

# Manejo de Restricciones usando penalidades y Procesos de Búsqueda Mejorados en Algoritmos Evolutivos aplicados a Problemas Dinámicos de Scheduling

Villagra A., Lasso M., Pandolfi D., de San Pedro E., Villagra S.,  
Rasjido J., Seron N., Orozco S., Montenegro C., Cossio M.  
LabTEM - Unidad Académica Caleta Olivia  
Universidad Nacional de la Patagonia Austral  
{avillagra, mlasso, dpandolfi, edesanpedro, svillagra, jrasjido,  
nseron,orozco,cmontenegro,mccossio}@uaco.unpa.edu.ar

**Leguizamón G.**

Laboratório de Investigación y Desarrollo en Inteligencia Computacional (LIDIC)  
Departamento de Informática - Universidad Nacional de San Luis  
legui@unsl.edu.ar

## CONTEXTO

Esta línea de Investigación forma parte del proyecto “*Manejo de Restricciones con algoritmos evolutivos aplicados a la Planificación de Locaciones Petroleras*” del Laboratorio de Tecnologías Emergentes (LabTEM) en el marco del programa de Investigación en Ciencia y Tecnología de la Universidad Nacional de la Patagonia Austral.

## RESUMEN

En este trabajo se presenta un proyecto de investigación y desarrollo de un prototipo experimental para la mejora en la planificación del mantenimiento de locaciones petroleras. Durante este año se pretende focalizar en las siguientes dos líneas. La primera relacionada con la investigación experimental de tres aspectos fundamentales de la herramienta: Manejo de restricciones usando penalidades, Scheduling Dinámico y Mejora de los Procesos de Búsqueda. La segunda línea constituye el desarrollo de un prototipo operacional denominado PAE. PAE, es una herramienta para la planificación del mantenimiento de locaciones petroleras sujeto a restricciones. El motor de búsqueda de esta herramienta está basada en un algoritmo evolutivo multirecombinativo conocido como SRI-MCMP (Stud and Random Immigrants - Multiple Crossover on Multiple Parents) y fue desarrollado por investigadores del LabTEM.

**Palabras clave:** Planificación, Mantenimiento, Algoritmo Evolutivo, Manejo de Restricciones, Penalidades.

## 1. INTRODUCCION

Las actividades petroleras de explotación y transporte del petróleo son muy importantes para el desarrollo económico de la sociedad industrial moderna. Sin embargo, estas actividades son generadoras de riesgos que se traducen en

contaminaciones accidentales que afectan directamente al ecosistema. El impacto ambiental ocasionado por la industria petrolera comprende los efectos de todas y cada una de las fases involucradas en las etapas tanto de exploración, explotación, transformación, distribución y comercialización. En muchas de las regiones donde se ha explotado el petróleo, se han generado contingencias de diferentes magnitudes como consecuencia de las operaciones desarrolladas en: tanques de almacenamiento, oleoductos, equipos de perforación, buques petroleros, etc. Además de los impactos generados en el medio como consecuencia de la exploración y explotación del petróleo, existen también daños ocasionados a las personas que lo emplean o se encuentran en contacto con él dentro de su ámbito laboral.

En la última década, las Empresas dedicadas a la explotación, producción y transporte del recurso, han visto la necesidad de implementar medidas de prevención a fin de evitar y / o minimizar los daños ocasionados al medio ambiente, personas y bienes materiales.

La mejor manera de atacar el problema de contaminación por petróleo es prevenir el incidente. Normalmente éstos se producen por fallas de equipos o del material y fallas humanas. Los primeros pueden ser subsanados mediante inspecciones periódicas y un mantenimiento adecuado; y los segundos, mediante la instrucción y el entrenamiento del personal en forma permanente. La minimización del tiempo entre cada período de inspección de las locaciones se obtiene con una mejora en la planificación del mantenimiento y esto puede ser abordado como un problema de scheduling. Se ha demostrado, que muchos problemas de scheduling pertenecen a la clase NP-hard [1] reflejando así la relevancia industrial de este tipo de problemas.

Los Algoritmos Evolutivos (AEs) han sido aplicados exitosamente en la resolución de diversos tipos de problemas de planificación tales como

scheduling o routing [2], [3]. Los AEs son metaheurísticas que comparten un concepto base común que es simular la evolución de los individuos que forman la población usando un conjunto de operadores predefinidos de selección y de búsqueda. Existe una gran variedad de AEs, dentro de ellos se incluyen los Algoritmos Genéticos [4] que son los utilizados en este problema. Tendencias actuales en AEs hacen uso de enfoques con multirecombinación [5] y enfoques con múltiples padres conocidos como MCMP (Multiple Crossover Multiple Parent) [6].

La mayoría de los problemas de optimización incluyen restricciones de cierta clase, que constituyen grandes desafíos a la resolución de problemas de optimización. Las restricciones son límites impuestos a las variables de decisión y en general las restricciones son una parte integral de la formulación de cualquier problema [7].

En el dominio específico de problemas discretos, tales como Knapsack Problem, Set Covering Problem, Vehicle Routing Problem, y todos los tipos de Scheduling Problems, todos están sujetos a restricciones. El espacio de búsqueda de estos problemas se subdivide en dos subconjuntos, el espacio de soluciones factibles y el espacio de soluciones no factibles. Estos subespacios no necesariamente son convexos y no necesariamente están conectados. Para la resolución del problema de optimización sujeto a restricciones los algoritmos de búsqueda, tal como lo son AEs, promueven soluciones que navegan en ambos subespacios. El problema consistirá entonces en cómo tratar soluciones no-factibles para explorar el subespacio de soluciones factibles [8]

Es importante destacar que el grupo viene desarrollando tareas de investigación en el problema de planificación del mantenimiento de locaciones petroleras en aspectos de planificación estática, dinámica y manejo de restricciones [9].

En la siguiente sección se presentará las líneas de investigación y desarrollo vinculadas con este proyecto.

## **2. LINEAS DE INVESTIGACION y DESARROLLO**

- Mejora en el proceso de búsqueda

Las metaheurísticas (MHS) [10] son 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. Aunque las metaheurísticas en general presentan un bajo nivel de desarrollo desde el punto de vista matemático, tales procesos son válidos en muchas situaciones prácticas para las cuales se han obtenido resultados

muy interesantes para problemas del mundo real, en particular en el ámbito de la industria.

Resta mencionar como punto adicional que la garantía de un adecuado desempeño de las MHS en general depende en gran medida del desempeño de los operadores o mecanismos de exploración propios de cada una de ella. En este sentido, la utilización de enfoques avanzados para mejorar el proceso de exploración es un tópico de interés dado su inmediata aplicación y beneficio directo respecto a posibles mejoras en el diseño de MHs. Por ejemplo, el concepto de sociobiología [11] es mecanismo evolutivo exitoso que podría ser usado como mecanismo alternativo en los modelos algorítmicos o metaheurísticas que imitan el proceso evolutivo. En este sentido, la perspectiva Darwinista tradicional explica la regulación de la descendencia a través de las restricciones del medio ambiente: alimentos, clima y depredación, las que en su conjunto regulan los tamaños y adaptabilidad de las poblaciones. Por el contrario, según [12], los animales pueden autorregular su propia población estimando restricciones del ambiente y por lo tanto variar sus tasas de reproducción. Por otro lado, la teoría de [13] sobre la evolución de genética del comportamiento social, propone que el valor adaptativo de un individuo se podría medir no solamente por su éxito personal en materia de reproducción, sino a través del beneficio de la reproducción de otros individuos (parientes). La suma de estos dos conceptos fue denominado como “inclusive fitness” o adecuación adaptativa global. Basado en estos conceptos previos y en el constante desarrollo e investigación de conceptos útiles para mejorar el desempeño de los enfoques metaheurísticos, se plantea como una alternativa, el desarrollo de algoritmos y/o mejoras en los enfoques metaheurísticos a través de la incorporación de elementos vinculados al comportamiento social de determinadas especies del mundo animal.

- Manejo de Restricciones con penalidades

Los Algoritmos Evolutivos han sido aplicados exitosamente en un amplio rango de aplicaciones [14,15,16], sin embargo, un aspecto que normalmente no se considera cuando se los usa para optimización, es que estos algoritmos son procedimientos de optimización sin restricciones y por esta razón es necesario encontrar mecanismos de incorporación de restricciones (que normalmente existen en cualquier aplicación del mundo real) en la función de aptitud.

El manejo de restricciones en algoritmos evolutivos puede abordarse de distintas técnicas y un amplio estudio del estado del arte es propuesto por Coello Coello [17]

La forma más común de incorporar restricciones en un algoritmo evolutivo ha sido a través de funciones de penalidad [18]. Teniendo en cuenta las

conocidas dificultades asociadas con su utilización se han propuesto diversas formas de automatizar la definición de factores buenos de penalidad, lo cual continúa siendo una debilidad importante cuando se usan funciones de penalidad.

Las funciones de penalidad fueron originalmente propuestas por Courant [19] y luego fueron expandidas por Carrol [20] y Fiacco & McCormick [21]. La idea de este método es transformar un problema de optimización con restricciones en un uno sin restricciones agregando (o sustrayendo) un cierto valor a la función objetivo basado en la cantidad de violación la restricción presentada en una solución.

Se pueden considerar dos tipos de funciones de penalidad: exterior e interior. En el caso de penalidad exterior, se comienza con una solución no-factible y desde ahí se mueve hacia una solución factible. En el caso de penalidad interior se inicia la búsqueda en la zona factible y se trata de evitar salir de la zona (hacia la región no-factible). A diferencia de la exterior, los puntos factibles para iniciar la búsqueda puede ser el “cuello de botella de este enfoque”.

El método más común utilizado en Algoritmos Evolutivos es el enfoque de penalidad exterior. Y es el que se utilizará en este trabajo.

Idealmente, la penalidad debe mantenerse lo más baja posible, justo sobre el borde inferior donde las soluciones no-factibles son óptimas (a esto se lo denomina, *regla de penalidad mínima* [22]. Esto se debe a que si la penalidad es muy alta o muy baja entonces podría convertirse en un problema muy difícil para un AE [22]. Si la penalidad es muy alta y el óptimo se encuentra en el borde de una región factible, el AE puede ser empujado fuera de la región factible muy rápidamente y no podrá regresar. Una penalidad grande no favorece la exploración de una región no-factible. Por otro lado, si la penalidad es muy baja, se empleará mucho tiempo de exploración en regiones no-factibles pues la penalidad es insignificante con respecto a la función objetivo [23]. Estos temas son de mucha importancia en AEs pues muchos de los problemas en los cuales se usan tienen los óptimos en los bordes de la región factible.

Algunas de las funciones de penalidad que se aplicaran al problema de planificación del mantenimiento de locaciones petroleras usando un algoritmo multirecombinativo serán: (a) Estática, (b) Dinámica, (c) Annealing, (d) Adaptativa y (e) Mortal.

Bajo la categoría de penalidad estática, se consideran enfoques en los cuales los factores de penalidad no dependen del número de generación actual y por esta razón se mantienen constantes durante en todo el proceso evolutivo, como se presentan en [24].

Dentro de la categoría de penalidad dinámica se considera cualquier función de penalidad en la cual

está involucrado el número de generación actual en el cálculo de la función de penalidad correspondiente (normalmente la función de penalidad se define de forma tal que se incrementa en el tiempo, es decir, las generaciones). Algunos ejemplos de los enfoques propuestos para penalidad dinámica son [25].

Notar que los dos enfoques que se describen a continuación (annealing y adaptiva) también son enfoques de penalidades dinámicas pero se consideren separadamente.

Los penalidades annealing están basadas en la idea de Simulated Annealing [26]: los coeficientes de penalidad de una vez en muchas generaciones (luego que el algoritmo ha quedado atrapado en un óptimo local). Únicamente se considerara las restricciones activas en cada generación y la penalidad se incrementa en el tiempo (es decir, la temperatura decrece en el tiempo) de tal forma que los individuos no-factibles son fuertemente penalizados en las últimas generaciones [27].

Algunos enfoques desarrollados para la penalidad adaptativa usan una función de penalidad que se retroalimenta del proceso de búsqueda [28]. Otras propuestas proponen la penalidad se modifica dinámicamente de acuerdo a la función de fitness de la mejor solución encontrada [29].

Se denomina penalidad mortal al rechazo de individuos no-factibles, es probablemente la manera más sencilla manejar las restricciones y es computacionalmente eficiente, porque cuando una solución viola una restricción se le asigna un fitness de valor cero [30].

### 3. RESULTADOS OBTENIDOS/ESPERADOS

A continuación se mencionan los resultados esperados del proyecto:

- Investigación en tendencias actuales en scheduling dinámico.
- Estudio y desarrollo de métodos para el manejo de restricciones con penalidades.
- Investigación en tendencias actuales respecto a la eficiencia de las distintas Metaheurísticas en la exploración del espacio de búsqueda.
- Determinación de nuevos conceptos a ser incluidos en la fase explorativa.
- Diseño e implementación de las distintas Metaheurísticas consideradas aplicando los conceptos alternativos o mejorados.
- Desarrollo e implementación del Prototipo operable para la Planificación Dinámica Sujeta a restricciones.

### 4. FORMACION DE RECURSOS HUMANOS

Un integrante de esta línea de investigación está desarrollando su Tesis de Doctorado en Mejoras en el proceso de Búsqueda.

Un integrante está desarrollando su Tesis de Maestría en Scheduling Dinámico.

Hay tres Becarios alumnos y dos pasantes en el LabTEM trabajando en el proyecto y se dirigen Trabajos Finales de Ingeniería en Sistemas en temas relacionados con este proyecto.

## 5. BIBLIOGRAFIA

1. Brucker P., Scheduling Algorithms, 3rd ed. Springer-Verlag New York, (2004).
2. Chang P., Hsieh J., and Wang Y. Knowledge Incorporation in Evolutionary Computation, chapter F. Divina and E. Marchiori. Springer-Verlag, 2005.
3. Jaskowski P. y Sobotka A. Multicriteria construction project scheduling method using evolutionary algorithm. Operational Research an International Journal, 6(3). (2006).
4. Goldberg, D.E.; Genetic Algorithms in Search, Optimization and Machine Learning; Addison-Wesley, Reading, MA, 1989.
5. Eiben A.E. y Bäck Th. "An Empirical Investigation of Multi-Parent Recombination Operators in Evolution Strategies", Evolutionary Computation, 5(3):347-365, (1997).
6. Esquivel S., Leiva A., Gallard R. "Multiple Crossover per Couple in Genetic Algorithms". Proc. Fourth IEEE Conference on Evolutionary Computation (ICEC'97), pp 103-106, Indianapolis, USA April (1997).
7. Dhar, V., and Ranganathan, N. Integer Programming versus Expert Systems: An Experimental Comparison. Communications of the ACM 33:323-336. (1990).
8. Michalewicz Z.; Genetic Algorithms + Data Structures = Evolutions Programs; Springer-Verlag, third, revised edition, 1997.
9. Villagra A., de San Pedro E., Lasso M., Pandolfi D.; "Algoritmo multirecombinativo para la planificación dinámica del mantenimiento de locaciones petroleras"; Revista Internacional "INFORMACIÓN TECNOLÓGICA"; La Serena, Chile; Agosto 2008. Vol. 19 Numero 4 pp. 63-70.
10. Glover F., Kochenberger G.H. (editors)- Handbook of Metaheuristics, Kluwer Academic Publishers, 2003.
11. Wilson E. O., Sociobiology: a new synthesis; Harvard University Press, 1975.
12. Wynne-Edwards, V. C.; Animal dispersion in relation to social behavior; Oliver y Boyd, Edimburgo, UK, 1962.
13. Hammilton W. D., The genetical evolution of social behaviour. Journal of Theoretical Biology, num 7, 1964, pp. 1-52.
14. Richardson J.T, Palmer M., Liepins G., and Hilliard M. Some Guidelines for Genetic Algorithms with Penalty Functions, In J. David Schaffer, editor, Proceedings of the Third International Conference on genetic Algorithms, pages 191-197; George Mason University, 1989. Morgan Kaufmann Publishers.
15. Goldberg D., Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley Publishing Co., Reading, Massachusetts, 1989.
16. Mitchell M., An Introduction to Genetic Algorithms. MIT Press, Cambridge, Massachusetts, 1996.
17. Coello Coello C., "Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art", Computer Methods in Applied Mechanics and Engineering, Vol. 191, No. 11-12. (4 January 2002), pp. 1245-128.
18. Schwefel P., Evolution and Optimum Seeking. John Wiley & Sons, New York, 1995.
19. Courant R., Variational Methods for the Solution of Problems of Equilibrium and Vibrations. Bulletin of the American Mathematical Society, 49:1-23, 1943.
20. Carroll C. W.,. The created response surface technique for optimizing nonlinear restrained systems. Operations Research, 9:169-184, 1961.
21. Fiacco A. V. and McCormick G. P. Extensions of SUMT for nonlinear programming: equality constraints and extrapolation. Management Science, 12(11):816-828, 1968.
22. Davis L., Genetic Algorithms and Simulated Annealing. Pitman, London, 1987.
23. Smith A. and Coit D., Constraint Handling Techniques Penalty Functions. In Thomas Bäck, David B. Fogel, and Zbigniew Michalewicz, editors, Handbook of Evolutionary Computation, chapter C 5.2.

- Oxford University Press and Institute of Physics Publishing, 1997.
24. Homaifar A, Lai S. H. Y., and Qi X., Constrained Optimization via Genetic Algorithms. *Simulation*, 62(4):242-254, 1994.
  25. Joines J. and Houck C., On the use of non-stationary penalty functions to solve nonlinear constrained optimization problems with GAs. In David Fogel, editor, *Proceedings of the first IEEE Conference on Evolutionary Computation*, pages 579-584, Orlando, Florida, 1994. IEEE Press.
  26. Kirkpatrick S., Gelatt Jr. C. D., and Vecchi M. P., Optimization by Simulated Annealing. *Science*, 220:671-680, 1983.
  27. Michalewicz Z. and Attia N. F. Evolutionary Optimization of Constrained Problems. In *Proceedings of the 3rd Annual Conference on Evolutionary Programming*, pages 98-108. World Scientific, 1994.
  28. Bean J. and Hadj-Alouane A., A Dual Genetic Algorithm for Bounded Integer Programs. Technical Report TR 92-53, Department of Industrial and Operations Engineering, The University of Michigan, 1992. To appear in *R.A.I.R.O.-R.O.* (invited submission to special issue on GAs and OR).
  29. Coit D. and Smith A., Penalty guided genetic search for reliability design optimization. *Computers and Industrial Engineering*, 30(4):895-904, September 1996. Special Issue on Genetic Algorithms.
  30. Schwefel H. *Numerical Optimization of Computer Models*. John Wiley & Sons, Great Britain, 1981.