

Integración de las Redes de Neuronas Artificiales con Lógica Difusa

Alejandro Pazos & César M. Dans

Laboratorio RNASA

Departamento de Computación

Universidade da Coruña

email: ciapazos@udc.es

email: mcesar@udc.es

1.- Introducción

La intención de este capítulo es ofrecer una panorámica de como se puede producir la integración de técnicas de Lógica Difusa (en adelante LD) con los métodos y técnicas de Inteligencia Artificial conocidas como “Redes de Neuronas Artificiales” (en adelante RNA). Las RNA o “Sistemas Conexionistas” (en adelante SC) son propuestos, inicialmente, en 1943 por McCulloch y Pitts, y tras pasar por 2 décadas de declive en los años 60 y 70, resurgen a principios de los años 80 gracias, en gran parte, a los trabajos de J. Hopfield y otros investigadores como S. Grossberg, T. Kohonen, etc. que, con una fundamentación matemática consistente, profundizan en la búsqueda de modelos biológicos que sean susceptibles de ser implementados en máquinas.

La construcción de este tipo de sistemas complejos integrando LD y RNA no es injustificado, sino que es el lógico e inevitable consecuente del intento de obtener sistemas que procesen los conocimientos, sobre todo los del mundo real, de la forma más “naturalmente” inteligente posible.

Siempre que se trabaje con conocimientos naturales (del contexto del mundo real) estos van a padecer todas, o alguna al menos, de las características que se conocen como la “maldición de la cuádruple I”; es decir, serán inciertos, incompletos, imprecisos e inconsistentes.

La incertidumbre se produce porque los datos, en los que se basan los razonamientos son inciertos (es decir, son verdaderos o falsos, pero no hay forma de saberlo), o porque las reglas de inferencia se obtienen directamente de la experiencia o son heurísticas y, por lo tanto, no completamente fiables. La forma de tratar la incertidumbre es aplicar, a los conocimientos, factores o coeficientes de certidumbre, o mediante la utilización de RNA ya que no precisan de una representación explícita de los conocimientos; y, por tanto, se evitan, generalmente, las imprecisiones.

La incompletud se presenta debido a que no todo lo pertinente al caso en curso puede observarse o recopilarse, o porque no existen suficientes recursos para efectuar todas las deducciones potencialmente interesantes, o aún, porque las teorías del mundo sólo son aproximaciones. Esto implica la exigencia de razonar en base a suposiciones. Las formas más habituales de manejar la incompletud son: asociar respuestas por omisión a ciertas cuestiones, emplear RNA para manejar los conocimientos, etc.

La inconsistencia emerge, en parte, por el manejo de la incompletud; por ejemplo, al pasar por alto una omisión, ya que se puede provocar una contradicción; y, en parte, porque la información puede proceder de fuentes contradictorias. Además, también, porque, a veces, el razonamiento en el mundo real es no-monótono. Para abordar el problema de la inconsistencia, podemos apoyarnos en el mantenimiento de una red de dependencias entre los hechos que luego pueden emplearse para restablecer la consistencia, el razonamiento desde distintos puntos de vista y la utilización de las RNA para procesar los conocimientos.

En cuanto a la imprecisión, se puede decir que: “una expresión es imprecisa, borrosa, vaga o, aún, difusa, si en ella no se define exactamente, al menos, alguna de las variables que engloba”. Más concretamente, se dice que son imprecisas aquellas expresiones que poseen cuantificadores del tipo: algún, mucho, la mayoría, bastante, etc. Para trabajar con la imprecisión se deben emplear técnicas como la LD, las categorías semánticas, las RNA, etc.

Por otra parte, la Teoría de Coordinación en las “máquinas inteligentes” de Wang-Saridis nos dice que estas máquinas presentan 3 niveles de actuación (Figura 1) y que, cuanto más inteligente sea el nivel, menos precisión puede alcanzar. El nivel de coordinación es el responsable de la distribución del control entre los diversos coordinadores, cada uno de los cuales es el responsable de coordinar una faceta del control en el nivel de ejecución (Figura 2).

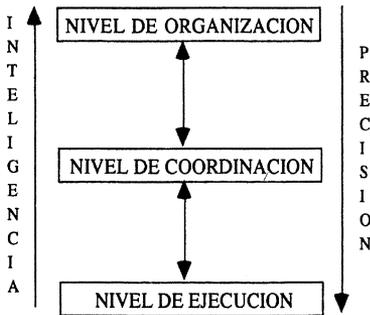


Figura 1.- Inteligencia vs precisión.

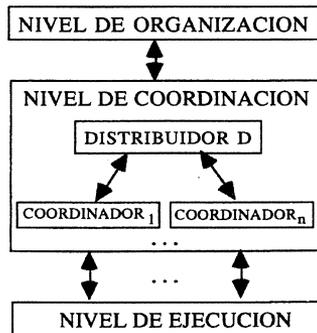


Figura 2.- Control entre coordinadores.

Como puede deducirse de lo previamente expuesto, las RNA pueden ser la única técnica de IA adecuada para tratar adecuadamente, y al mismo tiempo y caso, los cuatro principales inconvenientes planteados por los conocimientos naturales; y, por tanto, para abordar con éxito el intento de manipular conocimientos en los niveles más inteligentes de las máquinas; constituyéndose, así, en la herramienta de IA más oportuna para manejar, en las máquinas, este tipo de conocimientos.

La cantidad de literatura científica donde se integran RNA con otras técnicas y métodos de IA (Sistemas Expertos, Algoritmos Genéticos, etc.) y de Informática Convencional (Bases de Datos Relacionales, Interfaces, etc.) es tan amplia, actualmente, que sugiere una tendencia clara en esta dirección para una parte considerable de la comunidad investigadora.

2.- Justificación del uso de Redes de Neuronas Artificiales Difusas (RND)

Por lo analizado previamente, cuando se quieren utilizar las RNA para solucionar problemas del mundo real, se pueden encontrar dificultades para manejar determinados conocimientos naturales, puesto que éstos suelen ser de los denominados “mal definidos”. Por ejemplo, puede ser dificultoso para una RNA clasificar a una mujer “bastante guapa” o “muy alta”, puesto que estos cuantificadores mal definidos “bastante”, “muy”, etc., dependen en gran medida del contexto (para un pigmeo, una mujer muy alta sería la que midiese, por ejemplo, más de 1,65 metros; pero no lo sería para un escandinavo, donde la media de estatura de sus mujeres supera el 1'70 m.). Otras situaciones potencialmente difíciles de resolver por las RNA serían los conocimientos del tipo: “Si es muy interesante, entonces has de intentarlo insistentemente”; aquí, puede no ser suficiente la flexibilidad funcional de las RNA, ya que es más un problema de representación de los conocimientos, que de flexibilidad para manejarlos.

Para poder tratar adecuadamente estos problemas mal definidos (por ejemplo, ¿cuantos años se le adjudican a una persona de quién se dice que es madura?; 20, 30, 40, quizás 50 ó 60 años) puede ser necesario integrar sistemas adaptativos (como las RNA) con técnicas y métodos que permitan el procesamiento de información borrosa como la LD en las llamadas RND, ya que ambas técnicas, como se expuso previamente, son útiles y complementarias a la hora de manejar conocimientos imprecisos. La complementariedad de ambas técnicas (RNA y LD) se fundamenta, en parte, en el énfasis común en el uso de variables continuas (lo cual también permite un elevado grado de complementariedad con la “Teoría del control no-lineal” y las nuevas aproximaciones para conseguir hardware analógico. A veces, esta complementariedad es tan grande que dificulta el conocimiento de los efectos que produce, en la solución del problema, cada una de las dos técnicas; ya que, en ocasiones, utilizan los mismos procedimientos matemáticos.

Con estos sistemas RND, se potencia la funcionalidad de las RNA en diversos aspectos:

1. Mejora la capacidad o potencia de representación de los conocimientos de las RNA convencionales, al poder atender incluso a valores no definidos, mal definidos o con grados de imprecisión.

2. Como consecuencia del punto (1), se mejora la eficiencia del entrenamiento de las RNA convencionales: requiriendo un menor número de ejemplos para el entrenamiento, siendo más sencillo elaborar un conjunto de entrenamiento completo, etc. Disminuyen, en fin, los requerimientos de potencia y tiempo que han de poseer las máquinas para manejar estos conocimientos adecuadamente.

3. Se incrementa la capacidad de comunicación con el entorno y, por tanto, de la adaptación de la RNA al entorno en el que se desenvuelven o “universo de discurso”. Así, se consigue una mejora en la percepción por la RNA de los estímulos del medio, de forma que definirán mejor los problemas a resolver.

En resumen, la utilización de estos sistemas RND está justificada ya que son capaces de manejar problemas que padezcan de imprecisión, y en entornos que no estén bien definidos o que no tengan sus límites bien determinados, cosa muy frecuente cuando se ha de trabajar con conocimientos naturales o del mundo real.

3.- Alternativas en el funcionamiento conjunto de RNA y LD

Para conseguir estos sistemas RNA-LD (RND) se pueden utilizar varias alternativas. Lo más frecuente es reemplazando los valores escalares tradicionales de las RNA por “regiones difusas”. Dicho cambio puede producirse, sobre todo, a dos niveles: (a) en los parámetros intrínsecos de los elementos formales (EF) o neuronas formales de la RNA; y (b) en los valores de los pesos de las conexiones entre éstos EF de las RNA. Otra forma sería utilizar, independientemente, cada técnica (RNA y LD) en distintas partes de un mismo problema.

Cuando la separación entre los distintos conjuntos de elementos no es muy rígida o marcada, como habitualmente ocurre en los conocimientos naturales, se dice que su clasificación es en zonas difusas. Las alternativas de solución que se plantean a este tipo de problema son las siguientes: (a) si se conocen los sistemas basados en reglas (en adelante SBR), se pueden usar si se dispone, además, de un experto que sea capaz de utilizar LD en lugar de factores de certeza en el manejo de la incertidumbre; (b) si no se conocen los SBR o no se tiene el experto adecuado, se pueden utilizar las RNA para los que se precisará de un

adecuado conjunto de ejemplos para entrenar-construir y verificar la RNA y (c) si se tienen suficientes datos históricos, están bien referenciados y se tiene un experto “genuino” para interpretarlos, se puede usar el razonamiento basado en casos.

Normalmente, no es fácil disponer de un experto “genuino” que además esté familiarizado con la construcción de sistemas basados en el razonamiento (SBR) que manejen LD. Además, un experto puede decir fácilmente, por ejemplo, el porcentaje de mujeres de más de 1'70 m. pero le es más difícil decir el porcentaje de mujeres muy altas.

Por todo ello, se deben emplear los sistemas RND para intentar superar las limitaciones de la Lógica Booleana cuando uno se encuentra con el problema del manejo de conocimientos naturales que padecen la ya citada maldición de la cuádruple I (Imprecisión, Incertidumbre, Incompletud e Inconsistencia); sin caer en recurrir a una interpretación “subjetiva” de los hechos, que pueda ir más allá de una simple distinción entre procesamiento simbólico y subsimbólico de la información.

4.- Fundamentos teóricos

- Conjunto Borroso o Difuso:

Aproximadamente a mediados de los años 60, L. Zadeh presenta los denominados “Conjuntos Difusos o Borrosos” realizando su análisis y formalización.

En la teoría clásica de conjuntos, un elemento “x” pertenece, o no, a un determinado conjunto A, siguiendo la siguiente “función característica” o “función de pertenencia”: $F_P(x) = \begin{cases} 1 \Leftrightarrow x \in A \\ 0 \Leftrightarrow x \notin A \end{cases}$. Por

ejemplo, dado un conjunto $P = \{x: x \text{ es par}\}$ se tiene que $F_x(2) = 1$ y $F_x(3) = 0$. Pero, en los conocimientos naturales, habrá de tenerse en cuenta el contexto en el que está P; sin tener, por tanto, en este caso, una “función característica” sino una “función de compatibilidad” del elemento x con el conjunto P ($\mu_P(x)$). Así, se puede representar, por ejemplo, $\mu_A(1'75) = 0'4$ para definir la pertenencia de una mujer que mide 1'75 m. al conjunto (A) de las mujeres altas en Escandinavia; mientras que $\mu_A(1'75) = 0'9$, si (A) es el conjunto de las mujeres altas en

la tribu Pigmea. Por tanto, los conjuntos difusos se pueden definir como: $A = \{(x, \mu_A(x)), x \in X\}$; y un “sistema difuso” no es más que una aplicación entre dos conjuntos difusos.

La raíz de la diferencia entre la lógica clásica y la LD se halla, por tanto, en lo que Aristóteles llamó la “Ley del Tercio Excluido” (la cual es violada por los sistemas difusos), donde la frontera de pertenencia se va difuminando, siendo la función de pertenencia una curva, no un escalón. La única restricción impuesta a la LD, en este sentido, es que los grados de pertenencia de un objeto a conjuntos complementarios es 1 (Figura 3).

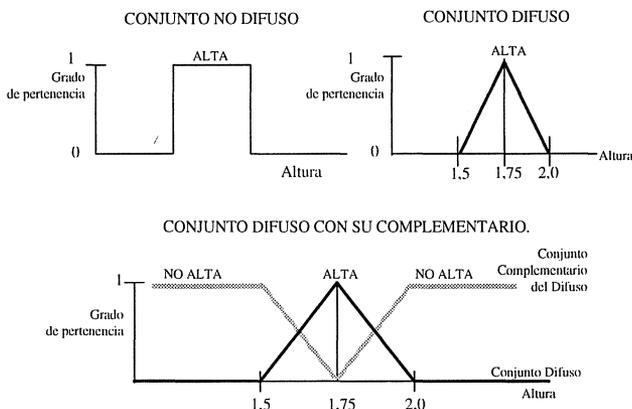


Figura 3.- Grados de Pertenencia en Conjuntos No Difusos, Difusos y Difusos con su Complementario.

Es conveniente, aquí, diferenciar entre “grado de pertenencia difuso” y “porcentaje de probabilidad”: las probabilidades se estiman en qué medida cabe esperar que algo concreto suceda o no, la borrosidad estima el grado en que algo está sucediendo ya, o en el que se está cumpliendo determinada condición. Por ejemplo, el enunciado: “la probabilidad de que la persona con la que cenaré mañana sea alta es del 60%”, expresa una hipótesis de si la persona será alta o no. Sin embargo, “la persona con la que cenaré mañana es alta en un 60%” significa que la persona será, en cierta medida y al mismo tiempo, y en distinto o igual grado, no-alta. La suma de pertenencia al conjunto difuso y a su complementario ha de ser 1. Por ejemplo, si es 60% “alta” también será un 40% “no-alta”.

• Lógica Difusa (LD).

Como consecuencia del análisis y formalización de los conjuntos difusos emerge la LD, la cual se convierte en una potente herramienta a la hora de acercar las matemáticas al razonamiento con “sentido común” y al adecuado procesamiento de los conocimientos naturales. Una de las principales características de la LD es que tiene naturaleza multivalente (acepta valores distintos a Verdadero o Falso) como resultado de no tener porqué ser, las proposiciones, completamente ciertas o completamente falsas.

Para la LD, se precisará de unos nuevos operadores de conjunción y de disyunción para predicados “vagos”, “borrosos” o “difusos” (aquellos que afirman o niegan algo sobre un conjunto difuso) que, usualmente, estarán basados en los valores máximos y mínimos que los elementos puedan adoptar:

$$\mu_{P \cup Q}(x) = \max (\mu_P (x), \mu_Q(x))$$

$$\mu_{P \cap Q}(x) = \min (\mu_P (x), \mu_Q(x))$$

O en el producto:

$$\mu_{P \cap Q}(x) = \mu_P (x) \cdot \mu_Q(x)$$

$$\mu_{P \cup Q}(x) = \mu_P (x) + \mu_Q(x) - \mu_P (x) \mu_Q(x).$$

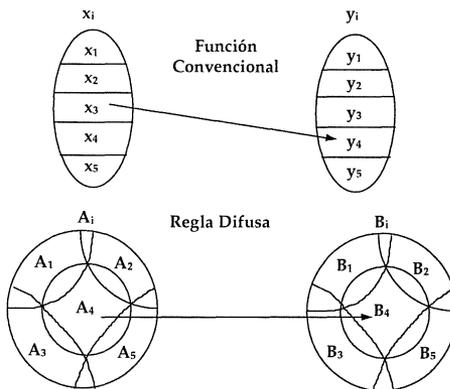


Figura 4.- Diferencia entre una función convencional y una regla difusa.

5.- Elementos Formales Difusos o Neuronas Difusas.

A continuación, en la Figura 5, se verá como se puede comparar a un elemento biológico (en adelante EB) con un elemento formal clásico tipo “McCulloch y Pitts” (en adelante EF) y con un elemento formal difuso (en adelante EFD). Ambos EF, clásico y difuso, suelen tener una arquitectura “ortogonal”; sin embargo, las diferencias, entre ellos, se evidencian cuando se examinan sus propiedades de control.

En la Figura 5, se observa como, en el EFD, se reemplazan los valores escalares de los parámetros de control (representan funciones) de las neuronas y los pesos de las conexiones por regiones difusas.

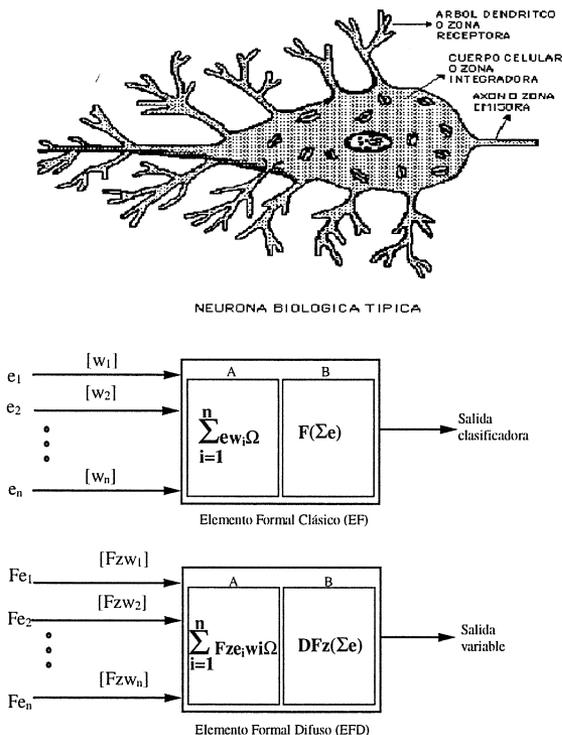


Figura 5.- Comparación entre Elemento Biológico, Elemento Formal Convencional y EF Difuso.

La Figura 7 muestra como la salida del EF es “torpemente” proporcional al estado difuso correspondiente; lo cual se aprecia si se hace una correspondencia entre la fuerza de la señal de entrada y el valor difuso correspondiente, estando representada esta correspondencia por la zona topológica (tamaño) del espacio umbral difuso.

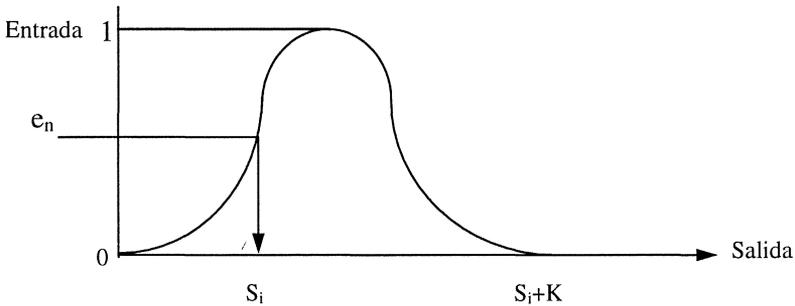


Figura 7.- Proporcionalidad de la salida de EFD.

6.- Redes de Neuronas con EFD

Las RNA solucionan muchos problemas por su capacidad de adaptación a la naturaleza de los datos (señales o estímulos) que reciben del entorno (puede ser otra RNA o cualquier otro dispositivo) mediante distintos tipos de aprendizaje: entrenadas con aprendizaje supervisado, no supervisado, no entrenadas (construidas), etc.

En las RNA con EFD, como ya se ha indicado, se produce una traducción de las arquitecturas de RNA habituales (Figura 8) en términos de matemática borrosa o difusa y se cambian los valores escalares de las conexiones entre los elementos por regiones difusas, y los EF clásicos por EFD.

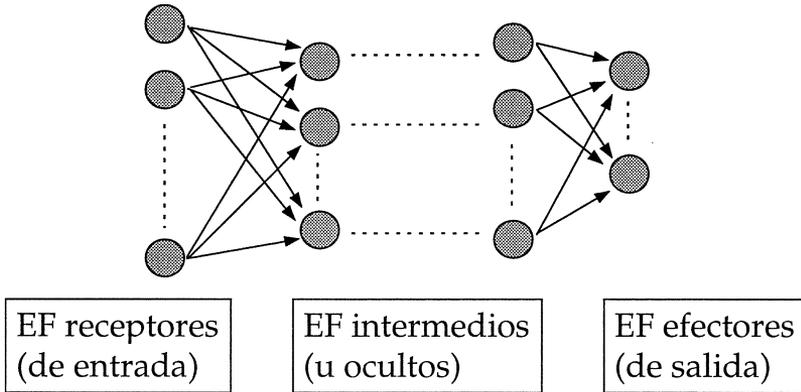


Figura 8.- Arquitectura de RNA clásica.

7.- Aprendizaje supervisado por Retropropagación del Error en las RNA

Como se ha comentado previamente, las RNA se adaptan, mediante un mecanismo de aprendizaje o entrenamiento, a las entradas que reciben del entorno.

Un tipo muy común de aprendizaje supervisado, el más usado en RNA alimentadas hacia adelante y con un tipo de entrenamiento “supervisado” (con un “maestro” que indica el error en la salida para una determinada entrada), es el de Retropropagación del Error, propuesto por P. J. Werbos en 1974, quién presenta una técnica redescubierta independientemente por D. B. Parker y el equipo de D. E. Rumelhart, G.E. Hinton y R.J. Williams en 1980, que ajusta los pesos de las conexiones, de los EF de la RNA, para reducir el error en la capa de salida.

La función lógica que usa este algoritmo de retropropagación es una derivada simple $D(F(e)) = \frac{\partial S}{\partial Te} = S(1-S)$, lo cual es importante en las representaciones difusas, pues requieren funciones universalmente diferenciables.

Para aplicar el algoritmo de “Retropropagación del Error” (en adelante AR) se requieren 2 pases, como se ve en la Figura 9, a través de la RNA. El primero, hacia adelante, (a) genera la clasificación del estado del problema. El segundo, hacia atrás, (b) aplica un procedimiento de ajuste

del error en los EF de cada capa de la RNA, de forma que, en los EF de la capa de salida, se reduce el error entre la clasificación que hace la red y la clasificación adecuada.

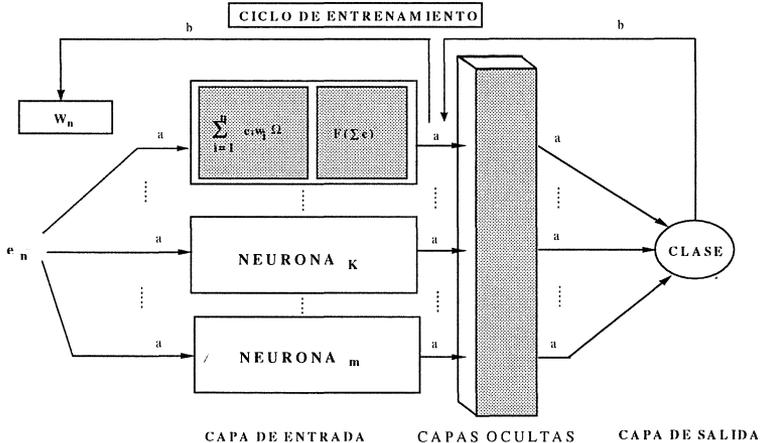


Figura 9.- Esquema de alto nivel de la técnica de "Retropropagación del Error".

8.- Algoritmo de retropropagación difusa (en adelante, ARD)

La primera referencia a la aplicación AR a una RND fué realizada, en 1988, por Paul Werbos. La compatibilidad de la LD y el AR viene dada por el hecho de que las reglas de LD son diferenciables. Por tanto, el algoritmo de aprendizaje (ARD) no se diferenciará sustancialmente, en cuanto a su mecánica, del algoritmo de aprendizaje AR convencional. De hecho, mucha de la literatura sobre aprendizaje en RNA se refiere directamente a cualquier red no-lineal que se comporte correctamente, pudiéndose aplicar directamente a estructuras de inferencia usadas en LD, siendo válida, en ambos casos (RNA y RND), la misma fundamentación matemática.

La retropropagación clásica es, simplemente, una implementación particular de la técnica de estimación del Error Cuadrático Medio (ECM).

Se usa, para ello, una técnica específica y eficiente para calcular las derivadas del ECM respecto a todos los pesos o parámetros en una RNA; entonces, se ajustan los pesos en proporción, directamente, a estas derivadas hasta que se hacen 0. Es conveniente destacar que lo que se retropropaga es el error, no la información.

El utilizar regiones difusas como valores de los pesos de las conexiones, en lugar de valores escalares, le confieren al ARD la característica de que modera el gradiente de la fuerza del peso total de entrada al EF receptor; pareciéndose, en cierta medida, a la idea del "Bias" y al concepto de "Momentum" de Rumelhart, que controlarían la "tendencia" del EF. Ambas características le confieren a la RNA un mayor y más racional poder de representación y un incremento en la velocidad de entrenamiento; precisándose, además, un menor número de pases del conjunto de entrenamiento para obtener el mismo resultado que con un AR convencional, con lo que ello significa en la mejora de la capacidad de generalización y ahorro de tiempo y recursos computacionales.

Por otra parte, el ARD no ofrece problemas serios a la hora de alcanzar estados estables, de caer en mínimos locales, etc., tal como se demostró utilizando "tests de prueba" tras introducir un número determinado de estados problema a clasificar con una RND con sólo 2 capas ocultas. La principal causa de este comportamiento de la RND quizá sea el incremento de poder de representación que se produce en las RND gracias a operar con valores de regiones difusas en vez de con valores escalares, y no gracias a incrementar el número de elementos y de capas ocultas como ocurre en las RNA convencionales.

Por otra parte, el uso de EFD le confiere a las RNA, que extraen conocimientos de una base de datos empírica usada como "conjunto de entrenamiento", unos conocimientos elicitados del experto que proporciona las reglas y los rangos de valores necesarios para definir las regiones difusas iniciales de la RND. En principio, son más fiables los datos empíricos; pero, cuando son demasiado limitados como para permitirle a la RNA aprender relaciones complejas, puede ser oportuna, e incluso imprescindible, la utilización del juicio experto, pasando de ser una fuente de conocimiento secundaria a ser vital para la solución del problema a representar; con lo que se pierde, en parte, cuando esto es así,

el objetivo primero de las RNA que es el uso de los conocimientos implícitos en los ejemplos.

Los sistemas que utilizan el ARD tienen la ventaja de que se pueden aplicar de forma flexible, utilizando una estructura de inferencia diferente para cada caso en el conjunto de entrenamiento. Esta estructura de inferencia puede contener saltos lógicos que van más allá de la capacidad reconocida al AR convencional.

9.- Formas de colaboración entre RNA y LD, en los RND

Actualmente, existen bastantes autores que utilizaron con notable éxito estos sistemas RND. Fu, propone el uso de reglas especiales para manejar el AR en estructuras simples de LD, y Hsu, la utilización de una LD modificada para una mejor integración con las RNA.

Entre las posibilidades obvias de utilización conjunta de LD con RNA está el uso de las RNA en la representación del conocimiento básico y utilizar la LD para reflejar la importancia, la complementariedad, la sustitutibilidad, etc., de los elementos de la RNA y sus conexiones; para poder reflejar, así, en ellos, los conocimientos del experto.

Otra posibilidad es la elaboración de reglas de inferencia difusa. Para ello hay que tener en cuenta que el razonamiento difuso convencional está asociado inherentemente a problemas de ajuste, ya que carece de funciones de pertenencia deterministas. Por ello, con las RND, se pueden formular razonamientos difusos sobre estructuras de RNA capaces de determinar funciones de pertenencia. Actualmente, los algoritmos que son capaces de realizarlo, denominados "NDF", tienen la limitación de que son incapaces de alterar las reglas de inferencia que representa la RNA cuando el entorno de construcción de estas reglas cambia dinámicamente. Por otra parte, se puede proponer un nuevo algoritmo llamado "NDFL" que coordine las reglas de inferencia para compensar la indeterminación del entorno inferencial y puede determinar la función de pertenencia óptima y obtener los coeficientes de las ecuaciones lineales en los consecuentes de las reglas, mediante la función de búsqueda del método de "búsqueda de patrones". Tanto los NDF como los NDFL son capaces, una vez dadas las variables de entrada-salida, de determinar las reglas de inferencia óptimas y las funciones de pertenencia utilizando la

no-linealidad de la retropropagación del error de las RNA y su capacidad de aprendizaje. Con esto, se demuestra, además, que es posible, en la forma ya expuesta previamente, introducir una función de aprendizaje en sistemas que utilicen LD.

10.- Aplicaciones de los sistemas híbridos (RND)

Dos de las principales áreas de aplicación de estos sistemas son:

1. **Generalización del control adaptativo:** adecuación del funcionamiento del sistema en entornos cambiantes.

2. **Maximización del rendimiento o minimización del coste temporal y, o, computacional;** sobre todo en entornos con ruido.

Se van a dividir estas dos áreas de aplicación en tres grandes grupos, dependiendo de cómo se produce la integración de ambas técnicas (LD y RNA).

A) Aplicando independientemente ambas técnicas (RNA y LD): se aplicarán, independientemente, sobre diferentes partes, subproblemas o etapas, del problema inicial; por ejemplo, si no se poseen los datos adecuados para todas las partes del problema, se puede plantear la existencia de etapas intermedias de resolución utilizando, en cada caso y según convenga, la técnica más adecuada (RNA si tenemos datos suficientes y LD si precisamos del conocimiento experto).

A-1. Amano y colaboradores construyeron una RND para reconocimiento de voz en la cual las RNA detectan las características y un sistema con LD realiza la clasificación.

A-2. Schreinemakers y Touretzky emplearon un modelo similar en tareas de diagnóstico industrial (averías en locomotoras) y médico (mastitis).

B) Aplicando conjuntamente RNA y LD: permite eliminar, en cierta medida, la restricción Verdadero/Falso, la cual es muy común en los sistemas simbólicos. Quizás su mejor aplicación sea el Neurocontrol Inteligente (NCI) el cual toma un fuerte impulso en 1988 con la creación, por parte de la National Science Foundation de EE.UU., de un laboratorio para trabajar en control en RNA, en la U. de NewHampshire, dirigido por W. T. Miller, definiéndose el NCI como un “conjunto difuso”, por

supuesto, de técnicas y métodos que surge de la intersección de las técnicas y métodos de la “Teoría de Control” con las de “Neuroingeniería”, tal como se expone en la Figura 10.

El grupo de Miller evidencia que los Trabajos que había en Control-RNA podría resumirse en varias estrategias básicas de diseño, genéricas y, por tanto, aplicables a cualquier red de elementos con funciones diferenciables “Redes funcionales”, y que se podían aplicar directamente a sistemas que utilizasen métodos de aprendizaje.

La aplicación de las RND de más éxito, probada, y estudiada es el “Control Inteligente” o Neurocontrol Inteligente (NCI). Las características específicas más destacables del NCI son: (a) es un nuevo paradigma para solucionar problemas de control que puede realizar tareas de decisión multinivel; (b) está relacionado con la información y la representación del conocimiento; (c) permite nuevas estrategias de planificación del control como la integración de planificación “fuera de línea” con control “en línea”; y (d) proporciona nuevas formas de abordar el complicado manejo de la incertidumbre en el control.

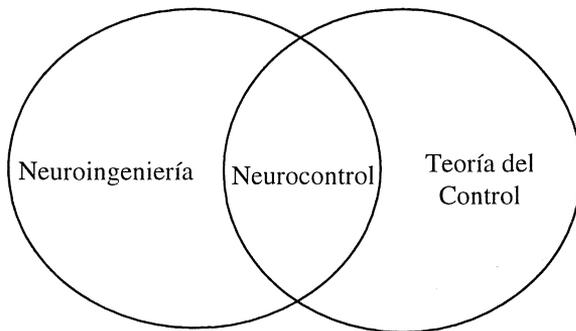


Figura 10.- Emergencia del Neurocontrol desde otras ramas de la ciencia.

En cuanto a la motivación de usar estos sistemas RNA-LD en tareas de control, destacar que los expertos humanos ejecutan bien el control usando el razonamiento aproximado y manejando conceptos difusos. Por ello, el manejo inteligente del control usando este tipo de sistemas

complejos RNA-LD es muy importante para aplicarlo, de forma práctica, en Ingeniería.

Por otra parte, desarrollar un modelo físico matemático en todos los problemas del mundo real no es siempre posible o computacionalmente factible. Así, es preciso un nuevo paradigma que permita solucionar problemas de control y que puede realizar tareas de decisión multinivel. Dicho paradigma ha de estar relacionado con el procesamiento de la información y con la representación del conocimiento. Además, la utilización de técnicas de aprendizaje en el control de un sistema físico puede ser tenido en cuenta, como un tipo de “inteligencia”. Teniendo todas estas premisas en cuenta es fácil adivinar la adecuación de esta técnica RNA-LD a las tareas que requieran Control Inteligente.

La utilización de RNA y RND en NCI es muy variable dependiendo, en gran medida, de la aplicación en particular. A pesar de que existen aproximaciones de carácter general son muy costosas en tiempo y capacidad computacionales.

Las áreas de aplicación más importantes del NCI son:

1) *Vehículos y Estructuras Industriales (motores, equipos, robots, etc.) en funcionamiento.* Según Sofge y White la industria aeroespacial es líder en la aplicación de estas técnicas (NSF-McDonall-Douglas, Jet Propulsion Lab, NASA, etc.) con la intención de hacer posible y realista, gracias a estos sistemas, la idea de un asentamiento espacial humano, sin reemplazar a los humanos en las misiones espaciales, simplemente ayudándole en sus tareas.

2) *Industria Química, en la fabricación continua de materiales ligeros y resistentes y de productos químicos con nuevas propiedades.* El procedimiento es controlar con NCI las reacciones químicas necesarias para obtener los productos.

3) *Telecontrol y ayuda a discapacitados.* Es un campo de acción actualmente en ebullición por la gran repercusión social del tema y los consecuentes recursos públicos destinados a la investigación en este área.

4) *Electrodomésticos y otros dispositivos electrónicos (cámaras de video, televisiones, etc.).* Quizá sea, aquí, donde primero se generalizará el uso del NCI, por ser sus procesos, en la gran mayoría, de propósito general aplicables al resto de los procesos específicos que se pretendan

contemplar. Además, es un campo de investigación que se verá afectado por el gran volumen de negocio que se maneja en el mundo de la “Domótica”, de forma que habrá grandes cantidades de recursos destinados a la investigación, ya que tendrán una “generosa” recuperación de la inversión consecuente. Ya existen lavadoras y lavavajillas que ajustan el ciclo de lavado a la colada, modificando el plan de lavado a medida que la limpieza progresa. Por otra parte, ya se usan RND para el filtrado y recuperación de la señal en televisores cuando reciben una señal baja. Además, con RND, se pueden ajustar cámaras de fotografiado y de video, asociando datos de las imágenes que se pretenden enfocar a diversos ajustes de las lentes (por ejemplo, Panasonic con 13 reglas difusas evita, en gran medida, el temblor al filmar).

5) *Seguimiento, en tiempo real, de trayectorias.* Este área es de especial interés para la industria militar en la fabricación de armamento, tanto de ataque como de detección de ataques; y, también, para la industria civil implicada en temas como el control aeronáutico, marítimo, etc.

6) *Modelización de Propósito General.* Está desarrollándose con mucha fuerza por las grandes aplicaciones prácticas que se vislumbran para las que podría ser muy útil el NCI; por ejemplo, en Economía.

7) *Comunicaciones.* Debido al crecimiento exponencial que se está produciendo en este área, sobre todo por la existencia de las nuevas redes de comunicación de uso masivo por la población (INTERNET, BITNET, ...) se precisará de NCI para controlar tanto la fiabilidad como la confiabilidad y eficiencia de estas comunicaciones multimedia.

8) *Investigación.* En la idea de conseguir nuevos y más potentes modelos hardware (analógicos).

9) *Optimización de Sistemas de Información.* Por ejemplo, la casa Omron supervisa, con LD en un sistema de 500 reglas, el acceso a 5 bases de datos médicas de un sistema de gestión sanitaria.

10) *Computación e Inteligencia Artificial.* Se produce una retroalimentación positiva entre todas estas técnicas y métodos de Computación y de IA; ya que los avances en unas provocan una mejora en los otros. Como ejemplo de esto, decir que se puede utilizar una RNA no supervisada para elegir adecuadamente el conjunto inicial de un sistema difuso, y una RNA supervisada para afinar estas reglas y refinar

el conjunto de ellas (el sistema). Dado que ambas, supervisadas y no supervisadas, se han mostrado útiles en 2 tareas complementarias se suelen usar, así, conjuntamente.

C) Chips de RNA con LD. Quizás sea esta la llave que abra, definitivamente, las puertas de la financiación para investigar, en profundidad, estos sistemas híbridos. La construcción de estos “chips” representa una gran complejidad por las dificultades intrínsecas de cada una de las dos características que pretenden incluir (RNA y LD). De todas formas, ya hay múltiples empresas y laboratorios de computación que tienen disponibles, en el mercado, chips de RNA-LD (Intel, Syntronics, Oxford Computing, Vision Harvest Inc., etc.) y se espera que su número se incremente exponencialmente en los próximos años, a medida que evolucione la tecnología óptica y, o, biológica para la construcción de chips eludiendo los actuales problemas de miniaturización de los chips basados en la tecnología del silicio (calor e interferencias en los canales de comunicación). El primer “chip” difuso fué construido por Toga y Wataneber, en 1985, en los laboratorios AT&T-Bell, manejando hasta 2 millones de reglas por segundo; estos “chips” usan microprocesadores que ejecutan algoritmos difusos de inferencia junto a sensores que miden condiciones de entrada variables.

En este mundo de los Sistemas Híbridos (RND), se está dando una rara circunstancia que consiste en que, en estos momentos, en el ambiente industrial se están manejando aspectos fundamentales, sobre todo en NCI, que la mayoría de los académicos apenas comienzan a vislumbrar. Este hecho, que aún no se puede apreciar si generará algún tipo de problema, puede ser debido a dos aspectos, quizá tres: el primero sería la afinidad de la industria a la hora de incorporar las nuevas tecnologías a los procesos industriales; el segundo sería debido a una especie de “insensatez” y “prematuridad” por parte de la industria, como resultado de competir en un mercado muy cambiante y ávido de nuevas tecnologías y sensaciones; y, el tercero, sería debido a una mezcla de las dos anteriores, en mayor o menor proporción. Probablemente exista, al menos en una pequeña parte, una cuarta causa-razón que sería la excesiva inercia, en algunos casos, del mundo académico a la hora de desarrollar e integrar nuevas técnicas y métodos.

Todas estas causas-razones pueden llevarnos a dos situaciones en este área tecnológica avanzada. O bien que la industria se equivoque al apostar por estas técnicas y métodos, o bien que la industria acierte y deje al mundo académico en un segundo plano muy distante perdiéndose, de este modo, definitivamente la posible, deseable y necesaria colaboración en Investigación y Desarrollo de productos industriales, entre el mundo Académico-Investigador y la Industria.

11.- Ejemplo de una RND: Mapas Cognitivos Difusos (MCD)

Fueron desarrollados por B. Kosko, en 1987, como una alternativa a la representación tradicional de los conocimientos en los sistemas expertos (SS.EE.). Estos MCD realizan la evaluación de la credibilidad del conjunto de reglas de inferencia de los SS.EE., evitando, así, una excesiva dependencia de los conocimientos del experto.

Conceptualmente, los MCD son una RNA “valorada” donde los nodos representan los diferentes conceptos del problema, y los arcos o conexiones entre los nodos reflejan la interacción entre dos conceptos mediante valores de relación adaptativos; esto es, automáticamente modificables ante la presencia de nuevas evidencias en la forma que, a continuación, se indica; y que recuerda la forma de aprendizaje que se conoce como “hebbiana”.

- Si la presencia de un nodo influye en la presencia de otro, la interacción es positiva,
- En caso contrario la interacción será negativa (incompatibilidad).
- En ausencia de relación, la interacción será nula.

La Figura 11 representa, genéricamente, la arquitectura y las relaciones entre los elementos constituyentes de un Mapa Cognitivo.

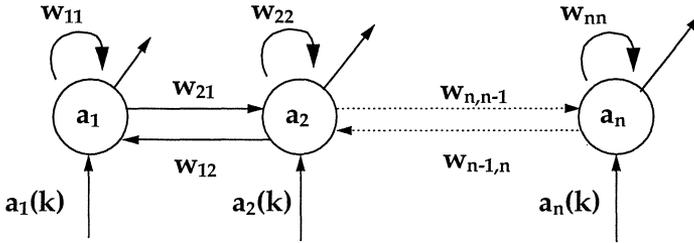


Figura 11.- Modelo de un Mapa Cognitivo de Kosko.

Los pasos para la construcción de un MCD son:

1. Determinar la arquitectura o topología previa del sistema: consiste en identificar los elementos fundamentales del problema a resolver y cuantificar, en lo posible, las relaciones entre ellos.

2. Establecer el mecanismo adaptativo que evaluará y corregirá los valores de las conexiones ante la llegada de nuevas evidencias para incorporar la nueva información, en una forma de “corrección del error” que puede ser de las usadas en RNA o cualquier otro tipo de aproximación de “aprendizaje automático” como el “aprendizaje inductivo” de Quinlan, Michalski, etc.

Un ejemplo de MCD se ve, en la Figura 12, con la información elicitada de un experto en tráfico y su grafo asociado, para resolver problemas de control de circulación en autopistas.

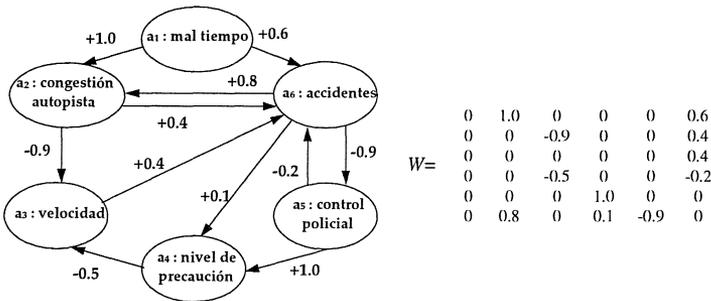


Figura 12.- Ejemplo de Conocimientos expresados mediante un Mapa Cognitivo Difuso.

Alguno de los conocimientos expresados en la Figura 12 son del tipo: “la credibilidad de que aumenten los accidentes en la autopista a causa del mal tiempo es de 0’6”.

Si se supone que, en el instante inicial, los conceptos a_j están presentes en un grado μ_{aj} , donde μ_{aj} es la función de compatibilidad de la evidencia con cada concepto a_j . Se puede identificar, entonces, el estado de activación de las a_j con la compatibilidad de la evidencia de los objetos considerados: $(a_1, a_2, \dots, a_n) = (\mu_{a1}, \mu_{a2}, \dots, \mu_{an})$.

Inicialmente, las relaciones entre los diferentes conceptos (a_j) los establece subjetivamente el experto, estando representados por los pesos entre los conceptos; siendo, por tanto, w_{ij} el grado de influencia del elemento i sobre el elemento j . En general, no se suelen usar conceptos autoexplicativos, siendo $w_{ii}=0$. Una vez representados los valores iniciales de certeza éntre los conceptos, ante la llegada de nuevas evidencias y mediante una variante del aprendizaje Hebbiano, estos valores se modifican automáticamente representando en las conexiones los nuevos conocimientos adquiridos.

Por ejemplo; ante la llegada de una nueva evidencia $k = (a_1(k), a_2(k), \dots, a_n(k))$, el conocimiento se incorpora variando la certeza (w_i) de las relaciones causales: si las variaciones de dos conceptos $a_i(k)$ y $a_j(k)$ van en el mismo sentido, se refuerza la relación de consecuencia, debilitándose en otro caso. El término $-w_{ij}$ relaja la relación entre ambos conceptos cuando no sufren variación. Se puede dar el caso, según la siguiente expresión, que si se aplica estrictamente, la certeza de una regla no es necesariamente un valor en $[0,1]$.

$$\Delta w_{ij} = -w_{ij} + \Delta f(a_i(k))\Delta f(a_j(k))$$

Las operaciones de la ecuación previa se refieren a la aritmética difusa y f es una función genérica que permite comportamientos no lineales del valor del concepto.

El estado general de un MCD viene dado por la expresión general:

$$\Delta a_i = -\alpha_i(a_i) \left[\beta_i(a_i) - \sum_{j=1}^p w_{ij} f(a_j) \right]$$

donde α es una función no decreciente, β_i es una función acotada arbitraria y f es una función sigmoideal. Generalmente, la fórmula anterior se simplifica a:

$$\Delta a_i = -a_i + \sum_{j=1}^n f(a_j)w_{ij} + I_i$$

siendo I_i el i ésimo componente de la entrada inicial. Un MCD estabilizado puede verse como una memoria autoasociativa aunque, según las expresiones matemáticas vistas previamente, generalmente los estados de la red no serán estables sino que mostrarán un comportamiento cíclico, no pudiéndose hablar, entonces, de un estado final que represente una determinada consecuencia. Esto es un grave inconveniente, ya que, al no haber un estado terminal, no se puede descifrar la secuencia de estados de las unidades.

Dado que se utilizan las salidas de los MCD como nuevas entradas al mismo, se convierten en unas Redes Recurrentes con comportamiento dinámico que puede proporcionar inferencias de nivel superior o más complejo, ofrecer relaciones insospechadas entre elementos, depurar el modelo ante inconsistencias, etc.

Una ventaja adicional de los MCD es que se pueden combinar MCD de diferentes dominios compartiendo conceptos comunes, de forma similar a como se cree que se procesa la inferencia en los circuitos cerebrales, donde cada neurona puede participar en la representación de diversos conocimientos, activándose cuando se “anuncia” cualquiera de los conocimientos en los que participa en su representación.

Por otra parte, los MCD también se pueden utilizar para agrupar, de forma relativamente sencilla, en un único MCD, los conocimientos de varios expertos; proponiendo Taber y Siegel que lo hacen más fácilmente, incluso, que si se usan SS.EE., existiendo múltiples mecanismos para verificar y validar la adecuación de los conceptos y las relaciones propuestas.

12.- Conclusiones

Las necesidades de un Sistema Realmente Inteligente actuando en un entorno del mundo real atenderá, al menos, a las 2 siguientes características.

• **Capacidad de Adaptación.** La mayoría de las “RND” son la “traducción” de las RNA en términos de LD. Ambas tecnologías RNA-LD son complementarias y ya hay disponibles en el mercado bastantes de estos sistemas “RND”. La adaptación se puede conseguir gracias a la utilización de algoritmos de aprendizaje que, automáticamente, modifiquen la credibilidad de las relaciones entre los conceptos del sistema, ante cada nueva entrada.

• **Flexibilidad de Representación.** Los “RND” son adecuados para representar un entorno y unos conceptos cambiantes o difusos, como los del Mundo Real. Estos sistemas, como ya se ha comentado, pueden presentar problemas de estabilidad, en el caso de los MCD, o de otro tipo si se usan otras arquitecturas, pero globalmente presentan un correcto funcionamiento.

Sin embargo, para emular verdaderamente el comportamiento inteligente, aún será necesario incrementar enormemente la complejidad de estos sistemas. Uno de los obstáculos a superar será la denominada “maldición de la dimensionalidad” de los sistemas que usan la LD: “el número de reglas para representar los conocimientos tiende a crecer exponencialmente cuando el número de variables del sistema aumenta”. Surge, así, la tendencia a la integración de las RNA con Sistemas Basados en Reglas, Sistemas de Aprendizaje Automático, Algoritmos Genéticos, Sistemas de Lógica Difusa, etc, conformando los denominados “Sistemas Híbridos” o “Sistemas de Filosofía Híbrida”, para intentar paliar, en lo posible, esta situación y no tener que recurrir a enormes sistemas para poder representar adecuadamente los conocimientos.

Es factible predecir que, probablemente, la próxima generación de RND ha de abordar sistemas no lineales a gran escala y con múltiples variables, con los problemas que ello supone.

Concluyendo, si lo que se quiere es emular, en algún grado, el comportamiento inteligente de los humanos, no queda otro remedio que abonar un coste que consiste en el incremento de la complejidad de los sistemas que pretenden realizar dicha emulación. La naturaleza nunca ha abierto todas las puertas con una única llave; así, nace la necesidad de construir los “sistemas híbridos” en un intento de aprovechar las características positivas de todos estos métodos y técnicas de la Lógica (Convencional y Difusa), la Informática (Convencional e Inteligencia

Artificial), la Ingeniería, etc. para lograr la construcción de estos complejos sistemas que se precisan para alcanzar, en sistemas artificiales, un verdadero y natural comportamiento inteligente.

Bibliografía

- Alonso Amo, F. & Pazos Sierra, J.: “La superación de los obstáculos para el desarrollo de la Inteligencia Artificial”. *Inteligencia Artificial: Fundamentos Teóricos y Aplicaciones*. Real Academia de Ciencias Exactas, Físicas y Naturales. 1992.
- Amano et al.: “On the use of NN and Fuzzy Logic in Speech Recognition”. *Proc. IJCNN-IEEE*. New York. 1989.
- Axerlod, R.: “Structure of Design”. Princeton University Press. Princeton. 1976.
- Bell, R.E. y L.A. Zadeh: “Decision Making in a Fuzzy Environment”. *Man. Sci.* 17, 4, pp. 141-164. 1970.
- Berenji, H.: “Fuzzy and Neural Control”. Antsalkis & Passino Eds. Elsevier. N. Holland. 1991.
- Cox, E.: “Integrating Fuzzy Logic into Neural Nets”. *AI Expert*. June 1992.
- Dubois, D. & Prade, H.: “Fuzzy Sets and Systems.” Academic Press. Nueva York. 1980.
- Fogel, D.B., Fogel L.J. y Porto, V.W.: “Evolving Neural Networks”. *Biological Cybernetics*, 63, pp. 487-493. 1990.
- Gupta, M.M. : “Cognitive information and Neural Computing Systems”. *Proc. of the 2nd. Intl. Conf. on Fuzzy Logic*, pp. 649-652. 1992.
- Hebb, D.O.: “The Organization of Behavior.” John Wiley & Sons. Nueva York. 1949.
- Kosko, B.: “Fuzzy Systems as Universal Approximators. *Proc. of IEEE FUZZ*, 1992.
- Kosko, B.: “Fuzzy Function Approximation. *Proc. IJCNN*, Baltimore. 1992.
- Kosko, B.: “Neural Networks and Fuzzy Systems. Prentice Hall. Englewood Cliffs, NJ. 1992.
- Kosko, B. & Isaka, S.: “Lógica Borrosa”. *Investigación y Ciencia*. Septiembre 1993.

- Minsky, M.: "Logical versus Analogical or Symbolic versus Connectionist or Neat versus Scruffy. en Winston, P.H. y Shellard, S.A. (ed) AI at MIT: Expanding Frontiers, pp. 219-243. MIT Press. Cambridge, MA. 1991.
- Morita et al: "Fuzzy Knowledge Model on NN. Type". IJCNN Proceedings. Erlbaum. Hillsdale. N.J. 1990.
- Narandra, K.: "Adaptive Learning Rule". Proc. 6th Yale Workshop on Adaptive and Learning Control. Yale Ed. New Haven. Conn. 1990.
- Olmeda I. & Barbo-Romero S.: "RNA: Fundamentos y Aplicaciones." Servicio de Publicaciones de la Universidad de Alcalá. Madrid. 1993.
- Scherinemakers, J. & Touretzky, D.: "Interfacing a NN. with rule-based reasoner for diagnostic mastitis". IJCNN Proc. Earlbaum. Hillsdale. NJ. 1990.
- Sontag, E.: "Feedback stabilization using to hidden layers net". SYCON-90-11. Rutgers University Center for Systems and Control. New Brunswick. NJ. 1990.
- Stork, D.G., Walter, S., Burns, M. y Jackson, B.: "Preadaptation in neural circuits." Proceedings of the international Joint Conference on Neural Networks, I, pp. 202-205. Erlbaum, Hillsdale, NJ. 1990.
- Sugeno, F.: "Industrial Applications of Fuzzy Control". North Holland. Amsterdam. 1985.
- Taber, R.: "Knowledge Processing with Fuzzy Cognitive Maps." Expert Systems with Applications, 2. pp. 83-87. 1991.
- Takagi, H.: "Fusion Technology of Fuzzy Theory and Neural Networks". Proc. Fuzzy Logic and Neural Networks. Izzuka. Japan. 1990.
- Togai, M. & Watanabe, H.: "Expert System on a Chip: An Engine for Realtime Approximate Reasoning. IEEE Expert, 1, pp. 55-62. 1986.
- Zadeh, L. A.: "Fuzzy Sets". Information and Control. 8. pp. 338-353. 1965.
- Varios autores: "Algunos aspectos del tratamiento de la Información en Inteligencia Artificial". Universidad de Granada. Dep. de Ciencias de la Computación e Inteligencia Artificial. 1991.
- Werbos, P.: "Neurocontrol and related techniques. Handbook of Neural Computing Applications". A. Marien Eds. Academic Press. New York. 1990.
- Werbos, P.: "Handbook of Intelligent Control". White and Sodge Eds. Van Nostrand. Amsterdam. 1992.

- Werbos, P.: "Neurocontrol and Fuzzy Logic: Connections and Design". National Science Foundations. Washington DC. 1992.
- Werbos, P.: "Backpropagation: Past and Future". Proc. 2nd IJCNN-IEEE. NY. 1998.
- Werbos, P.: "Making diagnosis work in the real world: A few tricks". Handbook of Neural Computing applications. A. Marien-Academic Press. NY. 1990.