



Enfoques no estándar de algoritmos evolutivos en un dilema de optimización

Oswaldo E. Vélez Langs

Departamento de Ingeniería, Universidad Jorge Tadeo Lozano

oswaldoe.velezl@utadeo.edu.co

Resumen

Este artículo pretende ser un ensayo de tipo crítico-reflexivo, que toma como base el conocido problema que se presenta en el Dilema Exploración-Explotación (DEE) cuando se trabaja con Algoritmos Evolutivos (AEs) y se centra en las propuestas, en este aspecto, tanto de los enfoques tradicionales, como de los enfoques recientes que manejan la población de soluciones (individuos) de manera distinta a los AEs estándar, a saber: el Modelo Evolutivo Aprendible (MEVA) y los Algoritmos de Estimación de Distribuciones (AEDs).

Palabras clave: Algoritmos de Estimación de Distribuciones, Algoritmos Evolutivos, Dilema Exploración-Explotación, Modelo Evolutivo Aprendible.

Abstract

This article is intended to be a critical-reflexive essay based on a well-known problem: the Exploration-Exploitation Dilemma (DEE, in Spanish) when working with Evolutionary Algorithms (AEs, in Spanish) and, in this respect, focuses on the proposals that study both: traditional approaches and recent ones handling the population of solutions (individuals) differently from the AEs standard, which are: the Learnable Evolution Model (MEVA, in Spanish) and the Estimation of Distribution Algorithms (AEDs, in Spanish)

Keywords: Estimation of Distribution Algorithms, Evolutionary Algorithms, Exploration-Exploitation Dilemma, Learnable Evolution Model.

Índice temático

[Introducción](#)

[Desarrollo](#)

[Conclusiones](#)

[Referencias](#)

OPCION: CLICK DIRECTO A CADA CAPITULO

Introducción

En un problema de optimización: ¿cuándo puede saberse que lo que se ha obtenido es lo suficientemente bueno frente a lo que aún se tiene por obtener? Sin duda existen distintos esquemas desde el método científico, de cómo responder a este dilema. Hay un ejemplo muy dicente, proveniente del diseño de experimentos en estadística, que ilustra muy bien el dilema exploración-explotación (DEE) en computación (Berry y Friestedt, 1985):

Hay una máquina tragamonedas que tiene distintos niveles y un apostador que juega con dicha máquina; con miras a obtener una máxima ganancia en el tragamonedas, el apostador debe establecer un equilibrio entre poder explotar el nivel que le da máxima ganancia esperada, y saber explorar, para poder tener mayor información, sobre las ganancias esperadas en otros niveles.

Este dilema es el que el presente ensayo trata de abordar desde el punto de vista de los algoritmos evolutivos (AEs) y sus modelos, no tradicionales, más recientes.

Los algoritmos evolutivos son métodos metaheurísticos de optimización y búsqueda basados en poblaciones de individuos y que se inspiran en la evolución natural (Bäck, Fogel y Michalewicz, 1997; De Jong, 2002; Eiben y Smith, 2003; Mitchell, 1986). Los AEs son bien conocidos por realizar de forma efectiva búsquedas contra espacios ruidosos y, en similitud al ejemplo anteriormente ilustrado, todo algoritmo de búsqueda necesita establecer un equilibrio entre dos factores aparentemente contrapuestos:

- Exploración del espacio de soluciones, para realizar una búsqueda en amplitud, localizando así zonas prometedoras.

- Explotación del espacio de búsqueda, para hacer una exploración en profundidad en dichas zonas, obteniendo así las mejores soluciones.

En los AEs, la explotación se muestra en la denominada “presión selectiva”, la cual se enfoca en regiones prometedoras del espacio de búsqueda, mientras la exploración trata de mantener diversidad, es decir, evitar que haya una rápida convergencia hacia zonas que no contienen óptimos o el óptimo global. La diversidad está asociada a que haya diferencia entre los individuos en la población, ya que si hay falta de diversidad genética, todos los individuos en la población serán muy parecidos, y la falta de diversidad conlleva prematuramente la búsqueda de óptimos locales, más adelante veremos que hay ciertos mecanismos que pueden darse para paliar este hecho. Existe un conjunto de operadores predefinidos en los AEs que se enfocan en la explotación y son los conocidos operadores de selección y de cruce; estos últimos facilitan el intercambio de información entre los individuos, mientras que hay otros operadores de exploración, y estos son los operadores de mutación, los cuales introducen diversidad.

Desde el punto de vista de la concepción y el diseño del algoritmo evolutivo (AE), un inapropiado balance exploración-explotación, conduce a una búsqueda ineficaz y por tanto a soluciones no deseadas o inservibles, y con miras a mantener un equilibrio cabal en el DEE, tiene sentido que los operadores encargados de la selección y el cruce realicen apropiadamente lo que deben hacer, es decir, que cada nuevo individuo tenga características interesantes de sus antecesores (o padres) y que el operador de la mutación permita al algoritmo alcanzar cualquier punto dentro del espacio de búsqueda, todo lo anterior enfocado en mantener una adecuada diversidad, caballo de batalla en la esencia de los AEs. Parte de lo anterior es expuesto dentro de los distintos enfoques, presentados a continuación, con que se ha abordado el DEE, para pasar finalmente a exponer algunas conclusiones y preguntas abiertas, respecto a la forma en que ha orientado, de manera tradicional y no tradicional, el DEE desde los AEs.

Desarrollo

Hay una clara intencionalidad en que un AE sea capaz, en la medida de lo posible, de afinar la relación exploración-explotación, y dado que ambos aspectos están relacionados con el uso de ciertos operadores ya sea de cruce o de mutación, existe una clara tendencia en realizar este

afinamiento con dichos parámetros. Un importante trabajo que contempla distintas aproximaciones a este afinamiento desde la llamada autoadaptación se encuentra en Hinterding, Michalewicz y Eiben (1997).

Aunque de manera intuitiva puede intentarse mantener el parámetro asociado a la mutación, denominado tasa de mutación, para contrarrestar la convergencia prematura, esto no es lo más apropiado, debido a que el algoritmo puede comenzar a divergir demasiado. Una solución más idónea a esto es adaptar la tasa de mutación y que sea considerable al inicio, y esta vaya reduciéndose a medida que el algoritmo comience a mostrar convergencia; un enfoque similar es el que aplica una tasa de mutación alta para soluciones malas y tasas de mutación pequeñas para soluciones buenas.

En relación con el cruzamiento puede también pretenderse, como ya se ha mencionado, mantener una efectiva diversidad cada vez que se aplica dicho operador. Hay al menos cuatro estrategias relacionadas con este objeto: (i) la técnica de emparejamiento (los padres se pueden seleccionar de forma que se mantenga la diversidad de la población); (ii) la técnica para generar los hijos, aquí hay un acervo documental importante desde los AGs con codificación real (Ballester y Carter, 2004; Deb y Agrawal, 1995; Eshelman y Schaffer, 1992); (iii) el número de padres (dos o más padres son usados para cruzarse), y (iv) el número de hijos (dos o más hijos son obtenidos de los padres).

En general, la variación (adaptación) de los operadores de cruce y mutación, puede darse de dos formas: a través de una regla determinística o de forma dinámica. Propuestas concretas en cuanto a una variación determinística de los operadores de cruce y mutación, pueden hallarse en: Fogarty (1989), Hesser y Männer (1991), Janikow y Michalewicz (1991), Bäck y Schütz (1996) y Bäck (1997).

Por otro lado, hay propuestas relacionadas con una variación dinámica y adaptiva de operadores, como la regla 1/5 de Rechenberg (1973). Entre otros tenemos a Davis (1989), Schaffer y Morishima (1987), White y Oppacher (1994) y Vekaria y Clack (1998).

Uno de los primeros enfoques de algoritmo genético (AG) no estándar, y que ilustra claramente lo expuesto, se encuentra en el denominado *cross generational elitist selection heterogeneous recombination cataclysmic mutation algorithm* (CHC). El CHC (Eshelman, 1991) es un AG no tradicional que utiliza una estrategia de selección muy conservadora: elige siempre a los

mejores individuos para formar parte de la nueva población. Aplica además un operador de recombinación muy explorador (HUX), que produce una descendencia lo más diferente posible a ambos padres; el CHC incorpora un mecanismo para reiniciar el algoritmo ante una condición de convergencia prematura. También introduce un sesgo para evitar el cruce de individuos similares. Cuando el CHC no puede insertar descendencia en la población en una generación sucesiva y el umbral de cruce ya ha alcanzado un valor de 0, infunde nueva diversidad dentro de la población, mediante una forma de reinicio conocida como mutación catastrófica.

La mutación catastrófica usa el mejor individuo de la población como un modelo para reiniciar esta. La población nueva incluye una copia de la cadena modelo y el resto de la población es generada mutando algún porcentaje de *bits* (por ejemplo el 35%) en la cadena modelo.

El *Breeder Genetic Algorithm* (BGA), propuesto por Mühlenbein y Schilierkamp-Voosen (1993), es un método basado en la crianza de los animales, dicha crianza ha avanzado desde un arte, basado en la intuición, a una ciencia empírica fundamentada en la estadística. Un criador humano no tiene información sobre el material genético, él debe estimar el valor agregado que se denomina el valor de crianza de un animal. El criador virtual del BGA conoce todos los genes de su población y en adición controla los operadores genéticos (tasa de mutación y cruce). El proceso de búsqueda en el BGA es sobre todo guiado por el cruce, convirtiéndolo así en un AG, la mutación es un operador de segundo plano en donde la razón de mutación es inversamente proporcional al número de parámetros a ser optimizado y el rango de mutación es fijo. El BGA trata de responder algunos interrogantes relacionados con lo que puede suceder dado un esquema de mutación, en relación con las mutaciones exitosas e igualmente lo que puede suceder con cruces exitosos, dado un esquema de selección y cruce. Normalmente la mutación y el cruce se consideran como operadores de rompimiento, el BGA supone la mutación y el cruce como operadores de construcción y los evalúa de acuerdo con la probabilidad que ellos tienen de crear mejores soluciones.

Alba y Dorronsoro (2005), presentan un algoritmo genético celular (AGc), en donde los individuos son localizados en una grilla bidimensional, detallan que cada individuo solo puede cruzarse con sus respectivos vecinos y proporcionan un apropiado mecanismo de diversidad poblacional cambiando la forma de especificar la vecindad en dicha grilla bidimensional, así se analizan diferentes formas de presión selectiva según la forma de la vecindad.

El trabajo de Thierens (2005) introduce un método alternativo de estrategia de asignación adaptativa (de aplicar un operador de selección) llamado método de persecución adaptativa (las denominadas reglas de asignación adaptativas son alternativas a la autoadaptación). El método propuesto es comparado con un enfoque de coincidencia de probabilidad en un entorno no estacionario. Los resultados experimentales muestran el desempeño superior del método propuesto.

Hamzeh, Rahmani y Parsa (2006), usan, dentro de un sistema clasificador aprendiz que utiliza un AG difuso, el método inteligente de exploración (MIE), dicho método procura una adecuada exploración, según cierta información que se mantiene del desempeño de los agentes en el entorno, el MIE también procura distinguir diversas fases en el ciclo de vida del clasificador: inicial, media y final.

Tan, Chiam, Mamun y Goh, (2009), proponen un interesante operador de variación adaptativa, el cual explota la estructura binaria de los individuos y presenta sinergia entre el cruce y la mutación, dicho enfoque se aplica a la optimización multiobjetivo (OMO).

Zhao, Luo, Nie y Li (2008), ofrecen el algoritmo *Bee-GA*, aplicado en el bien conocido problema del vendedor viajero, esta propuesta procura establecer el balance entre una gran diversidad de recorridos y la explotación de los mejores recorridos.

El trabajo de Oliveto, Lehre y Neumann (2009), examina un enfoque donde diferentes individuos tienen asociadas distintas tasas de mutación. Los individuos en la población actual son clasificados según su aptitud y la tasa de mutación se incrementa con el *ranking* de un individuo; la idea subyacente en esto es que buenos individuos producirán hijos buenos y cercanos mientras malos individuos permitirán explorar otras regiones en el espacio de búsqueda.

Al-Naqi, Erdogan y Arslan (2010), emplean una perspectiva muy particular basada en un AG de tipo celular, similar al enfoque de Alba y Dorronsoro (2005), pero con vecindad tridimensional, dicho enfoque, fundado en una medida de la diversidad, procura que el algoritmo, de forma gradual, vaya afinando la presión selectiva, modificando los parámetros, en específico, la probabilidad de la selección.

Debido al probado desempeño de la autoadaptación, de los pasos de mutación, en dominios continuos, y con codificación binaria, el trabajo de Serpell y Smith (2010) examina un método para adaptar la elección del operador de mutación en tiempo de ejecución, pero en codificaciones tipo permutación. Los algoritmos son evaluados en el dominio del TSP.

En Veerapen, Maturana y Saubion (2012) se trata la selección adaptiva de operadores en un contexto de búsqueda local. Como la diversidad es un concepto clave en los AEs, se considera una idea relacionada: la similitud entre la solución candidata y las soluciones en la trayectoria de búsqueda; dicho concepto, junto con la calidad de la solución, es usado para evaluar el desempeño de cada operador. Este trabajo introduce una nueva medida de utilidad para operadores de búsqueda local, la cual se compara con una medida basada en la pareto-dominancia.

De lo expuesto se extrapola, ello se vislumbraba al inicio, cómo hay una marcada tendencia en los autores, desde los orígenes hasta lo contemporáneo, por resolver el DEE de manera directa manipulando, ya sea de forma estática o dinámica a los operadores de cruce y mutación para afinar los mismos y que las representaciones de valores reales (típicamente usada en OMO) han podido llevar un tanto más allá las posibilidades de este enfoque de resolución. Así mismo, la separación espacial (dentro de los AGc) es un tema en boga, que ha venido aportando de modo más reciente al DEE.

Un reciente enfoque no estándar de AE es el modelo evolutivo aprendible (MEVA) (Michalski, 2000). El MEVA presenta una nueva idea al emplear técnicas de aprendizaje automático para guiar la generación de nuevas descendencias. La propuesta del MEVA ejecuta un AE en un “modo de aprendizaje”, en dicho modo se razona sobre el porqué de la superioridad de ciertos individuos en la población en relación con otros, para desempeñar cierta clase de tareas. Las razones se expresan como hipótesis inductivas y se utilizan, una vez establecidas, para crear nuevos individuos. Un aspecto muy importante del MEVA es que puede presentar “saltos evolutivos”, en los que el valor de la aptitud presenta grandes mejoras, lo cual en apariencia, se debe al descubrimiento del sentido correcto de la dirección de la evolución; por este tipo de comportamiento, el MEVA puede denominarse como un tipo de “evolución inteligente”.

El aspecto central de la evolución en el MEVA es su modo de aprendizaje, que crea las nuevas poblaciones empleando hipótesis acerca de los mejores individuos hallados en las pasadas poblaciones. En concreto, el modo aprendizaje consta de dos procesos: la generación de hipótesis, en donde se determina esta, caracterizando las diferencias entre individuos de aptitud alta e individuos de aptitud baja, de acuerdo con pasadas generaciones; y la instanciación de la hipótesis, la cual genera nuevos individuos sobre la base de la hipótesis aprendida. De este modo se producen nuevos individuos, no solamente basándose en las operaciones semialeatorias de un AE clásico,

sino utilizando un proceso de razonamiento donde se generan e instancian hipótesis sobre los individuos de la población.

El otro enfoque no estándar, que se presenta, es el de los algoritmos de estimación de distribuciones (AEDs) (Mühlenbein y Paaß, 1996). Un AED es un método que se funda en sustituir el cruce y la mutación por la estimación y posterior muestreo de una distribución de probabilidad aprendida a partir de los individuos seleccionados. Este conjunto de algoritmos ha sido objeto de atención de la comunidad científica alrededor de la computación evolutiva y los modelos gráficos probabilísticos. La población de individuos se recrea en cada generación, desde la distribución de probabilidad obtenida a partir de los mejores individuos de la generación anterior. Precisamente por el hecho de que la población no se obtiene desde individuos, sino desde las distribuciones de probabilidad alcanzadas, un AED se da el lujo de prescindir del uso de los operadores de cruce y de mutación. La aproximación de un AED consiste en un heurístico probabilístico de búsqueda, basado en un AE, y fundamentado en tres pasos básicos a iterar:

- Seleccionar algunos individuos de la población.
- Estimar el modelo probabilístico subyacente a dichos individuos seleccionados.
- Muestrear la distribución de probabilidad aprendida, con objeto de conseguir una nueva población de individuos.

Una vez expuestos los enfoques anteriores, puede verse de manera muy clara cómo estos dos últimos se separan de forma abierta de la tendencia general en los AEs, de ahí su designación de no estándar, y por tanto su manera de abarcar el DEE difiere de los enfoques utilizados con frecuencia. A manera informativa, hay un trabajo de tesis doctoral reciente (Miquelez, 2010), que de cierta forma hace una mixtura de los dos enfoques, es decir, trata de aplicarse el enfoque de aprendizaje (usado en el MEVA), mediante clasificadores bayesianos, dentro del marco de trabajo de un AED.

El comportamiento del MEVA, en relación con el DEE, es bastante particular, porque realiza una especie de partición progresiva del espacio de búsqueda, ya que al inicio, el programa que establece las reglas de aprendizaje, generaliza estas, con miras a explorar, y asegurarse de que no queden por chequear áreas en donde pueda haber un óptimo, luego este mismo programa, se aplica en especializar, tanto como se pueda, las reglas encontradas.

Sin duda, el modo en que puede resolverse el DEE, desde un AED, se relaciona con el poder de expresión del modelo probabilístico empleado, la manera en que este ha sido aprendido y la forma de realizar el muestreo. El mismo asunto, dentro del enfoque MEVA, es muy similar. Porque hay que ver qué tan efectivo es el modelo de aprendizaje que permite construir las hipótesis, que separan a la población buena de la población mala, y que por consiguiente luego son usadas para generar nuevos individuos instanciando dichas hipótesis. Podemos ver entonces que surgen las siguientes cuestiones:

- ¿Qué tan grande es el poder de expresión del modelo (ya sea probabilístico o de aprendizaje) que se maneja para generar nuevos individuos?
- ¿Tal modelo se está aplicando (ya sea muestreando o instanciado) adecuadamente? Dicho de otra manera: ¿Sí estoy obteniendo mejores soluciones que se encaminan al verdadero óptimo en cada generación?

Es curioso que el trabajo que relaciona los enfoques no estándar con el DEE, es un intento que procura involucrar a los conocidos operadores de cruce y mutación nuevamente, siendo que de forma original estos enfoques no estándar los subestimaban o dejaban a un lado. El estudio de Mahnig y Muhlenbein (2001), es uno de los primeros en diseminar dicha tendencia, allí se involucra el operador de mutación dentro de un AED: *univariate marginal distribution algorithm* (UMDA) y así mismo se implica la mutación en otro AED: *factorized distribution algorithm* (FDA), los resultados mostrados apuntan a que si bien el algoritmo tarda más en convergir (mayores generaciones), el tamaño de población necesario es menor (Santana, 2002); usa un operador de mutación adaptivo en el *mixture of trees factorized distribution algorithm* (MT-FDA) y evidencia que hay una mejora en el DEE (Handa, 2007). También involucra dos operadores de mutación en el marco de trabajo de un AED, a saber, emplea un típico operador de intercambio de valor de *bit* y un operador de mutación que ya se relaciona con el modelo de probabilidad que es generado por el EDA, el artículo concluye que el segundo operador (el que comprende el modelo de probabilidad) mejora el proceso de la búsqueda.

Conclusiones

Pudiera concluirse que, el trabajo relacionado en AEs por paliar el DEE, se ha enfocado de manera tradicional en los siguientes aspectos:

- La manipulación, en forma estática o dinámica, de los operadores de cruce y mutación para afinar los mismos a medida que se va dando la búsqueda, en cierto sentido es un concepto muy intuitivo, tratar de explorar al inicio y explotar al final, el quid del asunto ha estado relacionado en cómo determinar cuándo comienza o acaba una fase de inicio o terminación dentro del proceso de búsqueda.
- La representación con valores reales (en especial la aplicada en OMO) ha proporcionado un gran caudal de trabajo relacionado y así mismo los AEs que implican separación espacial, de manera más reciente, han dado una nueva manera de enfocar el DEE.

Los enfoques no estándar presentados, a saber el MEVA y los EDAs, si bien no involucran en su concepción a los operadores de cruce y mutación, han optado recientemente por involucrar operadores de mutación que han mostrado, en especial, cuando van en sintonía con el modelo probabilístico usado, mejoras en el proceso de la búsqueda.

Hay una clara ausencia de aportes que se preocupen por afrontar el DEE desde la esencia misma de los enfoques no estándar presentados y esto es, revisar a fondo el poder expresivo de los modelos utilizados para ir generando nuevos individuos en cada generación y la forma en que se generan dichos individuos, aquí pueden retomarse las cuestiones antes expuestas confrontadas al DEE:

- ¿Qué tan grande es el poder de expresión del modelo (ya sea probabilístico o de aprendizaje) que se usa para generar nuevos individuos?
- ¿Tal modelo se está aplicando (ya sea muestreando o instanciado) adecuadamente? Dicho de otra manera: ¿Sí estoy obteniendo mejores soluciones que se encaminan al verdadero óptimo en cada generación?

Puede verse con claridad que, todo trabajo futuro, que procure responder a las anteriores cuestiones, va a dar mayores luces al DEE en los AEs.

Referencias

AL-NAQI, A., ERDOGAN, A. T., y ARSLAN, T. 2010. «Balancing exploration and exploitation in adaptive three-dimensional cellular genetic algorithm via probabilistic selection operator 2010 NASA/ESA». En: *Conference on adaptive hardware and systems (AHS-2010)*, Anaheim, California, USA, June 15-18.

ALBA, E., y DORRONSORO, B. 2005. «The exploration/exploitation tradeoff in dynamic cellular evolutionary algorithms». En: *IEEE Transactions on Evolutionary Computation*, 9(2), pp. 126-142, April.

- BÄCK, T. 1997. «Mutation parameters». En: Bäck, T., Fogel, D., y Michalewicz, Z. (Eds.). *Handbook of evolutionary algorithms*. Institute of Physics Publishing Ltd. Oxford: Oxford University Press, Bristol/New York, pp. E1.2.1-E1.2.7.
- BÄCK, T., FOGEL, D. B., y MICHALEWICZ, Z. (Eds.). 1997. *Handbook of evolutionary computation*. Oxford: Oxford University Press.
- BÄCK, T., y SCHÜTZ, M. 1996. «Intelligent mutation rate control in canonical genetic algorithms». En: *Proceedings of the International Symposium on Methodologies for Intelligent Systems*, pp. 158-167.
- BALLESTER, J. P., y CARTER, N. J. 2004. «An effective real-parameter genetic algorithm for multimodal optimization». *ACDM Conference (April-04, Bristol, UK)*. *Adaptive computing in design and manufacture VI*. I.C. Parmee (Ed.). Springer, pp.359-364.
- BERRY, D. A., y FRIESTEDT, B. 1985. «Bandit problems: sequential allocation of experiments». En: *Monographs on statistics and applied probability*. London: Chapman & Hall.
- DAVIS, L. 1989. «Adapting operator probabilities in genetic algorithms». En: *Proceedings of the third international conference on genetic algorithms*, pp. 61-69.
- DE JONG, K. A. 2002. *Evolutionary computation*. MIT Press.
- DEB K., y AGRAWAL, R. B. 1995. «Simulated binary crossover for continuous search space». En: *Complex System*, 9, 115-148.
- EIBEN, A. E., y SMITH, J. E. 2003. *Introduction to evolutionary computing*. Springer.
- ESHELMAN, L. J. 1991. «The CHC adaptive search algorithm: how to have safe search when engaging in nontraditional genetic recombination». En: Rawlins, G. J. E. (Ed.). *Foundations of genetic algorithms-1*, pp. 265-283. Morgan Kauffman.
- ESHELMAN, L. J., y SCHAFFER, J. D. 1992. «Real-coded genetic algorithms and interval-schemata». En: *FOGA*, pp. 187-202.
- FOGARTY, T. 1989. «Varying the probability of mutation in the genetic algorithm». En: *Proceedings of the third international conference on genetic algorithms*, pp. 104-109.
- HAMZEH, A., RAHMANI, A., y PARSA, N. 2006. «Intelligent exploration method to adapt exploration rate in xcs, based on adaptive fuzzy genetic algorithm». En: *IEEE Conference on cybernetics and intelligent systems*, pp. 1-6.
- HESSER, J., y MÄNNER, R. 1991. «Toward an optimal mutation probability for genetic algorithms». En: *Proceedings of the first international conference on parallel problem solving from nature (PPSN I)*, pp. 23-32.

HINTERDING, R., MICHALEWICZ, Z., y EIBEN, A. E. 1997. «Adaptation in evolutionary computation: a survey». En: *Proceedings of the fourth IEEE international conference on evolutionary computation*, pp. 65-69.

HISASHI, H. 2007. «The effectiveness of mutation operation in the case of estimation of distribution algorithms». En: *Biosystems*, 87(2-3), February, pp. 243-251.

JANIKOW, C. Z., y MICHALEWICZ, Z. 1991. «An experimental comparison of binary and floating point representations in genetic algorithms». En: *Proceedings of the 4th international conference on genetic algorithms*, pp. 151-157.

MAHNIG, T., y MUHLENBEIN, H. 2001. «Optimal mutation rate using bayesian priors for estimation of distribution algorithms». En: Kathleen, S. (Ed.). *Proceedings of the international symposium on stochastic algorithms: foundations and applications (SAGA '01)*. Springer-Verlag, London, UK, UK, pp. 33-48.

MICHALSKI, R. S. 2000. «Learnable evolution model: evolutionary processes guided by machine learning». *Machine learning*, 38, pp. 9-40.

MIQUELEZ, T. M. 2010. «Avances en algoritmos de estimación de distribuciones. Alternativas en el aprendizaje y representación de problemas». Tesis doctoral. Universidad del País Vasco.

MITCHELL, M. 1996. *An introduction to genetic algorithms*. Cambridge MA: MIT Press.

MÜHLENBEIN, H., y PAAß, G. 1996. *From recombination of genes to the estimation of distributions I. Binary parameters*. PPSN, pp. 178-187.

MÜHLENBEIN, H., y SCHLIERKAMP-VOOSEN, D. 1993. «Predictive models for the breeder genetic algorithm i. continuous parameter optimization». En: *Evolutionary Computation*, 1(1), March, pp. 25-49.

OLIVETO, P. S., LEHRE, P. K., y NEUMANN, F. 2009. «Theoretical analysis of rank-based mutation - combining exploration and exploitation». En: *Proceedings of IEEE congress on evolutionary computation'2009*, pp. 1455-1462.

SANTANA, R. 2002. «An analysis of the performance of the mixture of trees factorized distribution algorithm when priors and adaptive learning are used». En: *Technical Report ICIMAF 2002-180*. Havana, Cuba: Institute of Cybernetics, Mathematics and Physics, March.

SCHAFFER, J. D., y MORISHIMA, A. 1987. «An adaptive crossover distribution mechanism for genetic algorithms». En: *Proceedings of the second international conference on genetic algorithms*, pp. 36-40.

SERPELL, M., y SMITH, J. E. 2010. «Self-adaptation of mutation operator and probability for permutation representations». En: *Genetic Algorithms. Evolutionary Computation*, 18(3), pp. 491-514.

TAN, K. C., CHIAM, S. C., MAMUN, A. A., y GOH, C. K. 2009. «Balancing exploration and exploitation with adaptive variation for evolutionary multi-objective optimization». En: *European Journal of Operational Research*, Elsevier, 197(2), pp. 701-713, September.

THIERENS, D. 2005. «An adaptive pursuit strategy for allocating operator probabilities». En: Hans-Georg B. (Ed.). *Proceedings of the 2005 conference on genetic and evolutionary computation (GECCO '05)*. ACM, New York, pp. 1539-1546.

VEERAPEN, N., MATURANA, J., y SAUBION, F. 2012. «An exploration-exploitation compromise-based adaptive operator selection for local search». En: Terence S. (Ed.). *Proceedings of the fourteenth international conference on genetic and evolutionary computation conference (GECCO '12)*. ACM, New York, pp. 1277-1284 .

VEKARIA, K., y CLACK, C. 1998. «Selective crossover in genetic algorithms: an empirical study». En: *Proceedings of the fifth international conference on parallel problem solving from nature (PPSN V)*, pp. 438-447.

WHITE, T., y OPPACHER, F. 1994. «Adaptive crossover using automata». En: *Proceedings of the third conference on parallel problem solving from nature (PPSN III)*, pp. 229-238.

ZHAO, G., LUO, W., NIE, H., y LI, C. 2008. «A genetic algorithm balancing exploration and exploitation for the travelling salesman problem». En: *Fourth international conference on natural computation*, pp. 505-509.