

Optimización de antenas mediante algoritmos genéticos

Jaume Anguera Pros
Aurora Andújar Linares

PID_00175735



Los textos e imágenes publicados en esta obra están sujetos –excepto que se indique lo contrario– a una licencia de Reconocimiento-NoComercial-SinObraDerivada (BY-NC-ND) v.3.0 España de Creative Commons. Podéis copiarlos, distribuirlos y transmitirlos públicamente siempre que citéis el autor y la fuente (FUOC. Fundació para la Universitat Oberta de Catalunya), no hagáis de ellos un uso comercial y ni obra derivada. La licencia completa se puede consultar en <http://creativecommons.org/licenses/by-nc-nd/3.0/es/legalcode.es>

Índice

Introducción	5
Objetivos	7
1. Elementos y partes de un algoritmo genético	9
2. Codificación de los parámetros	12
3. Estrategias de selección	13
3.1. Truncamiento de la población	13
3.2. Selección proporcional	14
3.3. Selección por torneo	15
4. Mejoras del algoritmo genético simple	16
4.1. Estrategia elitista	16
4.2. <i>GA steady-state</i>	16
5. El problema del viajero	18
6. Ejemplos de aplicación	21
6.1. Optimización de pesos de agrupaciones de antenas	21
6.2. Optimización de antenas	22
6.3. Optimización de redes de adaptación	23
Resumen	25
Bibliografía	27

Introducción

Los algoritmos genéticos (GA, de su sigla inglesa) se están empleando cada vez más para resolver problemas en muchas áreas, y entre ellas la del electromagnetismo, donde su aplicación ha experimentado un fuerte crecimiento.

Un factor que impulsó al uso de los GA fue la propia observación de la naturaleza. Darwin postula que la vida en la Tierra se ha ido adaptando y ha ido evolucionando a través de una selección natural (figura 1). Aceptado esto, se pensó que aplicar este algoritmo en el que se inspira la naturaleza a la solución de problemas complejos podía dar buenos resultados. Este fue uno de los primeros motivos que impulsó a la comunidad científica a trabajar con los GA.

Los GA están dentro de los llamados **optimizadores globales**, mientras que los métodos más tradicionales, como los del gradiente conjugado o el casi-Newton o el Simplex, se consideran técnicas locales, es decir, permiten encontrar máximos/mínimos pero pueden estancarse en uno relativo y no encontrar el absoluto. Por ejemplo, dentro del método casi-Newton, el de Davidon-Fletcher-Powell tiene una dependencia directa con la existencia de al menos la primera derivada. Lo mismo sucede con los métodos del gradiente conjugado, que son realmente poco eficientes si existen discontinuidades allá donde se evalúa el gradiente. Precisamente en estas condiciones es donde mejores resultados ofrecen los GA. Como contrapartida, la convergencia suele ser más lenta en los GA.

Dentro de las llamadas técnicas globales, los GA son más eficientes y tienen una convergencia más rápida que otras como el *random walk* o el Montecarlo.

A continuación se analizará con más detalle su funcionamiento y sus diferentes opciones de implementación.

Los GA se basan en los conceptos de la selección y la evolución natural. Son particularmente efectivos cuando el objetivo es encontrar una solución a un problema en el que existe un espacio de posibilidades extremadamente alto.

Por ejemplo, dada una agrupación de antenas, qué amplitudes complejas deben tener los elementos para conseguir un diagrama de radiación definido. Imaginemos por ejemplo que los valores de amplitud se restringen a 1 y 0, es




Figura 1. Charles Darwin, naturalista inglés (1809-1882)

Postuló la evolución de las especies a partir de una selección natural. Los algoritmos genéticos se basan en dicha evolución para resolver problemas electromagnéticos.

Lecturas complementarias

Sobre las ventajas y los inconvenientes de los diversos métodos de optimización tradicionales:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

R. L. Haupt; S. E. Haupt (2004). *Practical Genetic Algorithms*. John Wiley & Sons.

Lectura complementaria

Sobre los métodos *random walk* o Montecarlo, podéis consultar la obra siguiente:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

decir, un elemento particular de la agrupación puede estar conectado o desconectado. Suponed que la agrupación dispone de 30 elementos. Si se desease probar todas las combinaciones, estas serían 2^{30} . Suponiendo un tiempo de simulación por agrupación de un segundo, el tiempo total sería de 34 años. Es aquí donde el GA entra en juego, pues en pocas horas es capaz de encontrar la solución a este problema.

En un GA el primer paso es la creación de una **población inicial**, que estará formada por potenciales soluciones y que evolucionarán hacia la mejor solución (máximo/mínimo global) de la función. En el ejemplo de la agrupación, esta función puede ser por ejemplo la diferencia entre el diagrama de un candidato y el deseado, con lo que cuando la función tiende a cero, se tiende a la mejor solución. Esta evolución se realizará sobre la base de una selección fundamentada en la aplicación de una **función de coste** aplicada a la población. Esta función de coste será la que particularizará cada caso, puesto que es donde se definirá cuál es el parámetro que se quiere como elemento decisorio.

También habrá una etapa de **mutación** y recombinación de los individuos existentes para crear nuevos y se volverá a tener una población formada por posibles soluciones y otra vez se repetirá el proceso. Con la mutación se intenta evitar caer en máximos/mínimos relativos de la función de optimización.

El presente módulo se divide en varios apartados. En el apartado 1 se describe la arquitectura de un GA. En el apartado 2 se detalla cómo se pueden codificar los individuos para ser tratados computacionalmente. El apartado 3 ilustra diferentes técnicas de selección. En el apartado 4 se discute la estrategia elitista. En el apartado 5 se muestra un ejemplo denominado el problema del viajero. El apartado 6 recoge algunos ejemplos y finalmente las conclusiones se exponen en el resumen.

Objetivos

Con el estudio de este módulo didáctico, alcanzaréis los objetivos siguientes:

- 1.** Comprender el principio de funcionamiento de un algoritmo genético.
- 2.** Entender qué problemas de optimización puede resolver un algoritmo genético.
- 3.** Conocer el uso del cruzamiento, la mutación y el elitismo.

1. Elementos y partes de un algoritmo genético

En primer lugar se definirán los diferentes elementos que intervienen en un algoritmo genético (GA) y después se verán las diferentes partes que lo componen:

- **Gen:** es la parte mínima que contiene información. Normalmente es la codificación de los parámetros que se desean optimizar. Por ejemplo, en el caso de un *array* de antenas, será la amplitud, distancia o fase de cada elemento del *array*.
- **Cromosoma:** está formado por los genes. Representa una solución. Por ejemplo, para el caso de un *array*, los pesos de excitación, con el objetivo de manipular del diagrama de radiación.
- **Población inicial:** la forman los cromosomas que se consideran inicialmente como posibles soluciones. Posteriormente esta población se irá modificando y cada población aparecida en cada iteración se denominará **generación**. Por ejemplo: un conjunto de agrupaciones de antenas.
- **Padres:** se componen de pares de cromosomas que han sido “seleccionados” en cada población (o generación), que previamente se han ordenado según el resultado obtenido al evaluar la función de coste en cada uno de ellos. Serán empleados para obtener los descendientes como fruto de su recombinación (aplicando los operadores *crossover* y mutación), y estos serán los miembros de la nueva generación.
- **Crossover:** es uno de los principales operadores. Normalmente tiene una probabilidad asociada que suele tomar los valores de 0,6-0,8 y se utiliza para determinar el punto dentro del cromosoma a partir de cual se hará la división del cromosoma en “partes” que después se recombinarán. Por ejemplo: si el punto de cruzamiento fuera el 4, los descendientes quedarían tal y como ilustra la figura 2.

Figura 2. Ejemplo de funcionamiento del operador *crossover*



Lectura complementaria

Sobre los diferentes elementos que intervienen en un GA y sus diversas partes, puede consultarse la obra siguiente:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

Lectura complementaria

Sobre el valor de probabilidad asociado al *crossover*, puede consultarse la obra siguiente:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

Esta etapa dentro del GA que comprende la elección del valor del punto de cruzamiento y la recombinación de los cromosomas se denomina **apareamiento**.

- **Mutación:** es un mecanismo para evitar que la solución hacia la que evoluciona el GA no sea un máximo/mínimo local de la función en lugar del máximo/mínimo global deseado. Sirve para introducir material genético que no está presente en la población. También suele tener asociada una probabilidad. Por ejemplo, para agrupaciones de antenas donde se optimizan los pesos, una mutación consiste en cambiar un gen, es decir, un peso de la agrupación. Por ejemplo, si los pesos tuviesen únicamente dos posibilidades, 1 y 0, una mutación cambiaría el peso de un elemento de 0 a 1 o de 1 a 0.
- **Función de coste:** es la función que permite evaluar un cromosoma como solución. A la vez se podrán ordenar según el resultado obtenido y después se hará la selección pertinente. Es la función que relaciona el problema físico que se trata y el proceso de optimización del GA. Por ejemplo, para el caso de una agrupación de antenas, una posible función de coste sería la que evaluase la forma del diagrama de un cromosoma en comparación con un diagrama objetivo.

Las diferentes etapas de un GA se han ido viendo en las definiciones anteriores y se resumen en:

- 1) Codificación de los parámetros como genes y formación de los cromosomas (candidato). Inicialización de la población inicial, normalmente de una manera aleatoria.
- 2) Evaluación de la función de coste para cada cromosoma. Selección de los individuos según el resultado obtenido al aplicarles la función de coste.
- 3) Recombinación de los individuos para dar lugar a los nuevos individuos.
- 4) Mutación dentro de la población para obtener la nueva generación.
- 5) Aplicación de la función de coste, y se repite el proceso hasta llegar a la convergencia.


Para finalizar, se muestra un diagrama de bloques donde se aprecia el funcionamiento básico de un GA (figura 3).

Lectura complementaria

Sobre el valor de probabilidad asociado al operador de mutación, puede consultarse la obra siguiente:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

Figura 3. Diagrama de bloques de un algoritmo genético



Lectura complementaria

Sobre los diagramas de bloques de un algoritmo genético, puede consultarse la obra siguiente:
J. Anguera; A. Pérez (2008).
Teoría d'Antenes (ISBN: 978-84-935665-4-8).

2. Codificación de los parámetros

Los GA operan generalmente con la codificación de los parámetros de interés, en lugar de trabajar con los propios parámetros.

El hecho de representar los parámetros codificados en los genes y estos dentro del cromosoma, permite que los GA funcionen con total independencia de los propios parámetros, al margen del espacio de la solución.

Se pueden utilizar codificaciones binarias, vectores con coma flotante, una combinación de ambos, pero siempre es recomendable utilizar los alfabetos más cortos posibles. Estos también simplificarán el resto de las operaciones que vayan a poder aplicarse al GA.

En el caso de codificación binaria, se emplea la siguiente ecuación:

$$q = \left(\frac{q_{max} - q_{min}}{2^N - 1} \right) \cdot \sum_{n=0}^{N-1} 2^n \cdot b_n + q_{min} \quad 2.1$$

donde q_{max} es el valor máximo del parámetro que se codifica, q_{min} es el valor mínimo de ese mismo parámetro, N es el número de bits por gen y b_n es el bit binario en la posición n dentro del gen. Por ejemplo, en una agrupación de antenas, si un peso a_n puede ser como máximo 10 y el mínimo 0, entonces $q_{max} = 10$ y $q_{min} = 0$.

El GA actúa sobre el cromosoma para que evolucione hacia la solución óptima. La función de coste devuelve un resultado que da una medida de la bondad de la solución. La **función de coste** se utiliza para asignar un valor de coste a cada individuo de la población. Concretamente, es la única conexión entre el problema físico que se está optimizando y el GA. La única especificación requerida para la función de coste es que devuelva un valor que indique la bondad del individuo en cuestión.

Lectura complementaria

Sobre las codificaciones binarias, puede consultarse la obra siguiente:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

3. Estrategias de selección

La selección introduce la influencia de la función de coste en el funcionamiento del GA. La selección debe usar la función de coste aplicada a los individuos de cada generación (cromosomas), puesto que da una medida de la bondad del resultado obtenido hasta el momento.

Se debe tener presente que en la selección no se puede guardar únicamente la mejor solución encontrada hasta el momento, puesto que haciéndolo se podría estar dando como solución definitiva una que no lo es. Por ello, se preservan las características incluidas en otros cromosomas que no son los mejores, y se los incluye en la siguiente generación. Se puede llevar a cabo buscando su valor medio media y manteniendo los más cercanos a esa media, o manteniendo la mitad mejor de la generación, entre otros. A continuación se detallan diferentes estrategias de la selección que no son más que la elección de los padres que participarán en el proceso de reproducción.

3.1. Truncamiento de la población

La más simple de las estrategias determinísticas sería la supervivencia de los mejores, ordenados según el resultado obtenido al aplicar la función de coste a los individuos (cromosomas) de cada generación. Es decir, se eliminarían los peores.

Se puede fijar un valor mínimo de la función de coste a partir del cual se eliminan los individuos que queden por debajo. Los individuos que pasarán a la siguiente generación serían los utilizados para crear los nuevos cromosomas mediante el proceso de apareamiento.

Esta estrategia es determinística, puesto que los individuos eliminados son elegidos a partir de una comparación determinística entre el valor de su función de coste y el valor elegido como nivel mínimo requerido. Una variación sería, en lugar de considerar un nivel mínimo, conservar siempre los N mejores individuos.

La gran ventaja es su simplicidad y la gran desventaja es que, en este proceso de eliminación, en un individuo que haya sido descartado, su “característica individual” se habrá perdido.

Lectura complementaria

Sobre las diferentes estrategias de selección, puede consultarse la obra siguiente:

Y. Rahmat-Samii; E. Michielssen (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

Esta pérdida es producto de la evolución pero muchas veces puede suceder que tenga lugar antes de haber obtenido los beneficios aportados por la característica particular que tenía este individuo eliminado. De todos modos, es lógico pensar que manteniendo los mejores elementos se está yendo hacia la solución deseada.

La única manera de recuperar elementos descartados será a través de la mutación. Esta mutación se utilizará para explorar otras zonas del dominio de la solución, lo que añade nuevo material genético y por tanto amplía el dominio de exploración y evita caer en máximos/mínimos locales.

3.2. Selección proporcional

Pertenciente a las estrategias de selección estocásticas se encuentra la selección proporcional, también llamada ruleta (*roulette wheel*).

La selección de los individuos se hará en función de la proporción de selección (probabilidad de selección) indicada en la siguiente ecuación:

$$P_{\text{Selección}} = \frac{f(\text{cromosoma}_i)}{\sum_i f(\text{cromosoma}_i)} \quad 2.2$$

donde $f(\text{cromosoma}_i)$ indica el valor de la función de coste aplicada al cromosoma i .

Se observa, pues, que la probabilidad de que un individuo de una generación continúe en la siguiente generación es función del valor relativo que tenga su función de coste. Se mantendrán aquellos que tengan mayor “peso específico” en la generación. La diferencia frente a la estrategia anterior es que en este caso todavía hay una probabilidad de que los elementos con menor valor de coste participen en, al menos, algunos de los apareamientos, es decir, se preserve su información genética.

El proceso consiste en crear una ruleta y dividirla en tantas partes como individuos haya y con cada parte de un área proporcional a su valor de coste. Se rueda la ruleta y el elemento que acaba donde el indicador está situado sería el seleccionado. En los primeros pasos del GA se ven claramente beneficiados aquellos individuos con más valor de coste pero este cada vez se hace más igual para todos ellos. Se podría hacer un tipo de escalado para solventarlo.

La manera de implementarlo sería elegir un número aleatorio entre 0 y 1. Después se calcularía el valor de coste normalizado de cada individuo. Y finalmente, en un bucle se irían sumando los valores de coste normalizados hasta igualar o exceder el número aleatorio antes elegido. Entonces, la variable contador del bucle indicaría el individuo seleccionado.

3.3. Selección por torneo

El funcionamiento de esta estrategia es la selección aleatoria de N individuos (cromosomas) de cada generación.

De los N cromosomas aquel que tenga un valor de coste más alto será el ganador del torneo y será el elemento seleccionado. El resto de los N elementos se devuelven a la generación actual (imaginemos una caja donde cada elemento fuera una pieza) y entonces se repite el proceso. Normalmente se fija $N = 2$.

La selección de los N elementos se puede hacer asignando un número a cada uno y seleccionando el número aleatoriamente. Otra manera sería mediante una ruleta. Esta alternativa se denomina *Wetzel ranking*. Esta selección se repetiría hasta obtener los N individuos.

Tanto en esta estrategia como en la anterior se comprueba que se utiliza una estrategia con selección y reemplazo de manera que los individuos pueden, y normalmente lo hacen, participar en más de una selección. La selección por torneo tiene una convergencia ligeramente mejor hacia la solución en las iteraciones iniciales. Además, su tiempo de ejecución es más rápido. El tiempo de ejecución en la selección proporcional es del orden de n^2 , mientras que en la selección por torneo es de n .

Lectura complementaria

Sobre el *Wetzel ranking*, puede consultarse la obra siguiente:

D. E. Goldberg; J. J. Richardson (1987). "Genetic Algorithms with sharing for multimodal function optimization. In Genetic Algorithms and Their Applications". *Proceedings of the Second International Conference on Genetic Algorithms*.

4. Mejoras del algoritmo genético simple

Muchas modificaciones se han hecho en el GA optimizador simple, el que sería el básico. Conceptos como elitismo, utilización de codificación real de los parámetros, GA basados en la comunidad o algoritmos donde parte de la generación se mantiene serán algunos de los que a continuación se resumirán.

4.1. Estrategia elitista

Una de las extensiones más importantes aplicada al GA simple es la estrategia elitista, que fue introducida por K. A. de Jong. En el GA simple es posible que el mejor individuo de la nueva generación tenga un valor de coste menor al mejor individuo de una generación anterior. Esta pérdida de mejor individuo se debe a la naturaleza probabilística de la selección, cruzamiento y la mutación del GA.

Se trataría simplemente de que si se observara que el nuevo valor de coste es inferior a uno anterior, se añadiría este individuo de una generación anterior a la nueva generación.

Dado que una mutación altera un cromosoma, el nuevo individuo puede tener en el peor de los casos un peor comportamiento y por tanto en la estrategia elitista no se muta el mejor cromosoma. Pueden incluso no mutarse los mejores elementos de la población y mutar algunos de los peores.

El elitismo se puede emplear para asegurar un incremento del valor de coste en cada iteración del GA o, en el peor de los casos, el mismo valor.

4.2. GA *steady-state*

Una modificación importante del GA simple es la utilización de generaciones con solapamiento, a diferencia del simple, que cada vez crea una nueva generación. La alternativa serían los GA *steady-state*, que han demostrado tener ciertas ventajas como una convergencia más rápida en muchas de sus aplicaciones.

El usuario será quien elija qué porcentaje de la población se mantiene y cuál es reemplazado y podrá ir desde un solo individuo hasta la totalidad, en caso de ser el GA simple.

Lectura complementaria

Sobre la estrategia elitista, puede consultarse la obra siguiente:

K. A. de Jong (1975). "An analysis of the behavior of a class of genetic adaptive systems" (disertación doctoral). *Diss. Abstr. Int.* 36(10), 5140B (University Microfilms, núm. 76-9381). Ann Arbor: Universidad de Michigan.

Lectura complementaria

Sobre los GA *steady-state*, puede consultarse la obra siguiente:

K. A. de Jong (1975). "An analysis of the behavior of a class of genetic adaptive systems" (disertación doctoral). *Diss. Abstr. Int.* 36(10), 5140B (University Microfilms, núm. 76-9381). Ann Arbor: Universidad de Michigan.

El funcionamiento y la implementación resulta idéntica que el GA simple, con la diferencia de que todo el proceso de selección, cruzamiento y mutación solo se aplica a una parte de la población, que después es añadida a la población que se ha querido mantener.

Una variante mantiene toda la población actual y añade además la nueva, con lo que aumenta el total. Entonces se realiza el proceso de eliminación de toda esta nueva población.

Otros métodos, estrategias o funciones de coste han sido probadas y están siendo exploradas, como el uso de genes “dominantes” o recesivos o los conceptos de nicho y especiación.

Lectura complementaria

Sobre los conceptos de nicho, puede consultarse la obra siguiente:

D. E. Goldberg; J. J Richardson (1987). “Genetic Algorithms with sharing for multimodal function optimization. In Genetic Algorithms and Their Applications”. *Proceedings of the Second International Conference on Genetic Algorithms*.

5. El problema del viajero

A continuación se presenta un problema típico, como es el problema del viajero (*TSP*, de *travel salesman problem*), que trata de un vendedor que tiene que visitar diferentes localidades. El vendedor debe visitar cada una de estas localidades únicamente una vez y tiene que volver a casa al finalizar el viaje. El problema será encontrar la mejor de las rutas, ordenar el orden de visita de las ciudades, de modo que se minimice la distancia total recorrida por el vendedor. La abstracción del problema del viajero tiene aplicación por ejemplo en la optimización de la ruta que debe seguir un robot que monta componentes electrónicos en una placa de circuito impreso.

En este problema, la optimización se logrará con la correcta asignación del orden de visita de cada ciudad.

El problema que se puede encontrar con la utilización del operador cruzamiento estándar (elección de un punto único) es que fácilmente se crearán rutas no válidas, o rutas donde se visita una ciudad más de una vez. La posibilidad de que aparezcan rutas no válidas en las soluciones aumenta la dificultad de encontrar la solución óptima. Para solventar estas dificultades se variarán los operadores *crossover* y mutación.

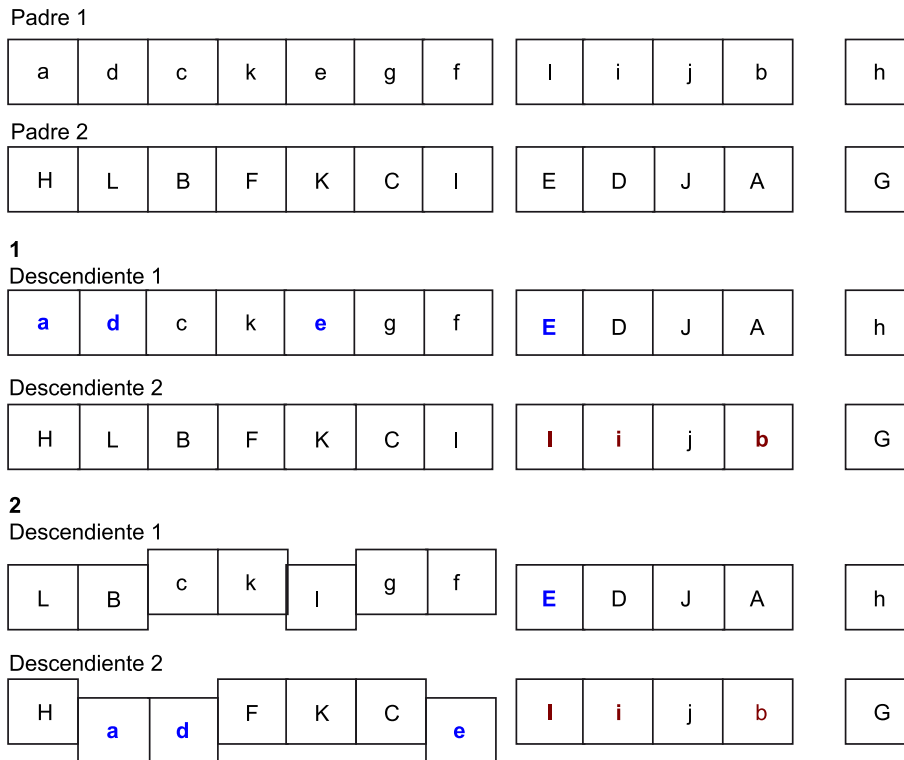
En el ejemplo que se muestra se utilizará el *PMX* (*partially matched crossover*). Este deriva de un cruzamiento de doble punto, que sigue la misma filosofía que el de un único punto pero eligiendo dos, y lo que haya entre ellos será lo que se intercambiará. También traerá asociada una probabilidad p_{Cross} , que ha de ser superada para realizarse el proceso. Hay que recalcar que como la ruta que seguirá el viajero es una ruta “cerrada”, la solución ...**ABCDA**... sería igual que la solución ...**CDABC**....

El *PMX* consta de dos partes: el **cruzamiento** y la validación de la ruta. La primera parte es la anteriormente descrita, donde los puntos seleccionados se asignarán de una manera aleatoria, la parte que cambie del *Padre 1* se copiará a las mismas posiciones del *Descendiente 2*, y lo mismo para el otro padre. Las partes restantes de los padres se copiarán a las mismas posiciones de los respectivos descendientes, del 1 al 1 y del 2 al 2 (figura 4). A continuación viene la segunda parte, que se ha denominado de validación de la ruta.

Una vez obtenidos los dos descendientes, se observa que en las partes fuera de los puntos de cruzamiento hay elementos que debido a la introducción de la “nueva parte”, ahora se repiten. En la figura 4 los elementos *a*, *d*, *e* del descendiente 1 también están en la nueva parte introducida *A*, *D*, *E*, y en el *Descendiente 2* pasa lo mismo con *L*, *B*, *I*. Estos elementos repetidos se sustituirán

por los elementos repetidos del otro descendiente ocupando las mismas posiciones (figura 4). La distinción entre mayúsculas y minúsculas se ha realizado únicamente para saber en todo momento la procedencia del elemento.


Figura 4. Funcionamiento del PMX



De este modo se ha obtenido como solución unas rutas totalmente válidas.

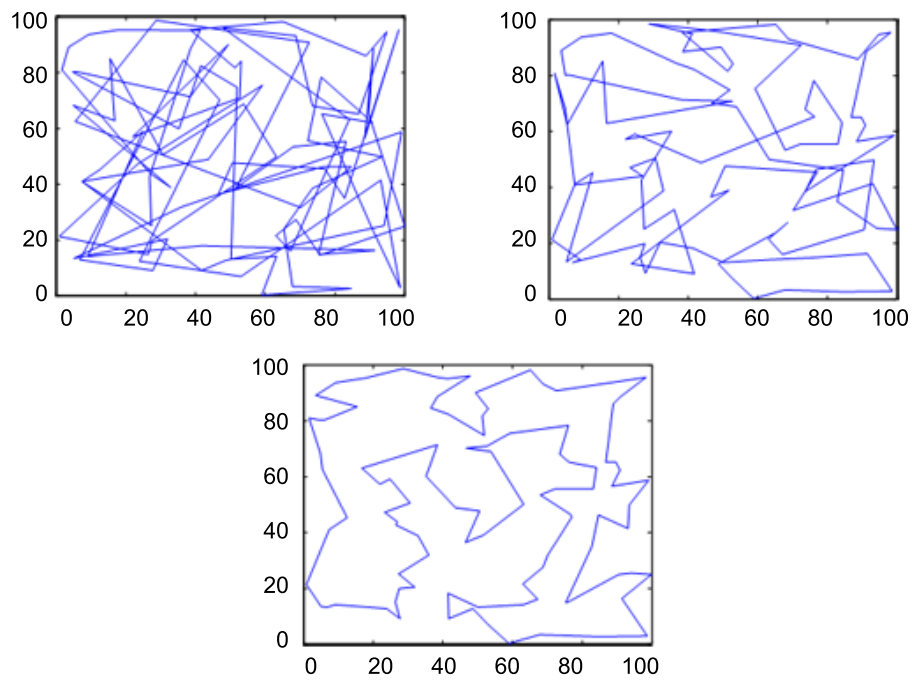
Del mismo modo que el cruzamiento podía dar soluciones no válidas, para el caso de la mutación puede suceder exactamente lo mismo; por ello también se modificará este operador haciendo que en lugar de provocar el cambio de un elemento del cromosoma, se intercambiará la posición de un par de elementos entre ellos. Si se intercambian elementos de una ruta válida, el resultado seguirá siendo una ruta válida. Se puede observar en la figura 5 en los elementos *d* e *y*.

Figura 5. Funcionamiento de la mutación en el TSP



Una vez presentado el funcionamiento de este GA se ilustran diferentes pasos de la evolución gráfica de la ruta cuando se ejecuta el GA (figura 6).

Figura 6. Evolución del recorrido del viajero por 100 ciudades



Los ejes de abscisas y ordenadas son magnitudes de distancia.

6. Ejemplos de aplicación

A continuación se ilustran algunos ejemplos de aplicación en el campo de las antenas. El primero de ellos utiliza GA para optimizar diagramas de radiación de una agrupación. El segundo de ellos muestra cómo es posible sintetizar antenas para que cumplan un cierto requisito, como por ejemplo un comportamiento de alta directividad. Finalmente, se detalla un caso en el que se optimizan los valores de una red de adaptación de una antena.

6.1. Optimización de pesos de agrupaciones de antenas

Son varios los métodos de síntesis de diagramas de radiación, como por ejemplo el método de Fourier.

La ventaja de optimización mediante GA es la posibilidad de optimizar no solo los pesos a_n tanto en fase como en módulo, sino también la posibilidad de optimizar la distancia entre elementos d_n (2.3):

$$\vec{E}(\vec{r}) = \vec{E}_0(\vec{r}) \cdot \sum_{n=0}^{N-1} a_n e^{jk d_n \cos\theta} \quad 2.3$$

donde los parámetros por optimizar podrían ser a_n y d_n y la función de coste la distancia euclídea entre el diagrama deseado y el de cada individuo en cuestión.

Además, la optimización mediante GA permite añadir restricciones al margen de valores que pueden adoptar las amplitudes, fases y distancias. Por ejemplo, el método de Fourier no limita el margen de valores de los pesos a_n . Esta limitación puede acarrear el problema de que la disparidad de pesos a_n sea tal que la red de distribución necesaria tenga líneas de transmisión con valores muy dispares de impedancia característica. Dicha disparidad puede entrar en conflicto con la tecnología disponible, pues valores muy altos de impedancia característica implican anchos muy reducidos de línea de transmisión en caso de implementarse con tecnología *microstrip*, por citar un ejemplo. Por el contrario, valores bajos de impedancia característica implican anchos muy elevados de la línea de transmisión. GA resuelve esta limitación al poder añadir restricciones en el proceso de optimización que estén en consonancia con los límites tecnológicos.

Lectura complementaria

Sobre el método de Fourier, puede consultarse la obra siguiente:

J. Anguera; A. Pérez (2008).
Teoría d'Antenes (ISBN:
978-84-935665-4-8).

6.2. Optimización de antenas

El diseño de antenas mediante GA permite sintetizar antenas de una manera automatizada.

Un procedimiento muy potente de diseño con GA consiste en la combinación de GA con métodos de resolución numérica de las ecuaciones de Maxwell mediante por ejemplo el método de los momentos (*method of moments* o *MoM*).

Ved también

El método de los momentos se estudia en el módulo "Método numérico para la resolución de las ecuaciones de Maxwell" de esta asignatura.

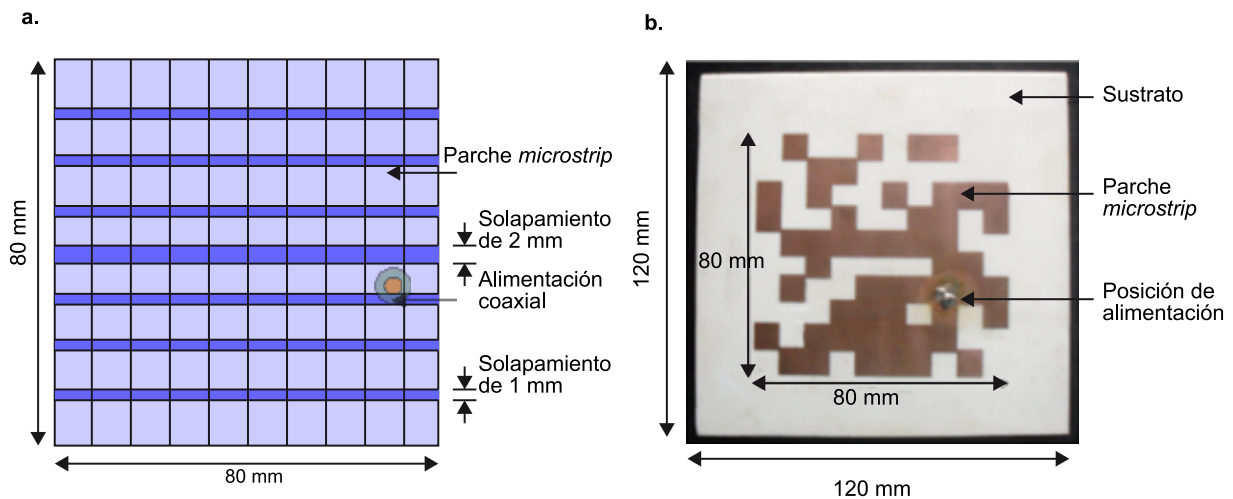
El ejemplo ilustrado en este subapartado muestra la síntesis de un parche *microstrip* para obtener elevada directividad en la dirección *broadside*. Sin pérdida de generalidad, en este caso no se ha utilizado el MoM, sino otra técnica denominada *FEM* (*finite element method*). El área de la zona se divide en 80 celdas, de modo que se solapen entre celdas adyacentes (figura 7).

Lectura complementaria

Podéis profundizar más sobre el MoM en:

J. M. Johnson; Y. Rahmat-Samii (1997). "Genetic algorithms in engineering electromagnetics". *IEEE Antennas and Propagation Magazine* (vol. 39, núm. 4, pág. 7-21).

Figura 7



a. Retícula inicial a partir de la cual se generarán los cromosomas a partir de activar y desactivar celdas; b. Antena *microstrip* optimizada

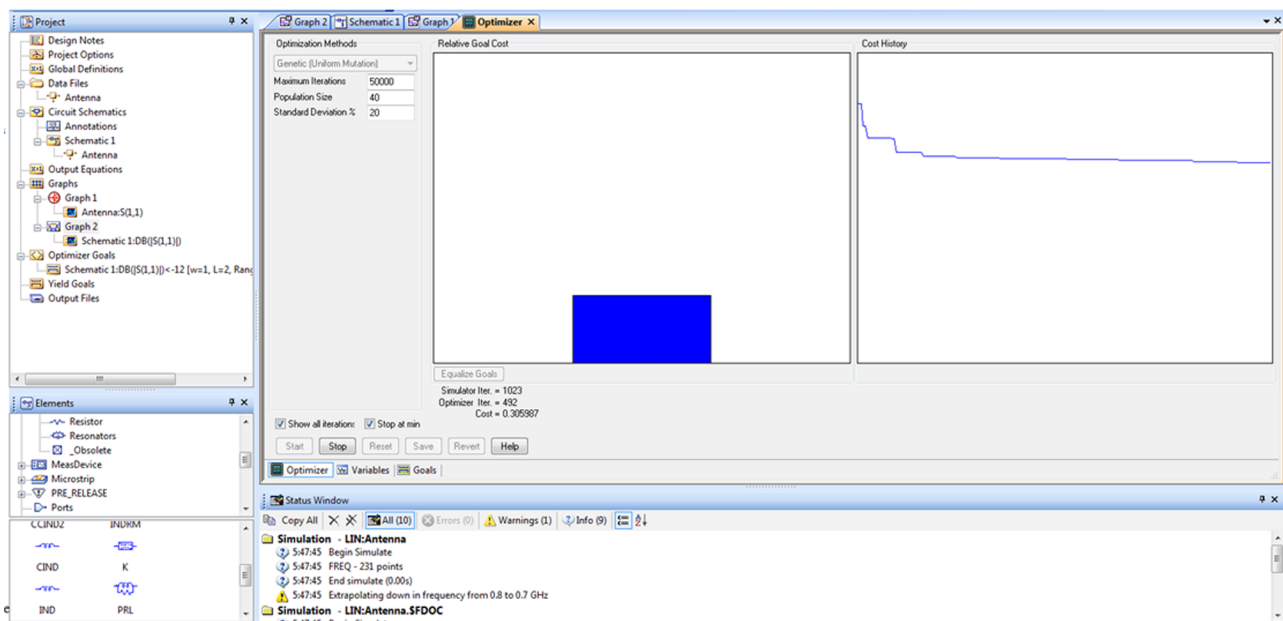
La propiedad de conductor o no conductor de cada celda se define utilizando la codificación binaria. Si una celda es conductora, el gen correspondiente se asigna a 1, y si una celda es no conductora, se le asigna 0. El propósito de la superposición entre células adyacentes es evitar tener un contacto infinitesimal entre las celdas que puede plantear un problema de conexión cuando se fabrica el parche *microstrip* debido a las tolerancias del grabado químico (figura 7).

La técnica propuesta también es adecuada para otros métodos de fabricación, tales como estampar el conductor usado para el parche *microstrip* en un soporte de plástico. Si las piezas del conductor tienen un contacto infinitesimal, el parche en general está compuesto por varias piezas que son difíciles de ensamblar en un soporte. Sin embargo, usando la técnica presente, se obtiene una sola pieza conductora, lo que simplifica la sujeción de esta en el soporte de plástico que se utiliza como sustrato. Por lo tanto, el método aquí propuesto simplifica la fabricación de antenas *microstrip* obtenidas a través de optimización GA. Observad que en este caso existen 2^{80} combinaciones posibles. Asumiendo un tiempo de simulación de cada individuo de 1 minuto, el tiempo total de la solución mediante una búsqueda exhaustiva sería de unos ¡2,3 trillones de años! Mediante GA, es cuestión de horas obtener la solución.

6.3. Optimización de redes de adaptación

Otro campo de aplicación de los algoritmos genéticos se encuentra en la optimización de circuitos de microondas, como redes de adaptación para antenas. En muchos casos, cuando el conjunto de variables que diseñar excede un cierto número, el diseño de la red deja de tener una solución sencilla, como puede ser la que tiene una red en L o una red en T .

Figura 8. Optimización mediante GA donde se muestra la evolución de la función de coste



Una de las formas de abordar el diseño multivariable sujeto además a restricciones, como podría ser acotar a un máximo y un mínimo el valor de un componente, es mediante GA (figuras 8 y 9). En este caso se ilustra la optimización de la impedancia de entrada de una antena para satisfacer un requisito de coeficiente de reflexión por debajo de un umbral. En este caso, se acota el valor

Lecturas complementarias

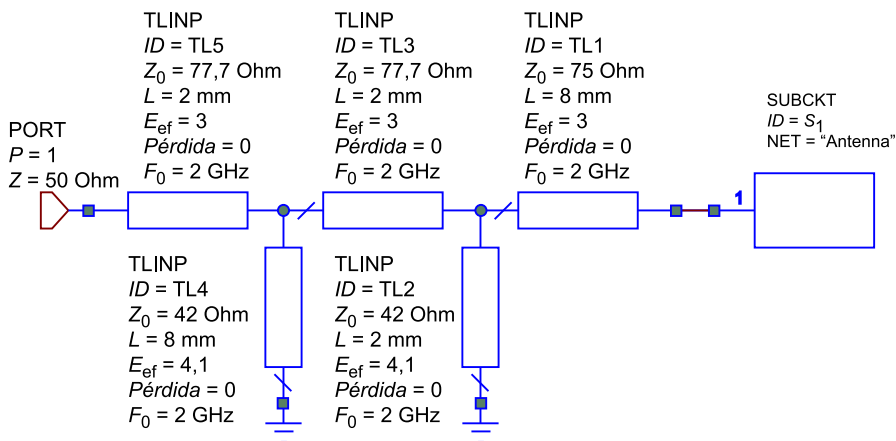
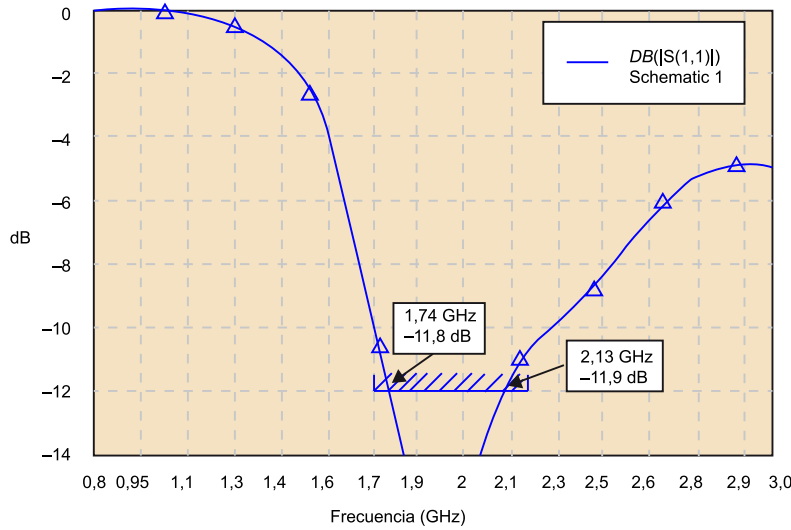
Podéis profundizar más en el método aquí propuesto en las obras siguientes:

J. M. Jayasinghe; J. Anguera; D. N. Uduwawala (2013). "Genetic Algorithm Optimization of a High-Directivity Microstrip Patch Antenna Having a Rectangular Profile". *Radioengineering* (vol. 22, núm. 3, septiembre, pág. 700-707).

J. M. Jayasinghe; J. Anguera; D. N. Uduwawala; A. Andújar (2014). "Genetic algorithm optimization of microstrip patch antennas for high-directivity applications". *International Journal of Electronic Letters*.

mínimo y máximo de la impedancia característica de las líneas de transmisión que conforman la red de adaptación, así como su longitud máxima, con el objetivo de simplificar su fabricación.

Figura 9. Red de adaptación donde las variables que se deben optimizar son las diferentes impedancias características de las líneas de transmisión *microstrip* y sus longitudes, es decir, se tiene un problema con 10 variables sujetas a restricciones



Resumen

Los GA permiten optimización de problemas con múltiples variables y restricciones. El proceso de optimización es global, en el sentido de que no se centra en máximos relativos sino en máximos absolutos gracias principalmente al operador mutación, que añade material genético nuevo que permite ampliar el dominio de la exploración. Si el nuevo elemento que ha experimentado mutación es mejor que la población, el proceso elitista lo colocará en el primer elemento de la cadena y su material genético se heredará a sus progenitores mediante múltiples cruzamientos.

Por tanto, GA es un proceso de optimización global que permite añadir restricciones que se ciñan a los límites impuestos bien por principios físicos bien por principios tecnológicos y que abre una posibilidad de diseño de antenas y circuitos de microondas de una manera automática que debe ser acompañada con las habilidades y los conocimientos del ingeniero de antenas.

Bibliografía

Anguera, J.; Pérez, A. (2008). *Teoria d'Antenes* (ISBN: 978-84-935665-4-8).

Goldberg, D. E.; Richardson, J. J. (1987). "Genetic Algorithms with sharing for multimodal function optimization. In Genetic Algorithms and Their Applications". *Proceedings of the Second International Conference on Genetic Algorithms*.

Haupt, R. L.; Haupt, S. E. (2004). *Practical genetic algorithms*. John Wiley & Sons.

Jayasinghe, J. M.; Anguera, J.; Uduwawala, D. N. (2013). "Genetic Algorithm Optimization of a High-Directivity Microstrip Patch Antenna Having a Rectangular Profile". *Radio-engineering* (vol. 22, núm. 3, septiembre, pág. 700-707).

Jayasinghe, J. M.; Anguera, J.; Uduwawala, D. N.; Andújar, A. (2014). "Genetic algorithm optimization of microstrip patch antennas for high-directivity applications". *International Journal of Electronic Letters*.

Johnson, J. M.; Rahmat-Samii, Y. (1997). "Genetic algorithms in engineering electromagnetics". *IEEE Antennas and Propagation Magazine* (vol. 39, núm. 4, pág. 7-21).

Jong, K. A. de (1975). "An analysis of the behavior of a class of genetic adaptive systems" (dissertación doctoral). *Diss. Abstr. Int.* 36(10), 5140B (University Microfilms, núm. 76-9381). Ann Arbor: Universidad de Michigan.

Rahmat-Samii, Y.; Michielssen, E. (1999). *Electromagnetic Optimization by Genetic Algorithms*. John Wiley & Sons.

