

# Optimización mediante algoritmos genéticos: aplicación al diseño de celosías



**José Luis Galindo Corvillo**

Ingeniero Industrial del ICAI. Desarrolla su actividad profesional en el Departamento de Ferroviaria de Instalaciones Inabensa S.A. Ha dirigido proyectos fin de carrera en el ICAI en el área de optimización de estructuras.



**Alberto Carnicero López**

Doctor Ingeniero Industrial por la ETSI-ICAI. Profesor del Departamento de Ingeniería Mecánica e Investigador en el Instituto de Investigación Tecnológica de la ETSI-ICAI. Sus campos de conocimiento están relacionados con la aplicación de métodos numéricos (elementos finitos y otros) a la resolución de problemas de dinámica de estructuras y mecánica de medios continuos, así como el modelado de materiales inteligentes para su empleo en actuadores o sensores.

## Introducción

Los Algoritmos Genéticos (AG) son una parte de los llamados Algoritmos Evolutivos, que fueron propuestos en los años 60 y 70 por Rechenberg con el fin de resolver grandes problemas de optimización y que se basan en las leyes de la evolución de las especies propuestas por Darwin en su libro *El origen de las especies* publicado en 1859. Según estas leyes, se dispone de una población de individuos que van a sufrir una serie de cruces o reproducciones y mutaciones para evolucionar a individuos mejor adaptados para el medio en el que se desarrollan. Se puede decir que los individuos más aptos sobreviven y los menos aptos, mueren.

Toda la información genética de una especie está contenida en su genoma. Éste consiste en una cadena de cromosomas, formados por genes, que contienen el ADN del individuo y codifican todos sus rasgos. La información genética se emplea en la reproducción de los individuos. Durante la reproducción, los genes de los padres se cruzan, formando nuevos cromosomas y, por lo tanto, los hijos contienen la información genética de los padres. Además, los hijos pueden sufrir mutaciones que hagan cambiar su ADN.

Los AG como tales fueron propuestos en 1973 por John Holland y desarrollados posteriormente en la Universidad de Michigan por él mismo y sus colaboradores, entre los que destaca DeJong, con sus estudios sobre

la efectividad del cruce multipunto; estas investigaciones fueron plasmadas en el libro *Adaptation in Natural and Artificial Systems* de Holland, publicado en 1975. Sin embargo no fue hasta 1989 cuando los AG se hicieron famosos, gracias a Goldberg, en un artículo sobre búsqueda, optimización y máquinas de aprendizaje.

La finalidad genérica de los AG es la de optimizar cuando las técnicas tradicionales presentan dificultades, como por ejemplo, en caso de que exista una gran cantidad de variables condicionadas a optimizar, o cuando se traten problemas altamente no lineales y con muchas restricciones. Por ello, los AG se pueden aplicar a numerosos campos, desde la ingeniería, hasta el modelado económico, social, político o comercial. Dentro del campo de la ingeniería las aplicaciones más comunes son la programación de actividades, el control, la planificación de redes, el diseño, la optimización de componentes y la robótica.

Los AG combinan dos fenómenos que son básicos para que cualquier algoritmo de optimización sea eficiente, la *exploración* y la *explotación* [Holland,1975]; la *exploración* consiste en investigar nuevos y desconocidos individuos en el espacio de las soluciones del problema. La *explotación* se usa para aprovechar el conocimiento que se tenía de los puntos anteriormente encontrados para encontrar puntos mejores.

Por último comentar que las fases y procedimientos empleados en la optimización con

algoritmos genéticos admiten muchos más matices y particularizaciones que los que aquí se presentan y dependen fundamentalmente del problema que se esté tratando. Se pretende mostrar simplemente en qué consiste esta técnica y presentar una aplicación práctica de la misma. A continuación se comentan brevemente las distintas etapas de las que consta un algoritmo genético.

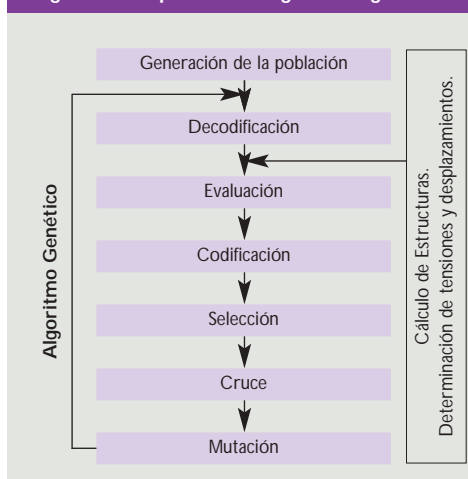
### Etapas de un Algoritmo Genético

Un AG comienza con la *generación de una población* inicial de los individuos, denominados cromosomas, que son posibles soluciones al problema planteado. Estos individuos están compuestos por cadenas de números (por ejemplo, ceros y unos) que codifican una serie de parámetros característicos (por ejemplo la sección de una viga, el tiempo empleado en hacer una tarea, el precio de la energía eléctrica, etc). El siguiente paso será la *decodificación* de dicha población para obtener el valor real (físico) de dichos parámetros; una vez obtenidos estos valores, los individuos son *evaluados*, indicando lo aptos que son para realizar la misión encomendada que se refleja en una función que modelará qué se quiere optimizar; los más aptos según dicha función de evaluación son *seleccionados* y se cruzan entre sí, produciendo una nueva población que sustituirá a la anterior; esta población obtenida del cruce pasa por un fenómeno de *mutación*, obteniéndose la población final después de la primera iteración (generación). Ésta, que se supone más apta que la anterior, será la población de la que se partirá para ejecutar la segunda iteración (segunda generación), en la que se vuelven a repetir las etapas del AG, hasta completar el número total de iteraciones de que conste el algoritmo (ver Figura 1).

Además de estas etapas, en la resolución de problemas de diseño de estructuras, como el que se presentará posteriormente, es necesario realizar una etapa de cálculo de esfuerzos entre la decodificación y la evaluación [González,1999], [Erbatur, Hasançebi, Tütüncü y Kiliç, 2000]; con objeto de determinar los desplazamientos en los nudos y las tensiones en los distintos elementos de cada una de las estructuras (cromosomas) que componen la población. Estos valores se emplearán posteriormente en la etapa de evaluación.

El *número de iteraciones* que se realicen en el AG es un parámetro definido por el diseñador del mismo, evaluando el tiempo de proceso, y dependerá del tipo de problema.

Figura 1. Etapas de un algoritmo genético



Debe ser suficientemente grande para que se produzca una exploración de soluciones, pero no excesivo para que no se emplee tiempo de proceso innecesario cuando ya se ha alcanzado una solución satisfactoria.

El *tamaño de la población* es otro parámetro a definir por el diseñador. En términos generales se puede decir que cuanto mayor es el tamaño de la población, mejor para el AG, ya que habría más individuos para poder llegar al óptimo. Sin embargo esto no es del todo cierto, ya que dependiendo del problema, puede que se tenga un tamaño de población mucho mayor del que sería necesario para resolver el problema, con lo que se estaría empleando un tiempo de computación innecesario con sus costes correspondientes.

### Generación de la población

La generación de la población está muy relacionada con la codificación, ya que para generar una población de individuos es necesario saber qué representan éstos. Consiste en la generación de una serie de cadenas de números aleatorios, cada una de las cuales representa un individuo de la población. Como ya se ha dicho previamente, la generación de la población sólo se efectúa en la primera iteración.

### Codificación y decodificación

La codificación es una de las fases más importantes dentro de los AG. De ella depende directamente poder llegar a un óptimo más o menos rápidamente. Para la correcta codificación, se debe tener conocimiento del problema e identificar, tanto las variables a codificar, como el orden de magnitud de dichas variables.

Los cromosomas son cadenas de números que representan al individuo y pueden codificar numerosos parámetros de éste. Cada parámetro se codifica mediante un grupo de números que pueden representar diferentes valores. Cada grupo de números representativos de cada parámetro se ponen seguidos unos de otros, formándose así el cromosoma. Existen varios tipos de codificación, como la binaria, la entera, la de árbol, la de valor, grey, etc... Las más usuales y simples son la codificación binaria, la entera y la grey.

Se presenta a continuación un ejemplo de codificación binaria por ser una de la más sencillas y extendidas. Ésta consiste en emplear una cadena de números binarios como cromosomas, como se puede observar en el siguiente ejemplo de codificación de tres parámetros (A, I, L) en una misma cadena con grupos de 4 bits por parámetro, que podrían representar el área, el momento de inercia y la longitud de una viga.

**Cromosoma G (C. Binario)**  
 1 0 0 1 0 0 0 1 1 1 0 1  
 A            I            L

El número de bits a emplear dependerá del orden de magnitud de las variables involucradas en el problema.

### Evaluación

La evaluación permite determinar el buen o mal ajuste que tiene cada individuo de la población a una función, que es la que va a regir el comportamiento de éstos en las sucesivas iteraciones. Esta función la denominaremos *función de ajuste*.

La *función de ajuste* modela el problema global de optimización, e incluso, a veces coincide con la función a optimizar o función objetivo. Dará valores mayores para aquellos cromosomas que sean mejores para la función a optimizar y menores para aquellos que sean peores.

Dentro del problema a optimizar, nos podemos encontrar con problemas que admitan soluciones sin ningún tipo de restricción, en cuyo caso la función de ajuste coincide con la función objetivo. Sin embargo, el caso habitual es que nos encontremos con restricciones sobre los valores de las variables (por ejemplo, la tensión en una barra no debe superar la tensión admisible por el material, el espesor mínimo puede estar limitado por criterios de corrosión, etc.). En este caso la

función de ajuste debe reflejar de alguna forma estas restricciones. La forma habitual es introducir algún tipo de penalización (constante o variable) en aquellos individuos que no cumplan las restricciones de forma que éstos vayan desapareciendo con el paso de las poblaciones.

En la evaluación de los problemas con restricciones se normalizan éstas de la forma  $g_i(x) \leq 0$ . Con esta forma y multiplicada por dos factores, C y K, la restricción se añade a la función de ajuste (suma o resta según maximicemos o minimicemos).

$$f(x) = f_{\text{objetivo}}(x) \pm K \cdot C \cdot g(x)$$

- C es un número binario cuyo valor es 1 si la restricción no se cumple y 0, si se cumple.
- K es la penalización. Suele ser un número real que se elige dependiendo del peso que se quiere dar a las soluciones que no cumplan las restricciones. Si el parámetro K es muy pequeño la solución final podría caer en una región no factible, pero si K es muy grande se puede dar convergencia prematura que impide evaluar otras posibles soluciones y por lo tanto encontrar el máximo o mínimo que buscamos. Generalmente se desea que K tenga valores pequeños en las generaciones iniciales y que vaya gradualmente aumentando a medida que van pasando las iteraciones. Una ecuación que tiene en cuenta lo anterior puede ser de la forma:  $K = K_0 [1+0.2 (n-1)]$ , donde  $K_0$  representa la penalización inicial (que dependerá de cada problema) y n la iteración [Suresh y Mohamed,1998]:

$$f(x) = f_{\text{objetivo}}(x) \pm K_0 [1+0.2 (n-1)] C \cdot g(x)$$

### Selección

La selección permite elegir a los individuos que sean más aptos según la evaluación anterior. Estos individuos se llevan aparte del resto de la población, a un grupo de cruce (GDC), para su posterior cruce entre ellos. La idea general de la selección es que los mejores individuos según la función de ajuste serán los que tengan más posibilidades de ir al GDC.

En la selección existe una gran variedad de métodos, cuyo uso debe depender del tipo de problema, el diseñador del AG debe evaluar cuál de los posibles métodos se puede ajustar más a su problema. A continuación se presenta uno de los métodos de selección posibles (ruleta) pero conviene no olvidar

# LÍDER EN SERVICIOS INTEGRALES PARA LA INDUSTRIA




- Ingeniería básica y de detalle de plantas de proceso **Intecsa-Uhde Industrial**
- Ingeniería básica y de detalle de centrales energéticas **Initec Energía**
- Mantenimiento industrial integral, montajes mecánicos y “pipelines” **Masa**
- Montajes eléctricos y de instrumentación, fabricación de equipos eléctricos **Cymi**
- Plataformas petrolíferas y grandes bienes de equipo **Dragados Offshore**
- Infraestructura y servicios de telecomunicaciones **Dyctel**
- Sistemas de control **Sice**

 **Dragados Industrial**

Avda. de Tenerife, 4-6  
San Sebastián de los Reyes  
28700 Madrid  
Teléfono 91 583 30 00

[www.dragados.com](http://www.dragados.com)



que existe una gran cantidad de métodos cuya utilidad depende del problema que se esté abordando.

Así, la selección por ruleta consiste en colocar todos los elementos de la población en una ruleta según su aptitud respecto de la *función de ajuste*. El que tiene un ajuste mejor, dispondrá de un área mayor en la ruleta y el que lo tenga peor dispondrá de un área menor. Luego se 'lanza' la ruleta para seleccionar un valor.

El método de la ruleta es uno de los más usados pero puede presentar problemas cuando hay funciones con varios máximos y mínimos. Cuando se da este tipo de problemas se suele fomentar la selección de algunos individuos con peor ajuste para que se produzca una mayor variabilidad en las poblaciones, o incluso, en la etapa de cruce se penalizan los cruces entre individuos con mayor ajuste.

En el siguiente gráfico se puede observar el funcionamiento de la ruleta (ver Figura 2).

### Cruce o cruzamiento

La etapa de cruce es otro elemento muy importante en los AG y está íntimamente relacionada con la de selección. Consiste en la reproducción de los padres que se cruzan entre sí para dar nuevos hijos que formarán parte de la nueva población. Estos padres son elegidos de entre todos los individuos del GDC, generalmente de forma aleatoria.

En el cruce existe un parámetro básico que es la *probabilidad de cruce* que indica la frecuencia con que se produce la selección. Es obligatorio en el AG que el cruce se realice de acuerdo a una *probabilidad de cruce*, para decidir si se produce o no cruce en las suce-

sivas iteraciones. Si no se produce el cruce los hijos serán copias exactas de los padres. La probabilidad de cruce puede depender del tipo de problema que se trate pero es frecuente emplear una probabilidad de cruce de 0.6.

Para formar la nueva población, una vez cruzados los padres, se puede proceder de dos formas. La primera es poner a los hijos directamente como miembros de la nueva población de manera que los padres desaparezcan de ésta. La segunda es poner en la nueva población los dos mejores cromosomas, ya sean padres o hijos, con lo que se mejora el ajuste de la función. Este último sistema se denomina *"niche"* [Beasley, Bull y Martin,1993].

Al igual que ocurre en la selección, existe una gran variedad de posibilidades dentro del cruzamiento en los AG: punto único, múltiple, uniforme... A modo de ejemplo se presenta el cruce con punto único.

Éste consiste en seleccionar un punto de la cadena de los padres, copiando desde el principio de la cadena hasta ese punto, en el primer hijo los valores de la cadena del primer padre, y en el segundo, los del segundo padre. Desde el punto hasta el final, se copian en el primer hijo los valores de la cadena del segundo padre, y en el segundo, los del primer padre.

En el siguiente ejemplo se aprecia el cruce de punto único (la coma representa el punto de cruce seleccionado):

PADRES	HIJOS
1111,1111111111	1000,1111111111
1000,0000000000	1111,0000000000

### Mutación

La etapa de mutación es el paso siguiente al cruce. El concepto de mutación en los AG es el mismo que en las leyes de la evolución. La mutación consiste en la variación de algún gen de los cromosomas de forma aleatoria, con lo que el individuo cambia sus características para mejorar o empeorar según sea el cambio.

El parámetro básico en esta etapa es la *probabilidad de mutación*. La *probabilidad de mutación* es un parámetro análogo a la *probabilidad de cruce* e indica la frecuencia con que se produce la mutación dentro de la población; generalmente este parámetro es pequeño para que no se desvirtúen los individuos obtenidos en la etapa de cruce, pero es necesario para que en la población se

produzca una cierta variabilidad y las poblaciones tengan posibilidad de cambiar. La probabilidad de mutación suele tener un valor en torno al 1%.

Después del proceso de mutación ya se ha evaluado completamente el AG en el que se partía de una población inicial y se ha obtenido otra población distinta y teóricamente más adaptada al medio.

### Aplicación al cálculo del máximo de una función

Como ejemplo sencillo de aplicación se estudia el comportamiento de los AG en el cálculo del máximo de la función  $f(x) = \text{arctag}(3x) - \text{arctag}(x)$ . Esta función presenta un solo máximo, en el punto  $x = 0.578$  y de valor  $f(0.578) = 30^\circ$ . La forma de la función aparece en el gráfico superior (ver Figura 3), en el que se presenta el comportamiento del AG en cada una de las etapas.

### Codificación y generación de la población

Para la codificación se va a emplear el sistema binario y se van a codificar dos parámetros, la parte entera y la parte decimal del número real "x". Para ello, la parte entera se codifica con el sistema binario clásico de potencias de 2 y se emplean 4 bits, con lo que se pueden evaluar números con parte entera desde 0 hasta 15. Para la parte decimal se emplea una base de potencias de 1/2, y se emplean 7 dígitos, con lo que existe una variación de valor mínimo 0.0078 ( $1/2^7$ ) y un rango de valores desde 0.0078 hasta

$$0.992 \left( \sum_{i=1}^7 1/2^i \right)$$

En el siguiente ejemplo de cromosoma se puede observar la codificación empleada para el número 11.695:

Cromosoma										
1	0	1	1	1	0	1	1	0	0	1
$2^3$	$2^2$	$2^1$	$2^0$	$1/2^1$	$1/2^2$	$1/2^3$	$1/2^4$	$1/2^5$	$1/2^6$	$1/2^7$
Base										
$1 \cdot 2^3 + 0 \cdot 2^2 + 1 \cdot 2^1 + 1 \cdot 2^0 + 1 \cdot 1/2^1 + 0 \cdot 1/2^2 +$ $1 \cdot 1/2^3 + 1 \cdot 1/2^4 + 0 \cdot 1/2^5 + 0 \cdot 1/2^6 + 1 \cdot 1/2^7$ $= 11.695$										

### Evaluación

En la evaluación, la función de ajuste que se emplea coincide con la función a optimizar, ya que no existen restricciones que obli-

Figura 3. Función empleada para el cálculo de un máximo



guen a penalizar. Por tanto, la función de ajuste será:

$$f(x) = \text{arc tan}(3x) - \text{arc tan}(x)$$

### Selección

Se realiza la selección mediante el método de la ruleta comentado anteriormente.

### Cruce

En esta etapa se ha empleado una probabilidad de cruce del 60%. La elección de los padres que se van a cruzar se va a realizar de forma aleatoria de entre los individuos que se encuentran en el GDC. Se escogen al azar dos padres del grupo y se cruzan entre ellos dando lugar a los hijos de la nueva población.

Se presenta aquí la forma de cruce más simple, es decir, que los hijos resultantes del cruce se ponen directamente en la nueva población.

Para cada una de las posibilidades anteriores se plantean dos métodos de cruce: el método de punto único y el cruce uniforme.

### Mutación

En esta etapa se ha empleado una probabilidad de mutación del 1%.

### Resultados

La siguiente tabla representa los valores óptimos obtenidos en los experimentos realizados (un número de 20 para cada caso), según los distintos métodos de selección y de cruce, y según el número de individuos de la población y el número de iteraciones considerados en cada caso ( $p$  representa el número de individuos de la población y  $n$ , el número de iteraciones). Además, muestran la media de todos los

Figura 4

	Punto Único				Uniforme			
	p=10 n=100	p=10 n=200	p=20 n=100	p=20 n=200	p=10 n=100	p=10 n=200	p=20 n=100	p=20 n=200
1	0.539	0.586	0.578	0.570	0.531	0.547	0.555	0.570
2	0.555	0.461	0.578	0.570	0.484	0.578	0.500	0.578
3	0.625	0.578	0.570	0.539	0.570	0.688	0.586	0.578
4	0.555	0.594	0.578	0.625	0.602	0.570	0.570	0.578
5	0.555	0.570	0.664	0.625	0.555	0.547	0.555	0.578
6	0.523	0.578	0.563	0.578	0.594	0.578	0.578	0.617
7	0.563	0.586	0.648	0.578	0.859	0.492	0.539	0.578
8	0.492	0.703	0.578	0.594	0.578	0.570	0.563	0.578
9	0.492	0.570	0.570	0.578	0.609	0.570	0.492	0.594
10	0.867	0.594	0.578	0.570	0.539	0.578	0.578	0.578
11	0.547	0.609	0.656	0.578	0.711	0.570	0.594	0.563
12	0.617	0.547	0.586	0.578	0.578	0.484	0.594	0.578
13	0.594	0.492	0.672	0.578	0.578	0.594	0.570	0.625
14	0.578	0.570	0.609	0.570	0.570	0.594	0.578	0.578
15	0.563	0.578	0.570	0.578	0.570	0.781	0.578	0.633
16	0.578	0.578	0.570	0.570	0.555	0.578	0.570	0.578
17	0.648	0.586	0.586	0.578	0.602	0.609	0.570	0.578
18	0.492	0.578	0.570	0.391	0.578	0.578	0.648	0.500
19	0.453	0.578	0.578	0.586	0.594	0.594	0.555	0.570
20	1.000	0.578	0.492	0.578	0.578	0.484	0.570	0.492
Media	<b>0.592</b>	<b>0.576</b>	<b>0.590</b>	<b>0.571</b>	<b>0.592</b>	<b>0.579</b>	<b>0.567</b>	<b>0.576</b>
Varianza	<b>0.128</b>	<b>0.046</b>	<b>0.042</b>	<b>0.046</b>	<b>0.076</b>	<b>0.066</b>	<b>0.033</b>	<b>0.033</b>

Figura 5. Pasarela a optimizar





Figura 6. Nudos y barras en la estructura simétrica



experimentos obtenidos y la varianza respecto de esa media.

Como se puede ver, de forma general, al aumentar la población y el número de iteraciones del AG se produce una mejoría en el resultado. La mejoría es menos acusada con el aumento de población que con el número de iteraciones. A la vista de los resultados se puede deducir que la función debe presentar un máximo en la zona de 0.57-0.58 (ver Figura 4).

### Aplicación a la optimización de una celosía

Como ejemplo de aplicación a un caso real de esta técnica se presenta la optimización en peso y forma de la superestructura de una pasarela peatonal, de 4 metros de ancho, cumpliendo las restricciones de la NBE-EA-95 (ver Figura 5).

Debido a la simetría existente en la estructura, se va a estudiar la mitad de ésta para reducir el tiempo de cálculo empleado en la optimización. Dicha mitad se descompone en 11 nudos y 19 barras numerados según la figura inferior. Cada una de las barras de la estructura está compuesta por dos angulares (ver Figura 6).

Los parámetros empleados para codificar este problema son las áreas de las barras, según una lista de perfiles L seleccionados previamente, y las posiciones vertical y horizontal de los nudos (en todos menos en el número 1, que es fijo).

Teniendo en cuenta los valores de acciones características definidos por la AE-88 y los coeficientes de ponderación especificados por la EA-95 se ha redondeado la carga a soportar por la estructura a 5000 kg/m.

Optimizando exclusivamente la sección de las barras y conservando la forma, el peso de la mitad de la estructura, con las cargas consideradas, es de 2560 kg.

La celosía se ha calculado siguiendo los criterios de la norma NBE-AE-95. El acero

empleado es de tipo A37 con un límite elástico ( $\sigma_e$ ) de 2400 kg/cm<sup>2</sup>. Las restricciones que deben verificar las barras de la celosía son:

\*Barra a compresión. Su tensión máxima viene limitada por la estabilidad de la barra y se establece de la forma:

$$\sigma_{\text{máx}} \leq \frac{\sigma_e}{\omega} = \frac{2400}{\omega} \frac{\text{kg}}{\text{cm}^2}$$

Siendo  $\omega$  un coeficiente que depende de la esbeltez ( $\lambda$ ) de la barra:

$$\lambda = \frac{l_k}{i}$$

donde  $l_k$  es la longitud de pandeo e  $i$ , el radio de giro.

\*Barra a tracción. Su tensión máxima está limitada por

$$\sigma_{\text{máx}} \leq \sigma_e = 2400 \frac{\text{kg}}{\text{cm}^2}$$

### Codificación y generación de la población

Cada individuo de la población deberá codificar las 19 áreas de las barras, las 8 coordenadas horizontales y 10 verticales de los nudos. La codificación de las barras se realiza mediante una tabla de perfiles angulares codificando la posición del perfil dentro de la tabla.

Se van a emplear 4 bits para la posición en la tabla de perfiles y 6 para las coordenadas verticales y horizontales. Según el número de bits de cada uno de los elementos (áreas y coordenadas), la estructura de las cadenas de los individuos de la población sería la siguiente (ver Figura 7):

### Evaluación

El objetivo es minimizar el peso cumpliendo las restricciones de tensión impuestas. Además se limita la longitud de las barras a 5 metros y los nudos que inicialmente son superiores deben quedar siempre por encima de los inferiores. La función de ajuste elegida toma la siguiente forma:

$$F = \sum_{i=1}^{19} (\text{Peso} + \phi_1 + \phi_2 + \phi_3 + \phi_4)$$

donde,

- Para las barras sometidas a tracción que superen la tensión admisible:

$$\phi_1 = C_1 \cdot (1+0.2 (n-1)) \cdot (\sigma-2400)$$

- Para las barras sometidas a compresión que superen la tensión admisible:

$$\phi_2 = C_1 \cdot (1+0.2 (n-1)) \cdot (\sigma - \frac{2400}{\omega})$$

- Para las barras cuya longitud sea mayor que la admisible (5 m):

$$\phi_3 = C_2 \cdot (1+0.2 (n-1)) \cdot (\text{longitud}-5)$$

- Para las estructuras que tengan alguna coordenada vertical de los nodos superiores por debajo de las de los inferiores se introduce la penalización:

$$\phi_4 = C_3 \cdot (1+0.2 (n-1)) \cdot (\text{coord} (f,j) - \text{coord} (f,i))$$

donde  $j$  es la coordenada inferior, e  $i$ , la superior y  $n$  es el número de iteración en el que se encuentra el AG.

Los valores de  $C_1$ ,  $C_2$  y  $C_3$  variarán según la rapidez y exactitud que se quiera para llegar a la solución. Si son valores grandes, los individuos peores se eliminan rápidamente de la población y no existe suficiente variación de soluciones para el cruce, pudiéndose llegar a lo que se denomina convergencia prematura, mientras que si son pequeños la penalización también lo es, con lo que no se eliminarían individuos no aptos y el tiempo de computación sería excesivo.

### Selección, cruce y mutación

La selección de los individuos para el GDC se realiza por medio del método de la ruleta. Se emplea cruce uniforme con una probabilidad del 60%. La elección de los padres del GDC se realiza de forma aleatoria y la población se mantiene a lo largo de las generaciones. Además se considera una probabilidad de mutación del 1%.

Figura 7

	Número de Barra					Coord. Horizontal del Nudo					Coord. Vertical del Nudo				
	1	2	...	18	19	1	2	...	7	8	1	2	...	9	10
Cadena	4b	4b	4b	4b	4b	6b	6b	6b	6b	6b	6b	6b	6b	6b	6b



## Resultados

Empleando distintos número de población y número de iteraciones se llega a reducciones de peso sobre la estructura óptima original (con las secciones optimizadas) de hasta el

31%. A continuación se muestra la forma óptima de algunas de las estructuras obtenidas (con diferentes poblaciones y número de iteraciones) así como la evolución del peso con el número de iteraciones (ver Figuras 8-12).

Figura 8. Peso óptimo de la estructura 1875 kg. Reducción de peso 26.7%

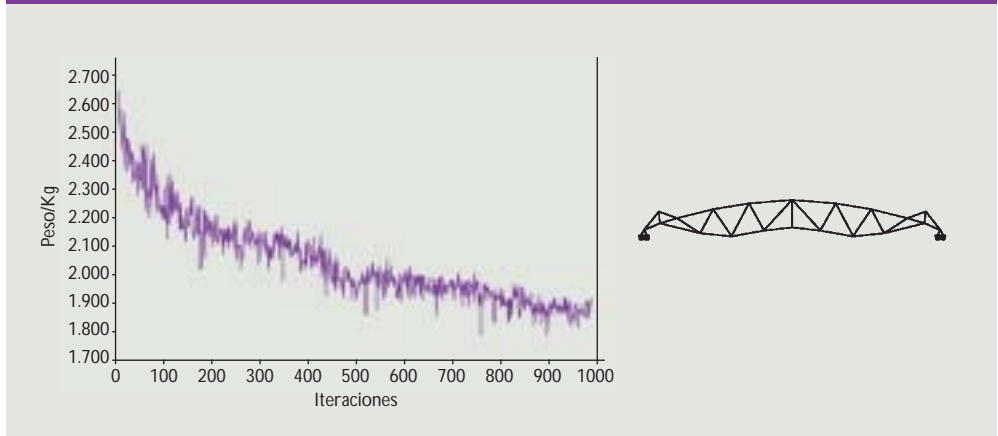


Figura 9. Peso óptimo de la estructura 1757 kg. Reducción de peso 31.3%

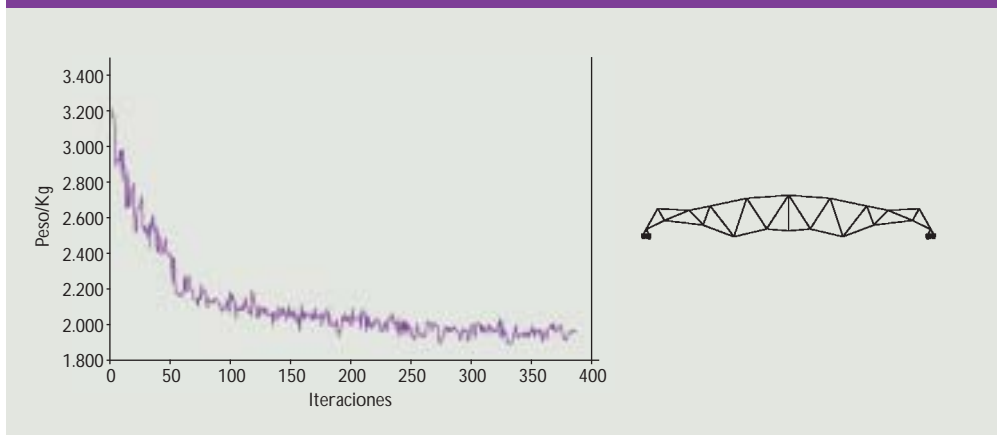


Figura 10. Peso óptimo de la estructura 1822 kg. Reducción de peso 28.8%



Figura 11. Peso óptimo de la estructura 2002 kg. Reducción de peso 21%

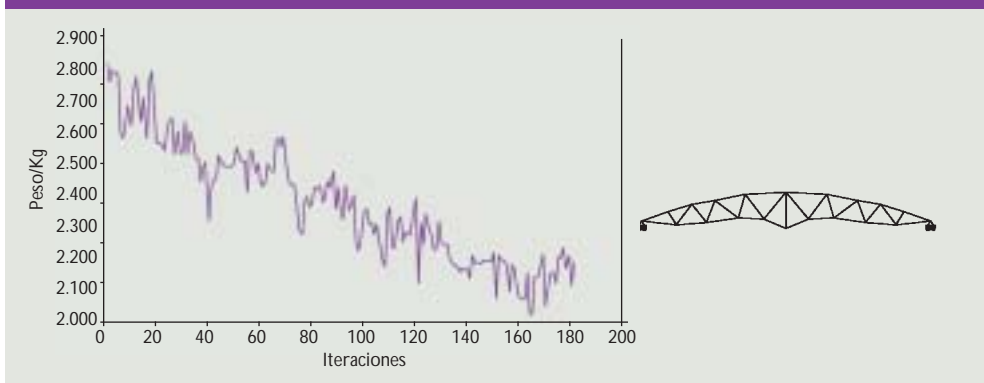
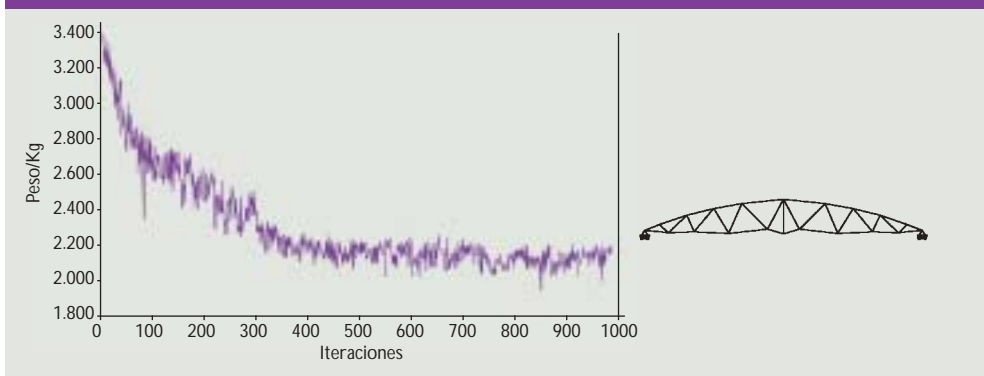


Figura 12. Peso óptimo de la estructura 1927 kg. Reducción de peso 24.7%



### Otros ejemplos

Se muestran a continuación otros ejemplos de formas óptimas (y la evolución del peso con el número de iteraciones) obtenidas

para el caso de torres de alta tensión. Como se puede ver, éstas son muy parecidas a las formas empleadas actualmente (ver Figura 13).

Figura 13. Otros ejemplos de formas óptimas

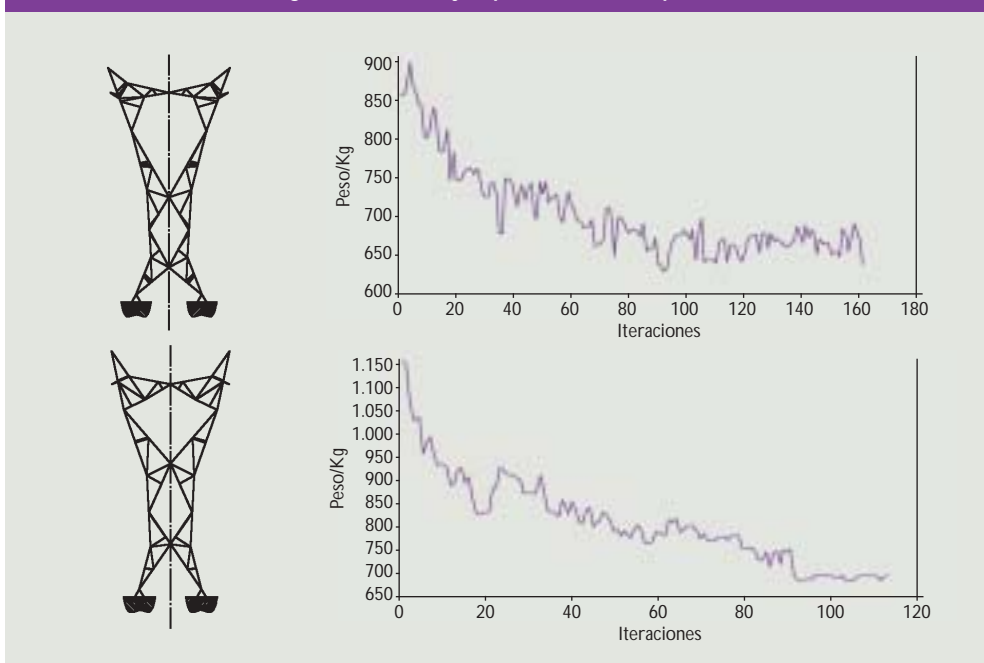
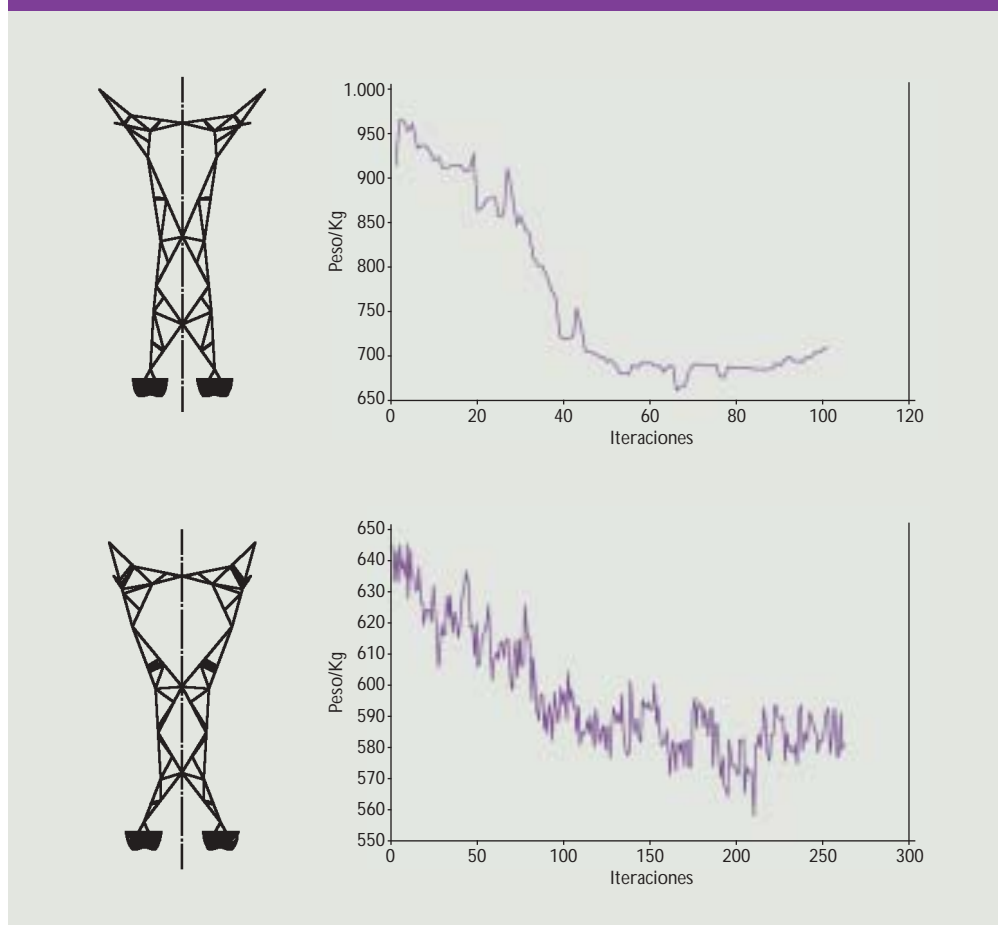


Figura 13 (continuación)



## Conclusiones

Los algoritmos genéticos se presentan como una herramienta interesante en temas de optimización en general y de estructuras en particular donde el número de parámetros a optimizar y el número de restricciones puede ser muy elevado. En este ejemplo la optimización se ha realizado en base a criterios exclusivamente resistentes, pero pueden ser incluidos otro tipo de criterios y restricciones como pueden ser criterios de tipo económicos, restricciones debidas a corrosión, periodos de entrega de materiales, durabilidad o funcionalidad.

El principal problema que presenta esta técnica aplicada al diseño de estructuras es su elevado tiempo de cálculo, lo que se puede convertir en un serio inconveniente en la optimización de grandes estructuras tridimensionales. En este caso se haría necesario realizar cálculo con procesadores en paralelo de forma que se reduzcan los elevados tiempos de computación. ■

## Referencias

- D. Beasley, D. R. Bull y R. R. Martin. 1993. An Overview of Genetic Algorithms. *University Computing*, 15 (4), 170-181.
- J.H. Holland. 1975. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- D. E. Golberg. 1989. *Genetic Algorithms in search, optimization and machine learning*. Addison-Wesley Publishing.
- I. Rechenberg. 1965. *Cybernetic solution path of and experimental problem*. Royal Aircraft Establishment, Library Translation 1122.
- I. Rechenberg. 1973. *Evolution Strategy: Optimization of technical systems according to the principles of biological evolution*. Frommann-Holzboog, Stuttgart.
- K. A. Dejong. 1975. *Analysis of the behaviour of a class of genetic adaptive system*. PhD Thesis, University of Michigan.
- C. González. 1999. *Una nueva formulación del algoritmo genético aplicado al diseño óptimo de estructuras*. *Métodos Numéricos en Ingeniería*. SEMI.
- A. Suresh y A. Mohamed. 1998. An improved genetic algorithm for the optimal design of large trusses. 4ª Conferencia Internacional sobre Tecnología Computacional de Estructuras. Escocia.
- F. Erbatur, O. Hasańcebi, I. Tütüncü y H. Kiliç. 2000. Optimal design of planar and space structures with genetic algorithms. *Computers and structures*, 75, 209-224.
- K. Matous, M. Leps, J. Zeman y M. Sejnoha. 2000. Applying genetic algorithms to selected topics commonly encountered in engineering practice. *Comput. Methods Appl. Mech. Engrg.* 190, 1629-1650.