

DISEÑO E IMPLEMENTACIÓN DE REDES HÍBRIDAS NEURO-DIFUSAS PARA EL CONTROL DE PROCESOS INDUSTRIALES *

Ing. Hernán Darío ALVAREZ, M.Sc. & Ing. Demetrio Arturo OVALLE C., Ph.D

UN-GIDIA (Grupo de Investigación y Desarrollo en Inteligencia Artificial,
Reconocimiento de Patrones e Informática Educativa)
Postgrado en Ingeniería de Sistemas
Facultad de Minas

UNIVERSIDAD NACIONAL DE COLOMBIA, Sede Medellín,
Calle 65 # 78-28, Bloque M1 piso 4°
tels: (94) 425 98 29 / 45, fax: (94) 234 10 02
e-mails:hdalvare@perseus.unalmed.edu.co,
dovalle@perseus.unalmed.edu.co

RESUMEN

La utilización de técnicas híbridas de Inteligencia Artificial se presenta como opción viable para abordar la construcción de sistemas inteligentes, con muchas ventajas sobre las individuales. Se propone una Red Híbrida Neuro-Difusa (RHND) que, sin utilizar una herramienta de Sistemas Expertos, implanta un control difuso con cualquier número de reglas de producción, trasladando el significado de dichas reglas y su relaciones internas a las conexiones de una red que posee nodos con funciones particulares. Se examina entonces la aplicación de una RHND al control en la producción de carbón activado de una planta piloto ubicada en la UNAL-Medellín. Finalmente, se exponen los resultados comparativos entre el controlador tradicional y el implantado con la RHND, para este proceso, comprobándose las ventajas del controlador que usa técnicas de IA para su operación.

1. INTRODUCCIÓN

Cualquiera que sea el área de la ingeniería en la que se esté intentando obtener una modelación de un sistema físico, lo primero que se debe abordar es la selección de un mecanismo de representación de todo el conocimiento que se tiene sobre el fenómeno. Los medios de representación se pueden dividir en dos grandes grupos.

1.1 Representaciones Simbólicas

Son las más comunes, puesto que atienden al mecanismo natural de comunicación del ser humano, la representación de los eventos de la naturaleza mediante símbolos, más o menos universales, que sin ser el objeto mismo que representan, transmiten el mensaje de la existencia

* Esta investigación es patrocinada por el proyecto 1118-14-091-94 de Colciencias intitulado: "Diseño y Desarrollo Metodológico de SBCs (Sistemas Basados en Conocimientos) distribuidos y cooperantes aplicados a la Ingeniería"

de dicho objeto y sus características más relevantes. Esta representación presenta muchas variantes, todas con el elemento común del símbolo como sustituto del objeto o propiedad real.

- **Representación Simbólica como Colección de Conocimientos**

Este tipo de representación busca emplear una estructura conceptual para describir y modelar los elementos del conocimiento que intervienen en el dominio de la aplicación y que son claves para la resolución del problema. De otra parte, cada estructura tiene asociado un proceso interpretativo o mecanismo de razonamiento el cual maneja los conocimientos almacenados en la estructura. La representaciones simbólicas más utilizadas son las reglas de inferencia, los marcos, las redes semánticas, con manejo de incertidumbre (mediante lógica difusa). A continuación se examinará esta última representación, la cual sirve de fundamento a las Redes Híbridas Neuro-Semánticas.

- **Representación Simbólica con manejo de Incertidumbre (mediante Lógica Difusa).**

En la lógica tradicional la pertenencia de un elemento a un conjunto se define con un atributo de pertenencia o no pertenencia, valores absolutos únicos y excluyentes uno del otro. Con este tipo de conjuntos claramente delimitados, la representación del conocimiento de un experto, que por lo general se expresa con términos lingüísticos, resultaba muy difícil de capturar con toda su riqueza, por lo que se recurrió a definir una clase particular de conjuntos de elementos que no tienen un límite definido sino difuso, de modo que para valorar la pertenencia de un elemento a uno de estos conjuntos borrosos se recurre a un calificativo numérico continuo entre 1 y 0 (pertenece o no pertenece respectivamente), denominado factor de pertenencia, que permite representar términos lingüísticos como Alto, Bajo, Rápido, Despacio, etc. como subconjuntos difusos que se superponen para conformar un universo de discurso del problema (Self, 90), (Driankov et al, 93).

1.2 Representaciones Conexionistas

Estas técnicas aparecen como imitaciones burdas del comportamiento del cerebro de los mamíferos, en los cuales, millones de células, muy limitadas en términos de la función individual que realizan, al unirse en una red altamente interconectada logran desarrollar tareas bastante complejas. Precisamente, el almacenamiento del conocimiento sobre el fenómeno se hace en las conexiones que unen los nodos individuales de la red, además de contar con la posibilidad de operar sobre la función de procesamiento que realiza cada nodo individualmente. En este tipo de representaciones, el símbolo no es evidente, puesto que la fortaleza de las conexiones y los parámetros internos de la función del nodo no son de interpretación directa, por lo que algunos autores denominan este tipo de representación como de caja negra. A diferencia de la representación simbólica, en la representación conexionista, los pesos de las conexiones y los parámetros internos de cada nodo se deben entrenar, con base en ejemplos o muestras del comportamiento del sistema que se desea modelar. Este tipo de procedimientos atienden a obtener muy buenos datos de entrada y salida del sistema. Existen varios tipos de medios para representación conexionista.

- **Redes Neuronales Artificiales.**

Es tal vez la tecnología con más carga de emotividad cuando se la ataca o cuando se la defiende, tal vez porque su idea original está en el cerebro del hombre, puesto que con las redes neuronales

artificiales se busca mimificar el comportamiento de las redes neuronales naturales que residen en el cerebro de los mamíferos. Se han logrado modelos matemáticos que permiten simular el comportamiento de una neurona individual frente a la carga de información que recibe desde otras neuronas y la manera en que produce una respuesta de inhibición o activación con esta información (Freeman and Skapura, 93). Con estos modelos individuales ha sido posible construir redes que burdamente imitan las reales del cerebro, de modo que se logra procesar información con un mecanismo similar al natural, logrando alta velocidad y características típicamente humanas como la generalización y el aprendizaje a partir de ejemplos, además de obtener procesamiento de información incompleta, vaga o incluso incierta, con la certeza que lo hace un ser humano. De estas características se han aprovechado áreas como la aeronáutica para construir y entrenar RNA que puedan operar un avión a altas velocidades (3 o más veces la velocidad del sonido) como la hace un ser humano a bajas velocidades, límite natural de la velocidad de reacción del hombre. Se han ensayado RNA que imitan perfectamente las destrezas del mejor piloto, pero que corriendo en un computador a alta velocidad de procesamiento, pueden operar el avión a velocidades mucho mayores que el mejor piloto humano.

Existen diversas configuraciones de RNA que se han ensayado, algunas buscando explicar el comportamiento del cerebro humano en labores como el razonamiento, el aprendizaje, etc. otras simplemente como invenciones ingenieriles de aplicación práctica. Pueden mencionarse, entre otras: la RNA de Alimentación desde Adelante (Feedforward Networks), la RNA de Hopfield o la RNA de Kohonen. Dichas redes no son el objeto de este artículo y por lo tanto no serán examinadas. Información más detallada sobre ellas puede ser encontrada en (Alvarez & Ovalle, 95).

- ***Redes Híbridas Neuro-Semánticas.***

La configuración en red, con nodos y enlaces entre ellos, permite más riqueza estructural y paramétrica que las representaciones simbólicas. A pesar de esta ventaja, las redes de nodos con funcionalidades genéricas: sigmoides, discriminantes duros, etc. pueden aprovechar en muy poca magnitud el conocimiento previo del fenómeno o la experiencia que sobre el mismo se tenga, porque estos nodos no permiten modificar el tipo de función de activación o de procesamiento interno. Por lo anterior, se requiere de la introducción de funciones de tipo semánticas, como calificativos lingüísticos de eventos, de estados posibles, de tendencias de variación, etc. y el aporte adicional del establecimiento de conexiones ponderables entre dichos nodos (Lin and Lee, 91). El aporte que realizan las redes neuronales artificiales a este tipo de representaciones, es significativo en la estructura y configuración genérica de los nodos, así como en los métodos de ajuste de los ponderadores o pesos de las conexiones, conocidos como entrenamiento o aprendizaje. La representación semántica, por su parte, aporta a esta representación híbrida la posibilidad de usar a-priori conocimiento y experiencia sobre el fenómeno que se está representando. Este tipo de aporte semántico se constituye en una pista o indicio para facilitar el aprendizaje de la red. Adicionalmente, se tienen ventajas de tipo funcional y operativo, porque se logra disminuir el tiempo de entrenamiento y se facilita el diseño inicial de la red, además permite representaciones mejores de sistemas complejos, a un costo computacional menor y con un grado de generalización más alto.

Una de las aproximaciones que más se está utilizando en el mundo por su versatilidad, en este tipo de configuraciones, es la de atributos difusos expresados como reglas típicas:

SI <atributo difuso> ENTONCES <atributo difuso>

El grupo de reglas que se obtienen como representación del conocimiento particular sobre el fenómeno, pueden usarse para inferir mediante algún mecanismo deductivo, consecuencias de las evidencias disponibles (Sugeno and Park, 93). Aunque lo más normal es la implantación mediante un motor de inferencia sobre las reglas, escritas como líneas individuales, es posible representar ese grupo de reglas como una red de nodos y realizar la inferencia como una propagación de información desde la entrada de la red hasta su salida. Las redes constituidas de esta manera, denominadas Redes Híbridas Neuro-Difusas RHND, toman su topología de las RNA típicas, pero intercalan capas de nodos con funciones internas más complejas, como por ejemplo las funciones de pertenencia a subconjuntos difusos. Esto no implica que se pierdan las habilidades típicas de las RNA en los aspectos de generalización y aprendizaje, ganando además en velocidad de entrenamiento, puesto que en este caso el número de pesos (parámetros) a ajustar es mucho menor, con la ventaja adicional de que se parte con un conocimiento heurístico del proceso, lo que facilita sobremanera el diseño del sistema en las etapas iniciales. Además, se pueden usar todas las reglas posibles de la partición de los universos de discurso de entrada, sin la reducción en el número de reglas recomendada en la literatura (Li and Lau, 89), (Yamakawa, 93). Esto permite que las transiciones en la salida del modelo sean más suaves y continuas, sin aumentar la carga computacional, debido al esquema de ejecución en paralelo que se logra con la RHND.

El ajuste de los parámetros de una RHND se puede hacer supervisadamente, mediante cualquier técnica de entrenamiento de redes: Algoritmos Genéticos (Holland, 93), Transmisión Química Bacteriana (TQB o en inglés Bacterial Chemotaxis) (Bremermann and Anderson, 90) e incluso retropropagación del error con algunas modificaciones (Fukuda and Shibata, 92). Cualquier técnica que se use debe poder acceder, sin distinción, a todos los parámetros ajustables de la red, que aquí a diferencia de las RNA son mixtos: internos a los nodos y externos a estos, como ponderaciones de conexiones.

2. CONTROL DE PROCESOS INDUSTRIALES

El control del estado de las variables de cualquier proceso productivo es una labor irremplazable, cuando se desea obtener la mejor calidad del producto final y aumentar la utilidad económica. Adicionalmente, los requerimientos de preservación ambiental están exigiendo más controles y más sofisticación en el manejo del proceso. Todo esto conduce a la necesidad de sistemas de control cada vez más efectivos, en las tareas bastante complejas de algunos procesos industriales, hasta hoy controlados pobremente. Muy a menudo una variable controlada en un proceso es una variable de carga para el siguiente en la línea de producción, lo que obliga a su control. Debido a que las variables de carga y las variables manipuladas afectan a las variables controladas, el problema del control es mantener una relación adecuada entre las variables de carga y las variables manipuladas, de modo que el proceso presente un comportamiento prefijado en sus variables controladas. El trabajo del sistema de control es, por lo tanto, permanentemente determinar y actualizar los valores de las variables manipuladas, con dos posibles fines: Mantener las variables controladas en los

valores deseados o puntos de ajuste, denominado control regulatorio; Alcanzar un valor deseado de la variable controlada, denominado control servo o control de seguimiento (Tracking Control).

Existen diversas maneras de implantar un sistema de control que actúe sobre el proceso que se desea manejar. Las más tradicionales y antiguas son todas mecánicas, evolucionando luego a las hidráulicas, posteriormente a las neumáticas, las cuales todavía sobreviven luego de reinar por más de medio siglo, hasta llegar a las tecnologías de controladores eléctricos y electrónicos, los cuales desde la irrupción del circuito integrado microprocesador en la década de los setenta, originaron el control asistido por computador, que es la implantación de mecanismos de control que más ha avanzado en los últimos cuarenta años, fundamentalmente debido a la flexibilidad que brinda en el cambio del control mismo en términos de modo, estrategia y aplicación.

No obstante el avance logrado con la irrupción del computador como herramienta para realizar control sobre el proceso, existen una buena cantidad de procesos que no han podido automatizarse usando técnicas tradicionales y algunas algorítmicas avanzadas. Esto se debe principalmente a las características inherentes al proceso como no linealidades, interacción fuerte entre variables, variaciones con el tiempo de las características del fenómeno, etc. El grado en el cual se requiere la intervención humana en el control de un proceso es un índice de su complejidad o de la baja capacidad de control del sistema instalado para este fin (Kinney, 83; Badavas, 84).

Una manera de hacer control que se esta abriendo paso rápidamente en el mundo para estos procesos, hasta hoy solo bajo control manual, es el Control Inteligente. Con este tipo de control se busca imitar las habilidades de un operador humano, que por lo general es el ultimo recurso y el que siempre logra un buen desempeño en la tarea de control sobre estos sistemas complejos. Estas implantaciones gozan de características de inteligencia, por lo que es mediante el uso de técnicas de Inteligencia Artificial que se puede llegar a este tipo de controladores inteligentes.

3. UNA PROPUESTA DE RED HÍBRIDA NEURO-DIFUSA APLICABLE AL CONTROL DE PROCESOS INDUSTRIALES

El uso de herramientas individuales de IA aplicas al control de procesos industriales es hoy un tópico bastante estudiado. Los que más avance han logrado son las RNA y los SBCs. Estos últimos son sistemas que se caracterizan por tener una representación de conocimientos sobre un área particular del saber. En control, han encontrado gran uso debido a su facilidad para emular el comportamiento humano frente a un problema particular (conocimiento experto) y permitir la mejora continua en el conocimiento almacenado. Una primera aproximación al control asistido por computador, que se apoya en esta técnica, es el uso de reglas exactas, sobre las cuales no pesa ninguna clase de incertidumbre. Por lo general esto no funciona del todo bien, puesto que sobre la información suministrada por el grupo de expertos operarios pesan varios tipos de incertidumbre. Aparecen enfoques alternativos, entre los que vale mencionarse la Lógica Difusa (Fuzzy Logic), un enfoque totalmente nuevo y que supera el escollo lingüístico en la comunicación con el grupo de expertos, además de proporcionar un mejor entendimiento de las cláusulas del sistema.

En esta Lógica Difusa (Zadeh, 65), cada término lingüístico calificativo de una evidencia, forma un subconjunto en el que la pertenencia de los elementos está en todo un intervalo de infinitas posibilidades (0 a 1), definido mediante un subconjunto difuso de grados de pertenencia μ , a un

calificativo lingüístico particular, sobre todo el universo de discurso o intervalo total de la variable. Con esta inclusión de una lógica difusa, para el manejo de las reglas, se gana también capacidad de aprendizaje, la que en los sistemas simples se logra mediante la generación de nuevas reglas o abolición de reglas existentes, con el riesgo de perder la consistencia del sistema experto. En el enfoque difuso, el aprendizaje se puede obtener con la modificación de la forma misma de los subconjuntos difusos de pertenencia a cada calificativo lingüístico, lo que permite aplicar técnicas de retropropagación de alguna señal, indicativa de la calidad del control para adecuar la forma de dichos subconjuntos (Fukuda and Shibata 92), (Werbos, 93).

De otra parte, las RNA han encontrado un terreno propicio para producir neurocontroladores capaces de mimificar el comportamiento de un operador humano en tareas tan complejas como el pilotar un avión de combate, todo mediante sus grandes capacidades de aprendizaje y generalización a partir de ejemplos. Esto pone un punto bastante alto pues solo es necesario contar con información suficiente sobre el fenómeno (Valores de entrada y salida por lo general) para lograr que una RNA con la topología adecuada pueda imitar con lujo de detalles el comportamiento del mejor operador humano, e incluso realizar labores para las cuales nunca fue entrenada, o sea de las que no habían datos de ejemplo.

En el mundo del control asistido por computador, la introducción del neurocontrol y del control difuso (fuzzy control), ha generado una gran cantidad de desarrollos en ambas tecnologías, todos con la mira del control autónomo, paso último en el ideal del mando automático de un proceso industrial, pero que exige el dominio previo de las técnicas de control inteligente. Se empieza a ver como horizonte en este campo el uso de técnicas híbridas, que resalten las ventajas y soslayen las desventajas de las técnicas individuales. Una aproximación que muestra gran futuro son las redes híbridas, conformadas por nodos en los cuales se realizan funciones diferentes sobre los datos de entrada, de modo que al combinar sus salidas en red, se logra una función con alto grado de no linealidad, con características particulares de acuerdo con las funciones internas de dichos nodos.

Con esta visión, la manera tradicional de implantar un control difuso, mediante una herramienta o entorno (shell) de desarrollo de sistemas expertos, está cambiando, debido a la exigencia de más facilidad de sintonía, adaptación y aprendizaje en estos sistemas de reglas de producción.

Entre los inconvenientes más reportados en los sistemas de neurocontrol se pueden destacar:

- Gran cantidad de tiempo en la selección y preparación de los datos de entrenamiento, debido al gran número que se requiere para lograr buena generalización en la red entrenada.
- Mucho tiempo en el proceso de entrenamiento, aun con computadores de alta velocidad. En ocasiones decenas de horas para una red relativamente pequeña.
- La necesidad de entrenar la red con todos los patrones nuevamente, cuando se quiere cambiar un patrón o un punto de operación dados, con los consabidos costos en tiempo de entrenamiento.

De otro lado, el control difuso adolece también de inconvenientes cuando se enfrenta a la tarea de control, con miras a ser un mecanismo inteligente:

- Pérdida de inteligibilidad en la base de conocimiento (por ejemplo un conjunto de reglas), cuando se deja libre para que un módulo de aprendizaje la modifique.
- Poca flexibilidad en los programas de implantación de sistemas expertos, cuando se desea cambiar un valor particular en una regla.
- Pérdida de consistencia en la base de conocimiento cuando las reglas se modifican individualmente a la luz de una labor de aprendizaje.

No se mencionan aquí las ventajas que presentan ambas técnicas sobre otras tradicionales que han intentado abordar la labor de aprendizaje (por ejemplo con técnicas algorítmicas), puesto que diversos artículos de la literatura muestran implantaciones no híbridas que operan con éxito (Li, Y. and Lau, C.C., 89), (Yamakawa, Y., 93), (Karr, C. and Gentry, E.J., 93).

Con el fin de evitar los inconvenientes de las técnicas individuales y reforzar sus ventajas, se han propuesto varios modelos de sistemas híbridos (Lin, C and Lee, C.S. 91), (Werbos, P., 93), de los cuales es posible tomar aportes para construir un modelo que mezcle las habilidades de entrenamiento de las RNA, con el manejo de información bajo incertidumbre del razonamiento difuso, de modo que se construya una manera mucho más eficiente de realizar aprendizaje en línea y desarrollar la tarea de control inteligente.

3.1 ¿Qué Son Las Redes Híbridas Neuro-Difusas (RHND) ?

Estas redes toman su topología de las RNA típicas (Freeman, J.A. y Skapura, D.M., 93), con nodos que desarrollan una función simple (Sigmoide, Logística o Lineal), pero intercalan capas de nodos con funciones internas más complejas (funciones de pertenencia, implicación y concreción en subconjuntos difusos). Esto no quiere decir que se pierdan las habilidades típicas de las RNA en los aspectos de generalización y aprendizaje, ganando además en velocidad de entrenamiento, puesto que en este caso el número de pesos (parámetros) a ajustar es mucho menor, con la ventaja de que se parte con un conocimiento heurístico del proceso, lo que facilita sobremanera el diseño del sistema en las etapas iniciales.

Como ejemplo, la Tabla 1 muestra la matriz de reglas de un control difuso simple. La Tabla 1 muestra la RHND que implanta este control difuso, usando todas las posibles combinaciones de las variables de entrada del proceso tomadas como universo de discurso (Error e y cambio del Error con el tiempo Δe) y usando una salida como cambio en la potencia aplicada ΔP .

Tabla 1. Matriz de reglas para un control difuso simple, tipo PI.

	e es Negativo N	e es Cero Z	e es Positivo P
Δe es Positivo P	Regla 1, ΔP es Z	Regla 2, ΔP es P	Regla 3, ΔP es N
Δe es Cero Z	Regla 4, ΔP es P	Regla 5, ΔP es Z	Regla 6, ΔP es N
Δe es Negativo N	Regla 7, ΔP es P	Regla 8, ΔP es N	Regla 9, ΔP es Z

3.2 Implementación de la Red Híbrida Neuro-Difusa.

La red que se propone, consta básicamente de 5 capas, cada una con un tipo particular de nodo genérico, de modo que se realiza toda la operación de un control difuso como si fuera una red. La

función y característica de los nodos en cada capa se muestran para un control difuso tipo PI, aunque puede usarse para otros tipos de control difuso (Driankov et al., 93).

La Capa 1 o capa de entrada es la encargada de cualquier preprocesamiento de las entradas que se estime necesario. La función que desarrollan estos nodos, en el modelo propuesto, es un acotado y escalado de los valores provenientes de sensores, de modo que los parámetros característicos del nodo son el valor central y el ancho del intervalo de la variable. Todos los universos de discursos quedan de este modo normalizados a valores de $[-1, 1]$ ó $[0,1]$. En esta capa, los parámetros a entrenar no son los pesos de las entradas (pues estos siempre valen uno), sino los valores del centro y del ancho del intervalo de la variable que se trabaja.

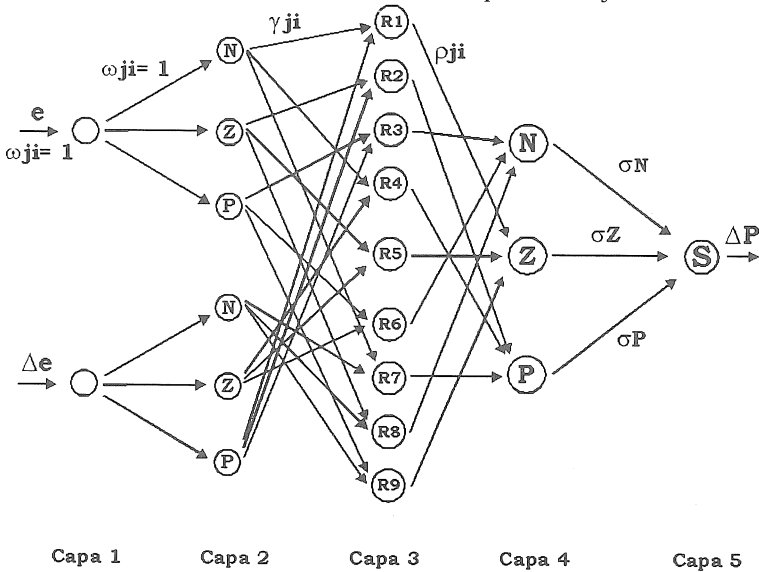


Figura 1. Red Híbrida Neuro-Difusa que implanta el control difuso de 9 reglas del ejemplo.

La capa 2, denominada capa de difusión o de cálculo de factores de pertenencia μ , es la encargada de realizar la difusión (Fuzzification) de los valores numéricos acotados y normalizados, para entregar en la salida de cada nodo un valor μ en el intervalo $[0,1]$, que es el valor de pertenencia de la entrada al conjunto difuso que representa el nodo. Entre estos nodos existen diversos tipos particulares, de acuerdo con la forma que se le da al conjunto difuso, por ejemplo: Triángulos, Campanas Gaussianas, Trapecios, etc. Cada una de estas figuras presenta un número diferente de parámetros, los cuales son los valores a ajustar en esta capa, porque aquí de nuevo los pesos de las conexiones ω_{ji} son iguales a uno.

La capa 3, es la capa que contiene la primera parte de la base de conocimientos. En esta capa cada nodo calcula el antecedente neto de una regla de producción del tipo:

SI <proposición difusa antecedente p> ENTONCES <proposición difusa consecuente q>

donde generalmente la proposición difusa antecedente es una función lógica Y entre dos o más grados de pertenencia a conjuntos difusos diferentes. De este modo, la función interna que desarrollan estos nodos de reglas, depende del tipo de T-Norma que se use para concluir sobre la

proposición Y . Nótese que cualquier proposición difusa que combine **O**, **Y**, **NO** (OR, AND y NOT), puede convertirse con facilidad en dos o más reglas simples con conectivo único tipo Y . La salida de cada nodo en esta capa es un factor de pertenencia μ que refleja el resultado de la operación lógica entre las entradas. Por ejemplo si se usa una T-Norma de mínimo, la salida del nodo será el mínimo de todos los valores de entrada.

En los nodos de la capa 3, los parámetros de entrenamiento son los pesos de las conexiones entre estos nodos y los nodos de difusión, puesto que los parámetros internos no deberían modificarse, porque se cambiaría drásticamente la T-Norma que se aplica, aunque queda abierta esta posibilidad de cambio. P. Werbos ha llamado a los pesos de las conexiones entre capa 2 y capa 3 Elasticidades γ_{ji} , y muestra como variando estos valores, es posible dejar intactas las reglas como relación entre antecedente y consecuente, lo que permite preservar la inteligibilidad del sistema, incluso después de ser sometido a un proceso de entrenamiento (Werbos, P., 93). Una interpretación a la luz del efecto final de estos pesos, que no es más que reforzar un miembro del antecedente frente a los otros, podría ser que estas elasticidades se relacionan con un cierto tipo de meta-conocimiento, que el operador humano ejecuta, pero que no puede detectarse con facilidad mediante técnicas de ingeniería del conocimiento y que está en los datos de entrada y salida del sistema. Debe recalarse como estos nodos de reglas de la capa 3, no realizan la inferencia de cada regla. Ellos, solo realizan el calculo del factor de pertenencia de la proposición difusa antecedente. Pero, la conexión entre cada nodo de regla y la capa siguiente, representa la regla completa.

La capa 4, denominada capa de inferencia o de conjuntos del consecuente, es la encargada de tomar los valores de salida de los nodos de regla de la capa anterior, y mediante el uso de uno de lo criterios comunes de interpretación de la implicación $p \rightarrow q$ evalúa la salida de la regla total:

SI p ENTONCES q

Las entradas a cada nodo en esta capa, están ponderadas mediante pesos que modifican la participación que tiene el resultado del antecedente difuso, sobre la conclusión final que tendrá dicha regla. Estos pesos ρ_{ji} , del mismo modo que las elasticidades γ_{ji} , actúan como meta-conocimiento, que puede ser modificado durante el aprendizaje. En los nodos de esta capa, los parámetros de entrenamiento son los pesos p_{ji} de las conexiones que llegan de la capa anterior. Los parámetros internos de cada nodo no se deben modificar, pues hacerlo causa un cambio de la implicación que se usa, además de acuerdo con el tipo de concreción que se haga en la capa 5, uno de los parámetros de cada nodo puede ser el centro de los conjuntos difuso de llegada o valor lingüístico de la salida recomendada al Elemento Final de Control (EFC).

Por último, la capa 5, salida en esta RHND, es la encargada de realizar la concreción (Defuzzification), que permite convertir el conjunto difuso que resulta de la inferencia de todas las reglas, en un valor numérico, que en última instancia es el que se aplica al EFC del proceso. En los nodos de esta capa, se puede aplicar cualquier método de concreción, de las muchos que se han planteado al momento y dependiendo del que se escoja, la ponderación de las conexiones que llegan a estos nodos σ_{ji} , pueden ser los centros de los conjuntos difusos del consecuente o estar fijos a uno, siempre que estos centros queden como parámetro interno en los nodos de la capa 4.

Vale la pena resaltar que el entrenamiento puede modificar los valores de estos centros en cualquiera de los dos casos.

3.3 Entrenamiento de la Red Híbrida Neuro-Difusa

Sin importar la topología interna que se use, siempre que se respete el desempeño del control difuso en la red híbrida, es posible disponer de un buen número de parámetros de aprendizaje, sobre los cuales recae la tarea de "Representación" y almacenamiento del conocimiento, ósea el aprendizaje. El ajuste de estos parámetros se puede hacer supervisadamente, mediante cualquier técnica de entrenamiento de redes: Algoritmos Genéticos (Holland, J.H. 75), Transmisión Química Bacteriana (Bacterial Chemotaxis, Bremermann, H.J. and Anderson, R.W., 90) e incluso retropropagación del error con algunas modificaciones. Cualquier técnica que se use debe poder acceder sin distinción a todos los parámetros ajustables de la red, que aquí a diferencia de las RNA son mixtos: internos a los nodos y externos a estos como ponderaciones de conexiones.

Es importante mencionar el significado que puede darse a los parámetros ajustables, al clasificarlos como parámetros de ajuste grueso (aprendizaje) y parámetros de ajuste fino (Adaptación o sintonía). Esta diferenciación es importante cuando se aspira a construir un control con características inteligentes, porque no todos los cambios del proceso son permanentes o de una duración temporal suficiente para provocar un cambio radical en las características y constitución del controlador (aprendizaje), y por el contrario, pueden ser corregidos con una sintonía o ajuste fino sobre los parámetros que permitan cambios leves (sintonía y adaptación).

3.4 Aplicación de la Red Híbrida Neuro-Difusa

La red propuesta fue desarrollada para implantar el control difuso de un reactor de lecho fluidizado, denominado Activador, en el cual se realiza la gasificación remanente y activación del carbón molido, después del proceso de gasificación principal en un reactor precedente, denominado Pirolizador. El activador hace parte de la planta piloto para la obtención en continuo de carbón activado en lecho fluidizado, método en proceso de patente por parte del grupo de investigación en Carboquímica de la Facultad de Minas de la Universidad Nacional de Colombia, sede Medellín (Aguirre y col., 91). En este tipo de procesos, la diversidad de reacciones químicas que ocurren, además de los cambios súbitos en las variables de carga (carbón alimentado, flujo de gases de fluidización, etc.), hacen que un control tradicional PID no pueda manejar con eficiencia la globalidad del proceso: Pirolización y Activación en serie, e incluso se quede corto en el control individual de cada reactor.

El proceso se simuló mediante balances de materia y energía, así como correlaciones experimentales de diverso autores sobre el fenómeno reactivo y de transferencia de masa. Para la simulación y puesta en operación de la RHND en un computador secuencial, se desarrolló un código en C++, el cual permite la definición de nodos con funciones particulares, pero que dispone de 4 tipos base, de los cuales se desprenden subtipos relacionados. Estos tipos base son:

- Tipo 0, Nodos funcionales (capa 1 y 4), que aplican una o más funciones.
- Tipo 1, Nodos Difusos (capa 2), que entregan el factor de pertenencia μ .
- Tipo 3, Nodos de T-Normas (capa 3) para operaciones lógicas Y.
- Tipo 4, Nodos de Concreción (capa 5), que entregan un valor numérico.

Tabla 2. Resultados comparativos de los dos controladores.

<i>Tipo de control y efecto medido.</i>	CONTROL PI		CONTROL DIFUSO	
	<i>Sobre impulso en °K.</i>	<i>Tiempo Establec. en minutos.</i>	<i>Sobre Impulso en °K.</i>	<i>Tiempo Establec. en minutos.</i>
<i>Aumento de 50% en flujo de char</i>	14.8	> 30	2.2	7.0
<i>Disminución 50% en flujo de char</i>	15.0	> 30	1.3	5.3

Para que los parámetros de sintonía, adaptación y aprendizaje, estén disponibles con toda facilidad, el sistema almacena todos los parámetros internos y externos (pesos) de los nodos en un archivo matricial. Cuando ya se tiene operando la red, el objeto *NodoRed* posee funciones miembro que permiten el cambio de parámetros internos, mientras que el objeto *Red* posee dos funciones independientes, una dedicada a Sintonía y Adaptación y otra dedicada al Aprendizaje. Ambas pueden variar parámetros internos y externos a los nodos.

La Tabla 2 muestra el desempeño del mejor controlador PI y el control difuso implantado con una RHND, cuando se aplican diversas perturbaciones en la carga de carbón semi-procesado (Char) al activador. Este desempeño se mide en términos del sobre impulso en la temperatura del reactor y en el tiempo de establecimiento que requiere el controlador para volver al valor prefijado (en este caso 1173 °K) la temperatura del reactor.

Como puede apreciarse en la Tabla 2, el desempeño del control difuso resultó muy superior comparado con el comportamiento del mejor control PI que se puede diseñar para este reactor, lo que demuestra la superioridad de esta técnica cuando se enfrenta al control de sistemas complejos.

4. CONCLUSIONES Y RECOMENDACIONES

Entre los aspectos que hacen atractivo el uso de RHND para la implantación de controles difusos, frente al camino tradicional de usar herramientas de sistemas expertos, pueden mencionarse los siguientes:

- Capacidad de aprendizaje sin que se pierda significado de las reglas originales o se presenten distorsiones severas en la interpretación del sistema después del entrenamiento.
- Disponibilidad de algoritmos de entrenamiento supervisado, ampliamente probados en RNA, los que pueden usarse con muy pocas modificaciones en las RHND.
- Menor tiempo de inferencia frente a las implantaciones con programas de SE, si además se procesa en forma masivamente paralela, puesto que se evitan las arduas búsquedas en árboles de decisión.
- La facilidad de programación de una RHND frente a la complejidad inherente de los programas de SE. Se permite la generación automática de código con mucha más facilidad.

La principal desventaja que presenta esta aproximación es su capacidad limitada de explicación cuando se compara con la que tienen los programas de SE. Esta tarea que informa al usuario sobre el razonamiento que se utilizó para obtener una conclusión, es de importancia capital en las labores de tutoría que buscan mantener un grado mínimo aceptable de pericia en los operarios. Esta característica podría mejorarse mediante técnicas de grafos que indiquen, en un esquema de la RHND, el camino que tomó la inferencia.

Finalmente, puede decirse que este tipo de sistemas híbridos de procesamiento de información, hacen que el conjunto sea mejor que las partes, lo que trae como consecuencia la formación de estructuras con alta sinergia, que encajan muy bien dentro del marco de desarrollo de los sistemas autónomos de control.

5. REFERENCIAS BIBLIOGRÁFICAS

- Alvarez, H.D. & Ovalle, D.A. Complejidad, Incertidumbre y Vaguedad. Propuestas de manejo estratégico con herramientas simbólico-conexion. de IA. Seminario sobre Caos, Complejidad y Estrategia. U.Nal Med., 1995.
- Alvarez, H.D. Redes híbridas y su uso en control inteligente de procesos. Memorias del Primer Congreso Nacional de Neurocomputación. Bogotá, junio de 1995.
- Aguirre, J., Ocampo, A. Y Espinel, J. Desarrollo de un proceso para producción de carbón activado. Informe de investigación, Universidad Nacional de Colombia, Sede Medellín. 1991.
- Bremermann H.J. and Anderson R.W. An alternative to Back-propagation. Center of pure and applied mathematics. University of California. Internal Publication number PAM-483. Jan. 1990.
- Driankov, D, Hellendomm, H and Reinfrank, M. An introduction to fuzzy control. First edition. Springer-Verlag Berlin-New York. 1993.
- Freeman, J.A. and Skapura, D.M Redes Neuronales, algoritmos, aplicaciones y técnicas de programación. Primera edición en español, Addison-Wesley / Diaz de Santos. 1993.
- Fukuda, T. and Shibata, T. Theory and applications of neural networks for industrial control systems. IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS. Vol. 39 No 6. Dec. 1992.
- Holland, J.H. Adaptation in natural and artificial systems. Second print of original text (Michigan University 1975), for MIT press edition , 1993.
- Karr, C.L. and Gentry, E.J. Fuzzy control of PH using genetic algorithms. IEEE TRANSACTIONS ON FUZZY SYSTEMS. Vol 1 No 1. Feb. 1993.
- Li, Y.F. and Lau, C.C.. Development of fuzzy algorithms for servo systems. IEEE CONTROL SYSTEMS MAGAZINE. April 1989.
- Lin, C. and Lee, C.S. Neural-network-based fuzzy logic control and decision system. IEEE TRANSACTIONS ON COMPUTERS. Vol 40, No 12. Dec. 1991.
- Pérez, G., Rojas, G. Y Urquijo, J. Expert system for real time control of rotary cement kiln. PROCEEDINGS OF THE WORD CONGRESS ON EXPERT SYSTEMS. 1993.
- Self, K. Designing with fuzzy logic. IEEE SPECTRUM. November 1990.
- Sugeno, M. and Park, G. An approach to linguistic instruction based learning. INTENATIONAL JOURNAL OF UNCERTAINTY, FUZZINESS AND KBS. Vol 1, No 1. Sept. 1993.
- Werbos, P.J. Neurocontrol and elastic fuzzy logic capabilities, concepts and applications. IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, vol 40, No 2. April 1993.
- Yamakawa, T. A fuzzy inference engine in non linear analog mode and its application to a fuzzy logic control. IEEE TRANSACTIONS ON NEURAL NETWORKS. Vol 4 No 3. May 1993.