

Metaheurísticas poblacionales aplicadas a la resolución de problemas complejos

Laura Lanzarini, Javier López
{javierhernanlopez@speedy.com.ar ; laural@lidi.info.unlp.edu.ar}

Instituto de Investigación en Informática LIDI
Facultad de Informática. UNLP.

CONTEXTO

Las investigaciones descritas en esta presentación han sido desarrolladas en el marco del Subproyecto “Sistemas Inteligentes” perteneciente al Proyecto “Algoritmos Distribuidos y Paralelos. Aplicación a Sistemas Inteligentes y Tratamiento Masivo de Datos” del Instituto de Investigación en Informática LIDI.

RESUMEN

Esta línea de trabajo está basada en la investigación y aplicación de metaheurísticas poblacionales para la resolución de problemas multi-objetivo. En particular, se selecciona la metaheurística conocida como Optimización por Cúmulo de Partículas (de aquí en más PSO por sus siglas en inglés de “*Particle Swarm Optimization*”), dado los buenos resultados alcanzados por la misma.

En una primera instancia, la investigación se centra en la optimización de problemas con un solo objetivo, y se propone una nueva versión del algoritmo PSO. Se utiliza un conjunto estandarizado de funciones de prueba con el objeto de realizar una evaluación comparativa entre la versión propuesta y la versión original de la metaheurística.

En una segunda instancia se expande el alcance de la investigación, abordando problemas con dos o más objetivos, sujeto a restricciones, y se espera proponer una variante inédita del algoritmo PSO. Se empleará un conjunto estandarizado de funciones de prueba multi-objetivo con el propósito de comparar el rendimiento de la versión propuesta con otros populares métodos de resolución representativos del estado del arte.

Por último, se considera la utilización de los algoritmos desarrollados para resolver problemas del mundo real del tipo de planificación de actividades y asignación de recursos.

Palabras clave: *Optimización Multi-objetivo, Optimización por cúmulo de partículas, Scheduling*

1. INTRODUCCIÓN

La optimización de problemas es un proceso muy frecuente en la vida real. Permanentemente, nos vemos ante la exigencia de encontrar soluciones que maximicen o minimicen algún recurso escaso. Cuando se trata de situaciones sencillas, el cerebro humano es capaz de resolverlas directamente pero a medida que se incrementa la complejidad del problema, es preciso contar con herramientas adicionales. En esta dirección, existe una amplia variedad de técnicas que pueden clasificarse en exactas y aproximadas.

Las técnicas exactas, si bien garantizan la obtención de la solución óptima para cualquier tipo de problema, requieren un costo computacional elevado. Esto ha volcado el interés hacia las técnicas aproximadas que permiten obtener una solución “casi” óptima en un tiempo “razonable”; en particular al uso de las metaheurísticas a las que se puede definir como “*métodos que integran de diversas maneras, procedimientos de mejora local y estrategias de alto nivel para crear un proceso capaz de escapar de óptimos locales y realizar una búsqueda robusta en el espacio de búsqueda.*”

En su evolución, estos métodos han incorporado diferentes estrategias para evitar la convergencia a óptimos locales, especialmente en espacios de búsqueda complejos” [4].

Una primera clasificación para las metaheurísticas está dada por el número de soluciones que procesan en un determinado momento durante el proceso de búsqueda, es decir, aquellas “basadas en trayectoria” y las “basadas en población” o poblacionales. En el primer caso, se caracterizan por la mejora continua de la solución actual mediante la inspección de un vecindario, mientras que las metaheurísticas basadas en población trabajan con un conjunto de soluciones que iterativamente son mejoradas a través de un proceso inteligente de exploración del espacio de búsqueda.

Dentro del conjunto de metaheurísticas poblacionales, la más difundida corresponde a las técnicas basadas en la Computación Evolutiva: Algoritmos Genéticos (AGs), Estrategias Evolutivas (EEs), Programación Evolutiva (PE) y Programación Genética (PG). Todos estos, generalmente referidos como Algoritmos Evolutivos (AEs) [8]. Sin embargo, en los últimos años han surgido diferentes enfoques alternativos, que si bien presentan algunas de las características de los AEs, tienen rasgos particulares que los diferencian de estos últimos. Dentro de estos podemos mencionar a Optimización mediante Cúmulo de Partículas (PSO) [1] [2], Evolución Diferencial (DE) [10], Optimización por Colonia de Hormigas (ACO) [3] o Algoritmos de Estimación de Distribución (EDA) [9]. Estas metaheurísticas han mostrado ser sumamente eficientes cuando se aplican a problemas complejos de laboratorio o del mundo real [7]. Si bien en ningún caso aseguran la obtención del mínimo o máximo global, han mostrado que son capaces de alcanzar soluciones de calidad en periodos de tiempo aceptables.

PSO es una metaheurística relativamente nueva que ha sido utilizada exitosamente en una amplia variedad de problemas de optimización. El diseño de PSO se basa en el comportamiento de grupos (generalmente en movimiento) o *swarm* de organismos biológicos que se comunican entre sí (en forma directa o indirecta) dentro de su hábitat (e.g., cardúmenes, bandadas, enjambres, colonias de hormigas, etc.)

El comportamiento destinado a la resolución de problemas y que emerge de la interacción de los agentes, conforman lo que se denomina “Swarm Intelligence” o Inteligencia Colectiva, mientras que los algoritmos diseñados siguiendo estos conceptos, son agrupados bajo el término “Inteligencia Computacional Colectiva”. Aplicaciones de PSO incluyen una amplia variedad de problemas continuos y discretos, sin embargo, en su concepción original, su diseño está orientado a resolver problemas mono-objetivos.

Por otro lado, es claro que muchos problemas del mundo real son multi-objetivo por naturaleza; habitualmente las decisiones a tomar no dependen de un único criterio y es por este motivo que resulta de interés el estudio de metaheurísticas que estén diseñadas para manejar esta característica.

Dado que la versión original de PSO no puede utilizarse en problemas multi-objetivo, se han desarrollado distintas modificaciones al respecto. En este punto es importante destacar que a diferencia de los problemas mono-objetivo (y dentro de éstos los uni-modales), en un problema con dos a más objetivos no existe una única solución mejor que optimice los respectivos objetivos involucrados. Por el contrario, una buena técnica para resolverlos es aquella que sea capaz de encontrar la mayor cantidad de “mejores” soluciones que cumplan satisfactoriamente con los objetivos implicados. En este sentido, para evitar una posible pérdida de diversidad en el proceso de búsqueda por parte de una metaheurística poblacional, es necesario proveer de algún mecanismo adecuado a fin de obtener un conjunto mayor de soluciones de buena calidad.

PSO como muchas otras metaheurísticas poblacionales, necesita de mecanismos eficientes para promover una adecuada exploración del espacio de búsqueda que en el caso de los problemas multi-objetivo, se vería reflejada por la diversidad del conjunto de soluciones óptimas. En [5] [6] [7] puede consultarse sobre distintos mecanismos para controlar la diversidad de la población en el contexto de Algoritmos Evolutivos que podrían ser aplicados o que pueden servir como base para ser usados en el contexto de PSO.

Si nos referimos a optimización mono-objetivo, existen diferentes versiones desarrolladas a partir de la idea original de PSO, la mayoría de ellas relacionadas con variación en los diferentes parámetros del algoritmo o combinación y variación de diferentes topologías, tamaños y cantidad de poblaciones. [13][16]. Incluso existen versiones con agregados de nuevos operadores inspirados en otras metaheurísticas evolutivas [14], y se han propuesto además variantes del algoritmo con cambios en la fórmula de actualización de velocidad, con el objetivo de mantener la diversidad y evitar el estancamiento en el proceso de búsqueda [12] [17] [18].

En esta línea de investigación se define y evalúa una nueva versión que utiliza el esquema general de funcionamiento propuesto por la metaheurística original, con el agregado de un método de búsqueda local que se activa de forma automática dependiendo de las características de movimiento de las partículas.

Se plantea como objetivo hacer más eficiente el proceso de búsqueda en la fase de aproximación final de las partículas a óptimos locales (globales). De acuerdo a trabajos anteriores realizados por otros autores [11], se encontró que este proceso de acercamiento final es ineficiente en la versión original del algoritmo PSO, utilizando esta versión muchas iteraciones para lograr aproximar el óptimo local (global).

Con esta consideración en mente, surgen dos cuestiones principales a resolver

1. Descubrir cuando el algoritmo está oscilando alrededor de algún óptimo local (global)
2. Desarrollar un procedimiento que haga más eficiente la aproximación final de la partícula al óptimo.

Para resolver el punto 1), se incorporó un procedimiento para detectar las oscilaciones, que analiza como varía el signo del componente velocidad de cada partícula en cada iteración. Para resolver el punto 2), se incorporó un procedimiento de búsqueda local determinista. El mismo intenta encontrar en la menor cantidad de iteraciones posibles donde se halla el óptimo.

De acuerdo a las pruebas realizadas, se puede afirmar que se alcanzó el objetivo previsto, dado que la variante propuesta igualó o mejoró el rendimiento mostrado por la versión canónica del algoritmo en las 10 funciones de prueba utilizadas [21].

El paso siguiente de esta línea de investigación será el análisis y la posterior propuesta de una nueva versión de un algoritmo del tipo MOPSO (Multi Objective Particle Swarm Optimization) [19], teniendo en consideración como premisas centrales de trabajo la manutención de la diversidad en la población, así como la eficiencia en la aproximación al conjunto de soluciones óptimas. Estas dos características permitirán que el algoritmo sea capaz de encontrar soluciones no dominadas preferentemente con distribución uniforme a lo largo del frente de Pareto [20]. Se efectuarán comparaciones de rendimiento de este algoritmo con aquellos métodos de optimización y búsqueda representativos del estado del arte [19] en optimización multi-objetivo, utilizando un conjunto de pruebas estándar desarrollado para tal propósito,

Como aportación final de esta línea de investigación, se avanzará en la implantación de los algoritmos estudiados en problemas del mundo real, aplicado a los procesos de producción de la industria de televisión. Existen antecedentes aplicados a la problemática de “*scheduling*” [15], pero no en la industria referida en particular, de acuerdo a lo mejor de nuestros conocimientos. Esta problemática de planificación y asignación de recursos se caracteriza por ser dinámica, de corto plazo, requiere múltiples recursos calificados escasos, estacional y administra recursos de terceros como propios.

2. LINEAS DE INVESTIGACION Y DESARROLLO

- PSO aplicado problemas mono-objetivo.
 - Estudio del estado del arte.

- Propuesta de nueva variante.
- Evaluación de rendimiento en funciones de laboratorio.
- PSO aplicado a problemas multi-objetivo con restricciones (MOPSO).
 - Estudio del estado del arte.
 - Propuesta de nueva variante.
 - Evaluación de rendimiento en funciones de laboratorio.
- Aplicaciones de la metaheurística PSO a problemas del mundo real, dentro del área de planificación y asignación de recursos.

3. RESULTADOS OBTENIDOS/ESPERADOS

La versión propuesta del algoritmo PSO dirigido a la resolución de problemas mono-objetivos mostró resultados prometedores. El desempeño de esta versión se reveló superior a la versión PSO original. En 5 de los 10 problemas de prueba, se alcanzó un resultado superior. En los 5 problemas restantes, no se pudo determinar cual fue el algoritmo con mejor desempeño. Los resultados obtenidos demuestran que se alcanzaron los objetivos planteados, y que esta nueva versión del algoritmo PSO exhibe un comportamiento mejor que la versión original del mismo, por lo menos en el conjunto de pruebas utilizado.

Respecto de la versión propuesta para la optimización multi-objetivo, la misma se encuentra en la fase de análisis y definición. Se prevé realizar una evaluación de rendimiento utilizando las funciones de prueba desarrolladas para este tópico. Se espera, al menos, alcanzar el rendimiento observado en los métodos representativos del estado del arte en esta rama de investigación.

Por último, con la aplicación de los métodos anteriores a la problemática del mundo real, se espera hacer mas eficiente los procesos de producción de la industria de televisión, utilizando una menor cantidad de recursos (mano de obra, equipos y locaciones) manteniendo los niveles de calidad requeridos.

4. FORMACIÓN DE RECURSOS HUMANOS

Dentro de los temas involucrados en esta línea de investigación se está desarrollando actualmente una tesis de Doctorado en Ciencias de la Computación dentro del ámbito de la Universidad Nacional de La Plata, Facultad de Informática.

5. BIBLIOGRAFIA

- [1] Engelbrecht A. **Fundamentals of Computational Swarm Intelligence** , John Wiley & Sons, Ltd, 2005.
- [2] Kennedy J., Eberhart R. **Particle Swarm Optimization**, in Proceedings of the IEEE International Joint Conference on Neural Networks, pp 1942-1948, IEEE Press, 1995.
- [3] Dorigo M., Stützle T. **Ant Colony Optimization** , MIT Press, 2004.
- [4] Glover F., Kochenberger G. **Handbook of Metaheuristics** , Kluwer Academic Publishers, 2003.
- [5] Deb G. **Multi-objective Optimization using Evolutionary Algorithms**, John Wiley & Sons, Ltd. 2001.
- [6] Coello Coello C. **EMOO Web Page**, <http://delta.cs.cinvestav.mx/~ccoello/EMOO/>
- [7] Jain A., Goldberg R. **Evolutionary Multiobjective Optimization. Theoretical Advances and Applications**, Springer, USA.
- [8] Bäck T. , Fogel T., Michalewicz Z. **Evolutionary Computation I** , Institute of Physics Publishing, Bristol and Philadelphia, 2000.
- [9] Larraña P., Lozano J. **Estimation of Distribution Algorithms - A New Tool for Evolutionary Computation**, Kluwer Academic Publishers, 2002.

- [10] Price K., Storn R, Lampinen J. **Differential Evolution**, Springer-Verlag, Berlin Heidelberg, 2005.
- [11] Monson C. **No Free Lunch, Bayesian Inference, and Utility: A Decision-Theoretic Approach to Optimization**, *Ph.D. dissertation*. Department of Computer Science. Brigham Young University. August 2006
- [12] Van den Bergh F. **An Analysis of Particle Swarm Optimizers**, *Ph.D. dissertation*. Department Computer Science. University Pretoria. South Africa. 2002
- [13] Esquivel S., Cagnina L. **Global Numerical Optimization with a bi-population Particle Swarm Optimizer**, LIDIC (Research Group) - Universidad Nacional de San Luis
- [14] Zhang W., Xiao-Feng Xie **DEPSO: Hybrid Particle Swarm with Differential Evolution Operator**, Institute of Microelectronics, Tsinghua University - IEEE International Conference on Systems, Man & Cybernetics (SMCC), Washington D C, USA, 2003: 3816-3821
- [15] Grobler J, Engelbrecht A, Joubert J., Kok S. **A starting-time-based approach to production scheduling with Particle Swarm Optimization**, Proceedings of the 2007 IEEE Symposium on Computational Intelligence in Scheduling (CI-Sched 2007)
- [16] Lanzarini L., Leza V., De Giusti A. **Particle Swarm Optimization with Variable Population Size**, *Proceedings of the 9th international conference on Artificial Intelligence and Soft Computing Zakopane, Poland*. Section: Evolutionary Algorithms and Their Applications pp: 438 - 449 Year of Publication: 2006
- [17] Riget J., Vesterstrøm J. **A Diversity-Guided Particle Swarm Optimizer – the ARPSO**. *Technical Report 2002-02*, Department of Computer Science, University of Aarhus, 2002.
- [18] Peer E.S., Van Den Bergh F., Engelbrecht A. Using **Neighbourhoods with the Guaranteed Convergence PSO**, *Swarm Intelligence Symposium, 2003*. SIS '03. Proceedings of the 2003 IEEE pp: 235-242 ISBN: 0-7803-7914-4
- [19] Reyes-Sierra M, Coello Coello C. **Multi-Objective Particle Swarm Optimizers: A Survey of the State-of-the-Art**, International Journal of Computational Intelligence Research. ISSN 0973-1873 Vol.2, No.3 (2006), pp. 287–308 Research India Publications <http://www.ijcir.info>
- [20] Dupont G., Adam S., Lecourtier Y., Grilheres B. **Multi objective particle swarm optimization using enhanced dominance and guide selection**, International Journal of Computational Intelligence Research. ISSN 0973-1873 Vol.4, No.2 (2008), pp.145–158 © Research India Publications <http://www.ijcir.info>
- [21] Suganthan P., Hansen N., Liang J., Deb K., Chen Y., Auger A. , Tiwari S. **Problem Definitions and Evaluation Criteria for de CEC 2005 Special Session on Real-Parameter Optimization**. *Special Session on Real-Parameter Optimization at CEC-05*, Edinburgh, UK, 2-5 Sept. 2005