entre cero y uno, asociado a cada hipótesis. El peso o fuerza asociativa es instanciado con un valor mínimo cuando se genera la descripción y se actualiza a medida que se va adquiriendo más experiencia. El peso indicará la utilidad de cada hipótesis.

El mecanismo concreto de asignación de pesos utilizado por IKASLE implementa el modelo propuesto por Dickinson y Shanks ([Dickinson, Shanks, 85], [Shanks, Dickinson, 87]) para dar cuenta de los juicios humanos de causalidad. Este modelo es una variación del modelo de condicionamiento de Rescorla-Wagner [Rescorla, Wagner, 72], que a su vez guarda un gran parecido con la regla delta, utilizada en el ámbito de las redes neuronales.

Dickinson y Shanks estudiaron los procesos por los que la gente descubre la relación causal entre dos eventos. Asumiendo que toda relación causal tiene lugar en presencia de múltiples causas potenciales, es decir de un contexto causal, la tarea del aprendiz consistirá básicamente en discriminar la efectividad de la causa putativa a solas.

La teoría, por tanto, se formula a través de la ecuación:

$$J_a = V_{ax} - V_x \quad (1)$$

donde  $J_a$  representa la efectividad del evento A,  $V_{ax}$  la fuerza asociativa del evento A acompañado por el contexto X, y  $V_x$  representa la fuerza del contexto causal cuando A no está presente [Dickinson, Shanks, 85].

La característica más importante del modelo de Dickinson y Shanks, a efectos de su

implementación en IKASLE, es la función de adquisición que determina el incremento o decremento de las fuerzas asociativas de los eventos en función del resultado (outcome) en un ensayo de entrenamiento. Estos cambios en la fuerza asociativa se determinan a través de la ecuación:

$$\Delta V = \sigma\beta (\lambda - V) \quad (2)$$

$\Delta V$  representa los cambios en la fuerza asociativa de la posible causa,  $\sigma$  es un parámetro sobre la proporción de aprendizaje asociado a la causa putativa,  $\beta$  es un parámetro equivalente para el resultado y  $\lambda$  es la asíntota de la fuerza asociativa. Se asume que el valor asíntótico es 1 si tiene lugar el resultado y 0 en su ausencia. Por lo tanto, los incrementos y decrementos en las fuerzas asociativas estarán determinados por la ocurrencia o no ocurrencia del refuerzo. Es decir, si el refuerzo aparece la asíntota será 1 y en consecuencia el valor  $\Delta V$  será positivo. De lo contrario la asíntota será 0 y el cambio en la fuerza asociativa será negativo, causando un decremento.

Como asumimos que algunos de los aspectos del aprendizaje de conceptos se pueden explicar por mecanismos similares, hemos simulado una adaptación del modelo de Shanks y Dickinson en IKASLE. La causa putativa del resultado, que en el modelo de Dickinson y Shanks (y otras teorías asociativas) es habitualmente una respuesta o un estímulo, en IKASLE es una hipótesis o una descripción. El resultado (outcome) es el *feedback* externo que informa de la capacidad de la hipótesis de clasificar correctamente un ejemplo.

Cuando una instancia positiva es clasificada correctamente, la hipótesis gana fuerza asociativa. Si un contraejemplo resulta incorrectamente incluido por una hipótesis, la hipótesis pierde fuerza. Los ejemplos positivos no incluidos por una descripción provocan una extensión o generalización de la hipótesis.

Una descripción con una fuerza asociativa alta es una hipótesis que ha sido confirmada por muchos ejemplos y ha recibido poca evidencia negativa. Cuanto más alto sea el peso de una hipótesis mayor será su poder predictivo y mayor también su utilidad.

Cuando el peso de una descripción es inferior a un determinado umbral, la descripción (ya sea parte de  $H_0$  o de  $H_1$ ) será eliminada de  $H$ . Se asume que esta hipótesis es poco útil o de poco valor predictivo.

Los dos mecanismos comentados permiten además simular efectos de tipicidad. Los conceptos que crea IKASLE tienen una configuración jerárquica definida no sólo por los diferentes grados de generalidad-especificidad entre las hipótesis sino también por su grado de tipicidad. El hecho de que los conceptos estén definidos por varias hipótesis con distintas fuerzas asociativas permite al sistema reconocer si una instancia es más típica o menos típica de una categoría determinada.

### 3.3. El Concepto Negativo

IKASLE aprende a través de la generalización; el sistema no especializa sus hipótesis. No obstante la evidencia negativa presentada al sistema no se reflejará únicamente en los procesos inhibitorios de la asignación de pesos.

Aunque IKASLE no especializa sus hipótesis, conserva la información provista por ejemplos negativos anteriores creando una versión negativa del concepto que se aprende. La función de contemplar evidencia negativa antigua consiste en poner un límite a la generalización realizada a partir de las instancias positivas [Langley, 87]. Es sabido que los animales y los humanos poseen un mecanismo por el cual son capaces de detectar posibles inconsistencias con datos anteriores y evitar generalizaciones excesivas [Mackintosh, 83].

Simultáneamente a la creación de  $H$ , IKASLE generará  $H^-$  o "el concepto negativo".  $H^-$  estará constituido, de manera análoga a  $H$ , por un conjunto de hipótesis originadas a partir de la generalización de ejemplos negativos.  $H^-$  se adquirirá siguiendo unos pasos parecidos a los seguidos




Figura 1. Efecto de los ejemplos sobre las versiones positiva y negativa del concepto.

en la adquisición de H: una combinación de mecanismos de generalización y asignación de fuerzas asociativas. La principal diferencia reside en el hecho de que los ejemplos positivos de H se considerarán ejemplos negativos de H- y los ejemplos negativos de H, como ejemplos positivos de H- (ver Figura 1). Se puede decir que IKASLE aprende la caracterización de un concepto y, al mismo tiempo, las condiciones que representan su negación.

IKASLE tendrá en cuenta las descripciones de H- a la hora de generalizar una hipótesis de H. Si un ejemplo positivo de H está incluido en alguna de las hipótesis de H-, H no se verá modificado (es decir, no se generalizará ninguna de las descripciones de H, puesto que podría tratarse, por ejemplo, de una instancia negativa que ha sido ahora erróneamente clasificada como positiva). Sin embargo, dado que dicho ejemplo presenta evidencia que contradice la información predicha en H-, las hipótesis de H- que incluyan a la instancia recibirán una inhibición en su peso.

Igualmente un ejemplo positivo de H- (un contraejemplo de H) no provocará generalizaciones en H- mientras esté incluido en alguna de las hipótesis de H.

Con la creación de dos conjuntos de hipótesis que se limitan entre sí (H y H-), se cumple una función similar a la del espacio de versiones de Mitchell [Mitchell, 77] donde la configuración de un concepto viene delimitada por los conjuntos G (máximamente general) y S (máximamente específico). Sin embargo, conviene insistir en el hecho de que las hipótesis del conjunto G, que en el espacio de versiones dan cuenta de la evidencia de las instancias negativas, se adquieren a través de mecanismos de especialización que no están contemplados en el aprendizaje que realiza IKASLE. IKASLE genera tanto las hipótesis de H como las de H- mediante procesos de generalización similares a los empleados en el espacio de versiones para dar lugar a las descripciones del conjunto S.

La Figura 2 representa los pasos a través de los cuales el algoritmo ejecuta las estrategias de aprendizaje que se acaban de explicar.

### 3.4. Resultados de la implementación en el MUS

En su implementación en el *mus*, el sistema basa sus decisiones de apuesta en los conceptos adquiridos. Cuando sus cartas están incluidas en las descripciones de H ("cartas buenas"), decide apostar o aceptar una apuesta. Si, por el contrario, las cartas están contenidas en H- ("cartas malas"), decide pasar o rechazar la apuesta. Cuando las cartas no están incluidas en ninguno de los dos conjuntos, toma sus decisiones al azar. A medida que va acumulando experiencia y mejoran las descripciones de H y H- disminuye el número de decisiones tomadas aleatoriamente.

### IKASLE (e)

Si  $e$  es el primer ejemplo

entonces  $H_0 = \{\emptyset\}$  ;  $H_0^- = \{\emptyset\}$

· si  $e$  es positivo

entonces  $H_1 = \{e\}$

·  $H_1^- = \{\emptyset\}$

si no  $H_1^- = \{e\}$

·  $H_1 = \{\emptyset\}$

si no  $H = H_1 \cup H_0$  ;  $H^- = H_1^- \cup H_0^-$

· si  $e$  es positivo

entonces · GENERALIZAR-REFORZAR ( $e, H, H^-$ )

· INHIBIR ( $e, H^-$ )

si no · GENERALIZAR-REFORZAR ( $e, H^-, H$ )

· INHIBIR ( $e, H$ )

### GENERALIZAR-REFORZAR ( $e, C, C'$ )

- $C = C_1 \cup C_0$
- Reforzar toda hipótesis de  $C$  que sea más general que  $e$ .
- Para cada hipótesis  $h$  de  $C_1$  que no sea más general que  $e$ , siempre que no exista otra hipótesis en  $C'$  que sí lo sea:

· Generalizar  $h$ :

- Sustituir  $h$  por su generalización más específica  $g$  que incluya a  $e$ , dándole un peso mínimo

· Incluir  $h$  en  $C_0$

· Excluir de  $C_0$  aquellas hipótesis que no satisfagan un criterio de recencia

### INHIBIR ( $e, C$ )

- Restar fuerza a toda hipótesis de  $C$  más general que  $e$
- Eliminar toda hipótesis de  $C$  cuyo peso esté por debajo de un valor umbral
- si  $C_1 = \{\emptyset\}$   
entonces añadir a  $C_1$  las hipótesis más generales de  $C_0$

Figura 2. Algoritmo de aprendizaje IKASLE.

La evaluación de IKASLE se llevó a cabo haciéndole jugar contra un oponente que tomaba todas sus decisiones al azar. Los dos jugadores contaban al comienzo de cada experimento con el mismo conocimiento inicial, siendo la única diferencia entre ellos la capacidad de IKASLE de aprender de la experiencia. Se tomó como variable independiente el número de decisiones hechas por el sistema; como variable dependiente se midió el porcentaje acumulado de estas decisiones que resultaron ser correctas al final de cada baza.

La Figura 3 muestra los resultados de IKASLE y de una versión del programa que carecía del mecanismo de asignación de pesos. Se puede observar que aunque las dos curvas son similares, el comportamiento de IKASLE es ostensiblemente mejor, acercándose al 90% de decisiones correctas. Además los resultados de estas dos versiones en las que se realiza algún tipo de aprendizaje contrastan con la curva de referencia, en la base de la figura, que refleja los resultados de un sistema que no adquiere nuevo conocimiento.




Figura 3. Evolución del porcentaje de clasificaciones correctas en función del total de decisiones tomadas en el juego del *mus* para a) IKASLE, b) la versión sin el mecanismo de asignación de pesos, c) un programa que no aprende.

#### 4.- CONCLUSIONES

El éxito inicial de IKASLE en el dominio del *mus* apoya el interés de un acercamiento a la adquisición de conceptos en el que se tienen en cuenta procesos explicativos postulados para dar cuenta de fenómenos psicológicos más básicos. IKASLE está diseñado para simular, en su interacción con un ambiente reactivo, el comportamiento adaptativo de las personas y los animales que normalmente ha sido tratado más eficazmente por los modelos conexionistas. Al mismo tiempo, se preservan la explicabilidad y los procesos inferenciales simulados por los algoritmos simbólicos de aprendizaje.

En IKASLE se enfatizan la provisionalidad y la incrementalidad, lo cual motiva la incorporación de sus mecanismos de asignación de pesos que permiten tratar el ruido o la existencia de inconsistencias en los datos. Igualmente, la implementación de estos mecanismos muestra la plausibilidad de un tratamiento de los fenómenos de tipicidad desde una perspectiva asociativa.

Quedan aún muchos aspectos por investigar con objeto de optimizar el aprendizaje que realiza IKASLE y de corroborar las aportaciones de las teorías asociativas y del estudio del condicionamiento a los procesos de aprendizaje de conceptos. A continuación se mencionan algunos de los aspectos que estamos considerando actualmente:

- Es necesario apoyo empírico adicional con el fin de determinar las ventajas de los mecanismos asociativos implementados en IKASLE sobre teorías del aprendizaje alternativas.
- Sería necesario también incorporar una medida de similitud que permita determinar la clasificación de una instancia en función de su mayor o menor proximidad a las descripciones de H o H- cuando dicha instancia no está incluida por ninguna hipótesis en cualquiera de los dos conjuntos.
- Otro elemento que debiera reforzarse en IKASLE es su potencial representacional. Aunque el juego del *mus* es un dominio complejo de resolución de problemas, las descripciones que trata IKASLE son extremadamente simples: pares atributo-valor que representan combinaciones de cuatro cartas. Resulta evidente la necesidad de implementar el algoritmo en dominios más ricos representacionalmente en los que explorar, por ejemplo, la capacidad de IKASLE para adquirir descripciones relacionales (y no sólo pares atributo-valor) y de crear disyunciones.

## 5.- AGRADECIMIENTOS

Queremos agradecer las aportaciones de Santi Rementería cuyos comentarios y sugerencias han sido de gran utilidad para la elaboración de este trabajo.

## 6.- REFERENCIAS

- [Dickinson, Shanks, 85] Dickinson, A. y Shanks, D.: Animal conditioning and human causality judgment. En L. G. Nilsson y T. Archer (Eds.) *Perspectives on learning and memory*. Hillsdale, NJ: Lawrence Erlbaum. (1985)
- [Gennari, Langley, Fisher, 89] Gennari, J.H., Langley, P. y Fisher, D.: Models of incremental concept formation. *Artificial Intelligence*, 40, 11-61 (1989).
- [Gluck, Bower, 88] Gluck, M.A y Bower, G.H.: From conditioning to category learning: an adaptive network model. *Journal of Experimental Psychology: General*, 117, 227-247 (1988).
- [Iba, Wogulis, Langley, 88] Iba, W., Wogulis, J. y Langley, P.: Trading-off simplicity and coverage in incremental concept learning. En *Proceedings of the Fifth International Conference on Machine Learning*. San Mateo, CA: Morgan Kaufmann (1988).
- [Langley, 87] Langley, P.: A general theory of discrimination learning. En D. Klahr, P. Langley y R. Neches (Eds.): *Production System Models of Learning and Development*. Cambridge, Mass: MIT Press (1987).
- [Mackintosh, 83] Mackintosh, N.J.: *Conditioning and Associative Learning*. Oxford: Clarendon Press (1983).

- [Michalski, Mozetic, Hong, Lavrac, 86] Michalski,R.S., Mozetic,I., Hong,J. y Lavrac,N.: The multipurpose incremental learning system AQ15 and its testing application to three medical domains. En *Proceedings of the Fifth National Conference on Artificial Intelligence*. Los altos, CA: Morgan Kaufmann (1986).
- [Michalski, 87] Michalski,R.S.: How to learn imprecise concepts: a method for employing a two-tiered knowledge representation in learning. En *Proceedings of the Fourth International Workshop on Machine Learning*. Los Altos, CA: Morgan Kaufmann (1987).
- [Mitchell, 77] Mitchell, T.M.: Version spaces: a candidate elimination approach. En *Proceedings of the Fifth International Conference on Artificial Intelligence*. Los Altos, CA: Morgan-Kaufmann (1977).
- [Mitchell, Utgoff, Banerji, 83] Mitchell,T.M., Utgoff,P.E. y Banerji,R.: Learning by experimentation: acquiring and refining problem-solving heuristics. En R.S. Michalski, J.G. Carbonell y T.M. Mitchell (Eds.): *Machine learning: An artificial intelligence approach*. Los Altos, CA: Morgan-Kaufmann (1983).
- [Mostow, Hayes-Roth, 79] Mostow,J. y Hayes-Roth,F.: Operationalizing heuristics: Some AI methods for assisting AI programming. En *Proceedings of the Sixth International Joint Conference on Artificial Intelligence*. Los Altos, CA: Morgan Kaufmann (1979).
- [Papini, Bitterman, 1990] Papini,M.R. y Bitterman,M.E.: The role of contingency in classical conditioning. *Psychological Review*, 97, 396-403 (1990).
- [Pearce, 1989] Pearce,J.M.: The acquisition of an artificial category by pigeons. *The Quarterly Journal of Experimental Psychology*, 41B, 381-406 (1989).
- [Quinlan, 83] Quinlan, J.R.: Learning efficient classification procedures and their application to chess end games. En R. S. Michalski, J. G. Carbonell y T. M. Mitchell (Eds.): *Machine learning: An artificial intelligence approach*. Los Altos, CA: Morgan Kaufmann (1983).
- [Rescorla, 68] Rescorla,R.A.: Probability of shock in the presence and absence of CS in fear conditioning. *Journal of Comparative and Physiological Psychology*, 66, 1-5 (1968).
- [Rescorla, Wagner, 72] Rescorla,R.A. y Wagner,A.R.: A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and non-reinforcement. En A. H. Black y W. F. Prokasy (Eds.): *Classical conditioning II: Current research and theory*. New York: Appleton (1972).
- [Samuel, 63] Samuel,A.L.: Some studies in machine learning using the game of checkers. En Feigenbaum and Feldman (Eds.): *Computers and thought*. New York: McGraw-Hill (1963).
- [Schlimmer, Fisher, 86] Schlimmer,J.C. y Fisher, D.: A case study of incremental concept induction. En *Proceedings of the Fifth National Joint Conference on Artificial Intelligence*. Los Altos, CA: Morgan Kaufmann (1986).
- [Schlimmer, Granger, 86a] Schlimmer,J.C. y Granger,R.H.: Incremental learning from noisy data. *Machine Learning*, 1, 317-354 (1986a).

- [Schlimmer, Granger, 86b] Schlimmer, J.C. y Granger, R.H.: Simultaneous configural classical conditioning. En *Proceedings of the Eighth Annual Conference of the Cognitive Science Society*. Hillsdale, NJ: Lawrence Erlbaum (1986b).
- [Shanks, Dickinson, 87] Shanks, D. y Dickinson, A.: Associative accounts of causality judgment. En G.H. Bower (Ed.): *The Psychology of Learning and Motivation, Vol. 21*. N.Y.: Academic (1987).
- [Shapiro, 87] Shapiro, A.D.: *Structured Induction in Expert Systems*. N.Y.: Addison-Wesley (1987).
- [Utgoff, 89] Utgoff, P.E.: Incremental induction of decision trees. *Machine Learning*, 4, 161-186 (1989).
- [Waterman, 69] Waterman, D.A.: Generalization learning techniques for automating the learning of heuristics. Technical Report. Stanford Artificial Intelligence Memo (1969).