

Sistemas híbridos neuro-simbólicos: una revisión

Florentino Fdez-Riverola⁺, Juan M. Corchado^{*}

⁺Dpto. de Informática
Universidad de Vigo
Edificio Politécnico, Campus Universitario, As Lagoas
32004 Ourense
e-mail: riverola@uvigo.es

^{*}Dpto. de Informática y Automática
Universidad de Salamanca
Plaza de la Merced s/n
37008 Salamanca
e-mail: corchado@tejo.usal.es

Resumen: Este artículo presenta una revisión general de los sistemas híbridos neuro-simbólicos de inteligencia artificial, centrándose en aquellos compuestos por Sistemas de Razonamiento Basados en Casos (CBR) y Redes Neuronales Artificiales (ANN). Un sistema híbrido de inteligencia artificial está formado por la integración de varios subsistemas inteligentes, los cuales colaboran entre sí y se influyen mutuamente. En este artículo se muestran varias clasificaciones de estos sistemas, prestando especial atención a las características distintivas de cada uno de los subsistemas que componen los modelos híbridos.

Palabras clave: sistemas híbridos neuro-simbólicos, razonamiento basado en casos, redes neuronales artificiales.

1 Introducción

Un sistema híbrido de inteligencia artificial está formado por la integración de varios subsistemas inteligentes, cada uno de los cuales mantiene su propio lenguaje de representación y un mecanismo diferente de inferir soluciones. El objetivo de los sistemas híbridos es mejorar la eficiencia y la potencia de razonamiento así como la expresión de los sistemas inteligentes aislados. Medsker (1995) muestra ejemplos de problemas en los que se ha mejorado la eficiencia de un modelo con el uso de mecanismos de control, que son capaces de

determinar cual de los elementos que forman parte del sistema se deben utilizar en cada momento.

En general la investigación en el campo de los sistemas híbridos trata de mejorar la forma de desarrollar sistemas y construir mecanismos más potentes, utilizando menos esfuerzo que el necesario para generar un sistema basado en un solo sistema inteligente (Corchado, 1999). Los sistemas híbridos tienen potencial para resolver algunos problemas que son muy difíciles de afrontar utilizando un único método de razonamiento. Medsker (1995) asegura, desde una perspectiva fundamentalista, que dichos sistemas también se podrían utilizar para aprender

más acerca de los mecanismos cognitivos y de los modelos que definen determinados sistemas.

En la actualidad, un grupo bastante numeroso de científicos están investigando la interacción entre diferentes sistemas de inteligencia artificial (Sun y Alexandre, 1997). En este sentido el espectro de posibilidades de investigación es muy amplio, ya que existe una gran variedad de sistemas inteligentes, incrementándose el número de posibles combinaciones (Aha y Daniels, 1998; Lees, 1999; Anand *et al.*, 1999). Las investigaciones van desde el estudio de cuestiones fundamentales acerca de la naturaleza del razonamiento y la teoría de la computación, hasta problemas prácticos de investigación.

La siguiente sección describe una introducción a los Sistemas de Razonamiento Basados en Casos (CBR) y las Redes Neuronales Artificiales (ANN), presentando las aplicaciones, ventajas y deficiencias de la utilización de cada uno de ellos como mecanismos válidos para solucionar un conjunto equivalente de problemas. La sección tercera presenta las posibles clasificaciones en cuanto a su integración en un sistema híbrido global de razonamiento. En la sección cuarta se realiza una revisión de aplicaciones desarrolladas que utilizan este enfoque como estructura de funcionamiento, finalizando la exposición con un apartado dedicado a conclusiones y futuras líneas de investigación en la sección quinta.

2 ANN y CBR

El objetivo de esta sección es presentar una visión general de la estructura y los conceptos fundamentales relacionados con cada modelo de conocimiento, sentando las bases para abordar en la sección cuarta, una revisión de los sistemas híbridos que hacen use de ambas técnicas.

2.1 Redes Neuronales Artificiales

Las ANN, son algoritmos implementados en forma de programa informático o modelo electrónico, influenciados por el funcionamiento del cerebro humano (Haykin, 1999). Es un hecho bien conocido que los hombres pueden solucionar fácilmente muchos problemas, difíciles de resolver para los ordenadores.

El proceso de almacenar información en patrones, utilizarlos y resolver problemas con ellos es el que tratan de imitar las redes neuronales artificiales

intentando reproducir el comportamiento humano mediante ordenadores (Freeman y Skapura, 1992). Las ANN no utilizan conceptos de programación propios de otros sistemas de inteligencia artificial, sino que utilizan mecanismos de procesamiento paralelo, entrenamiento de pesos, etc. Este campo tiene un vocabulario propio y utiliza términos como memoria, reacción, organización propia, etc. (Corchado *et al.*, 2000).

La figura 1 muestra un ejemplo de una ANN. En este diagrama se representan las neuronas como círculos. Algunas de ellas interactúan con el medio para recibir las entradas. Las neuronas de la capa de salida generan los valores que la red cree que corresponden con los valores de entrada a la red o bien los valores que la red cree que son la proyección adecuada de los valores de entrada. El resto de las neuronas están situadas en una o más capas intermedias.

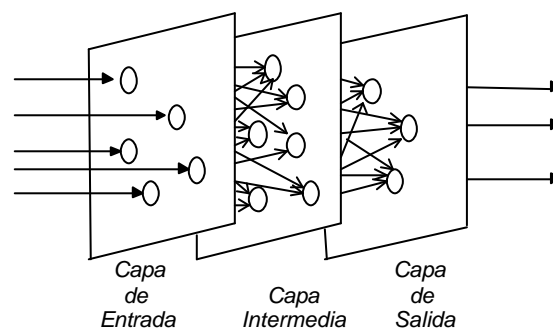


Figura 1: Estructura de una ANN multicapa.

Una red neuronal artificial puede verse como un conjunto de neuronas interconectadas, de tal forma que la salida de una neurona cualquiera, sirve generalmente como entrada de otras neuronas. Existen varios aspectos importantes a la hora de estudiar una red neuronal artificial (Haykin, 1999).

Por un lado, el número de neuronas, la disposición de las mismas y las conexiones existentes entre ellas determinan su componente estructural, también denominada arquitectura o topología de la red.

Por otro lado, ya que las neuronas están interconectadas, tiene sentido hablar de los caminos o rutas a través de los cuales se propagan las señales con el fin de procesar una información. Este procesamiento se realizará mediante el cambio de estado de las neuronas en dicho camino. El estado de todas y cada una de las neuronas se denomina estado de la red, y su variación en el tiempo se realiza de acuerdo con un determinado modo de operación.

Por último, los pesos asociados a cada una de las conexiones representan la configuración de la red. Esta configuración se modifica en el tiempo gracias a un proceso de entrenamiento que determina la capacidad de adaptación o aprendizaje del modelo.

La principal propiedad de una red neuronal artificial es la capacidad de aprender del entorno en el que opera y mejorar su funcionamiento. Dado que la noción de *aprendizaje* es muy genérica, se adopta la siguiente definición para expresar de forma más precisa lo que se entiende por aprendizaje en el contexto de las redes neuronales artificiales: el aprendizaje es el proceso mediante el cual los parámetros de una red neuronal artificial se adaptan como consecuencia de un proceso de estimulación llevado a cabo por el entorno en el que la red opera. El tipo de aprendizaje vendrá determinado por la forma en que cambie la configuración de la red.

Independientemente del tipo de aprendizaje, una clasificación de dicho proceso ampliamente extendida, atiende a la forma en que se modela el entorno en el que opera la red neuronal artificial. Bajo este punto de vista, se identifican tres paradigmas básicos de aprendizaje:

- **Aprendizaje supervisado** (*Supervised Learning*). Requiere la presencia de pares de vectores de entrenamiento. Cada par está compuesto por los valores de entrada a la red y los valores de salida esperados para tales entradas. En este caso es necesario que el entrenamiento de la red sea controlado por un supervisor o por un conjunto de reglas. Entre los modelos de redes neuronales artificiales que utilizan este esquema de aprendizaje se pueden citar: MLP (*Multilayer Perceptron*), RBF (*Radial-Basis Function Network*) y BAM (*Bi-directional Associative Memory*).
- **Aprendizaje no supervisado** (*Unsupervised Learning*). En este caso sólo se utilizan vectores de entrada para entrenar la red. Los valores de las salidas son determinados por la red durante el curso del aprendizaje. Se utiliza para construir modelos internos que capturan similitudes en los valores de los vectores de entrada, sin recibir información adicional. Existe una gran variedad de modelos que utilizan esta forma de aprendizaje, por ejemplo: SOM (*Self-Organising Maps*), PCA (*Principal Components Analysis*),

Redes de Hopfield, LVQ (*Learning Vector Quantization*), ART (*Adaptive Resonance Theory*) y FIR (*Finite Impulse Response*).

- **Aprendizaje por grados** o con fortalecimiento (*Reinforcement Learning*). En determinadas situaciones en las que no se dispone de pares de vectores de entrenamiento (entradas y salidas esperadas) para la red, es posible contar con un índice de rendimiento global de la misma. En estos casos se habla de aprendizaje con fortalecimiento que, en su forma más general, se basa en que un *crítico* externo proporciona una valoración global de la bondad de la red con una determinada periodicidad.

2.2 Razonamiento Basado en Casos

Con la intención de superar los problemas típicos de la construcción de sistemas expertos (KBS, *Knowledge Bases Systems*), Kolodner (1983a, 1983b) propuso un modelo revolucionario: un Sistema de Razonamiento Basado en Casos (CBR, *Case Based Reasoning*) que utiliza como base el modelo de razonamiento humano (Joh, 1997). Desde entonces, los CBR se han aplicado con éxito a un amplio espectro de problemas (Kolodner, 1993).

Un Sistema de Razonamiento Basado en Casos resuelve un problema por medio de la adaptación de soluciones dadas con anterioridad a problemas similares (Riesbeck y Schank, 1989). La memoria del CBR almacena un cierto número de problemas junto a sus correspondientes soluciones. La solución de un nuevo problema se obtiene recuperando casos (o problemas) similares almacenados en la memoria del CBR, ya que dichos problemas se estudian junto con sus soluciones. Por tanto un caso engloba un problema y la solución dada a dicho problema.

Un CBR es un sistema dinámico en el cual los nuevos problemas son añadidos continuamente a su memoria, de forma tal que los problemas parecidos o similares se eliminan, y paulatinamente se crean otros mediante la combinación de varios ya existentes. La idea que impulsó el desarrollo de esta metodología, se basa en el hecho de que los humanos utilizan lo aprendido en experiencias previas para resolver problemas presentes. Este hecho se experimenta de forma diaria y ha sido probado empíricamente por varios psicólogos (Klein y Whitaker, 1988; Ross, 1989).

Los CBR obtienen la solución a problemas por medio de algoritmos de indexación, recuperación de problemas previamente almacenados y técnicas de

comparación y adaptación a una determinada situación. Para ello utiliza el conocimiento almacenado en su memoria en forma de casos o problemas. Todas esas acciones están estructuradas y se pueden representar por una secuencia cíclica de procesos, que requiere generalmente la intervención humana. El razonamiento basado en casos se puede utilizar por sí mismo, o como parte de otro sistema convencional o inteligente. Los sistemas CBR están especialmente indicados cuando las reglas que definen un sistema de conocimiento son difíciles de obtener, o el número y complejidad de las mismas es demasiado grande como para crear un sistema experto. Esta tecnología se ha utilizado satisfactoriamente en disciplinas como el derecho, la medicina y los sistemas de diagnóstico con grandes bases de datos (Watson, 1997).

Un sistema típico CBR está compuesto por cuatro etapas secuenciales que se invocan siempre que es necesario resolver un problema (Kolodner, 1993; Aamodt y Plaza, 1994; Watson, 1997), aunque recientemente algunos autores se suman a la tendencia de estructurar el ciclo de vida de un CBR en seis etapas, tomando en consideración el proceso de modificación de determinados aspectos del sistema cuando se almacena un nuevo caso (Bergmann y Göker, 1999). La figura 2 muestra el ciclo de vida de un Sistema típico de Razonamiento Basado en Casos.

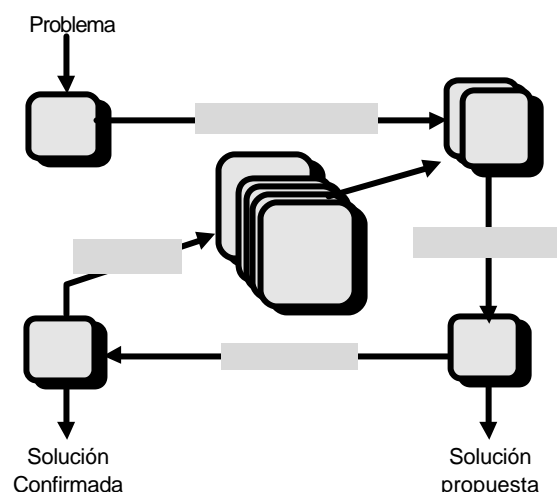


Figura 2: Ciclo de vida de un CBR.

Dicho proceso cíclico está compuesto por cuatro pasos fundamentales, representados por las palabras sombreadas en la figura 2.

- **Recuperación** de los casos o problemas más relevantes.

- **Reutilización** (adaptación) de los casos o problemas con la intención de solucionar el problema presente.
- **Revisión** de la solución propuesta si es necesario.
- **Retención** (aprendizaje) de la nueva solución como parte de un nuevo caso.

Al igual que otros mecanismos de resolución de problemas, el objetivo de un CBR es el de encontrar la solución de un problema determinado. La misión del algoritmo de recuperación consiste en buscar y seleccionar en la memoria del CBR los problemas más similares (junto con sus soluciones) al problema presente. Los casos deben representar tanto los problemas como sus respectivas soluciones. Los casos seleccionados de la memoria son reutilizados para generar una solución inicial. La adaptación de casos se realiza normalmente en esta fase. La solución dada en esa etapa se revisa (si es posible), y finalmente se crea un nuevo caso (constituido por el problema y la solución del mismo) almacenándose en la memoria.

Los casos de la memoria se pueden eliminar o modificar, y también se pueden obtener nuevos casos mezclando características de otros. Así, por ejemplo, cuando la solución dada a un problema sea insatisfactoria, y una vez encontradas las causas de esta deficiencia, se intentará eliminar de la memoria todos aquellos casos que promuevan dicha irregularidad. Este es un medio efectivo de aprendizaje que se asemeja a la estructura general del pensamiento humano. Por tanto un sistema CBR es capaz de utilizar el conocimiento de situaciones concretas experimentadas con anterioridad, en lugar de realizar asociaciones a lo largo de relaciones generales entre características de problemas, como haría un Sistema de Razonamiento Basado en Reglas (RBS, *Rule Based Systems*), o depender del conocimiento general sobre un determinado problema (Armengol y Plaza, 1994). Un CBR es un sistema de aprendizaje incremental, puesto que cada vez que se resuelve un problema, es posible crear un nuevo caso y almacenarlo en la memoria del CBR para su posterior reutilización.

La intervención humana es necesaria en muchas situaciones durante el ciclo de vida de un CBR, especialmente en las dos últimas fases del mencionado ciclo. La revisión y la retención de casos son realizadas normalmente por profesionales especializados, hecho que supone uno de los mayores inconvenientes de esta metodología y que se señala como un gran inconveniente por sus detractores.

3 Clasificaciones de sistemas híbridos de IA

Durante los últimos años, han tenido lugar varias conferencias internacionales en las que ha quedado patente la necesidad de combinar diferentes modelos de IA, para generar modelos más fuertes y eficaces (Medsker, 1995; Sun y Alexandre, 1997; Aha y Daniels, 1998; Lees, 1999; Anand *et al.*, 1999). A continuación se presentan tres posibles clasificaciones de integración diferentes.

3.1 Clasificación abc

Bezdek publicó en 1994 una clasificación (*Computational Intelligence Clasification*) que engloba a todos los sistemas híbridos de inteligencia artificial. Los niveles de integración definidos en el modelo, están clasificados en función de la complejidad con la que interaccionan los subsistemas que componen dicho modelo. Esta clasificación identifica tres niveles de integración:

- a: artificial.
- b: biológico.
- c: computacional.

En los tres niveles la complejidad aumenta al pasar del nivel de inteligencia computacional al nivel de inteligencia artificial, y de éste al de inteligencia biológica. En cada nivel se muestra cómo las pequeñas unidades de conocimiento (por ejemplo neuronas) pueden utilizarse para implementar técnicas de reconocimiento de patrones y así crear sistemas inteligentes.

Los procesos computacionales utilizan datos numéricos provenientes de sensores. El modelo muestra que los componentes de inteligencia artificial pueden ser construidos a partir de módulos simbólicos, combinando pequeñas piezas de conocimiento para crear procesos computacionales y estructuras de datos. La inteligencia biológica es el modelo a imitar, y procesa datos procedentes de órganos sensoriales utilizando mecanismos de memoria y técnicas relacionadas con las redes neuronales biológicas. Bezdek enfatiza el hecho de que los sistemas computacionales y artificiales no deben ser considerados inteligentes por sí mismos, y que las palabras como *aprendizaje* deben ser utilizadas con mucho cuidado cuando se aplican a elementos con pequeños niveles de complejidad.

El nivel computacional únicamente utiliza datos numéricos, tiene capacidad para reconocer ciertos patrones, y no utiliza el *conocimiento* en el sentido en el que se utiliza habitualmente en inteligencia artificial. Según Bezdek (1989) las redes neuronales artificiales son modelos computacionales inspirados en ciertos procesos biológicos. Ejemplos de estas redes son: Perceptrón Multicapa (MLP, *Multilayer Perceptron*), Red de Funciones de Base Radial (RBF, *Radial Basis Function*), Mapas Autoorganizados (SOM, *Self-Organizing Maps*) o cualquier otro modelo inspirado en sistemas biológicos como son los algoritmos genéticos. Por otra parte, los Sistemas Basados en Conocimiento (*Knowledge-Based Systems*) y los Sistemas de Razonamiento Basados en Casos pertenecen al nivel simbólico, ya que están inspirados en modelos de razonamiento de la mente humana. Desde el punto de vista del citado autor, la lógica difusa puede verse como el nexo de unión entre los dos niveles inferiores, ya que aglutina información numérica y semántica.

Un sistema híbrido en el modelo abc, es una forma de extender la inteligencia computacional a través de la inteligencia artificial, para alcanzar el objetivo final de modelar la inteligencia biológica.

3.2 Clasificación IRIS

Soucek (1991) desarrolló el Modelo IRIS (Integración de Razonamiento, Información y Servicio; *Integration of Reasoning, Informing and Serving*). La arquitectura IRIS permite la combinación de software, hardware y distintos tipos de sistemas inteligentes.

El objetivo de esta metodología es facilitar el diseño eficiente de sistemas inteligentes, creando así productos y servicios que satisfagan completamente las necesidades de los negocios para los que fueron concebidos. Para Soucek, el desarrollo de un sistema híbrido requiere la integración de diferentes disciplinas científicas incluyendo la biología, la psicología cognitiva, la lingüística y la informática.

3.3 Clasificación de Medsker y Bailey

Medsker y Bailey (1992) han definido cinco modos de integración que se muestran en la figura 3, donde SS representa a los sistemas simbólicos y SC a los sistemas conexionistas.

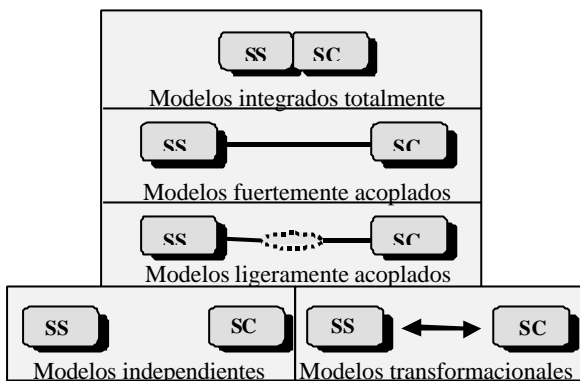


Figura 3: Modos de integración en sistemas de inteligencia artificial.

A continuación, se introducen cada una de estas formas de hibridación.

- **Modelos independientes**

Este modelo de hibridación se caracteriza por la utilización de varios sistemas inteligentes de forma paralela sin interacción entre ellos.

Se utiliza en situaciones como las siguientes:

- Necesidad de comparación de la eficacia y la eficiencia con la que dos sistemas de inteligencia artificial diferentes resuelven el mismo problema.
- Verificación de una solución dada por un sistema inteligente con otra proporcionada por un mecanismo diferente.
- Construcción de prototipos de forma rápida en paralelo con la intención de crear una aplicación sólida.

El uso de dos técnicas en paralelo para resolver un mismo problema provoca redundancia. Pero a la vez el desarrollar una técnica después de otra es una buena forma de validar la primera. La utilización de dos técnicas en paralelo es una forma de integración muy débil que en ciertas ocasiones simplifica la tarea de implementación del sistema, especialmente si la aplicación se desarrolla por dos o más grupos de trabajo diferentes.

- **Modelos transformacionales**

En este caso se empieza a resolver un problema utilizando un modelo inteligente y se termina empleando otro. Un ejemplo de este tipo de modelo se da en la situación en la que inicialmente se piensa que la mejor solución para resolver un problema es utilizar una red neuronal artificial, y durante el

transcurso de la implementación se decide que un sistema experto puede proporcionar una solución más adecuada puesto que absorbe ciertas características de la red neuronal.

Las ventajas del modelo son las siguientes:

- La experiencia demuestra que el modelo transformacional facilita una implementación más rápida que el modelo anterior, y posteriormente sólo requiere el mantenimiento de un sistema inteligente.
- El desarrollo del sistema final se realiza con la técnica más apropiada.

Aunque el modelo también tiene sus limitaciones:

- La creación de sistemas totalmente automatizados para transformar un sistema experto en una red neuronal y viceversa, son difíciles de implementar.
- Si se requieren grandes modificaciones en un sistema, es muy probable que sea necesario un nuevo desarrollo desde el principio.
- El sistema final está limitado por las capacidades del modelo seleccionado finalmente.

- **Modelos ligeramente acoplados**

Es la primera forma de auténtica integración de los sistemas inteligentes. En este caso una aplicación consta de varios sistemas inteligentes diferentes, que se comunican entre sí por medio de ficheros de datos.

Este tipo de integración, permite la interacción entre sistemas inteligentes con diferentes características de muy diversas formas.

- **Preprocesador:** una red neuronal artificial se puede utilizar como un procesador de datos de entrada que realice funciones de modificación, selección, etc., de los datos antes de introducirlos a un sistema experto. En este sentido, se han construido aplicaciones en las que redes neuronales se encargan de fusionar, transformar y categorizar datos, eliminar errores e identificar objetos, antes de enviar la información a un sistema experto (Medsker y Bailey, 1992).
- **Postprocesador:** los resultados obtenidos por un sistema experto se pueden enviar a una red neuronal artificial, por medio de un fichero. En este caso el sistema experto puede realizar

funciones de manipulación de datos, clasificación, selección, control, etc., y la red neuronal se encarga de hacer predicciones, análisis de datos, seguimiento de resultados, etc. (Medsker y Bailey, 1992).

- **Coprocesador:** requiere la comunicación bilateral entre los dos (o más) sistemas que forman parte del híbrido, permitiendo un comportamiento de cooperación entre, por ejemplo, una red neuronal y un sistema experto. Aunque según el autor no es una técnica muy utilizada, tiene potencial para solucionar problemas complicados que requieran un refinamiento de datos incremental o cierta dualidad para resolver problemas.
- **Interfaz de Usuario:** una red neuronal artificial se puede utilizar para facilitar la interacción entre un usuario y un sistema experto.

Estos modelos son más fáciles de desarrollar que aquellos que tienen una integración más fuerte, como los que se verán a continuación. Las mayores limitaciones de los modelos vistos anteriormente son:

- El tiempo de operación de los sistemas es elevado, ya que los protocolos de comunicación por medio de ficheros tienen asociado un alto coste de comunicación.
 - El desarrollo de sistemas inteligentes separados con posibilidades de comunicación entre ellos, conlleva una duplicación de esfuerzos.
- **Modelos fuertemente acoplados**

Este modelo es similar al anterior, sin embargo, aquí la información se comparte entre los sistemas inteligentes por medio de estructuras residentes en la memoria, y no por medio de ficheros de datos externos, lo que incrementa la capacidad de interacción entre sistemas y mejora la eficacia del modelo visto anteriormente. Dicha técnica se puede utilizar en los cuatro submodelos presentados: preprocesador, postprocesador, coprocesador e interfaz de usuario.

- **Modelos totalmente integrados**

El modelo de integración total se caracteriza porque los distintos sistemas inteligentes que lo forman, comparten las estructuras de datos y la representación de los mismos. La comunicación entre los diferentes submódulos se efectúa utilizando la

naturaleza dual (conexionista y simbólica) de las estructuras de datos.

El razonamiento se realiza en la mayoría de los casos utilizando un modelo cooperativo, o mediante el uso de un componente que hace de controlador y optimiza el híbrido. Existen varios sistemas que utilizan esta forma de razonar y que incluyen redes neuronales, sistemas expertos, nodos de entrada y salida y diferentes tipos de mecanismos de control (Medsker y Bailey, 1992).

Los sistemas expertos conexionistas son una de las variedades más importantes del citado modelo. Dependen de la representación local del conocimiento, al contrario que las redes neuronales artificiales que son distribuidas y razonan por medio de la interpretación de las activaciones de las neuronas. Los sistemas expertos conexionistas utilizan las relaciones existentes entre pequeños nodos de conocimiento y razonamiento, comunicándose entre ellos por medio de canales ponderados.

Las ventajas del modelo son:

- El producto final es robusto y sólido.
- Mejora de las capacidades de resolución de problemas.
- Durante el desarrollo del sistema no existe redundancia.
- Mejora la capacidad de adaptación, generalización, tolerancia al ruido, justificación y deducción lógica con respecto a sistemas no integrados.

Las limitaciones del modelo son:

- Relativas al aumento en la complejidad del modelo.
- Dificultad de construcción de herramientas que elaboren estos híbridos de forma automática.
- La validación, verificación y mantenimiento de estos sistemas requiere más trabajo.

4 Modelos neuro-simbólicos: CBR/ANN

Una aportación de especial relevancia y objeto de numerosos estudios y aplicaciones prácticas de inteligencia artificial, son los sistemas híbridos CBR/ANN.

Los Sistemas de Razonamiento Basados en Casos son algoritmos muy flexibles capaces de absorber las propiedades beneficiosas de otras tecnologías.

Durante la pasada década el número de científicos interesados en este campo se ha incrementado notablemente, desarrollándose sistemas muy interesantes. Antes de revisar los híbridos CBR/ANN que reflejan el estado y las tendencias de la investigación realizada en este campo, definiremos las características de ambos modelos que favorecen el citado tipo de hibridación (Hilario *et al.*, 1995).

Las redes neuronales artificiales no son apropiadas para resolver problemas que requieran el uso de razonamientos escalonados. Por otra parte, es muy difícil explicar su forma de razonamiento y justificar los resultados obtenidos por ellas, sin embargo, sus capacidades de generalización y adaptación son muy interesantes y se pueden utilizar para resolver determinados problemas. Por tanto, las redes neuronales artificiales no se pueden utilizar en situaciones que requieran la justificación del razonamiento. Por el contrario, son apropiadas en áreas en las que sea necesaria la generalización de datos. Si los datos son adecuados y la red neuronal se entrena correctamente, el aprendizaje de la misma se realiza fácilmente. Esta propiedad de las redes neuronales puede resultar particularmente útil, ya que en los sistemas CBR el aprendizaje es parte intrínseca de su ciclo de vida. Así pues, las redes neuronales se pueden utilizar para aprender a recuperar los casos más adecuados de la memoria, o dicho de otra forma, para aprender a identificar la distancia más corta entre varios casos. Incluso, una red neuronal puede hacer que a un sistema CBR le resulte relativamente fácil generar nuevas soluciones, generalizar a partir de casos conocidos y adaptarlos a situaciones presentes.

Los CBR y las ANN son técnicas complementarias:

- Las ANN son más aconsejables en problemas de tipo numérico.
- Los CBR son más aconsejables en problemas relacionados con el conocimiento simbólico.

Aunque el conocimiento simbólico se puede transformar a una representación numérica y viceversa, hay que considerar que la transformación supone un riesgo de pérdida de información y precisión. La combinación entre los CBR y las ANN supondría la eliminación de una transformación de este tipo, y un aumento en la precisión de los resultados. Como se mencionó anteriormente, la capacidad de generalización es una excelente característica de las redes neuronales, pero en algunas ocasiones es conveniente mantener información relativa a casos concretos, y ésta es una capacidad natural de los sistemas CBR.

En la literatura se describen varios ejemplos de híbridos CBR/ANN. Según Reategui (1996) la forma más común de este tipo de hibridaciones es aquella en la que los casos forman parte de una red neuronal simbólica, o dicho de otra forma, un CBR conexionista. De esta manera, el CBR puede usar satisfactoriamente los casos en la etapa de recuperación y durante la indexación. Por ejemplo, en el sistema híbrido creado por Myllimaki y Tirri (1993), los casos están contenidos en las neuronas del nivel intermedio, creando así una red neuronal simbólica. El CBR hace uso de probabilidades bayesianas y está implementado como si se tratara de una red conexionista, que utiliza dichas probabilidades para determinar la activación entre las neuronas y proporcionar una explicación teórica de las soluciones dadas.

Bezdek y Jazayeri (1989) han desarrollado un sistema híbrido centrado en problemas de diseño, en el que los casos se representan como neuronas en la capa intermedia de una red neuronal, y la recuperación de los datos se hace con una estructura híbrida. Thrift (1989) utiliza una red neuronal que aprende utilizando técnicas de retropropagación (*back-propagation*) para filtrar casos en la etapa de recuperación. La red selecciona los casos más relevantes de la memoria del CBR.

GAL (Alpaydin, 1991) se basa en una arquitectura similar a las anteriores. El elemento distintivo de este sistema es la utilización del principio de construcción incremental de prototipos, en el que cada clase de objetos, está representada por el conjunto de características comunes a todos ellos y sus diferencias con respecto a las representaciones de otra clase. En dicha arquitectura, sólo hay lugar para casos representativos, al igual que sucede con los algoritmos KNN. El tamaño de la memoria de la red aumenta cuando aprende y disminuye cuando olvida.

INSIDE (Lim *et al.*, 1991) y ARN2 (Azcarraga y Giacometti, 1991) son similares al sistema anterior. En este caso las neuronas de la capa de entrada representan los atributos, las neuronas de la capa siguiente representan los prototipos (implementados como vectores de n dimensiones), y las neuronas de la capa de salida representan las clases. Cada vector de n dimensiones tiene un área de influencia de una dimensión determinada, que se reduce durante la etapa de aprendizaje si la solución dada por el sistema es errónea. Aunque INSIDE y ARN2 son muy similares, se diferencian en la metodología que

utilizan para aprender a crear los prototipos y ajustar sus áreas de influencia.

PBIS (*Prototype-Based Indexing System*) fue creado por Malek (1995) con el objetivo de mejorar la eficacia del modelo ARN2. PBIS mantiene tanto los casos prototípicos como los no prototípicos, dividiendo la memoria en dos niveles. El primer nivel es igual a la capa intermedia del modelo ARN y contiene casos prototipo. El segundo nivel es una memoria *plana*, en la que los casos similares se agrupan en regiones. Cada región con casos similares se asocia al prototipo más próximo a ella. PBIS contiene una zona donde almacenar casos que están en la frontera entre dichas regiones y que tienen asociada una cierta incertidumbre. Cuando se presenta un nuevo caso a la red simbólica, se selecciona el prototipo con el mayor valor de salida, siempre y cuando se haya activado una sola clase. Si se activan varias clases se seleccionan los prototipos asociados a las clases activadas y se recuperan los casos más similares. Si no se activa ninguno de los prototipos, el sistema busca en las zonas atípicas de la memoria plana.

Mao *et al.* (1994) han desarrollado un algoritmo para la recuperación de datos basado en el uso de analogías utilizando redes neuronales artificiales. Han aplicado con éxito su algoritmo al diseño de turbinas de vapor. Main *et al.* (1996) han investigado el uso de lógica difusa y redes neuronales durante las etapas de recuperación e indexación de casos en sistemas CBR.

PATDEX/2 (Richter y Weiss, 1991) es un híbrido CBR/ANN en el que ambos mecanismos de razonamiento mantienen una relación completamente diferente a la que tienen los sistemas mencionados con anterioridad. PATDEX/2 es un sistema de diagnóstico de fallos basado en la forma de razonar de los CBR. Los casos son vectores de síntomas y el diagnóstico asociado a los mismos. La red neuronal utiliza un mecanismo de aprendizaje competitivo, y es el centro del mecanismo de recuperación de casos. El mecanismo de aprendizaje competitivo se basa en una matriz que asocia la relevancia de cada síntoma con cada diagnóstico posible. Los pesos de la matriz son modificados por una red neuronal en función del éxito de cada diagnóstico.

García Lorenzo y Bello Pérez (1996) utilizan una red neuronal para calcular la medida de la similitud entre un nuevo problema, y los casos almacenados en la memoria. La red neuronal proporciona un mecanismo para recuperar casos utilizando información que en otros modelos puede requerir una arquitectura

paralela. Sun (1996) argumenta que la conexión entre los CBR, sistemas basados en reglas y elementos conexionistas, es una forma muy adecuada de razonar utilizando el sentido común.

Agre y Koprinska (1996) muestran un híbrido muy diferente a los vistos anteriormente. Su sistema combina un CBR con una red neuronal basada en conocimiento (*Knowledge-Based ANN*). Estas redes se caracterizan porque hacen uso del conocimiento del problema que quieren resolver para definir su estructura inicial. En este caso el CBR se utiliza solamente para corregir las soluciones erróneas de la red neuronal basada en conocimiento. Las correcciones son recuperadas por el CBR de entre los casos que se utilizaron para entrenar la red neuronal. Agre y Koprinska han probado que el híbrido mejora substancialmente la eficacia de la red.

Reategui *et al.* (1995, 1996), han trabajado con varios tipos de híbridos CBR/ANN en diferentes problemas. Sus híbridos constan básicamente de dos componentes, un CBR y una ANN. Ambos sistemas trabajan de forma independiente, y hay una unidad central de control que se encarga de activarlos alternativamente. En uno de sus experimentos, mientras que la red neuronal aprendía a reconocer patrones generales de tarjetas de crédito, el CBR controlaba las transacciones realizadas con dichas tarjetas (los datos utilizados por el CBR y la red neuronal son diferentes). La unidad de control hace de puente de comunicación entre ambos sistemas.

En el campo de los diagnósticos médicos, Reategui *et al.* (1996) han utilizado una red neuronal integrada en un CBR. El objetivo de la red es crear hipótesis y guiar el mecanismo de recuperación del CBR, que se encarga de buscar aquellos casos que coinciden con la hipótesis generada. El modelo ha sido creado para diagnosticar enfermedades coronarias congénitas. El sistema híbrido es capaz de resolver problemas que una red no puede solucionar por sí misma.

También en el campo de los diagnósticos, Liu y Yan (1997) han explorado el uso de redes neuronales con componentes de lógica difusa que trabajan en colaboración con CBR. En sus experimentos en el campo del diagnóstico de síntomas de sistemas eléctricos, han intentado mejorar problemas de ambigüedad e incertidumbre en la descripción de síntomas.

Corchado *et al.*, han desarrollado sistemas híbridos CBR/ANN capaces de predecir temperaturas oceanográficas de forma más acertada de lo que lo harían cualquiera de los sistemas de razonamiento

utilizados en el híbrido por sí mismos. En uno de sus sistemas híbridos (Corchado *et al.*, 1997), ambas técnicas se complementan entre sí y comparten la misma estructura de datos. Este sistema inicial, fue mejorado para realizar predicciones oceanográficas en tiempo real (Corchado, 1999). En este caso se utiliza una red neuronal artificial en la fase de adaptación del CBR. La red neuronal se entrena con los casos recuperados y se utiliza para realizar una primera predicción. Este es un CBR con fuertes connotaciones sintácticas.

Marinilli *et al.* (1999), presentan un híbrido CBR/ANN como sistema de filtrado de documentos de texto y HTML provenientes de la Web, basado en las preferencias y características del usuario final. Este sistema interactivo, emplea dos perceptrones multicapa encargados de clasificar el perfil del usuario y la categoría a la que pertenece el documento, y se utilizan para indexar casos en la memoria del CBR y construir las librerías de estereotipos y categorías de documentos.

Martin *et al.* (1999) están trabajando en el desarrollo de STOIY (Sistema de información para la planificación del impacto del ruido en el ambiente), que tiene como finalidad monitorizar, controlar y planificar la polución acústica proveniente de una escuela de artillería en Noruega. El sistema, que implementa un CBR con aproximación de conocimiento intensivo, utiliza una red neuronal como preprocesador para el reconocimiento de las diferentes fuentes de ruido (conducción de tanques, fuertes disparos, etc) generadas en el entorno, que son medidas cada segundo por ocho estaciones meteorológicas, para su posterior inclusión en la base de casos del CBR (indexación de nuevos casos). Los autores aseguran que el porcentaje correcto de reconocimiento de fuentes de ruido supera el 90%, mientras que los casos restantes (en los que no se ha podido identificar el origen del ruido), son grabados para ser identificados manualmente.

Recientemente, se han presentado una serie de hibridaciones que combinan los sistemas CBR con las redes de bayes. Aamodt y Langseth (1998) presentan resultados de su investigación en el proyecto NOEMIE (EU Esprit IV), en el que se combinan minería de datos (DM, *Data Mining*) y sistemas CBR para mejorar la transferencia y reutilización de la experiencia en entornos industriales. Utilizan mecanismos de recuperación de casos basados en fuertes connotaciones semánticas (aproximación de conocimiento intensivo; *Knowledge Intensive Approach*), generando las

explicaciones a partir de un modelo de dominio que consiste en parte en una red semántica y en parte en una red bayesiana (BN, *Bayesian Network*). La red bayesiana ayuda en la recuperación e indexado de los casos, así como en el aprendizaje del conocimiento general del dominio utilizado.

Dentro del ámbito del proyecto NOEMIE presentado en el párrafo anterior, Langseth *et al.* (1999), trabajan actualmente en procesos de producción industrial, en cooperación con la compañía petrolífera noruega Saga. Su investigación se centra en el campo de los sistemas CBR con una aproximación de conocimiento intensivo, donde los casos forman parte de una red semántica (red bayesiana), que mantiene un conocimiento más general del dominio del problema. Las redes bayesianas se utilizan para extraer información de los datos, automatizando la construcción y el refinamiento dinámico de un modelo basado en casos específicos y conocimiento general.

Dingsøyr (1998) ha desarrollado un marco de trabajo para integrar redes bayesianas como mecanismo para la recuperación de casos en un CBR. El sistema presentado (denotado como CBRDM), usa este tipo de redes para calcular métricas de similitud entre casos, y ha sido testeado con datos pertenecientes a una base de datos proveniente de la industria del petróleo (OREDA). Los resultados muestran que el híbrido mejora las prestaciones de un CBR tradicional, especialmente en aquellas situaciones en las que los casos poseen atributos de los que no se conoce su valor.

Shinmori (1998) propone la hibridación de redes bayesianas en la fase de recuperación de casos en un CBR, para la implementación de un sistema prototipo interactivo que asista en la resolución de problemas software a la hora de instalar/trabajar con dichas aplicaciones. El sistema se basa en las palabras clave que un usuario emplea a la hora de intentar encontrar ayuda ante un problema. El objetivo de las redes bayesianas es reformular la petición del usuario para generar una nueva *query* que recupere casos con información relevante del error soportado.

Friese (1999) propone la combinación del sistema *Creek* (Aamodt, 1991). Este sistema implementa un CBR con aproximación de conocimiento intensivo y aprendizaje continuo (retención de nuevos casos). Friese aboga por integrar *Creek* con redes bayesianas para lograr un solucionador de problemas. La red bayesiana se utiliza para modelar el conocimiento del dominio de un problema

(aprendizaje estructural), calculando los pesos de los arcos que constituyen la explicación de un determinado caso, y por tanto, el grado de similitud con los demás (recuperación de casos).

5 Conclusiones

La tabla 1 muestra de manera esquemática el conjunto de híbridos analizados que representan el estado actual de la investigación en este tema. Donde **Recuperación (ANN)** indica que la ANN se ha utilizado en la fase de recuperación del CBR.

Híbrido	Característica distintiva	Tipo de hibridación
<i>Aamodt y Langseth (1998)</i>	<ul style="list-style-type: none"> Integración de BN en CBR con aproximación de conocimiento intensivo. BN asiste en recuperación, indexado y aprendizaje de conocimiento general. 	<ul style="list-style-type: none"> Indexación(BN)-Recuperación(BN)-CBR. Co-procesador.
<i>Agre y Koprinska (1996)</i>	<ul style="list-style-type: none"> Combina un CBR con una red neuronal basada en conocimiento (ANNbc). 	<ul style="list-style-type: none"> CorrecciónDeErrores(CBR) - ANNbc. Co-procesador.
<i>ARN2 Azcarraga et al. (1991)</i>	<ul style="list-style-type: none"> Atributos - Prototipos - Clases. 	<ul style="list-style-type: none"> Red neuronal simbólica. Integración total.
<i>Becker y Jazayeri (1989)</i>	<ul style="list-style-type: none"> Problemas de diseño. La recuperación de los datos se hace con una estructura híbrida. 	<ul style="list-style-type: none"> Red neuronal simbólica. Integración total.
<i>Corchado et al. (1997)</i>	<ul style="list-style-type: none"> Predicciones oceanográficas. 	<ul style="list-style-type: none"> ANN-CONTROL- CBR. Co-procesador.
<i>Corchado et al. (1999)</i>	<ul style="list-style-type: none"> Predicciones oceanográficas en tiempo real. 	<ul style="list-style-type: none"> Adaptación(ANN) - CBR.
<i>DingsEyr (1998)</i>	<ul style="list-style-type: none"> BN para calcular métricas de similitud entre casos. 	<ul style="list-style-type: none"> Recuperación(BN)-CBR. Co-procesador.
<i>Friese (1999)</i>	<ul style="list-style-type: none"> CBR orientado a explicaciones (solucionador de problemas). BN asiste en recuperación y aprendizaje de conocimiento general. 	<ul style="list-style-type: none"> Recuperación(BN)-CBR. Co-procesador.
<i>GAL Alpaydin (1991)</i>	<ul style="list-style-type: none"> El sistema sigue el principio de construcción incremental de prototipos. 	<ul style="list-style-type: none"> Red neuronal simbólica. Integración total.
<i>García Lorenzo y Bello Perez (1996)</i>	<ul style="list-style-type: none"> Se utilizada una ANN a modo de métrica de similitud. 	<ul style="list-style-type: none"> Recuperación(ANN) - CBR. Co-procesador.
<i>INSIDE Lim et al. (1991)</i>	<ul style="list-style-type: none"> Atributos - Prototipos - Clases. 	<ul style="list-style-type: none"> Red neuronal simbólica. Integración total.
<i>Langseth et al. (1999)</i>	<ul style="list-style-type: none"> BN como soporte de conocimiento general. Los casos forman parte de una red semántica. 	<ul style="list-style-type: none"> Indexación(BN)-Recuperación(BN)-CBR. Co-procesador.
<i>Liu y Yan (1997)</i>	<ul style="list-style-type: none"> ANN - lógica difusa –diagnóstico de síntomas de sistemas eléctricos. 	<ul style="list-style-type: none"> Co-procesador.
<i>Main et al. (1996)</i>	<ul style="list-style-type: none"> ANN - Lógica difusa - recuperación de casos. 	<ul style="list-style-type: none"> Recuperación(ANN) - CBR. Co-procesador.
<i>Mao et al. (1994)</i>	<ul style="list-style-type: none"> ANN - recuperación de casos. Diseño de turbinas de vapor. 	<ul style="list-style-type: none"> Recuperación(ANN) - CBR. Co-procesador.

continuación

<i>Marinilli et al. (1999)</i>	<ul style="list-style-type: none"> • Sistema de filtrado de documentos de provenientes de la Web. • ANN (Multi-layer Perceptron) para indexación de casos. 	<ul style="list-style-type: none"> • Indexación(ANN) – CBR. • Co-procesador.
<i>Martin et al. (1999)</i>	<ul style="list-style-type: none"> • CBR como sistema para la planificación del impacto del ruido en el ambiente. 	<ul style="list-style-type: none"> • Indexación(ANN)-CBR. • Pre-procesador.
<i>Myllimaki y Tirri (1993)</i>	<ul style="list-style-type: none"> • Probabilidades bayesianas. 	<ul style="list-style-type: none"> • Red neuronal simbólica. • Integración total.
<i>PATDEX/2 Richter et al. (1991)</i>	<ul style="list-style-type: none"> • ANN - recuperación de casos. • Diagnóstico de fallos. 	<ul style="list-style-type: none"> • Recuperación(ANN) - CBR. • Co-procesador.
<i>PBIS Malek (1995)</i>	<ul style="list-style-type: none"> • Mantiene tanto casos prototípicos como no prototípicos. 	<ul style="list-style-type: none"> • Red neuronal simbólica. • Integración total.
<i>Reategui et al. (1996)</i>	<ul style="list-style-type: none"> • ANN memoriza patrones de uso de tarjetas de crédito. • CBR controla transacciones realizadas con tarjetas de crédito. 	<ul style="list-style-type: none"> • ANN- CONTROL-CBR. • Co-procesador.
<i>Reategui et al. (1996)</i>	<ul style="list-style-type: none"> • ANN crea hipótesis y guía la fase de recuperación del CBR. 	<ul style="list-style-type: none"> • Recuperación(ANN) - CBR. • Co-procesador.
<i>Shinmori (1998)</i>	<ul style="list-style-type: none"> • BN asiste en recuperación y adaptación de casos. 	<ul style="list-style-type: none"> • Recuperación(BN)-CBR. • Co-procesador.
<i>Thrift (1989)</i>	<ul style="list-style-type: none"> • ANN (back-propagation) para filtrar casos. 	<ul style="list-style-type: none"> • Red neuronal simbólica. • Integración total.

Tabla 1: Sumario de sistemas híbridos CBR/ANN.

Dicha tabla muestra el tipo de hibridación de cada sistema, obviando los detalles irrelevantes con el fin de poder clasificar fácilmente un conjunto de híbridos tan heterogéneo. La segunda columna de la tabla presenta las peculiaridades generales de cada modelo. En la tabla 1 se aprecia que cada uno de los sistemas híbridos tiene una característica distintiva que lo hace especial y diferente al resto por alguna causa. Sin embargo, atendiendo al tipo de hibridación que utilizan se observa que la mayoría de ellos:

- O bien tienen una integración total, en la forma de una red neuronal simbólica.
- O bien ambos subsistemas están parcial o fuertemente acoplados.

En este último caso, lo normal es que la red neuronal se utilice durante la recuperación de los casos. En ocasiones los dos coprocesadores pueden estar controlados por un sistema intermedio o simplemente trabajar en paralelo. Los creadores de los sistemas híbridos expuestos analizan las ventajas y los

inconvenientes de sus modelos. En todos los casos las propiedades beneficiosas de los híbridos superan a sus problemas.

Los últimos avances en este campo, se centran en la utilización de redes de creencia o redes bayesianas en la fase de indexación/recuperación de casos, integrando conocimiento concreto obtenido en situaciones pasadas, con conocimiento general de un dominio particular. Habitualmente estos sistemas están parcialmente acoplados siguiendo una arquitectura de coprocesador, donde el CBR controla el sistema y utiliza la red bayesiana como soporte en alguna de sus fases.

6 Bibliografía

Aamodt A. (1991). **A Knowledge-Intensive, Integrated Approach to Problem Solving and Sustained Learning**. PH. D. thesis, May 1991, Dept. of Computer Systems and Telematics, University of Trondheim, Norway.

- Aamodt A. y Plaza E. (1994). **Case-Based Reasoning: foundational Issues, Methodological Variations, and System Approaches**. AICOM. Vol. 7. No 1. Marzo 1994.
- Aamodt A. y Langseth H. (1998). **Integrating Bayesian Networks into Knowledge-Intensive CBR**. Case-Base Reasoning Integrations. Papers from the 1998 Workshop Technical Report WS-98-15. AAAI Press, ISBN 1-57735-068-5. Pag. 1-6.
- Agre G. y Koprinska I. (1996). **Case-Based Refinement of Knowledge-Based Neural Networks**. Albus J., Meystel A. y Quintero R., Ed. Proceedings of the International Conference "Intelligent Systems: A Semiotic Perspective". Vol. II: Applied Semiotics. Octubre 20-23. Gaithersburg, MD, USA, 1996. US Government Printing Office. Pag. 221-226.
- Aha D. y Daniels Jody J. (1998). **Case-Based Reasoning Integrations**. Papers from the 1998 Workshop. AAAI Press.
- Alpaydin G. (1991). **Networks that grow when they learn and shrink when they forget**. Technical Report TR 91-032. International Computer Science Institute. Mayo, 1991.
- Anand S., Aamodt A. y Aha D. (1999). IJCAI '99. Workshop ML-5. Automating the Construction of Case Based Reasoners. Stockholm, Sweden. 1999. Pag. 73-76.
- Armengol E. y Plaza E. (1994). **A knowledge level model of knowledge-based reasoning**. Wess S., Altho K. D. y Richter M.M., Ed. Topics in Case-Based Reasoning. First Europe an Workshop, EWCBR'93. Kaiserslautern. Springer Verlag. Berlín 1994.
- Azcarraga A. y Giacometti A. (1991). **A prototype-based incremental network model for classification tasks**. Fourth International Conference on Neural Networks and their Applications. Nimes, Francia. 1991.
- Bergmann y Göker. (1999). **Developing Industrial Case-Based Reasoning Applications Using the INRECA Methodology**. IJCAI '99. Workshop ML-5. Automating the Construction of Case Based Reasoners. Stockholm, Sweden. 1999.
- Bezdek J. C. y Jazayeri K. (1989). **A connectionist approach to case-based reasoning**. K. J. Hammond, Ed. Proceedings of the Case-Based Reasoning Workshop. Pensacola Beach, Florida. Morgan Kaufmann. Pag. 213-217.
- Bezdek J. C. (1994). **"What is Computational Intelligence?," in Computational Intelligence: Imitating Life**. IEEE Press. Nueva York. Ed. Zurada J. M., Marks II R. J. y Robinson C. J. Pag. 1-12.
- Corchado J. M., Lees B., Fyfe C. y Rees N. (1997). **Hybrid Knowledge Generation and Learning System**. Ninth International Conference on Software Engineering and Knowledge Engineering, Madrid, España. Junio 17-20.
- Corchado J. M. (1999). **Neuro-Symbolic model for real-time forecasting problems**. PH. D. thesis, Dec 1999, Dept. of Computing and Information Systems, University of Paisley, United Kingdom.
- Corchado J. M., Díaz F., Borrajo L. y Fdez-Riverola F. (2000). **Redes Neuronales Artificiales: Un enfoque práctico**. Departamento de publicaciones de la Universidad de Vigo.
- Dingsøyr T. (1998). **Retrieval of Cases by using a Bayesian Network**. Case-Base Reasoning Integrations. Papers from the 1998 Workshop Technical Report WS-98-15. AAAI Press, ISBN 1-57735-068-5. Pag. 50-54.
- Freeman, J. A. y Skapura, D. M. (1992). **Neural Networks, Algorithms, Applications, and Programming Techniques**. Addison Wesley.
- Friese T. (1999). **Utilization of Bayesian Belief Networks for Explanation-Driven Case-Based Reasoning**. IJCAI '99. Workshop ML-5. Automating the Construction of Case Based Reasoners. Stockholm, Sweden. 1999. Pag. 73-76.
- García Lorenzo M. M. y Bello Pérez R. E. (1996). **Model and its different applications to case-based reasoning**. Knowledge-Based Systems. Noviembre. Vol. 9. No 7. Pag. 465-473. Elsevier Science B.V. Amsterdam, Holanda.
- Haykin, S. (1999). **Neural Networks: a Comprehensive Foundation**. 2nd Edition, Prentice Hall.
- Hilario M., Orsier B., Rida A. y Pellegrini C. (1995). **Integration of model-based reasoning and neural processing**. Mix deliverable d4 part i, CUI. University of Geneva.

- Joh D. Y. (1997). **CBR in a Changing Environment**. Case Based Reasoning Research and Development. ICCBR-97. Providence, RI, USA.
- Klein G. A. y Whitaker L. (1988). **Using Analogues to Predict and Plan**. Proceedings of a Workshop on Case-Based Reasoning. Pag. 224-232.
- Kolodner J. (1983a). **Maintaining organization in a dynamic long-term memory**. Cognitive Science. Vol. 7. Pag. 243-280.
- Kolodner J. (1983b). **Reconstructive memory, a computer model**. Cognitive Science. Vol. 7. Pag. 281-328.
- Kolodner J. (1993). **Case-Based Reasoning**. San Mateo, CA, Morgan Kaufmann. 1993.
- Langseth H., Asmodt A. y Martin O. (1999). **Learning Retrieval Knowledge from Data**. IJCAI '99. WorkShop ML-5. Automating the Construction of Case Based Reasoners. Stockholm, Sweden. 1999. Pag. 77-82.
- Lees B. (1999). **Hybrid Case-Based Reasoning Systems**. Workshop 4, Proceedings of the Workshop at ICCBR'99, University of Kaiserslautern.
- Lim H. C., Lui A., Tan H. y Teh H. H. (1991). **A connectionist case-based diagnostic expert system that learns incrementally**. Proceedings of the International Joint Conference on Neural Networks. Pag. 1693-1698. 1991.
- Liu Z. Q. y Yan F. (1997). **Fuzzy neural network in case-based diagnostic system**. IEEE Transactions on Fuzzy Systems. Mayo 1997. Vol. 5. No 2. Pag. 209-222.
- Main J., Dillon T. S. y Khosla R. (1996). **Use of fuzzy feature vectors and neural networks for case retrieval in case based systems**. Proceedings Biennial Conference of the North American Fuzzy Information Processing Society - NAFIPS. Pag.438-443. IEEE, Piscataway, NJ, USA.
- Malek M. (1995). **A connectionist indexing approach for CBR systems**. Veloso M y Aamodt A., Ed.. Case-Based Reasoning: Research and Development. First International Conference, ICCBR-95. Pag. 520-527. Sesimbra, Portugal. Springer Verlag. 1995.
- Mao Q., Qin J., Zhang X. y Zhou J. (1994). **Case prototype based design: philosophy and implementation**. Proceedings. Computers in Engineering 1994. Vol. 1. Pag. 369-74. Ed. Ishii K. Septiembre 11-14. Minneapolis, MN, USA.
- Marinilli M., Micarelli A. y Sciarone F. (1999). **A Hybrid Case-Based Architecture for Information Filtering on the Web**. ICCBR'99. Workshop 4 – Hybrid Case-Based Reasoning Systems: Challenges for Case-Based Reasoning. Proceedings of the Workshops. Pag. IV-23, IV-32.
- Martin O., Inge H., y Brede N. (1999). **Applying CBR and Neural Networks to Noise Planning**. IJCAI '99. WorkShop ML-5. Automating the Construction of Case Based Reasoners. Stockholm, Sweden. 1999. Pag. 50-55.
- Medsker L. R. y Bailey D. L.(1992). **Models and guidelines for integrating expert systems and neural networks**. Hybrid Architectures for Intelligent Systems. Ed. Kandel A. y Langholz G. CRC Press, Boca Raton.
- Medsker L. R. (1995). **Hybrid Intelligent Systems**. Kluwer Academic Publishers.
- Myllimaki P. y Tirri H. (1993). **Massively parallel case-based reasoning with probabilistic similarity metrics**. Althoff K.D., Richter K. y Wess S., Ed. Proceedings of the First European Workshop on Case-Based Reasoning. Pag. 48-53. Kaiserslautern, 1993.
- Reategui E. B. y Campbell J. A. (1995). **A classification system for credit card transactions**. Haton J.P. , Keane M. y Manago M., Ed. Advances in Case-Based Reasoning: Second European Workshop. EWCBR-94. Pag. 280-291. Chantilly, Francia. Springer Verlag.
- Reategui E. B., Campbell J. A. y Leao B. F. (1996). **Combining a neural network with case-based reasoning in a diagnostic system**. Artificial Intelligence in Medicine. Enero. Vol. 9. No 1. Pag.5-27. Elsevier Science B.V. Amsterdam, Holanda.
- Richter A. M. y Weiss S. (1991). **Similarity, uncertainty and case-based reasoning in PATDEX**. Boyer R.S., Ed. Automated reasoning. Kluwer. Pag. 249-265.

Riesbeck C. K. y Schank R. C. (1989). **Inside Case-Based Reasoning**. Lawrence Erlbaum Ass. Hillsdale.

Ross B. H. (1989). **Some psychological results on case-based reasoning**. K. J. Hammond, Proceedings of the Case-Based Reasoning Workshop. Pag. 318-323. Pensacola Beach, Florida. Morgan Kaufmann.

Shinmori A. (1998). **A Proposal to Combine Probabilistic Reasoning with Case-Based Retrieval for Software Troubleshooting**. Case-Base Reasoning Integrations. Papers from the 1998 Workshop Technical Report WS-98-15. AAAI Press, ISBN 1-57735-068-5. Pag. 149-154.

Soucek B. e IRIS group (1991). **Neural and Intelligent Systems Integration**. John Wiley & Sons, Nueva York.

Sun R. (1996). **Commonsense reasoning with rules, cases, and connectionist models: a paradigmatic comparison**. Fuzzy Sets and Systems. Vol. 82. No 2. Pag. 187-200. Elsevier, Septiembre. 1996.

Sun R. y Alexandre F. (1997). **Connectionist-symbolic integration: from unified to hybrid approaches**. Sun R. y Frederic A., Lawrence Erlbaum Associates.

Thrift P. (1989). **A neural network model for case-based reasoning**. Hammond K. J., Ed. Proceedings of the Case-Based Reasoning Workshop. Pag. 334-337. Pensacola Beach, Florida. 1989. Morgan Kaufmann.

Watson I. (1997). **Applying Case-Based Reasoning: Techniques for Enterprise Systems**. Morgan Kaufmann.