

# Algoritmos Genéticos para el Ajuste de Parámetros y Selección de Reglas en el Control Difuso de un Sistema de Climatización HVAC para Grandes Edificios

R. Alcalá<sup>†</sup>, O. Cordon<sup>††</sup>, F. Herrera<sup>††</sup>

*Resumen*— En este trabajo se comparan dos enfoques diferentes para la optimización de controladores difusos dedicados al control de sistemas de Ventilación, Calefacción y Aire Acondicionado (mejora del rendimiento energético manteniendo el confort). Para ello se han desarrollado dos procesos de optimización genética, uno para el aprendizaje de pesos y selección reglas (ajuste a nivel de regla) y otro para el ajuste de la semántica del controlador (ajuste a nivel de base de datos). Ambos serán comparados al aplicarlos sobre un módulo de pruebas real.

*Palabras clave*— Sistemas HVAC, controladores difusos, reglas difusas ponderadas, selección de reglas, ajuste, algoritmos genéticos

## I. INTRODUCCIÓN

EN los países de la UE, el consumo de energía primaria en grandes edificios representa aproximadamente el 40% del consumo total de energía, y dependiendo del país, más de la mitad de esta energía es destinada a climatizar el interior de dichos edificios. Desde un punto de vista tecnológico, se estima que la consideración de tecnologías tales como los Sistemas de Administración de Energía en Edificios —*Building Energy Management Systems* (BEMSs)— puede ahorrar hasta un 20% del consumo de energía del sector inmobiliario, es decir, un 8% del consumo total de la CEE [1]. Con dicha intención, los BEMSs son aplicados solamente al control de sistemas activos, es decir, sistemas de Ventilación, Calefacción y Aire Acondicionado —*Heating, Ventilating, and Air Conditioning* (HVAC)—.

Los sistemas HVAC son equipos usualmente desarrollados para mantener un confort satisfac-

torio en grandes edificios. El consumo de energía así como aspectos relativos al confort en el interior de edificios con ventilación y aire acondicionado, son altamente dependientes del diseño, rendimiento y control de sus equipos y sistemas HVAC. Por lo tanto, el uso de estrategias de control automático adecuadas para el control de sistemas HVAC, como los *controladores difusos* [2], podría resultar en importantes ahorros de energía cuando se compara con el control manual [3], [4].

En los sistemas actuales, varios criterios se consideran de forma independiente. Además, dichos sistemas son a menudo diseñados considerando reglas escogidas a dedo no siempre compatibles con los requerimientos de los equipos controlados, el rendimiento energético y las expectativas y demanda de los usuarios [4]. Por lo tanto, se requiere un funcionamiento razonable y una mejora en el rendimiento del controlador difuso para un buen funcionamiento del sistema HVAC. En la literatura especializada [5] se han considerado muchas y distintas posibilidades para mejorar el rendimiento del modelo/controlador lingüístico. Compararemos dos enfoques concretos para el ajuste de parámetros del modelo y del número de reglas con el objetivo de mejorar el rendimiento energético y el nivel de confort del sistema:

- El uso de reglas lingüísticas ponderadas [6], [7], [8] (a las que se asocia un factor de importancia o peso) combinado con una selección de reglas [9], [10]. Ambos, aprendizaje de pesos y selección de reglas, presentan propiedades complementarias para la obtención de controladores más simples y precisos.
- El ajuste de la semántica del controlador difuso mediante la modificación de los componentes de la Base de Datos (compuesta por las definiciones de las funciones de pertenencia de las etiquetas lingüísticas). Este enfoque ya se presentó en [3] y nos permite realizar un ajuste de parámetros global (a nivel de la base de datos).

Este trabajo ha sido financiado por el Ministerio de Ciencia y Tecnología y los Fondos FEDER bajo el proyecto TIC-2002-04036-C05-01.

<sup>†</sup> Departamento de Ciencias de la Computación. Universidad Jaén. E-23071 Jaén, España. E-mail: alcala@ujaen.es .

<sup>††</sup> Departamento de Ciencias de la Computación e I.A., Universidad de Granada, E-18071 Granada, España. E-mail: {ocordon, herrera}@decsai.ugr.es




Fig. 1. Estructura genérica de un sistema HVAC para un edificio de oficinas

Así, el controlador podría obtenerse a partir de un experto y después ser ajustado mediante ambas técnicas de optimización automáticas. Para ello se han desarrollado dos procesos evolutivos [11] eficientes que serán probados considerando el simulador calibrado y validado de un edificio de pruebas real.

El trabajo se organiza como sigue. En la próxima sección se presentan los aspectos básicos de los sistemas HVAC y su control. En la Sección III, se presentan el módulo de pruebas y el problema concreto que será resuelto en este trabajo. La Sección IV presenta los dos procesos de optimización evolutivos propuestos. Finalmente, las Secciones V y VI muestran los resultados y conclusiones obtenidos, respectivamente.

## II. SISTEMAS DE VENTILACION, CALEFACCION Y AIRE ACONDICIONADO

*¿Qué son?* - Un sistema HVAC está compuesto por todas las partes electromecánicas del edificio usadas para acondicionar el aire interior del mismo. El sistema HVAC es necesario para proporcionar a los trabajadores un entorno de trabajo cómodo y productivo que satisfaga sus necesidades fisiológicas. No hay datos estadísticos recopilados sobre tipos y tamaños de sistemas HVAC relativos a cada tipo de edificio en diferentes países europeos. Por lo tanto, proporcionar un sistema HVAC compatible con el ambiente es una tarea del diseñador de BEMS basada en su propia experiencia. En la Figura 1, se presenta un típico sistema HVAC para oficinas. Este sistema consta de un conjunto de componentes capaces de aumentar y disminuir la temperatura y la humedad relativa del aire suministrado.

*¿Qué se persigue?* - En un edificio inteligente moderno, un control sofisticado del sistema debería proporcionar un excelente control ambiental [4]. *Dentro de este marco de trabajo (automatización de edificios), el objetivo de un controlador global es mantener el ambiente dentro de los límites deseados (o estipulados). En nuestro caso, mantener las condiciones ambientales dentro de la zona de confort y controlar la calidad del aire interior. Además, otros objetivos importantes son requeridos, por ejemplo, ahorro de energía (nuestro principal objetivo), estabilidad del sistema, etc.* En cualquier caso, numerosos factores deben ser considerados para conseguir dichos objetivos. Esto hace el sistema controlado muy complejo y provoca una fuerte no linealidad.

*¿Cómo conseguirlo?* - Como se ha dicho, en la mayoría de los casos las reglas del controlador difuso son escogidas a dedo. Estos enfoques necesitarían de una modificación de la Base de Conocimiento inicial para obtener un controlador óptimo. Muchas y diferentes posibilidades han sido consideradas en la literatura especializada para mejorar el rendimiento del modelo/controlador lingüístico [5] mediante el uso de técnicas de optimización automáticas. Todas ellas comparten la idea de mejorar la forma en que el modelo/controlador realiza el razonamiento interpolativo forzando una mejor cooperación entre las reglas. En este caso seguiremos dos:

- El aprendizaje de pesos y selección del subconjunto de reglas que presente la mejor cooperación.
- El ajuste de la semántica del controlador difuso mediante la modificación de los componentes de la base de datos [3].

Para evaluar el rendimiento del controlador,

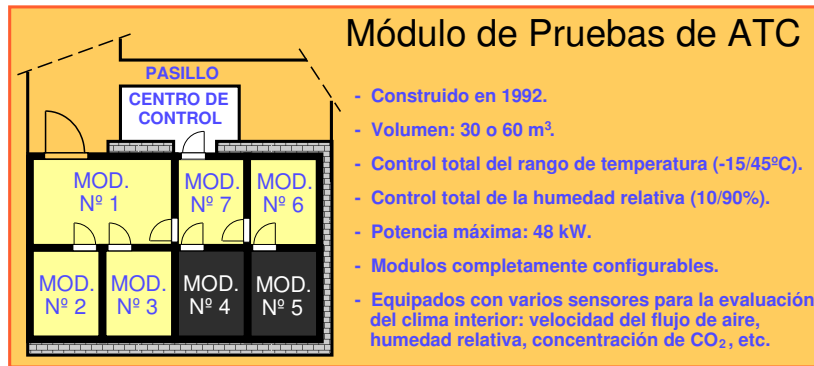


Fig. 2. Representación y principales características de los módulos de ATC

usualmente es necesaria una modelización física de los edificios controlados. Así, tendremos la posibilidad de evaluar el controlador en el simulador con las condiciones ambientales deseadas.

### III. EL MÓDULO DE PRUEBAS DE ATC

Dentro del marco de trabajo del proyecto GENESYS<sup>1</sup>, un módulo de pruebas fue provisto por una empresa privada cuyo nombre debe permanecer anónimo. A partir de ahora, este lugar será llamado módulo de pruebas de ATC —del inglés, *Anonymous Test Cell*—. Situado en Francia, este entorno de prueba consta de siete módulos alrededor de los cuales se puede recrear un clima artificial en cualquier momento. La Figura 2 ilustra este entorno. Dos módulos gemelos adyacentes estuvieron disponibles para nuestros experimentos, el número 4 y el 5.

Lo primero fué desarrollar el modelo térmico de los módulos de prueba. El mayor logro fué el desarrollo de un modelo de edificio monozona completo. Los datos disponibles fueron usados para calibrar el modelo. *La experimentación de este trabajo ha sido realizada considerando el modelo de simulación de ATC calibrado y validado.* Concretamente, el modelo de verano de ATC.

#### A. Objetivos y Función de Adaptación

**El principal objetivo fué mejorar el rendimiento energético manteniendo el nivel de confort deseado.** Para ello, el objetivo global fué **minimizar** los siguientes cinco criterios:

**O<sub>1</sub>** Límite de confort térmico superior:  
*si*  $PMV > 0.5$ ,  $O_1 = O_1 + (PMV - 0.5)$ , donde  $PMV$  —del inglés, *Predicted Mean Vote*— es el índice de confort térmico ISO 7730<sup>2</sup>, incorporan-

<sup>1</sup>Fuzzy controllers and smart tuning techniques for energy efficiency and overall performance of HVAC systems in buildings, European Commission, Directorate-General XII for Energy (contract JOE-CT98-0090).

<sup>2</sup><http://www.iso.org/iso/en/ISOOnline.frontpage>

do la humedad relativa y la temperatura media irradiada.

**O<sub>2</sub>** Límite de confort térmico inferior:

*si*  $PMV < -0.5$ ,  $O_2 = O_2 + (-PMV - 0.5)$ .

**O<sub>3</sub>** Requisito de calidad del aire:

*si*  $CO_2 conc. > 800ppm$ ,  $O_3 = O_3 + (CO_2 - 800)$ .

**O<sub>4</sub>** Consumo de energía:  $O_4 = O_4 + potencia$  en el tiempo  $t$ .

**O<sub>5</sub>** Estabilidad del sistema:  $O_5 = O_5 + Cambios$  del sistema desde el  $t$  al  $(t - 1)$ , donde cambio del sistema representa un cambio de funcionamiento, por ejemplo, un cambio de la velocidad del ventilador o posición de una válvula.

Los cinco criterios serán combinados en una función objetivo global por medio de un vector de pesos. Cuando se dispone de pesos fiables, este enfoque reduce el espacio de búsqueda proporcionando la dirección de búsqueda más adecuada y por lo tanto es recomendable. En nuestro caso, los expertos proporcionaron pesos fiables para la función de evaluación del módulo de pruebas de ATC:  $w_1^O = 0.0083022$ ,  $w_2^O = 0.0083022$ ,  $w_3^O = 0.00000456662$ ,  $w_4^O = 0.0000017832$  and  $w_5^O = 0.000761667$ . Finalmente, la función objetivo a minimizar fué calculada como:

$$F = \sum_{i=1}^n w_i^O \cdot O_i .$$

#### B. Variables y Arquitectura del Controlador

El experto en BEMS propuso una arquitectura jerárquica considerando el  $PMV$ , la concentración de  $CO_2$ , el estado previo del sistema HVAC y la temperatura exterior. Dicha arquitectura, las variables y la base de reglas inicial se muestran en la Figura 3. La base de datos inicial, mostrada en la Figura 7 (Sección V, junto a la base de datos ajustada), está compuesta de particiones difusas simétricas con funciones de pertenencia triangulares etiquetadas desde  $L1$  a  $Ll_i$  (siendo  $l_i$  el número de etiquetas de la  $i$ -ésima variable). La Figura 3 representa las tablas

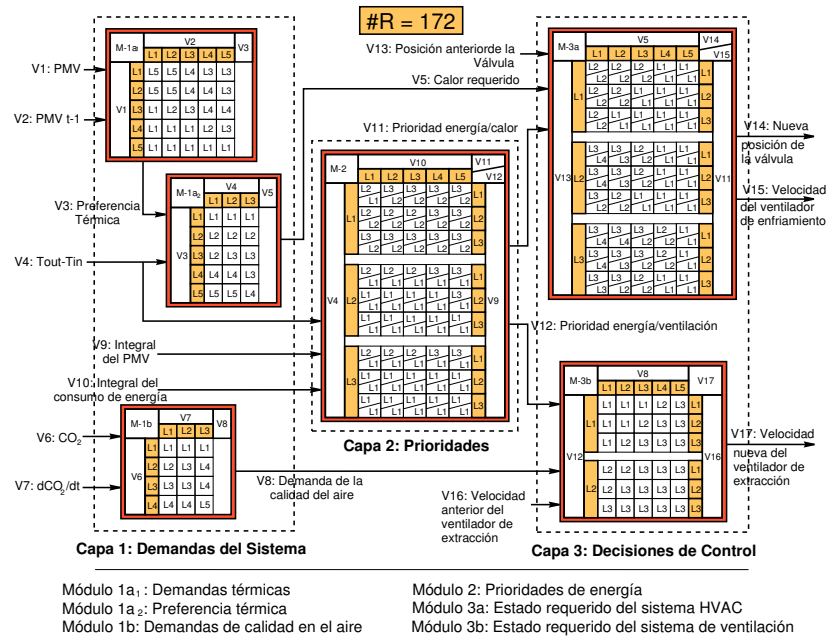


Fig. 3. Base de reglas inicial y estructura del controlador difuso de verano de ATC

de decisión de cada módulo del controlador en términos de dichas etiquetas. Cada celda representa un subespacio/regla difusa y contiene el consecuente(s) de salida, es decir, la etiqueta(s). Las variables de salida se indican en la esquina superior derecha para cada módulo. Ambas, la base de reglas y la base de datos inicial, fueron suministradas por el experto en BEMS.

Debido al elevado tiempo de evaluación del modelo del sistema y para obtener un sistema de inferencia eficiente, consideraremos como estrategia de defuzificación *la Media de Máximos ponderada por el grado de disparo de las reglas* [2].

#### IV. AJUSTE GENÉTICO DEL CONTROLADOR

En esta sección se presentan los algoritmos de optimización evolutiva que se han desarrollado para los dos enfoques propuestos en este trabajo, el de aprendizaje de pesos y selección de reglas y el de ajuste de la base de datos. Para ello seguiremos uno de los enfoques propuestos en [3], que será exactamente el mismo que utilizemos como algoritmo para el ajuste de la base de datos. En lo que sigue se presentarán primero las partes comunes del algoritmo mencionado para después concretar en su aplicación a ambos enfoques (esquemas de representación y operadores).

##### A. Algoritmo

El algoritmo propuesto está basado en un Algoritmo Genético (AG) estacionario [12] con una función de adaptación basada en objetivos pon-

derados. El enfoque estacionario consiste en seleccionar dos de los mejores individuos de la población y combinarlos para obtener dos hijos. Los dos nuevos individuos reemplazarán en la población a los dos peores si están mejor adaptados que ellos. De esta manera las mejores soluciones son utilizadas pronto en el proceso genético y por lo tanto, la convergencia es acelerada y el número de evaluaciones disminuye (en nuestro caso será crucial ya que los modelos tardarán varios minutos en ser evaluados).

Para hacer el método más robusto e independiente de la selección de los pesos para la función de adaptación, consideraremos metas difusas que adaptarán la dirección de búsqueda del algoritmo. Por otro lado, el esquema de selección está basado en el muestreo universal estocástico de Baker considerando elitismo.

##### A.1 Evaluación del Cromosoma

La función de evaluación (véase la Sección III-A) ha sido modificada para considerar el uso de metas difusas que disminuyen la importancia de cada objetivo cuanto más cerca esté de satisfacer su meta o lo penaliza cuando se empeora respecto al controlador inicial considerado. Para ello se incluye una función que modifica el valor de adaptación para cada objetivo individual,  $\delta_i(x)$  (tomando valores que pueden llegar hasta 1). En ésta función se ha incluido un factor de penalización,  $p_i$ , que permite al usuario dar una cierta prioridad a los objetivos (0 menor prioridad y

1 máxima prioridad). La función de adaptación global finalmente obtenida es:

$$F' = \sum_{i=1}^5 w_i^O \cdot \delta_i(O_i) \cdot O_i ,$$

Dos situaciones diferentes pueden presentarse dependiendo de los valores de las metas,  $g_i$ , y el valor de la solución inicial para cada objetivo,  $i_i$ . Por ello se aplicarán dos funciones  $\delta$  diferentes:

- Cuando el valor de  $g_i$  es menor que el valor de  $i_i$ , el objetivo es anulado si se consigue la meta y es penalizado si se empeora el valor inicial (véase la Figura 4).




Fig. 4.  $\delta_i(x)$  cuando  $g_i \leq i_i$

- Cuando el valor inicial  $i_i$  es menor que la meta  $g_i$ , el valor inicial puede empeorarse mientras que la meta se cumpla, y se penaliza en caso contrario (véase la Figura 5).




Fig. 5.  $\delta_i(x)$  cuando  $g_i > i_i$

## A.2 Esquema de Reiniciación

Para no caer en óptimos locales, el algoritmo usa un esquema de reiniciación [13]. Así, cuando la población converge a soluciones muy similares (prácticamente el mismo valor de adaptación en

toda la población), se genera aleatoriamente la población completa excepto el mejor individuo. Este esquema permite al algoritmo una mejor exploración del espacio de búsqueda.

## B. Aplicación al Aprendizaje de Pesos y Selección de Reglas

En esta sección se explican la representación a seguir y los operadores específicos necesarios para aplicar el algoritmo al aprendizaje de pesos y la selección de reglas. Para ello, primero se presenta la estructura de regla lingüística ponderada.

### B.1 Estructura de Regla Lingüística Ponderada

En este trabajo utilizamos la estructura de regla y el sistema de inferencia propuestos en [8]:

**SI**  $X_1$  es  $A_1$  y ... y  $X_n$  es  $A_n$   
**ENTONCES**  $Y$  es  $B$  con  $[w]$ ,

donde  $X_i$  ( $Y$ ) son las variables de entrada (salida),  $A_i$  ( $B$ ) son las etiquetas lingüísticas utilizadas en la regla,  $w$  es un valor real representando el peso de la regla, y *con* es un operador que modela la aplicación del peso asignado a dicha regla. Así, el razonamiento difuso debe ser extendido. El enfoque clásico es trabajar en modo B [2] y calcular la salida real como sigue:

$$y_0 = \frac{\sum_i m_i \cdot w_i \cdot P_i}{\sum_i m_i \cdot w_i} ,$$

donde  $m_i$  es el grado de disparo de la  $i$ -ésima regla,  $w_i$  es su peso asociado, y  $P_i$  es la *Media de Máximos* del conjunto difuso de salida obtenido a partir de la misma.

### B.2 Representación y Operadores Genéticos

En este caso se utilizará un esquema de representación doble ( $C = C_1 + C_2$ ) con dos vectores de tamaño  $m$  para representar las reglas y sus pesos (siendo  $m$  el número de reglas inicial):

$$\begin{aligned} C_1^p &= (c_{11}^p, \dots, c_{1m}^p) \mid c_{1i}^p \in \{0, 1\}, \\ C_2^p &= (c_{21}^p, \dots, c_{2m}^p) \mid c_{2i}^p \in [0, 1], \\ C^p &= C_1^p C_2^p. \end{aligned}$$

De esta forma, la parte  $C_1^p$  es un vector binario en el que cada celda representa la existencia o no (1 ó 0) de la regla correspondiente. Y la parte  $C_2^p$  es un vector de números reales en el que cada celda representa el peso asociado a dicha regla.

Para hacer uso de la información disponible, la población inicial se obtiene con un individuo presentando en todos sus genes el valor '1' (inclusión del controlador inicial), y el resto generados aleatoriamente:

$$\forall k \in \{1, \dots, m\}, c_{1k}^1 = 1 \text{ and } c_{2k}^1 = 1.0 .$$

Como operadores de cruce se consideran el cruce en dos puntos aplicado sobre  $C_1$ , y el cruce BLX- $\alpha$  [14] junto con un híbrido entre un BLX- $\alpha$  y un cruce aritmético [15] aplicado sobre  $C_2$ . Si se cruzan dos padres,  $C_2^v = (c_{21}^v, \dots, c_{2k}^v, \dots, c_{2m}^v)$  y  $C_2^w = (c_{21}^w, \dots, c_{2k}^w, \dots, c_{2m}^w)$ , en  $C_2$ :

1. Se genera un descendiente (cruce BLX- $\alpha$  [14])  $C_2^h = (c_{21}^h, \dots, c_{2k}^h, \dots, c_{2m}^h)$  con  $c_{2k}^h$  siendo generado aleatoriamente en el intervalo  $[I_{L_k}, I_{R_k}] = [c_{min} - I \cdot \alpha, c_{max} + I \cdot \alpha]$ ,  $c_{min} = \min(c_{2k}^v, c_{2k}^w)$ ,  $c_{max} = \max(c_{2k}^v, c_{2k}^w)$  y  $I = c_{max} - c_{min}$ .
2. Se genera otro descendiente (cruce aritmético [15])  $C_2^h$  con  $c_{2k}^h = aI_{L_k} + (1 - a)I_{R_k}$  en el intervalo  $[I_{L_k}, I_{R_k}]$ . Siendo  $a \in [0, 1]$  un valor aleatorio generado cuando se aplica el cruce.

Sobre los cuatro hijos obtenidos, combinando los dos de  $C_1$  y los dos de  $C_2$ , se aplica el operador de mutación negando el gen cuando se aplica sobre  $C_1$  y tomando un valor aleatorio cuando se aplica sobre  $C_2$ . Finalmente, se seleccionan los dos mejores como descendientes.

### C. Aplicación al Ajuste de la Base de Datos

En esta sección se explican la representación a seguir y los operadores específicos necesarios para aplicar el algoritmo al ajuste de la base de datos. Para ello se describirá muy brevemente uno de los enfoques propuestos en [3] (WMC-SSGA), que será exactamente el mismo que utilizemos como algoritmo para el ajuste de la base de datos.

El esquema de representación codifica de manera consecutiva las  $l_i$  etiquetas lingüísticas de cada una de las  $n$  variables que componen la base de datos:

$$C_i = (a_1^i, b_1^i, c_1^i, \dots, a_{l_i}^i, b_{l_i}^i, c_{l_i}^i), \quad i = 1, \dots, n, \\ C = C_1 C_2 \dots C_n.$$

Como en el enfoque anterior, para hacer uso de la información disponible, la población inicial se obtiene con un individuo incluyendo los valores correspondientes al controlador inicial, y el resto generados aleatoriamente dentro de sus intervalos de variación. Los intervalos de variación se calculan a partir de la solución inicial, siendo los mismos para el grupo de puntos compuesto por el punto central de una etiqueta y los extremos más cercanos de la anterior y la posterior. A partir de estos grupos, los intervalos se obtienen como el punto intermedio entre los puntos más cercanos de dos grupos consecutivos [3].

Dichos intervalos serán adaptados dinámicamente a partir del mejor individuo tras cada iteración del algoritmo, evitando así las restricciones que supone el fijarlos desde el principio.

Como operadores genéticos de cruce y mutación se seleccionaron: el cruce Max-Min-Aritmético [15] y la mutación no uniforme de

Michalewicz [11]. Tras la aplicación del operador de mutación sobre los cuatro hijos generados por el operador de cruce propuesto, se seleccionan los dos mejores como futuros descendientes.

## V. EXPERIMENTOS

Para evaluar la bondad de las dos técnicas propuestas, se han realizado algunos experimentos considerando el modulo de ATC (presentado en la Sección III). Para facilitar el cálculo de la función de adaptación de las técnicas propuestas, los expertos obtuvieron modelos precisos del edificio controlado, así como el controlador difuso inicial. Para las evaluaciones se realizaron simulaciones de 10 días con las condiciones climáticas deseadas (con un tiempo de computo aproximado de 3 o 4 minutos por simulación).

Los controladores obtenidos serán comparados con el controlador difuso inicial y un On-Off. *Las metas y mejoras serán calculadas respecto a éste último como en el proyecto GENESYS*<sup>1</sup>. La intención de los expertos fué obtener un 10% de ahorro de energía junto con una mejora global en el comportamiento del sistema comparado al On-Off. Los parámetros de confort podrían incrementarse, pero no más de 1.0 para  $O_1$  y  $O_2$ . Los valores considerados para los parámetros utilizados en los experimentos son: 31 individuos, probabilidad de mutación 0.2, 0.3 como factor  $\alpha$  del operador BLX y 0.35 para el factor  $a$  del operador de cruce max-min-aritmético.

En la primera parte de la Tabla I (donde % representa el tanto por ciento de mejora respecto al controlador On-Off para cada criterio y #R el número de reglas difusas) se muestran los resultados obtenidos con el controlador On-Off y el controlador difuso inicial junto con los parámetros considerados para el cómputo de la función de adaptación en el AG ( $F'$ ), las metas y los factores de penalización. En la tabla no se han representado porcentajes de mejora para  $O_1 \dots O_3$ , puesto que siempre se consiguen los objetivos y el controlador On-Off presenta valor cero.

Los controladores presentados en la segunda y tercera parte de la Tabla I se corresponden con los mejores individuos de la población en la iteración 500 considerando el enfoque de pesos y selección de reglas (PS) o considerando el ajuste de la base de datos (BD). En vista de los resultados obtenidos, se puede destacar que se producen mejoras importantes sobre el controlador On-Off y el difuso inicial.

Con el primer enfoque, PS, se ha conseguido una reducción de reglas importante junto con un buen balance entre energía y estabilidad, presentando mejoras alrededor de un 14% en la función

TABLA I  
RESULTADOS OBTENIDOS CONSIDERANDO AMBOS ENFOQUES

MODELO	#R	F. Adapt.		PMV		CO <sub>2</sub>		Energía		Estabilidad	
		F	%	O <sub>1</sub>	O <sub>2</sub>	O <sub>3</sub>	O <sub>4</sub>	%	O <sub>5</sub>	%	
Controladores iniciales y parámetros usados en la función de adaptación ( $F'$ )											
ON-OFF	—	6.58	—	0.0	0	0	3206400	—	1136	—	
CONTR. DIFUSO	172	6.32	4	0.0	0	0	2901686	9.50	1505	-32.48	
Metas ( $g_i$ )	—	—	—	1.0	1	7	2000000	—	1000	—	
Facts. Penaliz. ( $p_i$ )	—	—	—	1	1	1	0.9	—	0.97	—	
Considerando pesos y selección de reglas (PS)											
PS-1	102	5.59	15	0.7	0	0	2731798	14.80	942	17.08	
PS-2	123	5.68	14	0.9	0	0	2769621	13.62	970	14.61	
Considerando ajuste de la base de datos (BD)											
BD-1	172	5.43	17	0.0	0	0	2596875	19.01	1051	7.48	
BD-2	172	5.44	17	0.0	0	0	2575949	19.66	1115	1.85	

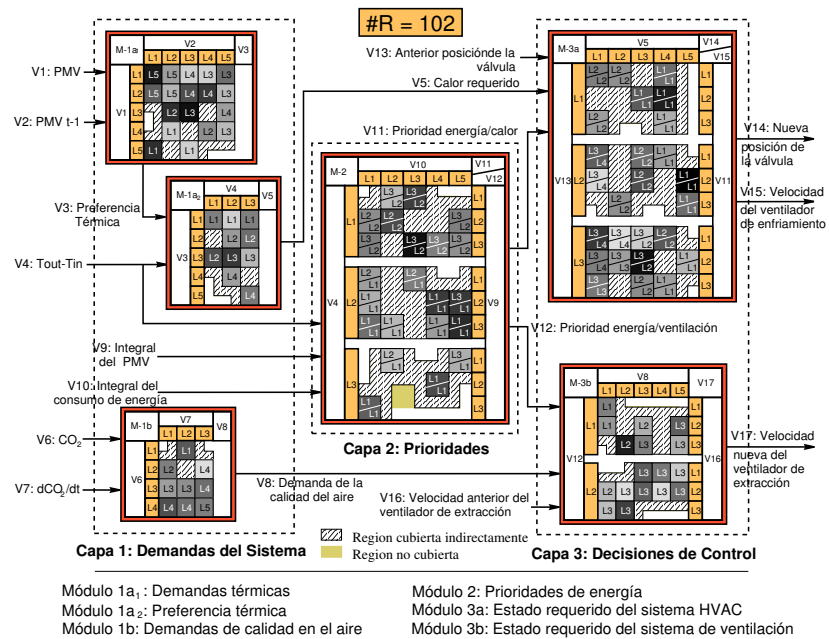


Fig. 6. Base de reglas ponderadas y estructura final del controlador

de adaptación y en energía, y alrededor de un 16% en estabilidad. Además, el algoritmo propuesto presenta una buena convergencia y uniformidad en la población finalmente obtenida. Por otro lado, con el segundo enfoque, BD, se obtienen grandes mejoras en energía (19%) aunque no haya un buen equilibrio con la estabilidad (7.5 y 1.8 %). En este caso, si se presenta diversi-

dad en la población final y en algunos casos el algoritmo se ve levemente afectado por factores aleatorios.

La Figura 6 representa las tablas de decisión del modelo obtenido a partir del primer enfoque PS-1 (en la Sección III-B puede encontrarse una explicación para esta figura). En este caso, el peso se representa mediante la escala de grises des-




Fig. 7. Base de datos inicial y ajustada

de el negro (peso 1) hasta el blanco (peso 0). Así podemos ver la importancia de las reglas respecto a sus vecinas. Por otro lado, la Figura 7 representa la base de datos inicial y la base de datos ajustada por el segundo enfoque BD-1. Se puede observar como pequeños cambios en los conjuntos difusos provocan grandes mejoras en el controlador.

## VI. CONCLUSIONES

En este trabajo se comparan dos enfoques diferentes para la optimización de controladores difusos dedicados al control de sistemas HVAC. Para ello se han desarrollado dos procesos de optimización genética, uno para el aprendizaje de pesos y selección reglas (ajuste a nivel de regla) y otro para el ajuste de la semántica del controlador (ajuste a nivel de base de datos).

Las técnicas propuestas, han obtenido resultados claramente mejores que el controlador On-Off, mostrando su buen comportamiento sobre este tipo de problemas complejos. Ambas técnicas han superado los objetivos planteados en el proyecto GENESYS<sup>1</sup>, presentando mayor robustez el aprendizaje de pesos y selección de reglas con un mejor balance entre el rendimiento energético y la estabilidad, y una reducción importante del número de reglas.

## REFERENCIAS

- [1] A. L. Dexter, D. Phil, and C. Eng, "Intelligent buildings: fact or fiction?," *HVAC&R Research*, vol. 2, no. 2, pp. 105–123, 1996.
- [2] D. Driankov, H. Hellendoorn, and M. Reinfrank, *An introduction to fuzzy control*, Springer-Verlag, 1993.
- [3] R. Alcalá, J. Casillas, J.L. Castro, A. González, and F. Herrera, "A multicriteria genetic tuning for fuzzy logic controllers," *Mathware and Soft Computing* 8:2, vol. 8, no. 2, pp. 179–201, 2001.
- [4] S. Huang and R. M. Nelson, "Rule development and adjustment strategies of a fuzzy logic controller for an hvac system - parts i and ii (analysis and experiment)," *ASHRAE Transactions*, vol. 100, no. 1, pp. 841–856, 1994.
- [5] J. Casillas, O. Cerdón, F. Herrera, and L. Magdalena, "Accuracy improvements to find the balance interpretability-accuracy in fuzzy modeling: an overview," in *Fuzzy modeling and the interpretability-accuracy trade-off. Part II, accuracy improvements preserving the interpretability*, J. Casillas, O. Cerdón, F. Herrera, and L. Magdalena, Eds., pp. 3–24. Physica-Verlag, Heidelberg, Germany, first edition, 2002.
- [6] J.S. Cho and D.J. Park, "Novel fuzzy logic control based on weighting of partially inconsistent rules using neural network," *Journal of Intelligent Fuzzy Systems*, vol. 8, pp. 99–110, 2000.
- [7] H. Ishibuchi and T. Takashima, "Effect of rule weights in fuzzy rule-based classification systems," *IEEE Transactions on Fuzzy Systems*, vol. 3, no. 3, pp. 260–270, 2001.
- [8] N.R. Pal and K. Pal, "Handling of inconsistent rules with an extended model of fuzzy reasoning," *Journal of Intelligent Fuzzy Systems*, vol. 7, pp. 55–73, 1999.
- [9] M. Setnes and H. Hellendoorn, "Orthogonal transforms for ordering and reduction of fuzzy rules," in *Proceedings of the 9th IEEE International Conference on Fuzzy Systems*, San Antonio, Texas, USA, 2000, vol. 2, pp. 700–705.
- [10] J. Yen and L. Wang, "Simplifying fuzzy rule-based models using orthogonal transformation methods," *IEEE Transactions on Systems, Man, and Cybernetics—Part B: Cybernetics*, vol. 29, pp. 13–24, 1999.
- [11] Z. Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*, Springer-Verlag, 1996.
- [12] D. Whitley and J. Kauth, "Genitor: A different genetic algorithm," in *Proceedings of the Rocky Mountain Conference on Artificial Intelligence*, Denver, 1988, pp. 118–130.
- [13] L. J. Eshelman, "The chc adaptive search algorithm: How to have safe search when engaging in nontraditional genetic recombination," in *Foundations of Genetic Algorithms*, G. J. E. Rawlins, Ed., San Mateo, CA, 1990, pp. 265–283, Morgan Kaufman.
- [14] L. J. Eshelman and J. D. Schaffer, "Real-coded genetic algorithms and interval-schemata," in *Foundations of Genetic Algorithms*, San Mateo, CA, 1993, vol. 2, pp. 187–202, Morgan Kaufman.
- [15] F. Herrera, M. Lozano, and J. L. Verdegay, "Fuzzy connectives based crossover operators to model genetic algorithms population diversity," *Fuzzy Sets and Systems*, vol. 92, no. 1, pp. 21–30, 1997.