

Técnicas de Diversidad para Algoritmos Meméticos: Un Estudio Experimental

Daniel Molina

Dept. de Inteligencia Artificial y
Ciencias de la Computación
ETS Ingeniería Informática
Univ. de Granada
18071 Granada
dmolina@decsai.ugr.es

Francisco Herrera

Dept. de Inteligencia Artificial y
Ciencias de la Computación
ETS Ingeniería Informática
Univ. de Granada
18071 Granada
herrera@decsai.ugr.es

Manuel Lozano

Dept. de Inteligencia Artificial y
Ciencias de la Computación
ETS Ingeniería Informática
Univ. de Granada
18071 Granada
lozano@decsai.ugr.es

Resumen

Se denomina Algoritmo Memético (AM) a la combinación de un Algoritmo Evolutivo (AE) con un proceso de búsqueda local. Dado que la incorporación de un proceso de búsqueda local aumenta la presión selectiva, es conveniente que el AE utilizado mantenga suficiente diversidad en la población para evitar el riesgo de convergencia prematura. Este problema, no obstante, no es nuevo, por lo que dentro de los AGs se han definido a lo largo del tiempo distintas técnicas para fomentar la diversidad en la población. Este trabajo consiste en un estudio de la aplicación de algunas de éstas técnicas a los AMs. En particular, nos hemos centrado sobre el modelo de AG estacionario, comparando distintos métodos de selección y de reemplazo. El objetivo es determinar qué combinaciones de selección y reemplazo ofrecen los mejores resultados cuando se incorpora un procedimiento de búsqueda local.

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) [20]. Un AM se compone de un AG encargado de realizar la búsqueda global, al que denominaremos Algoritmo para Evolucionar la Población (AEP), y de un procedimiento de búsqueda local (BL) independiente que se aplica para refinar a los nuevos individuos de la población. En estos algoritmos es esencial el equilibrio entre la exploración (búsqueda global) de los AGs y la capacidad de explotación de la BL ([17]).

La diversidad en la población es crucial para que un AG pueda mantener una exploración conveniente dentro del espacio de búsqueda. La pérdida temprana de diversidad puede provocar un estancamiento de la búsqueda en una región que no contenga al óptimo local. 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 origina una alta probabilidad de conducir la búsqueda hacia óptimos locales, aumentando el riesgo de la convergencia prematura. El AEP, por tanto, debe preservar suficiente diversidad en la población para contrarrestar este comportamiento. 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 ([16, 17, 15]).

En este trabajo estudiaremos la influencia

de la diversidad sobre el AM. Como el AEP es el componente que aporta la diversidad en la búsqueda nos centraremos en él. Utilizaremos como AEP un *algoritmo genético estacionario* (AGE)[27]. 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[14] destacan su alto rendimiento frente a los AGs generacionales (en los cuáles la población entera se reemplaza por la población de descendientes obtenidos en cada generación). Además, 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 búsqueda. Esta flexibilidad justifica un estudio más en profundidad sobre sus posibilidades como un AEP dentro de un AM ([18]). Este trabajo realiza un estudio sobre distintos métodos de selección y estrategias de reemplazo en los AGEs, para intentar determinar la combinación más adecuada para un AGE que se desee utilizar como AEP de un AM.

Este trabajo está organizado de la siguiente forma: En la sección 2, se introducen los métodos de selección y de reemplazo que se considerarán en el estudio. En la sección 3, se describen los experimentos realizados. En la sección 4, se estudian los resultados obtenidos. Finalmente, en la sección 5, se indican las conclusiones generales del estudio.

2. Métodos de Selección y Reemplazo Considerados

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

2.1. Las estrategias de selección

- Selección Aleatoria (*Random Selection, RS*). RS 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 utilizaremos $N_{TS}=3$.
- Orden Lineal (*Linear Ranking, LR*)[3]. Se ordenan los individuos de la población por su valor de la función objetivo en orden descendente de mejor a peor. A cada individuo se le asigna un valor de probabilidad de ser elegido padre, en función de la posición que ocupa en dicho listado: Será mayor dicha probabilidad cuanto menor sea su posición. Se seleccionan ambos padres utilizando dichas probabilidades. En nuestros experimentos utilizaremos como valor de $\eta_{min} = 0,75$ (donde η_{min} está definido en [3]).
- El Emparejamiento Variado Inverso (*Negative Assortative Mating, NAM*) [8]. En esta selección se escoge un padre aleatoriamente, y para seleccionar el otro se muestrean aleatoriamente N_{NAM} individuos de la población, y se escoge el más distante al primero (aplicando una medida de distancia). Está orientado a generar diversidad. En nuestros experimentos utilizaremos $N_{NAM} = 3$.

2.2. Las estrategias de reemplazo consideradas

- Reemplazar el peor (*Worst Strategy, RW*)[9]. Se reemplaza el peor elemento de la población si el nuevo elemento lo mejora. Ofrece alta presión selectiva, incluso cuando sus padres son elegidos aleatoriamente.
- Selección de Torneo Restringido (*Restricted Tournament Selection, RTS*)[11]. Su-

pongamos que A es el individuo a ser incluido en la población. *RTS* muestrea aleatoriamente w (*window size*) individuos de la población y selecciona el individuo más parecido a A de entre ellos. A compete con este elemento y si A gana se introducirá en la población. En nuestros experimentos utilizaremos $w = 3$.

- Reemplazar el Peor entre Semejantes (*Worst Among Most Similar Replacement, WAMS*)[4]. Se compone de los siguientes pasos. Primero, se muestrean de la población aleatoriamente C_f grupos de C_s elementos cada uno. Después, se identifica para cada grupo el individuo más similar al descendiente considerado. Este proceso genera C_f individuos como candidatos para ser reemplazados, de los que se selecciona aquél con peor valor de la función objetivo. El descendiente reemplazará a éste si es mejor. En nuestros experimentos utilizaremos $C_f = 6$ y $C_s = 9$.
- Algoritmo de *Crowding* Determinístico (*Deterministic Crowding, DC*)[19]. En nuestro caso, utilizaremos una variante en la que en cada cruce se genera únicamente un hijo, que se comparará (mediante una medida de distancia) con cada uno de sus padres. El hijo se introducirá en la población sustituyendo a su padre más cercano sólo en el caso de que mejore a éste.

3. Experimentos

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.

3.1. Funciones de Tests

El conjunto de test empleado se compone de diez funciones de test y tres problemas del mundo real.

Las funciones de test utilizadas son las siguientes: El Modelo Esfera [13, 22], función de

Rosenbrock generalizada [13], Problema *Schewefel 1.2* [22], función *generalizada de Rastrigin* [2, 25], la función de *Griewangk* [10], la expansión de f_{10} [28], la función de *Ackley* [1], la función de *Watson* [21], la función de *Bohachevsky* [21], la función de *Colville* [5, 21]. Los problemas del mundo real son los siguientes: *Sistemas de Ecuaciones Lineales* [6], *Problema de Identificación de Parámetros Sonoros Mediante Modulación de Frecuencia* [26] y el *Problema de Ajuste Polinomial* [24].

Para todos estos problemas (a excepción de *Watson*), el fitness del óptimo local vale cero.

3.2. Parámetros de los algoritmos estudiados

Para poder estudiar la combinación de los métodos de selección y reemplazo hemos implementado distintos AMs. Todos ellos siguen un mismo esquema que utiliza un AGE con codificación real como AEP y como método de BL el *Solis Wets*[23]. Estos AMs implementados se diferencian únicamente en la combinación de los métodos de selección y reemplazo utilizados. Las características comunes de todos ellos son:

- El uso del operador de cruce *BLX* – α ($\alpha = 0,5$)[7].
- Una mutación no uniforme aplicada al 12,5 % de los genes.
- Se aplica la BL con distintos número de iteraciones asignadas a la BL N_I (profundidad de la BL). Los valores de N_I aplicados son: 0 (sin BL), 10 y 50 iteraciones. La tabla 1 muestra para cada uno de dichos valores el porcentaje de evaluaciones que se invierte en realizar la BL.
- Se aplica la BL al 6,25 % de los nuevos individuos[12].
- Tamaño de la población de 60 individuos.
- El algoritmo finaliza cuando se han realizado 100000 evaluaciones.
- En cada cruce se ha generado únicamente un hijo, que se introducirá en la población utilizando la estrategia de reemplazo utilizado en cada caso.

N_I	Ratio
0	0 %
10	55 %
50	85 %

Cuadro 1: Porcentaje de evaluaciones realizadas durante la BL

3.3. Metodología de la experimentación

Para evaluarlos hemos ejecutado cada algoritmo ejecutado sobre cada función de test 50 veces para cada uno de los valores N_I considerados. A cada algoritmo se le ha asignado una puntuación. Para calcularla se han aplicado los siguientes pasos:

1. Para cada función, se ordenan los algoritmos considerados por su valor de la función objetivo (la media de las 50 ejecuciones).
2. Para cada algoritmo se aplica la prueba estadística *t-test de Student* con el mejor para esa función utilizando 0.05 como valor de significancia.
3. Para cada función se le asigna a cada algoritmo una puntuación entre 0-5 puntos. Se le asignan 5 puntos al primer elemento (con mejor media), 4 al siguiente y así sucesivamente. Cuando varios algoritmos sean identificados como estadísticamente equivalente entre sí (según la prueba de *t-test*), todos ellos recibirán la misma puntuación.
4. Para cada algoritmo se suman los puntos obtenidos para cada una de las 13 funciones consideradas.

En nuestro estudio, mostraremos los resultados obtenidos para los distintos valores N_I considerados. La idea es estudiar el comportamiento en cada caso y poder valorar las diferencias que se producen conforme N_I aumenta.

4. Resultados y Análisis

En este apartado se muestran los resultados obtenidos para los distintos valores de N_I considerados. Finalmente, se compararán todos los algoritmos considerados entre sí.

4.1. Análisis con $N_I = 0$ (Sin aplicar la BL)

En las figuras 1 y 2, se muestran gráficamente los resultados obtenidos de realizar las comparaciones cuando $N_I = 0$ (sin BL). Dichas gráficas muestra la puntuación obtenida para cada algoritmo agrupados por su método de selección y estrategia de reemplazo, respectivamente.




Figura 1: Resultados con $N_I = 0$ (agrupados por selección)




Figura 2: Resultados con $N_I = 0$ (agrupados por reemplazo)

De la figuras se pueden extraer las siguientes conclusiones:

- Se observa que la combinación NAM-RW es claramente mejor que cualquier otra combinación. Esto es debido a que el aporte de diversidad que ofrece el NAM se complementa bien con la alta presión selectiva del RW lo cual lo convierte en una combinación muy prometedora, al mantener un adecuado equilibrio de exploración y explotación.
- En general, la utilización de la estrategia de reemplazo DC ofrece muy buenos resultados, lo que muestra la conveniencia de utilizar estrategias de reemplazo que mantengan la diversidad.
- Comparando las gráficas 1 y 2 se puede observar que parece que la influencia del criterio de reemplazo es mayor que la del método de selección. Debido a esto en los apartados posteriores se mostrarán los algoritmos agrupados por la estrategia de reemplazo.

4.2. Análisis con $N_I = 10$ (55 % de las evaluaciones en la BL)

En la figura 3, se muestra gráficamente 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 $N_I = 10$

Se observa el siguiente comportamiento:

- El NAM-RW sigue ofreciendo los mejores resultados tras la incorporación de la BL.

- La estrategia de reemplazo WAMS ahora es la que ofrece mejores resultados de media, al alcanzar un adecuado equilibrio entre la presión selectiva y el mantenimiento de la diversidad. Esto confirma la necesidad ya anunciada de que debido a la aplicación de una búsqueda local sobre los nuevos individuos, aumenta la necesidad de diversidad. Así pues, el criterio de reemplazo WAMS que fomenta mayor diversidad que el criterio de reemplazo DC ofrece mejores resultados.
- Cuando se utiliza un operador de reemplazo que mantenga diversidad, es muy conveniente un método de selección que fomente la explotación (como el torneo). Esto es debido a que este tipo de operadores favorecen que los individuos resultantes de aplicar la BL influyan más rápidamente sobre la población, orientando más la búsqueda sobre las zonas más prometedoras.

4.3. Análisis con $N_I = 50$ (85 % de las evaluaciones en la BL)

En la figura 4, se muestra los resultados obtenidos cuando $N_I = 50$, de los que se pueden extraer las siguientes conclusiones:




Figura 4: Resultados con $N_I = 50$

- En este caso, el uso de la estrategia RW ofrece los mejores resultados (para la mayoría de los operadores de selección). Esto es debido a que el porcentaje de esfuerzo invertido en la BL implica un número

bajo de iteraciones del AGE. Para dicho número de iteraciones es necesario un método de reemplazo con alta presión selectiva como el RW por dos motivos: a) Para obtener una convergencia rápida, y b) para aprovechar el esfuerzo invertido en la BL, ya que es el criterio de reemplazo que facilita más la introducción de un nuevo individuo.

- Conforme aumenta el esfuerzo invertido en la búsqueda local aumenta la conveniencia de un método de selección con mayor presión selectiva (como la selección por torneo). Esto puede ser debido a que con estos métodos se fomenta que los individuos resultantes de aplicar la Búsqueda Local generen más descendientes.

4.4. Resultados Globales

Tras comparar los resultados obtenidos para cada uno de los valores de N_I , se muestra en la figura 5 una comparativa global de los algoritmos estudiados. Para cada algoritmo se visualiza la puntuación obtenida para cada valor N_I .

De la gráfica 5 podemos alcanzar 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 de cada algoritmo: la bondad del reemplazo DC disminuye, mientras que los que utilizan el reemplazo RW o WAMS poseen una tendencia ascendente.

5. Conclusiones

En este artículo hemos comparado AMs utilizando como AEP AGEs con distintos métodos de selección 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. El

criterio de reemplazo determina tanto si los nuevos descendientes se introducen en la población como la permanencia de cada individuo en la misma, por lo que se puede limitar el nivel de influencia de una determinada solución, manteniendo mayor diversidad.

- El comportamiento del AM varía conforme aumenta la profundidad de la búsqueda, y se confirma que un buen AEP requiere un nivel de diversidad mayor que un AG que trabaja de forma independiente.
- Con el uso de una BL se observa una mayor necesidad de diversidad. En la gráficas destacan dos tendencias adecuadas:
 1. Uso de un método de reemplazo que mantenga diversidad (como el DC o el WAMS), y un método de selección que explote las soluciones (para que favorezca la influencia de los individuos mejorados mediante BL a la población).
 2. Mediante un operador de selección que fomente diversidad (como el NAM) y un método de reemplazo que favorezca la explotación (como el RW), estableciendo un equilibrio adecuado.
- 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 artículos que ya han utilizado esta combinación para diseñar AMs[18].
- Hay que establecer un equilibrio entre el porcentaje de esfuerzo destinado a la Búsqueda Global y el esfuerzo destinado a la BL.

Agradecimiento al proyecto

Este trabajo ha sido realizado gracias al proyecto TIC 2002-04036-C05-01.

Figura 5: Resultados con $N_I = 50$

Referencias

- [1] D. H. Ackley. A connectionist machine for genetic hillclimbing. *Kluwer Academic Publishers*, 1987.
- [2] T. Bäck. Self-adaptation in genetic algorithms. *Proc of the First European Conf. on Artificial Life*, pages 263–271, 1992.
- [3] J. E. Baker. Adaptive selection methods for genetic algorithms. In *Proceedings of the 1st International Conference on Genetic Algorithms*, pages 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*, 1968.
- [6] L. J. Eshelman, K. E. Mathias, and J. D. Schaffer. Convergence controlled variation. *Foundations of Genetic Algorithms*, pages 203–224, 1997.
- [7] L. J. Eshelman and J. D. Schaffer. Real-coded genetic algorithms in genetic algorithms by preventing incest. *Foundation of Genetic Algorithms 2*, pages 187–202, 1993.
- [8] 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*, pages 60–66, 2001.
- [9] D. E. Goldberg and K. Deb. A comparative analysis of selection schemes used in genetic algorithms. *Foundations of Genetic Algorithms*, pages 69–93, 1991.
- [10] A.O. Griewangk. Generalized descent of global optimization. *Journal of Optimization Theory and Applications*, 34:11–39, 1981.
- [11] G. Harik. Finding multimodal solutions using restricted tournament selection. *Proc. 6th Int. Conf. Genetic Algorithms*, pages 24–31, 1995.
- [12] W.E. Hart. *Adaptive Global Optimization With Local Search*. PhD thesis, Univ. California, San Diego, CA., 1994.
- [13] K. A. De Jong. *An Analysis of the Behaviour of a Class of Genetic Adaptive Systems*. PhD thesis, Univ. of Michigan, Ann Arbor, 1975.
- [14] K.A. De Jong and J. Sarma. Generation gaps revisited. *Foundations of Genetic Algorithms 2*, pages 19–28, 1993.

- [15] 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.
- [16] 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*, pages 987–994, 2000.
- [17] 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*, pages 432–439, 2001.
- [18] M. Lozano, F. Herrera, N. Krasnogor, and D. Molina. Real-coded memetic algorithms with crossover hill-climbing. *Evolutionary Computation*, 12(3):273–302, 2004.
- [19] S.W. Mahfoud. Crowding and preselection revised. *Parallel Problem Solving from Nature 2*, pages 27–36, 1992.
- [20] P. A. Moscato. Memetic algorithms: a short introduction. *New Ideas in Optimization*, pages 219–234, 1999.
- [21] R. C. Reynolds and C. Chung. Knowledge-based self-adaption in evolutionary programming using cultural algorithms. *Proc. of 1997 Int. Conf. on Evolutionary Computation*, pages 71–76, 1997.
- [22] H-P. Schewefel. *Numerical Optimization of Computer Models*. Wiley, Chichester, 1981.
- [23] F. J. Solis and R. J. Wets. Minimization by random search techniques. *Mathematical Operations Research*, 6:19–30, 1981.
- [24] 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.
- [25] A. Törn and Z̃ Antanas. Global optimization. *Lecture Note in Computer Science*, 350, 1989.
- [26] S. Tsutsui and Y. Fujimoto. Forking genetic algorithm with blocking and shrinking modes. *Proc. 5th Int. Conf. on Genetic Algorithms*, pages 206–213, 1993.
- [27] 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*, pages 116–121, 1989.
- [28] D. Whitley, R. Bereridge, C. Graves, and K. Mathias. Test driving three 1995 genetic algorithms: New test functions and geometric matching. *J. Heuristic*, 1:77–104, 1995.