

Tópico: Computación Evolutiva

## UN ALGORITMO GENÉTICO BASADO EN NÚMEROS DIFUSOS TRIANGULARES

Jessica Carballido<sup>1</sup>, Ignacio Ponzoni<sup>1</sup> y Diana Brignole<sup>2</sup>

*<sup>1</sup>Departamento de Ciencias de la Computación  
Universidad Nacional del Sur  
Av. Alem 1253 – CP 8000 - Bahía Blanca – ARGENTINA*

*<sup>2</sup>Departamento de Matemática  
Universidad Nacional del Sur  
Av. Alem 1253 – CP 8000 - Bahía Blanca – ARGENTINA*

### RESUMEN

En este trabajo se presenta un algoritmo genético basado en números triangulares difusos el cual tiene por objetivo superar los problemas de diversidad poblacional observados en los algoritmos genéticos clásicos. En la técnica propuesta se representa cada individuo a través de un conjunto difuso, y se redefinen las operaciones de cruzamiento y mutación para adecuarse a este nuevo patrón genético. Con el fin de establecer el alcance de nuestra propuesta se implementó el algoritmo genético tradicional y el algoritmo genético basado en conjuntos difusos para comparar sus desempeños. Los resultados obtenidos muestran que la variante difusa logra mejor diversidad poblacional sin perder eficacia en la búsqueda de la solución óptima.

**Palabras clave:** Algoritmos Genéticos, Números Difusos, Diversidad Poblacional.

## INTRODUCCIÓN

La Computación Evolutiva (CE) es reconocida actualmente como una disciplina de investigación en expansión (Goldberg, 1989; Michalewicz, 1996; Banzhaf *et al.*, 1998; Gen & Cheng, 2000), la cual engloba distintos enfoques de simulación de la evolución: **algoritmos genéticos (AG)**, estrategias evolutivas y programación evolutiva. Todos ellos tienen en común la reproducción (cruzamiento), modificaciones aleatorias (mutación), competencia y selección de individuos que rivalizan en una población. Estos cuatro procesos son la esencia de la evolución y una vez puestos a funcionar, ya sea en la naturaleza o en la computadora, la evolución resulta inevitable.

En particular, los AG son métodos de búsqueda que utilizan operadores basados en la genética natural para explorar el espacio de búsqueda. En términos generales, los AG resultan robustos, eficientes y eficaces en problemas de optimización complejos, aunque también poseen otros campos de aplicación tales como tareas de planificación (routing, scheduling, packing, etc), diseño, simulación e identificación, control y clasificación.

En pocas palabras, un AG procesa una población de individuos que representan potenciales soluciones del problema tratado. La idea central es que esta población va evolucionando con cada nueva generación hasta alcanzar una solución al problema bajo estudio. Este proceso evolutivo se logra empleando tres operadores básicos: **selección**, **cruzamiento** y **mutación**. El operador de selección sigue los principios de Charles Darwin de supervivencia de los más aptos. Por tal motivo, se establecen mayores probabilidades de supervivencia a aquellos individuos con “mejores” características. Por otro lado, los operadores de mutación y cruzamiento han sido inspirados en los mecanismos de mutación genética y recombinación de cromosomas presentes en la genética biológica. El papel desempeñado por estos dos operadores es crear nuevos individuos, conformados con parte del código genético de sus padres, a fin de recorrer regiones aún no exploradas.

### **PRESIÓN SELECTIVA, DIVERSIDAD POBLACIONAL Y PROBLEMAS DE CONVERGENCIA PREMATURA**

La diversidad poblacional y la presión selectiva constituyen dos de los factores más importantes en el proceso de búsqueda genética. Por un lado, la diversidad poblacional refiere a la variedad de esquemas genéticos presentes en la población. A mayor cantidad de esquemas, mayor es la diversidad poblacional. En cambio, la presión selectiva es consecuencia directa de las características del operador de selección empleado. Cuando más se favorezca la supervivencia de los individuos con mejor fitness (en detrimento de los cromosomas de fitness más bajo) mayor presión selectiva se estará ejerciendo.

Ambos conceptos están estrechamente vinculados ya que un aumento de la presión selectiva ocasiona una disminución de la diversidad poblacional. Esto se debe a que los individuos con mejor fitness son preferidos para el cruzamiento, provocando que la población tienda a converger a los esquemas de cromosomas derivados de estos individuos. Inversamente, un aumento en la diversidad poblacional conlleva a una reducción de la presión selectiva.

Estos aspectos poseen una fuerte incidencia en los resultados obtenidos por el AG. Por un lado, si se está en presencia de un AG con una fuerte presión selectiva se corre el riesgo de alcanzar una convergencia prematura a un máximo (o mínimo) local sin encontrar el máximo (mínimo) global. Esto se debe a la pérdida de diversidad poblacional. Muchas veces sucede que un individuo con bajo fitness posee uno o más genes que forman parte del código genético de la solución óptima.

Sin embargo, este individuo desaparece sin dejar descendientes dado que una fuerte presión selectiva sólo favorece el cruzamiento de los mejores miembros de la población. Luego, su esquema genético se pierde para siempre. Por otra parte, si el AG preserva una gran diversidad poblacional, la convergencia puede tornarse muy lenta debido al aumento del espacio de búsqueda explorado.

En este escenario, la mejor alternativa parece ser una posición intermedia, con niveles de presión selectiva y diversidad poblacional equilibrados. Sin embargo, cada problema tiene características propias, las cuales hacen difícil establecer en general un nivel de balance apropiado para estos factores. Esto último constituye la principal motivación del presente trabajo, en donde se propone una variante difusa del AG tradicional con el fin de lograr una metodología que posea una buena diversidad poblacional sin perder demasiada presión selectiva, y así evitar la convergencia prematura.

## TEORÍA DE SUBCONJUNTOS DIFUSOS: NOCIONES BÁSICAS

La lógica y teoría de subconjuntos difusos, conocida actualmente como fuzzy logic, es introducida por L.Zadeh (1965), como una herramienta para abordar problemas caracterizados por la presencia de imprecisión, inexactitud, o incertidumbre, y al aceptar estas características obtiene en general mejores resultados que mediante la aplicación de los métodos clásicos.

En la matemática clásica, dado un elemento  $x$  y un subconjunto  $X$  de un cierto universo  $U$ , ó  $x$  pertenece a  $X$ , ó  $x$  no pertenece a  $X$ . Zadeh admite el grado de pertenencia de un elemento a un subconjunto borroso  $X$  del universo  $U$ , aceptando así la imprecisión.

Un subconjunto borroso  $\bar{X}$  de  $U$ , queda definido por su función de pertenencia:  
 $f_{\bar{X}}$  definida en  $U$  y tomando como valores los números reales entre 0 y 1, siendo  
 $f_{\bar{X}}(x)$  el grado de pertenencia del elemento  $x$  a  $\bar{X}$ .

Un tipo especial de subconjuntos difusos del conjunto  $\mathbf{R}$  de los números reales, son los números difusos triangulares que se indican por la notación:

$$\bar{X} = [x_1, x_2, x_3], \quad x_1, x_2, x_3 \text{ números reales, } x_1 < x_2 < x_3$$

siendo su función de pertenencia:

$$f_{\bar{X}}(x) = \begin{cases} \frac{x - x_1}{x_2 - x_1} & \text{si } x_1 < x \leq x_2 \\ \frac{x - x_3}{x_2 - x_3} & \text{si } x_2 < x \leq x_3 \\ 0 & \text{si } x < x_1 \text{ ó } x > x_3 \end{cases}$$

es decir  $x_2$  posee el mayor grado de pertenencia a  $\bar{X}$ , y este grado disminuye a medida que  $x$  se aleja de  $x_2$ , acercándose a los extremos del intervalo  $[x_1, x_3]$ , donde será nulo.

En todo algoritmo o proceso en que se introduzcan variables fuzzy, se obtendrá como resultado un subconjunto fuzzy, y deberá recurrirse a algún procedimiento de "defuzzyficación". En Klir- BoYuan, páginas 336 y siguientes, y en página 355, pueden encontrarse los métodos más usuales. En general, la bondad del procedimiento elegido dependerá de la aplicación en particular.

## ALGORITMOS GENÉTICOS Y CONJUNTOS DIFUSOS

Varios trabajos referidos a la integración de los conceptos de AG y Matemática Difusa han sido propuestos en los últimos años, entre los que se pueden citar Buckley & Hayashi (1994), Herrera *et al.* (1997), Bastian (2000), Wu & Yu (2000) y Huang & Wang (2000). Entre las distintas técnicas propuestas se pueden reconocer dos grandes enfoques. Por un lado, el empleo de los AG como método para la optimización de las reglas de inferencia difusas utilizadas por los controladores borrosos. Aquí, los AG son utilizados para optimizar las funciones de pertenencia empleadas por los modelos difusos. Dentro de esta rama se enmarcan los trabajos de Bastian (2000), que utiliza programación genética para identificar modelos matemáticos difusos, Wu & Yu (2000), en donde se propone un AG basado en aprendizaje para la identificación de modelos TSK, y Huang & Wang (2000), que desarrollaron un algoritmo genético de macroevolución adaptiva para diseños de modelos borrosos.

La segunda rama, aborda la integración en sentido inverso, presentando diferentes alternativas para la fuzziyficación o introducción de los conceptos de la matemática difusa en los AG clásicos. De este modo, han surgido diversas variantes difusas de los AG. Ejemplos de estos desarrollos son las investigaciones de Buckley & Hayashi (1994), quienes presentan un Algoritmo Genético Difuso (AGD) con una representación fuzziyficada para los genes de los individuos, y Herrera *et al.* (1997), en donde se proponen operadores genéticos difusos para una clase particular de AG conocidos como Real-Code Genetic Algorithms (RCGA).

Este trabajo se enmarca dentro de esta segunda línea de investigación, presentándose un AGD cuyo principal objetivo es superar los problemas de diversidad poblacional observados en los AG tradicionales. El nuevo algoritmo emplea una representación de los cromosomas diferente a la planteada por Buckley & Hayashi (1994), en donde cada individuo es ahora caracterizado a través de un número difuso. Asimismo, los operadores genéticos tradicionales son redefinidos en términos de la nueva estructura genética.

## ALGORITMOS GENÉTICOS TRADICIONALES

Cada individuo de la población es representado mediante su cromosoma, el cual es usualmente codificado como una cadena binaria de unos y ceros, donde cada bit constituye un gene del patrón genético. El cromosoma también se conoce como *genotipo* del individuo, mientras que el valor asociado a esta estructura constituye su *fenotipo*.

Asimismo, cada individuo posee un “fitness”, el cual constituye una medida de las bondades del individuo como posible solución al problema. En términos generales, sea  $t$  el número de generaciones y  $P(t)$  la población en la  $t$ -ésima generación, el AG puede expresarse como sigue:

```
 $t \leftarrow 0$ ; {  $t$  representa el número de generaciones }
Inicializar la población inicial  $P(t)$ ;
Calcular el fitness de los individuos de  $P(t)$ ;
Mientras la condición de terminación no se satisfaga hacer:
   $t \leftarrow t+1$ ;
  Seleccionar una subpoblación  $S(t)$  de individuos de  $P(t-1)$ ;
  Efectuar el cruzamiento y mutación de los miembros de  $S(t)$  formando una subpoblación  $S'(t)$ ;
  Calcular el fitness de los individuos de  $S'(t)$ ;
  Obtener  $P(t)$  sustituyendo algunos individuos de  $P(t-1)$  por los individuos de  $S'(t)$ ;
fin-mientras
```

Como se puede observar, en cada iteración  $t$  del AG se selecciona un subconjunto  $S$  de individuos de  $P(t)$  los cuales son cruzados y/o mutados. Esta selección se realiza de forma tal que aquellos cromosomas con mejor fitness poseen mayores posibilidades de integrar  $S$ . Posteriormente, estos nuevos individuos son incorporados a la generación  $t+1$  de la población. Finalmente, y con el objeto de mantener estable la población, se elimina un número igual de individuos de la  $t$ -ésima generación. Estos pasos se repiten hasta satisfacer alguna condición de terminación predeterminada.

## PLANTEO DIFUSO DEL PROBLEMA DE OPTIMIZACIÓN

El primer paso hacia la fuzzyficación de los AG es establecer un planteo para el problema de optimizar conjuntos difusos. En particular, para problemas de maximización se puede establecer la siguiente formulación:

Sea  $F$  tal que:  $\bar{Y} = F(\bar{X})$

donde  $\bar{X}$  es un subconjunto difuso para algún intervalo  $[0, M] \subseteq \mathbf{R}$  con  $M > 0$ .

$\bar{Y}$  es un subconjunto difuso de  $\mathbf{R}$ .

Nuestro problema consiste en encontrar el  $\bar{X}$  en  $[0, M]$  tal que “maximiza”  $\bar{Y}$ . Sin embargo, no es posible maximizar directamente  $\bar{Y}$  dado que se trata de un conjunto difuso. Por tal motivo, resulta necesario definir una función  $M$  que permita “medir” cuan grande es un determinado  $\bar{Y}$ . Sea  $M(\bar{Y}) = \Theta$ , donde  $\Theta$  es un subconjunto de  $\mathbf{R}$ . De este modo, el problema ahora consiste en encontrar un  $\bar{X}$  que maximice  $\Theta$ , quedando nuestro problema de optimización replanteado como:

$$F(\bar{X}) = \Theta$$

## FUZZYFICACIÓN DE LOS ALGORITMOS GENÉTICOS TRADICIONALES

Para fuzzificar los AG es necesario establecer en primer lugar la representación binaria de un número difuso, lo cual constituye la base para la representación del cromosoma de un individuo.

### Definición: (Representación Binaria de un Cromosoma Difuso)

Sea  $\bar{X}$  un número difuso triangular,  $\bar{X} = [x_1, x_2, x_3]$ , diremos que su correspondiente representación binaria difusa es  $\bar{B} = [b_1, b_2, b_3]$  donde  $b_1$ ,  $b_2$  y  $b_3$  son los genotipos de los fenotipos  $x_1$ ,  $x_2$  y  $x_3$  respectivamente.

Asimismo, el fitness de un cromosoma difuso  $\bar{X}$  es definido como el  $M(F(\bar{X}))$ . Dada esta definición, el operador de selección para los algoritmos genéticos difusos (AGD) resulta idéntico al de los AG clásicos dado que emplea el valor real correspondiente a  $M(F(\bar{X}))$ . Sin embargo, la redefinición de la estructura de un cromosoma como una terna de números binarios torna necesario un replanteo de los operadores de cruzamiento y mutación.

### Definición: (Operador de Cruzamiento)

Sean  $\bar{X}_1$  y  $\bar{X}_2$  dos individuos cuyos cromosomas son  $\bar{B}_1 = [b_{11}, b_{12}, b_{13}]$  y  $\bar{B}_2 = [b_{21}, b_{22}, b_{23}]$ , y sea  $n$  la cantidad de bits empleados para la representación binaria. Un cruzamiento de

un punto generará dos nuevos individuos  $\bar{X}_3$  y  $\bar{X}_4$  cuyos cromosomas  $\bar{B}_3 = [b_{31}, b_{32}, b_{33}]$  y  $\bar{B}_4 = [b_{41}, b_{42}, b_{43}]$  serán tales que los primeros  $n/2$  genes de  $b_{31}$ ,  $b_{32}$  y  $b_{33}$  serán iguales a los  $n/2$  primeros genes de  $b_{11}$ ,  $b_{12}$  y  $b_{13}$  y los  $n/2$  últimos genes de  $b_{31}$ ,  $b_{32}$  y  $b_{33}$  serán iguales a los  $n/2$  últimos genes de  $b_{21}$ ,  $b_{22}$  y  $b_{23}$ . Mientras que los primeros  $n/2$  genes de  $b_{41}$ ,  $b_{42}$  y  $b_{43}$  serán iguales a los  $n/2$  primeros genes de  $b_{21}$ ,  $b_{22}$  y  $b_{23}$  y los  $n/2$  últimos genes de  $b_{41}$ ,  $b_{42}$  y  $b_{43}$  serán iguales a los  $n/2$  últimos genes de  $b_{11}$ ,  $b_{12}$  y  $b_{13}$ . El cruzamiento de cromosomas difusos puede generar un hijo  $\bar{B} = [b_1, b_2, b_3]$  en donde no se verifique que  $b_1 \leq b_2 \leq b_3$ . En tales casos, resulta necesario reordenar los  $b_i$  para obtener un número triangular difuso consistente.

La última etapa del cruzamiento consiste en analizar el fitness de cada  $b_i$  y construir su cromosoma difuso de la siguiente forma:

- 1) Si  $(\text{fitness}(b_1) \text{ y } \text{fitness}(b_2)) \leq \text{fitness}(b_3)$  entonces el  $\bar{B} = [b_1, b_3, b_3]$
- 2) Si  $(\text{fitness}(b_3) \text{ y } \text{fitness}(b_2)) \leq \text{fitness}(b_1)$  entonces el  $\bar{B} = [b_1, b_1, b_3]$
- 3) Si  $(\text{fitness}(b_1) \text{ y } \text{fitness}(b_3)) \leq \text{fitness}(b_2)$  entonces el  $\bar{B} = [b_1, b_2, b_3]$

Esta regla asegura que el centro del número difuso corresponda al  $b_i$  que posee mejor fitness. De este modo, no se modifica el rango de valores correspondiente al conjunto difuso, lo cual preserva los niveles de diversidad poblacional, y se aumenta la presión selectiva.

### **Definición: (Operador de Mutación)**

Sea  $A$  un individuo cuyo cromosoma es  $[b_1, b_2, b_3]$ . La mutación genética de  $A$  puede producirse en cualquiera de los cromosomas de la terna, e incluso en varios de ellos a la vez. Básicamente, la mutación para números triangulares difusos aplica el operador de mutación tradicional a cada uno de los  $b_i$ . Nuevamente, si luego de la mutación, no se preserva la relación  $b_1 \leq b_2 \leq b_3$ , un reordenamiento de los  $b_i$  resultará necesario.

### **ALGORITMO GENÉTICO BASADO EN NÚMEROS TRIANGULARES DIFUSOS**

Habiéndose definido los conceptos de cromosoma, cruzamiento y mutación basados en números triangulares difusos se presenta a continuación el AGD:

```

t ← 0; {t representa el número de generaciones}
Inicializar la población difusa inicial P(t);
Calcular el fitness de los individuos de P(t);
Mientras la condición de terminación no se satisfaga hacer:
    t ← t+1;
    Seleccionar una subpoblación difusa S(t) de individuos de P(t-1);
    Efectuar el cruzamiento y mutación difusa de los miembros de S(t)
        formando una subpoblación difusa S'(t);
    Calcular el fitness de los individuos de S'(t);
    Obtener P(t) sustituyendo algunos individuos de P(t-1)
        por los individuos de S'(t);
fin-mientras

```

Como puede apreciarse, el AGD tiene la estructura del AG tradicional, sólo que la representación de los cromosomas y los operadores genéticos ahora son difusos.

## ANÁLISIS COMPARATIVO ENTRE EL AG TRADICIONAL Y EL AGD

Para analizar el desempeño del AGD frente al AG tradicional (ó AG), se implementaron ambos algoritmos en lenguaje C, y se utilizaron ambas técnicas para resolver varios casos de estudio. En todos los casos, el problema consistió en obtener el óptimo de una función.

La función empleada para la desfuzzyficación de un individuo difuso (ID) fue la siguiente:

$$\text{Valor Desfuzzycado} = (\text{ID.fmay} + 2 * \text{ID.fmed} + \text{ID.fmen}) / 4$$

donde ID.fmen es el fenotipo correspondiente cromosoma menor de ID,  
ID.fmed es el fenotipo correspondiente al cromosoma medio de ID,  
ID.fmay es el fenotipo correspondiente al cromosoma mayor de ID,


Es importante aclarar que se definió esta forma de desfuzzificación para ponderar con mayor peso al fenotipo del centro. Esta elección se debe a que, como se explicó anteriormente, el cruzamiento difuso asegura que el valor del medio poseerá siempre un fitness mayor o igual al de los extremos del conjunto borroso.

## DESCRIPCIÓN DE LOS CASOS DE ESTUDIO

Ambos algoritmos fueron testeados con una amplia variedad de ejemplos. En general se observó que las principales diferencias de desempeño se presentan para funciones discontinuas, cuyos máximos locales dificultan la convergencia del AG hacia el máximo global. Por esta razón , los resultados aquí reportados se basan en la optimización de las siguientes funciones  $f: R \rightarrow R$ :


### Caso de Estudio 1:

$$f(x) = x * \text{sen}(10 * \pi * x) + 1,0 \quad \text{donde } x \in [-1..2]$$




Caso de Estudio 2:

$$f(x) = \begin{cases} x & \text{si } x \leq 30 \\ 20 & \text{si } 30 < x \leq 70 \\ 100 - x & \text{si } x > 70 \end{cases} \quad \text{donde } x \in [0..100]$$



Caso de Estudio 3:


$$f(x) = \begin{cases} \log(x) & \text{si } x \leq 15 \\ 1 & \text{si } 15 < x \leq 30 \\ \log(x) - x * 0,05 & \text{si } x > 30 \end{cases} \quad \text{donde } x \in [1..50]$$






Caso de Estudio 4:

$$f(x) = \begin{cases} x^2 & \text{si } x \leq -10 \\ 900 & \text{si } -10 < x < 10 \\ x^2 + x * 0,1 & \text{si } x \geq 10 \end{cases} \quad \text{donde } x \in [-40..40]$$



Caso de Estudio 5:

$$f(x) = \begin{cases} 5,5 & \text{si } x < 0 \\ x + 3 & \text{si } 0 \leq x < 3 \\ 5,5 & \text{si } 3 \leq x < 9 \\ x - 5,5 & \text{si } 9 \leq x \leq 12 \\ 5,5 & \text{si } x > 12 \end{cases} \quad \text{donde } x \in [-3..13]$$



## RESULTADOS

Los cinco casos de estudio fueron resueltos por ambos algoritmos empleando probabilidades de 0,15 y 0,8 para la mutación y el cruzamiento respectivamente. La tabla 1 muestra los resultados obtenidos. Las primeras tres columnas identifican el caso de estudio, la cantidad de generaciones y tamaño de la población utilizados en cada corrida. Las columnas centrales muestran los mejores individuos y sus respectivos fitness hallados por ambos algoritmos. Finalmente, las últimas dos columnas muestran los valores de  $x$  y  $f(x)$  correspondientes al máximo global de la función.

Función	Cant. Gen.	Tam. Pob.	AGD		AG		$x$	$f(x)$
			valor	fitness	valor	fitness		
CE1	200	20	1,849	2,849	1,850	2,850	1,850	2,850
CE2	100	30	30,000	30,000	70,000	29,990	30,000	30,000
CE2	200	30	30,000	30,000	70,000	29,990	30,000	30,000
CE3	100	30	15,000	1,176	15,000	1,176	15,000	1,176
CE4	100	20	39,993	1603,439	-39,990	1599,207	40,000	1604,000
CE4	200	20	39,996	1603,642	-40,000	1599,999	40,000	1604,000
CE5	50	50	2,990	5,990	12,000	6,500	12,000	6,500
CE5	100	50	11,986	6,486	12,000	6,500	12,000	6,500

**Tabla 1.** Resultados

En los casos de estudio 1 y 3 se puede observar que ambos algoritmos obtienen el óptimo de la función. Para los ejemplos 2 y 4, el AGD alcanzó el máximo global mientras que el AG convergió a un máximo local. Observando los gráficos de estas dos funciones, se aprecia que el peor desempeño del AG se debe a que su fuerte presión selectiva concentra la búsqueda en el sector del dominio correspondiente al máximo local, lo cual conduce hacia una convergencia prematura. Esta situación se mantiene aún luego de duplicar la cantidad de generaciones a explorar.

En el último caso de estudio, el AGD cae en una convergencia prematura. No obstante esto, al duplicarse la cantidad de generaciones el algoritmo difuso logra alcanzar el máximo global. Esto es consecuencia de que el AGD preserva una mayor diversidad poblacional, lo cual le permite mantener los esquemas genéticos necesarios para generar la solución óptima.

## CONCLUSIONES

En este trabajo se presentó una propuesta de fuzzificación de los algoritmos genéticos cuyo principal objetivo fue superar los problemas de convergencia prematura exhibidos en los algoritmos genéticos tradicionales. Nuestro enfoque apunta a mejorar la diversidad poblacional mediante una nueva representación de los individuos de la población basada en el uso de conjuntos difusos. Junto con esta variante en la estructura genética de los cromosomas, se realizó una redefinición de los operadores genéticos de cruzamiento y mutación.

El algoritmo genético basado en números triangulares difusos fue implementado y comparado con el tradicional. Los resultados obtenidos para varios casos de estudio revelaron que la nueva propuesta posee efectivamente una mejor diversidad genética, logrando así superar los problemas de convergencia prematura presentes en estos ejemplos.

A futuro se proyecta experimentar con distintas estrategias de desfuzzificación y proponer operadores genéticos difusos alternativos que permitan acentuar los logros alcanzados por este nuevo método.

## REFERENCIAS

**Banzhaf, W.; Nordin, P.; Keller, R.E. & Francone, F.D.** “Genetic Programming: An Introduction: On the Automatic Evolution of Computer Programs and Its Applications”, Morgan Kaufmann Publishers, ISBN: 155860510X, 1998.

**Bastian, A.** “Identifying Fuzzy Models Utilizing Genetic Programming”, *Fuzzy Sets and Systems*, 113, 333-350, 2000.

**Buckley, J.J. & Hayashi, Y.** “Fuzzy Genetic Algorithm and Applications”, *Fuzzy Sets and Systems*, 61, 129-136, 1994.

**Gen, M. & Cheng, R.** “Genetic Algorithms and Engineering Optimization”, Wiley Series in Engineering Design and Automation, John Wiley & Sons, ISBN: 0471315311, 2000.

**Goldberg, D.E.** “Genetic Algorithms in Search, Optimization and Machine Learning”, Addison-Wesley Pub Co, ISBN: 0201157675, 1989.

**Herrera, F.; Lozano, M. & Verdegay, J.L.** “Fuzzy Connectives Based Crossover Operators to Model Genetic Algorithms Population Diversity”, 92, 21-30, 1997.

**Huang, Y.-P. & Wang, S.-F.** “Designing a Fuzzy Model by Adaptive Macroevaluation Genetic Algorithms”, *Fuzzy Sets and Systems*, 113, 367-379, 2000.

**Klir, G. & Yuan, B.** “Fuzzy Sets and Fuzzy Logic, Theory and Applications”, Prentice Hall, 1995.

**Michalewicz, Z.** “Genetic Algorithms + Data Structures = Evolution Programs”, 3ra edición revisada, Springer Verlag, ISBN: 3540606769, 1996.

**Wu, B. & Yu, X.** “Fuzzy Modelling and Identification with Genetic Algorithm Based Learning”, *Fuzzy Sets and Systems*, 113, 351-365, 2000.

**Zadeh, L.A.** “Fuzzy Sets”, *Inf. Control* 8, 1965.

Nombre de archivo: CACIC 2001 - Un Algoritmo Genético basado en Conjuntos Difusos  
(versión final).doc  
Directorio: C:\WINDOWS\DESKTOP  
Plantilla: C:\WINDOWS\Profiles\ponzoni\Application  
Data\Microsoft\Plantillas\Normal.dot  
Título: UN ALGORITMO GENÉTICO BASADO EN CONJUNTOS  
DIFUSOS  
Asunto:  
Autor: U.N.S.  
Palabras clave:  
Comentarios:  
Fecha de creación: 8/15/01 5:30  
Cambio número: 21  
Guardado el: 8/15/01 6:38  
Guardado por: NN  
Tiempo de edición: 65 minutos  
Impreso el: 8/15/01 6:40  
Última impresión completa  
Número de páginas: 11  
Número de palabras: 3,473 (aprox.)  
Número de caracteres:19,105 (aprox.)