

# Optimización de Redes de Distribución con Algoritmos Genéticos

**Josep R. Medina**

Catedrático de Universidad, Departamento de Ingeniería e Infraestructura de los Transportes,  
Universidad Politécnica de Valencia, España.

**Víctor Yepes**

Director del Área de Producto, *Agència Valenciana del Turisme*,  
*Generalitat Valenciana*, España.

## RESUMEN

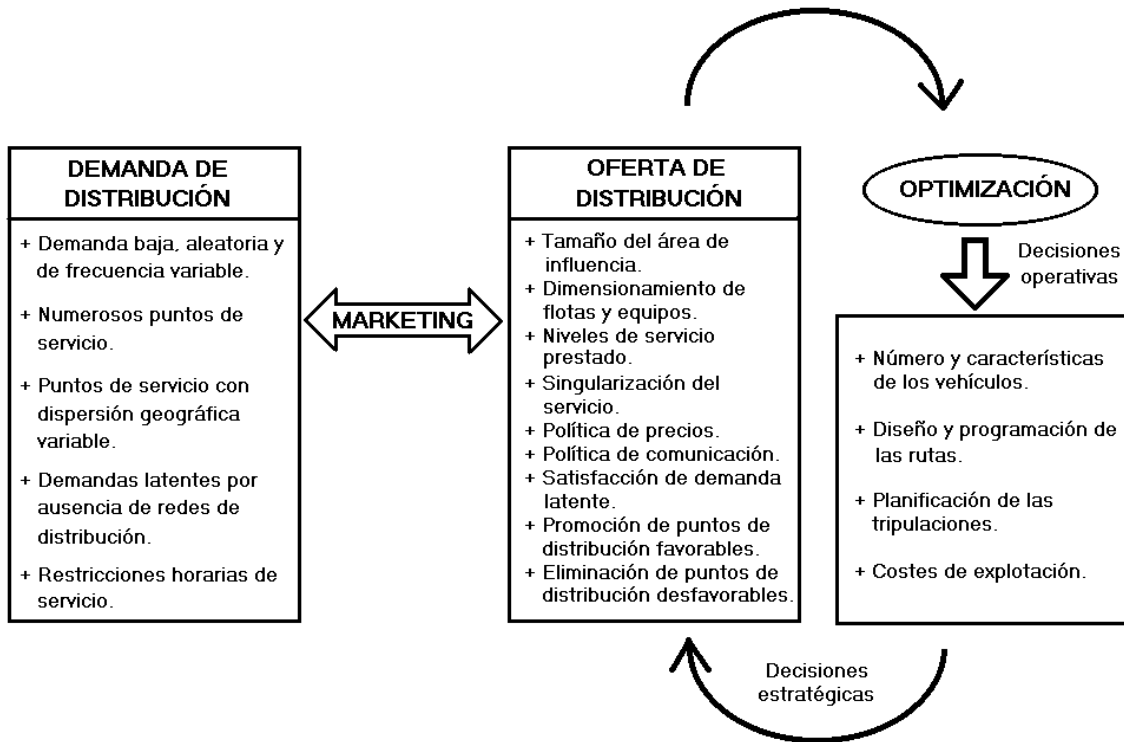
En este artículo se utilizan los ocho elementos básicos para diseñar algoritmos genéticos aplicables a estudios de optimización de carácter general descritos por Medina(1998a). Esta técnica meta-heurística originalmente desarrollada para resolver el TSP ha sido modificada para resolver satisfactoriamente el CVRP y el SCVRP. Se aplica al problema de distribución de baja demanda con pasajeros que viajan entre un aeropuerto “hub” en Alicante y 30 destinos turísticos en Europa Occidental y Norte de Africa. Se analiza la flexibilidad y robustez de los algoritmos genéticos y la posibilidad de combinarse con la inteligencia humana en la solución de problemas complejos y dinámicos de distribución de pasajeros y mercancías, afectados por cambios frecuentes de legislación y política tarifaria.

## 1. INTRODUCCIÓN

La planificación y gestión de redes de distribución de baja demanda exige disponer de técnicas eficientes de optimización de rutas. El sistema de optimización de rutas disponible, no sólo afecta el desarrollo de operaciones sino, también las decisiones tácticas y estratégicas como el tamaño óptimo de flota, estimación de costes, políticas de publicidad y rotura de servicio, etc. Por ejemplo, es habitual la venta de paquetes turísticos que incluyen el transporte; los precios se fijan mucho antes de que la demanda de transporte sea conocida, siendo frecuentes las cancelaciones de última hora y la llegada de nuevos clientes. Si el número de pasajeros que debe ser transportado es pequeño, en comparación con la máxima capacidad de carga del vehículo óptimo a la distancia correspondiente, los beneficios o pérdidas generadas por el transporte dependen críticamente de la eficiencia del sistema de optimización de rutas. La Figura 1 describe la influencia de la optimización de operaciones en la planificación y gestión de redes de distribución de baja demanda.

Así pues, la planificación y gestión de redes de distribución de baja demanda genera una variedad de problemas de decisión que dependen críticamente de la optimización de operaciones, con espacios de soluciones muy grandes y además crecientes exponencialmente con el número de destinos y tamaño de flota. Esta explosión combinatoria de soluciones y la complejidad de las variables a optimizar impiden que la optimización pueda ser abordada con técnicas de optimización exactas; por el contrario, las técnicas meta-heurísticas y probabilísticas son alternativas siempre viables que, aunque no garantizan alcanzar la solución óptima absoluta, sí pueden proporcionar buenas soluciones a problemas reales complejos (ver Diaz y otros, 1996). En este contexto, los sistemas inteligentes son métodos apropiados para resolver problemas

complejos de optimización combinatoria como el planteado (ver Goonatilake and Treleaven, 1996, Fayyard et al., 1996 y Medina, 1999). En este artículo, se ha utilizado un algoritmo genético originalmente diseñado para resolver el TSP, para abordar problemas más complejos como el CVRP y el SCVRP, utilizando funciones de coste y restricciones muy variadas.



*Figura 1.- Planificación y Gestión de Redes de Distribución de Baja Demanda.*

Por otro lado, el problema de optimización de operaciones de transporte es crucial para la propia existencia de un cierto nicho de mercado de baja demanda. Si se consigue una distribución muy eficiente, es posible aflorar una demanda latente y satisfacerla con una flota pequeña y un costo razonable. Esta situación se produce en el mercado turístico con destinos poco masificados. En el ejemplo de aplicación presentado en este artículo, se utiliza Alicante como aeropuerto hub, con un hinterland de más de 48.000 plazas hoteleras y un parque temático para tres millones de visitantes anuales (Friedmann, 1998). Tanto para fijar precios como para definir la mejor estrategia comercial, resulta imprescindible disponer de un sistema flexible para optimizar la distribución de pasajeros y unos modelos estocásticos de simulación de escenarios.

En el punto 2 se describe la construcción en ocho pasos siguiendo el esquema de Medina(1998a) del algoritmo genético utilizado en el proceso de optimización de rutas. En el punto 3 se analiza la flexibilidad y robustez de los algoritmos genéticos en la optimización de problemas de distribución, sus ventajas e inconvenientes. En el punto 4 se describe el simulador de escenarios y los resultados del problema de optimización realizado en el ejemplo seleccionado: distribución desde aeropuerto hub en Alicante a 30 aeropuertos de Europa Occidental y Norte de África. Finalmente se presentan unas conclusiones en las que se resalta la utilidad de los algoritmos genéticos en la optimización de rutas y en el cálculo de precios de transporte en redes de distribución de baja demanda.

## 2. DISEÑO DEL ALGORITMO GENÉTICO

En este punto se describe el proceso de diseño y construcción del algoritmo genético utilizado para la optimización de rutas asociada al problema de las redes de distribución de baja demanda. Para diseñar el algoritmo genético se sigue el procedimiento en ocho pasos descrito por Medina(1998a).

El problema de optimización de rutas pertenece al tipo de los problemas combinatorios difíciles. En este campo es razonable considerar el uso de sistemas de optimización inteligentes que, aunque no garantizan encontrar la solución óptima, sí permiten definir una buena solución con un esfuerzo de computación razonable. Durante la última década, se han publicado numerosas aplicaciones de técnicas de Inteligencia Artificial a una variedad de campos técnicos y científicos (ver Ansari y Hou, 1997). Algoritmos genéticos, redes neuronales, búsqueda tabú, cristalización simulada y lógica borrosa son algunas de las técnicas que han probado ya su eficacia en la minería de datos, en el descubrimiento de conocimiento (Fayyad et al., 1996) y en la solución de problemas combinatorios difíciles en diferentes campos. En este contexto, los algoritmos genéticos son particularmente apropiados para resolver problemas de optimización de rutas reales debido a su robustez y flexibilidad para adaptarse a entornos cambiantes.

Existen multitud de procedimientos para diseñar algoritmo genéticos en la solución de problemas de optimización complejos (ver Davis, 1996). En este artículo se utiliza un algoritmo genético diseñado siguiendo los ocho pasos descritos por Medina(1998a); en cada paso se indica la correspondiente relación con la aplicación descrita.

### **2.1) Arquitectura genética**

Debe existir una relación que se pueda decodificar entre una cadena de genes que caracteriza al individuo y una solución del problema. En este artículo, la codificación elegida es la cadena de números que se corresponden con las ciudades (aeropuertos) a visitar, existiendo tantas llegadas al aeropuerto hub como aviones tiene la flota.

### **2.2) Poblaciones y su tamaño**

Para el tamaño del problema planteado (30 ciudades y una decena de rutas), el algoritmo genético encuentra el óptimo con facilidad, sin utilizar ninguna heurística de mejora, utilizando 40 islas independientes y poblaciones de 200 individuos. El programa emula una evolución en paralelo primero y después formando una población inicial última compuesta por una muestra de cada una de las poblaciones finales obtenidas anteriormente.

### **2.3) Población inicial**

El resultado final no es muy sensible a la población inicial; sin embargo, una heurística puede reducir el tiempo de convergencia al óptimo. Para tamaños de problema superiores a 100, la heurística es muy conveniente para reducir los tiempos de computación a niveles razonables (horas).

### **2.4) Evaluación**

La selección natural opera bajo el principio de eliminar probabilísticamente a los individuos menos adaptados al entorno. En este artículo se han chequeado las técnicas con ejemplos TSP, considerando exclusivamente la distancia total recorrida asociada a cada gen. Para su aplicación al problema de optimización de rutas con demanda estocástica, se ha considerado una función de coste específica que considera la distancia total recorrida por los aviones (500 ptas/milla), un coste diario por avión disponible (500.000 ptas/avión), un coste diario asociado a cada

tripulación adicional (300.000 ptas/tripulación). Se consideran además unos sobrecostes: (1)ligeros por rebasar 6 horas de recorrido (incomodidades y horas extra de trabajo) o por rebasar el 90% de ocupación de las plazas de avión (incomodidades), y (2) fuertes si se rebasan las 9 horas de recorrido (tripulación adicional) y la capacidad máxima de los aviones (rotura de servicio de un millón de ptas).

### **2.5) Selección**

Las soluciones con menor coste deben tener más probabilidades de sobrevivir y generar la siguiente generación. El algoritmo asigna una probabilidad de sobrevivir inversa al número de orden del individuo en la generación, siendo el 1º el de menor coste. Los individuos supervivientes se eligen aleatoriamente sesgados de una generación para producir la siguiente. Además se asigna una pequeña probabilidad de seleccionar adicionalmente el campeón absoluto aunque no pertenezca a la generación en curso.

### **2.6) Cruzamiento**

Se han utilizado dos operadores de cruzamiento: (1)cruzamiento simple ("one point crossover") y (2)cruzamiento de rutas generalizado basado en el concepto general "edge mapped recombination" de Whitley et al.(1996) con una generalización a tres rutas de Medina(1998a).

### **2.7) Mutación**

Se han utilizado una amplia variedad de operadores de mutación especializados en resolver defectos distintos de una mala solución (de uno y varios puntos, de traslación, de inversión, etc.), pero ninguno especializado en eliminar cruces en planta para permitir un rápido chequeo visual de la calidad de las soluciones encontradas.

### **2.8) Probabilidades de cruzamiento y mutación**

Se ha seguido la sugerencia de Julstrom(1995) de asignar probabilidades dinámicas. Inicialmente, se asignan probabilidades del 5% y 15% a los operadores de cruzamiento, mientras que los siete operadores de mutación tienen probabilidades asignadas entre el 5% y el 20% cada uno. Iniciada la evolución, las probabilidades de operar asignadas inicialmente se mantienen constantes hasta que hay mejoras en un número prefijado de generaciones; en tal caso, las probabilidades de operar se cambian aleatoriamente dentro de un rango definido.

## **3. FLEXIBILIDAD Y ROBUSTEZ DEL ALGORITMO GENÉTICO**

El algoritmo genético se ha programado en Visual BASIC 5.1 para usarse en ordenadores personales. El programa admite una flota heterogénea con aviones de distinta capacidad y con las variables de entrada agrupadas en cinco bloques: (1)longitud y latitud del aeropuerto hub y los aeropuertos de destino, (2)velocidad media y capacidad máxima de los aviones, (3)tiempos normales de taxi, aterrizaje y despegue y de retraso medio asociado a cada aeropuerto, (4)costes asociados a la flota, tripulaciones, pasajeros y distancia recorrida, y (5)número de pasajeros a traer y llevar a cada destino desde el aeropuerto hub. A diferencia de otros algoritmos, los genéticos pueden ser adaptados con facilidad para considerar nuevas variables de entrada o nuevas condiciones (número de aterrizajes por ruta, condiciones laborales de las tripulaciones, etc.). En el ejemplo desarrollado, tanto la flota como las tripulaciones tienen su base en Alicante y todos los pasajeros a transportar tienen su origen o destino el aeropuerto de Alicante.

La flexibilidad de los algoritmos genéticos es una cualidad buena para adaptarse a entornos

cambiantes, pero impone la necesidad de tomar decisiones subjetivas para adaptar la función de coste al objetivo realmente buscado. Por otro lado, la construcción de un algoritmo genético impone la necesidad de tomar decenas de decisiones de diseño apriorísticas que pueden afectar la eficiencia del algoritmo. Existen millones de alternativas para construir algoritmos genéticos para resolver un determinado problema y como sólo unas pocas variantes pueden ser estudiadas, la inteligencia humana es imprescindible para conseguir una buena solución genética a un problema dado.

Los algoritmos genéticos son robustos (poco sensibles a variaciones de parámetros), pero su eficiencia depende de su diseño y del número de errores de código no depurados. La robustez intrínseca de los algoritmos genéticos es una gran virtud que permite obtener buenas soluciones en cualquier circunstancia y, a la vez, un defecto que dificulta la depuración de programas, ya que son capaces de proporcionar resultados razonables incluso con errores de código notables.

La evaluación de los algoritmos genéticos en la solución de problemas complejos no es tarea fácil. Por un lado, si se plantean problemas pequeños con solución óptima conocida, es muy posible que el algoritmo genético encuentre la solución óptima aunque sea un programa poco eficiente lleno de errores. Si el problema planteado es grande, suelen existir librerías con problemas tipo resueltos que pueden servir para comparar la solución encontrada con “la mejor conocida”. Para problemas grandes y complejos parecidos a los reales (CVRP con restricciones y penalizaciones), no hay librerías ni referencias válidas no sesgadas; sólo es posible comparar un método contra otro alternativo para un problema dado. Algunos autores intentan comparar sistemas inteligentes alternativos (Búsqueda Tabú, Cristalización Simulada, Redes Neuronales, etc.) con la pretensión de justificar la idoneidad de una técnica de optimización concreta; sin embargo, lo que suele quedar reflejado en la comparación es la competencia del autor en el uso de técnicas de optimización diferentes y no la técnica en sí. Cuando el problema es grande y complejo (los problemas de transporte reales suelen serlo), se debe contrastar con problemas simplificados tipo de tamaño similar en librerías como TSPLIB95 (Reinelt, 1995) y confiar que el uso de funciones de coste complejas no cambia su efectividad.

#### **4. EJEMPLO: DISTRIBUCIÓN DE BAJA DEMANDA**

Para ilustrar las posibles aplicaciones de los algoritmos genéticos en la solución de problemas complejos, se presenta una aplicación para optimizar las rutas de una red de distribución de baja demanda similar al descrito por Medina y Yepes(2000). Tenemos una pequeña flota con base en un aeropuerto hub con la que deseamos atender una demanda muy irregular de transporte turístico a destinos “exóticos” en el Norte de Africa y Europa Occidental. Esta demanda de transporte “latente” entre el aeropuerto hub (Alicante) y los destinos “exóticos” puede activarse con una oferta de transporte razonable; en este caso, la oferta de transporte consiste en trasladar al turista en un único avión, en uno o varios saltos y sin transbordos, en un tiempo medio fijado de antemano y tiempo máximo acotado. Esta distribución de pasajeros permite recoger en varios saltos pasajeros cuyo destino final es el aeropuerto hub (Alicante) y tomar en el aeropuerto hub pasajeros con varios destinos “exóticos”. Si tenemos en cuenta que el hinterland de Alicante tiene 48.000 plazas hoteleras y un parque temático de 3 millones de visitantes anuales (Friedmann, 1998), es razonable pensar que existe una pequeña demanda latente aprovechable entre Alicante y destinos “exóticos” dentro de los 2.250 km de alcance de los aviones considerados en el ejemplo (Fokker 50).

Para simular las condiciones de la demanda de transporte (pequeña y con elevada variabilidad), se ha construido un simulador con una estructura estocástica, lognormal, bi-variada y autoregresiva de primer orden que cumple las ecuaciones

$$x(j,n) = \frac{(\log[q_1(j,n)]) - Q_0(j)}{SQ_0(j)} \quad (1a) \quad y(j,n) = \frac{(\log[q_2(j,n)]) - Q_0(j)}{SQ_0(j)} \quad (1b)$$

donde  $q_1(j,n)$  es la demanda de transporte en el día  $n$  del aeropuerto hub al destino  $j$   $q_2(j,n)$  es la demanda de transporte en el día  $n$  del destino  $j$  al aeropuerto.  $Q_0(j)$  y  $SQ_0(j)$  son los parámetros de la fdd lognormal. En este estudio, se ha usado  $Q_0(j)=2.6$  y  $SQ_0(i)=0.5$  para todos los destinos, lo que significa una media aproximada de 16 pasajeros con un coeficiente de variación del 55%. La estructura estocástica con memoria viene dada por

$$x(j,n) = A x(j,n-1) + \sqrt{(1-A^2)} w(j,n) \quad ; \quad n = 1,2,3,\dots \quad (2)$$

$$y(j,n) = B x(j,n-d) + \sqrt{(1-B^2)} v(j,n) \quad ; \quad n = 1,2,3,\dots \quad (3)$$

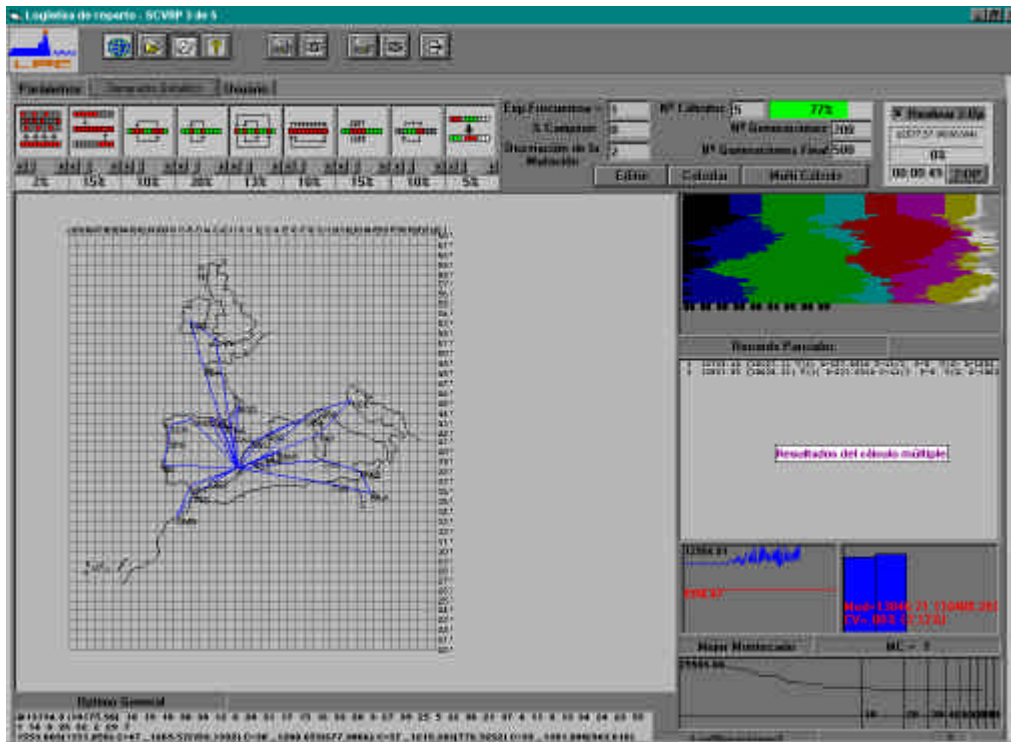
donde  $x(j,n)$  e  $y(j,n)$  son series temporales normalizadas;  $w(j,n)$  y  $v(j,n)$  son ruido blanco independiente; A y B son los parámetros de correlación; y  $\delta$  es el parámetro de retraso temporal. En este artículo,  $A=0.50$ ,  $B=0.95$  y  $\delta=7$ .

Se supone una flota de 5 aviones con 20 tripulaciones para atender a la demanda. La capacidad máxima del avión es de 50 pasajeros, el alcance 2.250 km y la velocidad de crucero es 240 nudos. Toda la demanda tiene que ser atendida cada día, minimizando el número de aviones necesarios y la distancia total recorrida, sin superar la capacidad de los aviones y limitando la duración máxima de ruta a 10 horas. Los 30 aeropuertos de destino considerados son: Ajaccio, Brest, Burdeos, Cannes, Cardiff, Dublin, Tangier, Casablanca, Tunis, Malta, Cagliari, Genoa, Palermo, Venezia, Lisbon, Oporto, Girona, Vitoria, Santander, Oviedo, Santiago de Compostela, Pamplona, Zaragoza, Granada, Jerez, San Sebastian, Reus, Mallorca, Menorca e Ibiza.

La optimización de operaciones permite reducir costes de distribución y calcular costes y rendimientos. Las Ecuaciones 1 a 3 describen un escenario muy variable; simulando la demanda de transporte y la optimización de rutas, es posible calcular los costes del mismo. La Tabla 1 presenta el valor medio y el coeficiente de variación estimados de las variables de coste y carga de transporte más importantes, simulando treinta días consecutivos de distribución. La Figura 2 presenta una salida gráfica típica del programa de optimización de rutas de un día concreto.

Variable	Media	Coeficiente de variación
Número de pasajeros a/desde cada destino	16	55%
Número diario de pasajeros transportados	960	7,5%
Número de pasajeros por km a hub	730 000	7,6%
Ocupación de asientos en aviones (%)	67	4,3%
Coste de pasajero transportado a/desde hub (ptas)	19 800	2,9%

**Tabla 1.- Media y coeficiente de variación de las variables de coste y carga de transporte**



**Figura 2.- Salida típica del programa de optimización de rutas.**

## 5. RESUMEN Y CONCLUSIONES

Los algoritmos genéticos, inspirados en los principios de selección natural, son una herramienta robusta y flexible para la solución de problemas combinatorios difíciles. Los algoritmos genéticos pueden utilizarse como herramientas de optimización objetivas y también pueden usarse en colaboración con la experiencia e inteligencia humana, potenciándose mutuamente. La flexibilidad de los algoritmos genéticos permite adaptarse a entornos legales, técnicos y empresariales cambiantes, pudiendo considerar una amplia variedad de restricciones y objetivos, muchas veces ambiguos e incluso contradictorios.

El concepto de algoritmo genético es muy amplio, permite multitud de variantes con diferente efectividad en la solución de problemas concretos. Se describe la construcción de un algoritmo genético en ocho pasos para su aplicación a la solución de un problema de distribución de pasajeros entre aeropuertos de poca demanda y alta variabilidad. La ventaja fundamental del algoritmo genético es su facilidad para adaptarse a funciones de coste muy complejas que describan una realidad con objetivos y restricciones múltiples. Se presenta una aplicación a la solución del problema de satisfacer una demanda de transporte latente entre un aeropuerto hub (Alicante) y 30 destinos “exóticos” en el Norte de Africa y Europa Occidental. Un simulador estocástico bivariado, lognormal y autorregresivo de primer orden permite simular escenarios y calcular costes de transporte.

## AGRADECIMIENTOS

Los autores agradecen el soporte financiero de la *Dirección General de Enseñanza Superior e Investigación Científica (CICYT MAR98-0339)* y la información recibida de la *Agència Valenciana del Turisme (Generalitat Valenciana)*. Se agradecen también los comentarios de Francisco Amor relativos a distribución y el código escrito por Juan J. Navarro.

## REFERENCIAS

- ANSARI, N. y HOU, E.(1997). *Computational Intelligence for Optimization*. Kluwer Academic Publishers Boston, USA.
- DAVIS, L.(1996). *Handbook of Genetic Algorithms*. International Thompson Computer Press. Boston (USA).
- DIAZ, A., GLOVER, F., GHAZIRI, H.M., GONZÁLEZ, J.L., LAGUNA, M., MOSCATO, P. y TSENG, F.T.(1996). *Optimización Heurística y Redes Neuronales en Dirección de Operaciones e Ingeniería*. Editorial Paraninfo S.A., Madrid (España).
- FAYYARD, U.M., PIATETSKI-SHAPIRO, G., SMYTH, P. y UTHURUSAMI, R.(1996). *Advances in Knowledge Discovery and Data Mining*. MIT Press.
- FRIEDMANN, M.(1998). Parques temáticos: Terra Mítica y el desarrollo turístico valenciano. *Revista Valenciana d'Estudis Autonòmics*, Vol 25, pp. 109-117.
- GOONATILAKE, S. and TRELEAVEN, P. (1996). *Intelligent Systems for Finance and Business*. John Wiley.
- JULSTROM, B.A.(1995). What have you done for me lately?. Adapting operator probabilities in a steady-state genetic algorithm. *Proc. 6th International Conference on Genetic Algorithms*, Morgan Kauffmann Pub., San Mateo, California, pp. 81-87.
- MEDINA, J.R.(1998a). Algoritmos genéticos para la optimización de redes de distribución. *Actas del X Congreso Panamericano de Ingeniería de Tránsito y Transporte*. Santander 1998, Ministerio de Fomento (España), pp. 339-347.
- MEDINA, J.R.(1998b). Wind effects on runup and breakwater crest design. *Proc. 26<sup>th</sup> International Conferencie on Coastal Engineering*, ASCE, pp.1068-1081.
- MEDINA, J.R. y YEPES, V. (2000). Optimization of touristic distribution networks using Genetic Algorithms, *European Journal of Marketing*, (in review).
- MEDINA, J.R., GIMÉNEZ, M.H. y HUDSPETH, R.T. (1991). A Wave Climate Simulator. *Proc. XXIV IAHR Congres*, IAHR, (B)521-528.
- REINELT, G.(1995). *Discrete Optimization. Available Software and Data. TSPLIB95-TSPLIB*. <http://www.iwr.uni-heidelberg.de/iwr/comopt/soft/TSPLIB95/>.