

INTRODUCIENDO MEJORAS EN LOS ALGORITMOS EVOLUTIVOS

ESQUIVEL S. C., GALLARD R.H.

¹Laboratorio de Investigación y Desarrollo en Inteligencia Computacional,
Universidad Nacional de San Luis, Argentina
{esquivel, rgallard}@unsl.edu.ar

RESUMEN

Hoy día se conocen como algoritmos evolutivos (AEs), a una familia de algoritmos basados en los principios de reproducción, variación aleatoria, competencia y selección de individuos. Una de las clases más exitosas la constituyen aquellos basados en lo que originalmente se conoció como algoritmos genéticos. Estos tienen en particular el uso de operadores genéticos (crossover y mutación) no siempre presentes en otras clases de algoritmos evolutivos. Esta presentación muestra variantes introducidas en esta clase de AEs para mejorar su habilidad en problemas de optimización.

INTRODUCCIÓN:

En los últimos cinco años se han producido avances en las técnicas de la Computación Evolutiva. Estos avances tienden esencialmente a mejorar la calidad de las soluciones provistas por un algoritmo evolutivo y se han logrado a través de la implementación del paralelismo, la creación de nuevos métodos de recombinación, la hibridización y la inserción de conocimiento específico del problema en la representación de las soluciones y/o en el proceso evolutivo. Esta presentación discute cada uno de estos enfoques y los avances logrados en algoritmos evolutivos basados en algoritmos genéticos.

PARALELISMO

Las implementaciones paralelas de los algoritmos evolutivos tienen como objetivo mejorar su performance. Una forma naturalmente distribuida de implementar algoritmos evolutivos paralelos es a través del modelo *isla*. Aquí se produce la migración de individuos entre poblaciones que evolucionan independientemente, favoreciendo de este modo el proceso evolutivo. Este intercambio se efectúa escogiendo individuos desde una población fuente y exportándolos a poblaciones receptoras. De esta forma se mejora la diversidad genética. A la llegada del individuo, es usual que éste se acepte sin ejercer política alguna sobre su aceptación. Esta falta de discriminación de individuos provenientes de poblaciones externas puede, en muchos casos, producir convergencia prematura (un super-individuo puede arrastrar hacia sí a los demás individuos de la población por selección repetida para el apareamiento).

En trabajos previos [4,8] hemos implementado tres estrategias de control de migración. La primera *Maximum Gap Allowed (MGA)*, intenta prevenir la propagación desbalanceada de genotipos utilizando un umbral de aceptación de los cromosomas inmigrantes. La segunda, *Dynamic Arbiter Strategy (DAS)*, permite la evolución independiente de las poblaciones y actúa cuando se detecta un posible estancamiento en la evolución. En esta situación se evade el óptimo local insertando un individuo de esperada disímil composición genética para proveer diversidad en la población. En este caso el sistema intercambia información asociada con el mejor y peor individuos globales y la media poblacional. La tercera alternativa, *Combined MGA-DAS Strategy (CMGA-DAS)*, combina ambas estrategias. Los ensayos preliminares se hicieron utilizando un algoritmo genético simple optimizando aquellas funciones de testing (uni y multimodales) que resultaron más dificultosas, utilizando nodos reales y

virtuales. Posteriormente los algoritmos evolutivos paralelos con 4 a 10 islas se implementaron para resolver el problema del flow shop [5].

RECOMBINACIÓN

En los AEs basados en AGs, la recombinación es el mecanismo básico para la generación de nuevos individuos. Esto se logra a través del intercambio genético de los padres. Los métodos convencionales SCPC (Single Crossover Per Couple), aplican el crossover sólo una vez sobre un par de padres generando dos hijos que conformarán la nueva población. En 1995 (1er CACIC), en un trabajo realizado conjuntamente con Michalewicz [3], se presenta por vez primera MCPC (Multiple Crossovers Per Couple), un método de aplicación repetitiva del crossover sobre un par de padres. Aquí los $2n_1$ (siendo n_1 el número de crossovers) hijos generados se insertaban en la nueva población. Los primeros resultados mostraban una mejor performance que la de SCPC si n_1 se mantenía entre 2 y 4. En otro caso existía el riesgo de convergencia prematura, originada en la presión selectiva emanada del método de selección (proportional selection) y la superexplotación de las características de buenos padres (alto fitness).

Para solucionar el problema, se implementaron AEs con MCPC, utilizando mecanismos alternativos de selección (ranking selection, dynamic ranking selection, fitness proportional couple selection). Todos estos métodos aunque más costosos mejoraron sensiblemente la performance de MCPC. Implementaciones actuales de MCPC, seleccionan uno, algunos pero no todos los hijos provenientes de una misma pareja para su inserción en la nueva generación. La elección del hijo a insertar se hace según algún criterio preestablecido. Todas ellas resultan en un menor esfuerzo computacional y no muestran convergencia prematura.

Una última familia de métodos recombinativos se conoce como MCMP (Multiple Crossovers on Multiple Parents). Estos métodos agregan a la visión de padres múltiples de Eiben [1,2], la de la repetitividad de crossovers. De esta forma se logra un balance entre exploración aportada por la multiplicidad de padres (una muestra mayor del espacio de búsqueda) y la explotación repetitiva de las buenas características de esos padres, evitándose la convergencia prematura. MCMP, con sus nuevas variantes (uso del semental e inmigrantes aleatorios, Fig. 1) ha provisto muy buenos resultados en problemas de optimización de simple y múltiples objetivos en el área de scheduling [6, 7]. Aquí, el proceso de creación de nuevos hijos es el siguiente. Desde la vieja población se escoge un individuo como semental aplicando selección proporcional. El número n_2 de padres en el buffer de apareamiento se completa con individuos aleatoriamente generados (inmigrantes random). El semental se aparea con cada uno de los padres restantes y las parejas son sometidas a crossover. El mejor de los $2n_2$ hijos generados se inserta temporariamente en una estructura transitoria. La operación de crossover se realiza n_1 veces con un punto distinto de corte cada vez, hasta completar la estructura transitoria. Los hijos no son sometidos a mutación, pues los inmigrantes proveen alta diversidad genética. Finalmente el mejor de los hijos en la estructura transitoria se inserta en la nueva población.

Una característica valiosa de los métodos de multirecombinación es la agrupación de los valores de fitness de los individuos de la población final alrededor del fitness del mejor individuo. O sea, los algoritmos proveen soluciones alternativas distintas de muy cercano valor objetivo, las que pueden ser utilizadas en caso que las condiciones del sistema varíen dinámicamente.

HIBRIDIZACIÓN E INSERCIÓN DE CONOCIMIENTO ESPECÍFICO DEL PROBLEMA

Las técnicas de hibridización combinan, en el proceso de búsqueda, el accionar de distintas heurísticas con el algoritmo evolutivo. En nuestro caso hemos estudiado el comportamiento de AEs hibridizados en distintas etapas del proceso evolutivo. Esto va desde la inserción de semillas (buenos individuos

provistos por otras heurísticas) en la población inicial o durante la evolución o alternativamente mejorar las soluciones provistas por el algoritmo evolutivo al iniciarse el proceso, durante el mismo o a su finalización. Dado que las heurísticas propias de un problema se basan en ciertas características del mismo, estamos insertando un conocimiento que es dependiente del problema y que el AE intrínsecamente ignora (la búsqueda se basa sólo en el fitness de una solución).

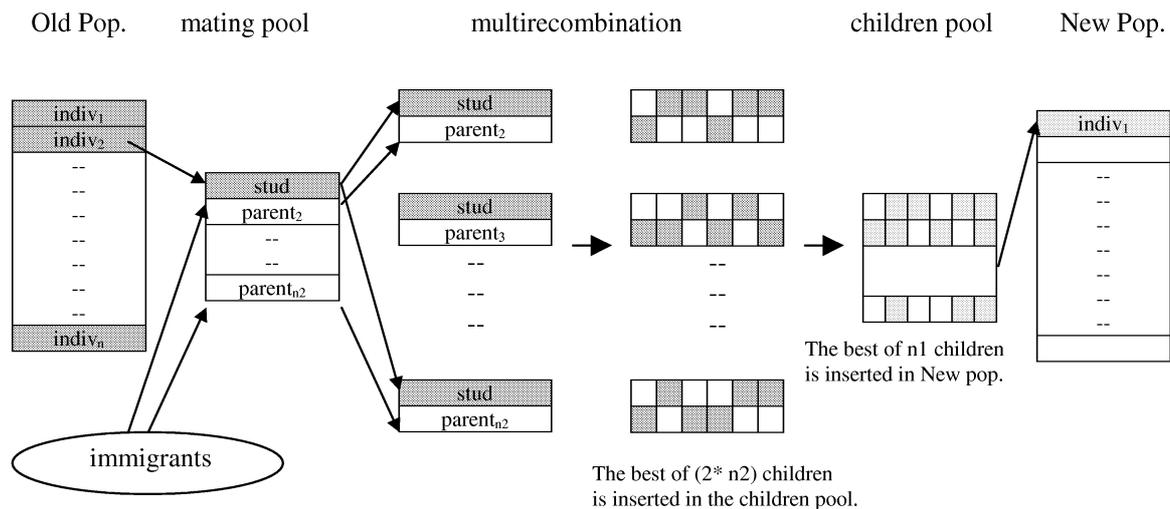


Fig. 1. The stud and random immigrants multirecombination process.

Otra forma de insertar conocimiento específico del problema es conociendo de antemano ciertas condiciones de optimalidad. Lamentablemente en la mayoría de los problemas complejos del mundo real esta información no se encuentra disponible. Pero en los casos como el de earliness/tardiness de scheduling de máquina única, donde una solución óptima tiene una forma V de ordenamiento, puede reducirse el esfuerzo de búsqueda limitándonos a buscar soluciones que cumplan tal propiedad. Como consecuencia de ello, métodos de multirecombinación con inserción de conocimiento específico han producido nuevos upper-bounds para tamaños considerables del problema en cuestión, para instancias propuestas de la OR-Library [9].

En caso de no conocer condiciones de optimalidad, es recomendable insertar repetitivamente durante la evolución, individuos generados por varias heurísticas en el pool de padres para forzar la recombinación de su material genético con el de padres provenientes de la evolución y de otros aleatoriamente generados. Esto ha producido muy buenos resultados en problemas de weighted tardiness de máquina única y en flow shop.

Por último, dada la naturaleza autoadaptativa de los AEs, podemos explotar esta propiedad y conservar las formas (subsecuencias del cromosoma) comunes en los padres diseñando operadores genéticos que las preserven. Aquí el conocimiento específico del problema es detectado por el AE.

CONCLUSIONES Y TRABAJOS FUTUROS

Cuando los AEs se utilizan como algoritmos para la búsqueda de soluciones óptimas en distintos problemas, debe tenerse en cuenta que su oportunidad de supervivencia está basada, sólo en la bondad relativa de la solución. Otros factores como la naturaleza del espacio de soluciones, o su vecindario no son tenidos en cuenta. En consecuencia, dependiendo del seteo de los parámetros del algoritmo

(tamaño de población, probabilidad de operadores, límite para el proceso de búsqueda, etc) el algoritmo podrá converger a un óptimo local o global.

Este comportamiento (convergencia prematura o no) será consecuencia del balance entre la exploración y explotación en el espacio de soluciones. Las técnicas aquí enumeradas tienden a proveer una mejora en ese balance, con la consecuente mejora en la calidad de soluciones.

Los trabajos actuales y futuros, estudian nuevas estrategias para la inserción de conocimiento a través del uso de semillas, preservación de formas, multirecombinación y heterosis. Este último enfoque sugiere el cruzamiento de distintas líneas reproductivas. Implica evolucionar endogámicamente varias poblaciones y luego mezclarlas.

REFERENCIAS

- [1] Eiben A.E., Raué P-E., and Ruttkay Zs., *Genetic algorithms with multi-parent recombination*. In Davidor, H.-P. Schwefel, and R. Männer, editors, *Proceedings of the 3rd Conference on Parallel Problem Solving from Nature*, number 866 in LNCS, pages 78-87. Springer-Verlag, 1994
- [2] Eiben A.E. and. Bäck Th. An empirical investigation of multi-parent recombination operators in evolution strategies. *Evolutionary Computation*, 5(3):347-365, 1997.
- [3] Esquivel S., Gallard R., Michalewicz Z., - "MCPC: Another Approach to Crossover in Genetic Algorithms" *Proceedings del Primer Congreso Argentino de Cs. de la Computación*, pp 141-150, Universidad Nacional del Sur, Octubre 1995.
- [4] Esquivel S., Leguizamon G., Ochoa C., Gallard R. - "An Overview Of A Symbiotic Coalition: Evolutionary Algorithms And Distributed Systems"- *Intelligent Information Systems*, Bahamas, pp 550-556, IEEE press, ISBN 0-8186-8218-3, Diciembre 1997.
- [5] Esquivel, S., Printista M., Zuppa F. y Gallard R. - "Paralell and Sequential Evolutionary Algorithms for the Flow Shop Scheduling Problem", expuesto y publicado en los Anales del VI Congreso Argentino de Ciencias de la Computación, CACIC, Universidad Nacional de la Patagonia San Juan Bosco, 2-7 de Octubre de 2000, pag. 1311.
- [6] Esquivel S., Gatica C., Gallard R. *Conventional and Multirecombinative Evolutionary Algorithms for the Parallel Task Scheduling Problem*. *Lecture Notes in Computer Science*, LNCS 2037, pp 223-232, Springer Verlag 2001
- [7] Esquivel S., Ferrero S., Gallard R., Salto C., Alfonso H. Schütz M., "Enhanced evolutionary algorithms for single and multiobjective optimization in the job shop scheduling problem". *Journal of Knowledge Based Systems*, Vol 15/1-2, pp 13-25, Elsevier, January 2002.
- [8] Ochoa C., Gallard R. -"Controlling Asynchronous Migration in Parallel Genetic Algorithms"- Presentado y publicado en los *Proceedings del International Symposium on Engineering of Intelligent Systems*, University of La Laguna, Tenerife, España, Vol. 1, pp 242-248, ISBN 3-906454-12-6, Febrero 1998.
- [9] Pandolfi D., De San Pedro M., Villagra A., Vilanova G., Gallard R.- " Studs mating immigrants in evolutionary algorithm to solve the earliness-tardiness scheduling problem" . Aceptado para publicación en *Cybernetics and Systems del Taylor and Francis Journal*, a aparecer (U.K.) en abril 2002.