

Técnicas de Diversidad para Algoritmos Meméticos¹

D. Molina²
F. Herrera²
M. Lozano²
C. García Martínez²
A.M. Sánchez²

1. Introducción

Actualmente se admite que los algoritmos genéticos (AGs) en su forma básica no son adecuados para realizar búsquedas en espacios complejos. Una alternativa para solventar este problema consiste en combinar los AGs con otros procedimientos de búsqueda. Los algoritmos resultantes de la hibridación de los AGs con procedimientos de búsqueda local (BL) se denominan *algoritmos meméticos* (AMs) [18]. Un AM se compone de un AG encargado de realizar la búsqueda global, al que denominaremos AG Base (AGB), y de un procedimiento de búsqueda local independiente que se aplica para refinar a los nuevos individuos de la población. En estos algoritmos es esencial el equilibrio entre la exploración del AGB y la capacidad de explotación de la BL ([14]).

La diversidad en la población es crucial para que un AG pueda mantener una exploración conveniente del espacio de búsqueda. La pérdida temprana de diversidad puede provocar un estancamiento de la búsqueda en una región que no contenga el óptimo global. Este hecho, llamado *convergencia prematura*, es un serio problema de los AGs. En el caso del AM este problema es aún mayor, ya que la BL al aplicarse sobre los nuevos individuos conduce la búsqueda hacia óptimos locales. El AGB, por tanto, debe de preservar suficiente

diversidad en la población para contrarrestar esta tendencia. En la literatura sobre AMs existen distintas propuestas que abordan el importante tema de mantener la diversidad en la población al usar conjuntamente un AG y BL ([13, 14, 12]).

En este artículo estudiaremos la influencia de la diversidad sobre el AM. Como el AGB es el componente que aporta la diversidad nos centraremos en él. Utilizaremos como AG Base un *algoritmo genético estacionario* (AGE) [24] para estudiar, en particular, la influencia de la diversidad que se obtiene mediante distintas combinaciones de métodos de selección de padres y de reemplazo.

Usualmente en un AGE se producen únicamente uno o dos hijos en cada generación. En primer lugar, se seleccionan los individuos que se utilizarán como padres para producir hijos. Después, se aplica una estrategia de reemplazo para decidir qué cromosomas de la población van a ser sustituidos por los nuevos cromosomas.

Estudios realizados sobre la efectividad de los AGEs destacan su buen rendimiento y lo atribuyen a los altos niveles de presión selectiva que introducen y a la balanza entre exploración y explotación derivada del uso de diferentes estrategias de selección de padres y de reemplazo. Esta flexibilidad justifica un estudio más en profundidad sobre sus posibilidades como AGB [15].

2. Materiales y Métodos

A continuación, describimos los distintos métodos de selección de padres y estrategias de reemplazo que se han considerado para promover diversidad en los AGEs, producir presión selectiva o fomentar ambas.

2.1 Las estrategias de selección

- Selección Aleatoria (*Random Selection*, *RS*). *RS*

¹Este trabajo ha sido parcialmente financiado por el proyecto TIC-2002-0436-C05-01

²Univ. de Granada, 18071 - Granada, Spain e-mails: {dmolina, herrera, lozano, cgarcia}@decsai.ugr.es amlopez@ugr.es

selecciona un individuo aleatoriamente de la población. No origina ninguna presión selectiva.

- Selección por Torneo (*Tournament Selection, TS*). Se muestrea aleatoriamente un grupo de N_{TS} individuos de la población y se selecciona el que posea el mejor valor para la función objetivo. Origina bastante presión selectiva. En nuestros experimentos utilizamos $N_{TS}=3$.
- Ranking Lineal (*Linear Ranking, LR*) [3]. Se ordenan los individuos de la población por su valor objetivo, y se selecciona los padres según un valor de probabilidad de estar en función de su posición en dicha lista ordenada, será mayor cuanto mejor sea su posición. En nuestros experimentos utilizaremos $\eta_{min}=0.75$.
- Emparejamiento Variado Inverso (*Negative Assortative Mating, NAM*) [7]. Está orientado a generar diversidad. En nuestros experimentos utilizamos $N_{NAM}=3$.

2.2 Las estrategias de reemplazo

- Reemplazar el Peor (*Replace Worst Strategy, RW*). Se reemplaza el peor elemento de la población si el hijo lo mejora. Ofrece alta presión selectiva, incluso cuando sus padres son elegidos aleatoriamente.
- Selección de Torneo Restringido (*Restricted Tournament Selection, RTS*) [9]. En nuestros experimentos utilizamos un tamaño de ventana (*window size*) de 3.
- Reemplazar el Peor Entre Semejantes (*Worst Among Most Similar Replacement, WAMS*) [4]. En nuestros experimentos utilizamos 6 grupos de reemplazo de

un tamaño de 9 individuos cada uno.

- Algoritmo de *Crowding* Determinístico (*Deterministic Crowding, DC*) [16]. Para facilitar la comparativa utilizaremos en nuestros experimentos una variante del DC en el que para cada cruce se generará un único descendente, que sustituirá al padre más parecido en el caso de que lo mejore.

3. Experimentos: Resultados y Discusión

Para estudiar la combinación entre los distintos métodos de selección y reemplazo descritos en las secciones anteriores hemos realizado experimentos de minimización sobre un conjunto de tests. Dicho conjunto de test se compone de diez funciones de test y tres problemas del mundo real.

3.1 Problemas de Prueba

Las funciones de test utilizadas son las siguientes: Modelo *Esfera* [11, 20], función de *Rosenbrock generalizada* [11], Problema *Schewefel 1.2* [20], la función *generalizada de Rastrigin* [2], la función de *Griewangk* [8], la expansión de F_0 [25], la función de *Ackley* [1], la función de *Watson* [19], la función de *Bohachevsky* [19] y la función de *Colville* [5, 19].

Los problemas del mundo real son los siguientes: *Sistemas de Ecuaciones Lineales* [6], *Problema de Identificación de Parámetros Sonoros Mediante Modulación en Frecuencia* [23] y el *Problema de Ajuste Poligonal* [22].

3.2 Algoritmos

Usaremos un esquema de AM que utiliza un AGE con codificación real como AGB, y como método de BL el *Solis Wets* [21]. Se diferencian en los métodos de selección y reemplazo utilizados.

Las características comunes de los algoritmos son:

- El uso del operador de cruce $BLX-\alpha, \alpha=0.5$.
- Una mutación uniforme ([17]) aplicada con una probabilidad de 0.125.
- Se aplica la BL con distinto número de iteraciones asignadas a la BL, N_I (profundidad de BL). Los valores de N_I aplicados son 0 (sin BL), 10 y 50.
- Se aplica la BL al 6.25% de los nuevos individuos [10].
- Tamaño de la población de 60 individuos.
- Se ha ejecutado cada algoritmo 50 veces, y en cada ejecución se realiza un valor máximo de 100000 evaluaciones.

3.3 Método para el estudio

Para comparar los algoritmos, se le ha asignado una puntuación, según el siguiente criterio:

- Para cada función, se ordenan los algoritmos por su valor de función objetivo (la media de las 50 ejecuciones).
- Para cada algoritmo, se aplica la prueba estadística t -test con el mejor para esa función usando 0.05 como valor de significancia.
- Se asignan 5 puntos al primero, 4 al segundo y así sucesivamente. Cuando varios algoritmos se identifican como estadísticamente equivalentes entre sí (según la prueba t -test), todos ellos recibirán los mismos puntos.
- Para cada algoritmo se suman los puntos obtenidos para cada una de las 13 funciones consideradas.

En nuestro estudio, mostramos los resultados obtenidos para los distintos valores N_I considerados.

3.4 Análisis con $N_I=0$ (Sin aplicar BL)

En la figura 2, se muestra gráficamente los resultados obtenidos de realizar las comparaciones cuando $N_I = 0$ (sin BL). Dicha gráfica muestra la puntuación obtenida por cada algoritmo agrupados por su estrategia de reemplazo.




Figura 2: Resultados con $N_I=0$


De la figura 2 se pueden extraer las siguientes conclusiones:

- La combinación $NAM-RW$ es claramente mejor que cualquier otra. Esto es debido a que el aporte de diversidad que ofrece NAM se complementa bien con la alta presión selectiva de RW .
- En general, la utilización de la estrategia de reemplazo DC ofrece buenos resultados, lo que muestra la conveniencia de utilizar estrategias de reemplazo que mantengan altos niveles diversidad.

3.5 Análisis con $N_I = 10$

En la figura 3 se muestra los resultados obtenidos de realizar las comparaciones cuando $N_I=10$. El formato de la figura es equivalente al de la figura 2.

Figura 3: Resultados con $N_I = 10$






Figura 5: Resultados Generales

Se observa el siguiente comportamiento:

- El *NAM-RW* sigue ofreciendo los mejores resultados tras la incorporación de la BL.
- Ahora se perfila la estrategia de reemplazo *WAMS* como una técnica que ofrece buenos resultados, al alcanzar un adecuado equilibrio entre la presión selectiva y el mantenimiento de la diversidad.




Figura 4: Resultados con $N_I = 50$

Análisis con $N_I=50$

En la figura 4 se muestra los resultados cuando $N_I = 50$. En este caso, el uso de la estrategia *RW* ofrece los mejores resultados (para todos los operadores de selección). Este comportamiento es debido a que en este caso N_I implica un número bajo de iteraciones del AGB. En dicha circunstancia es conveniente un método de reemplazo con alta presión selectiva como el *RW* para facilitar una rápida convergencia, y para aprovechar el esfuerzo invertido en la BL (ya que es el criterio de reemplazo que facilita más la introducción de un nuevo individuo).

3.7 Comparativa Global

La figura 5 muestra una comparativa global de todos los algoritmos. Se muestra para cada algoritmo la puntuación obtenida para cada valor N_I .

De los resultados podemos extraer dos conclusiones:

- La combinación *NAM-RW* es la que mejor resultados ofrece tanto sin aplicar BL como aplicándola.

- La influencia de aumentar N_I depende del algoritmo: En el reemplazo *DC* la bondad disminuye, mientras

que los que utilizan el reemplazo *RW* o *WAMS* poseen una tendencia ascendente.

4. Conclusiones

En este artículo hemos comparado AMs utilizando como AGB AGEs con distintos métodos de selección de padres y de reemplazo, para estudiar la influencia sobre la diversidad que aportan estos métodos. De los experimentos realizados se han obtenido las siguientes conclusiones:

- La influencia del reemplazo es mayor que la del método de selección de padres, ya que determina tanto si los nuevos descendientes se introducen en la población como el tiempo de permanencia de cada individuo en la misma. Esto influye en la diversidad:

cuanto mayor sea la duración de un individuo en la población mayor puede ser su influencia en la búsqueda.

- El comportamiento de los AMs varía conforme aumenta la profundidad de la búsqueda, y se confirma que un buen AGB requiere un nivel de diversidad mayor que un AG que trabaja de forma independiente (sin BL).
- El uso de *NAM* con *RW* ofrece los mejores resultados en la figura 5, por lo que se confirma como una prometedora combinación tanto para un AGE sin aplicar BL como para su uso en un AM. Existen trabajos que ya han utilizado esta combinación para diseñar AMs [1].

Trabajo Futuros:

Este estudio sobre diversidad puede ser extendido considerando métodos adicionales de fomento de diversidad, e incluso utilizando como AGB esquemas de AGs distintos al modelo estacionario (AGE).

5. Bibliografía

- [1] D. H. Ackley. A connectionist machine for genetic hill-climbing. *Kluwer Academic Publishers*, 1987.
- [2] T. Bäck. Self adaptation in genetic algorithm. *Proc. of the First European Conf. On Artificial Life*, páginas 263-271, 1992.
- [3] J.E. Baker. Adaptive selection methods for genetic algorithms. In *Proceedings of the 1st International Conference on Genetic Algorithms*, páginas 101-111. Lawrence Erlbaum Associates, Inc., 1985.
- [4] W. Cedeño and V. Vemuri. Multi-niche crowding in genetic algorithms and its application to the assembly of dna restriction-fragments. *Evolutionary Computation*, 2(4):321-345, 1995.
- [5] A.R. Colville. A comparative study of nonlinear programming code. *Technical Report N° 320-2949*.
- [6] L. J. Eshelman, K. E. Mathias, and J. D. Schaffer. Convergence controlled variation. *Foundations of Genetic Algorithms*, páginas 203-224, 1997.
- [7] C. Fernandes and A. Rosa. A study of non-random matching and varying population size in genetic algorithm using a royal road function. *Proc. of the 2001 Congress on Evolutionary Computation*, páginas 60-66, 2001.
- [8] A.O. Griewangk. Generalized descent of global optimization. *Journal of Optimization Theory and Applications*, 34: páginas 11-39, 1981.
- [9] G. Harik. Finding multimodal solutions using restricted tournament selection. *Proc. 6th Int. Conf. Genetic Algorithms*, páginas 24-31, 1995.
- [10] W.E. Hart. Adaptive Global Optimization With Local Search. PhD thesis, Univ. California, San Diego, CA., 1994.
- [11] K.A. De Jong. An Analysis of the Behaviour of a Class of Genetic Adaptive System. *Phd Thesis*, Univ. Of Michigan, Ann Arbor, 1975.
- [12] N. Krasnogor. Studies on the Theory and Design Space of Memetic Algorithms. *PhD thesis*, Faculty Computation, Math. Eng, Univ. West of England, Bristol U. K., 2002.
- [13] N. Krasnogor and J. E. Smith. A memetic algorithm with self-adapting local search: Tsp as a case study. *Proceedings of the 2000 International Conference on Genetic and Evolutionary Computation*, páginas 987-994, 2000.
- [14] N. Krasnogor and J. E. Smith. Emergence of profitable search strategies based on a simple inheritance mechanism. *Proceedings of the 2001 International Conference on Genetic and Evolutionary Computation*, páginas 432-439, 2001.
- [15] M. Lozano, F. Herrera, N. Krasnogor, and D. Molina. Real-coded memetic algorithms with crossover hill-climbing. *Evolutionary Computation*, 12(3):273-302, 2004.

- [16] S.W. Mahfoud. Crowding and preselection revised. *Parallel Problem Solving from Nature 2*, páginas 27-36, 1992.
- [17] Z. Michalewicz. Genetic algorithm + data structures = evolution programs. Springer-Verlag, 1996.
- [18] P. A. Moscato. Memetic algorithms: a short introduction. *New Ideas in Optimization*, páginas 219-234, 1999.
- [19] R. C. Reynolds and C. Chung. Knowledge-based self-adaption in evolutionary programming using cultural algorithms. *Proc. of 1997 Int. Conf. on Evolutionary Computation*, páginas 71-76, 1997.
- [20] H.P. Schewefel. *Numerical optimization of computer models*, Wiley, Chichester, 1981.
- [21] F. J. Solis and R. J. Wets. Minimization by random search techniques. *Mathematical Operations Research*, 6:19-30, 1981.
- [22] R. Storn and K. Price. Differential evolution: a simple and efficient adaptive scheme for global optimization over continuous spaces. *Technical Report TR-95-012*, 1995.
- [23] S. Tsutsui and Y. Fujimoto. Forking genetic algorithm with blocking and shrinking modes. *Proc. 5th Int. Conf. on Genetic Algorithms*, páginas 206-213, 1993.
- [24] D. Whitley. The genitor algorithm and selection pressure: why rank-based allocation of reproductive trials is best. *Proc. of the Third Int. Conf. On Genetic Algorithms*, páginas 116-121, 1989.
- [25] D. Whitley, R. Bereridge, C. Graves, and K. Mathias. Test driving three 1995 genetic algorithms: New test functions and geometric matching *Journal Heuristic*, 1:77-104, 1995.

[25] D. Whitley, R. Bereridge, C. Graves, and K. Mathias. Test driving three 1995 genetic algorithms: New test functions and geometric matching. *Journal Heuristic*, 1:77-104, 1995.