

# OPTIMIZACION EN SIMULACION VIA INTELIGENCIA ARTIFICIAL: APLICACION A UN PROBLEMA DE MANEJO DE MATERIALES

SIMULATION OPTIMIZATION VIA ARTIFICIAL INTELLIGENCE:  
APPLICATION TO A MATERIAL HANDLING PROBLEM

GUILLERMO BUOT RICO<sup>1</sup>, FREDDY HENRÍQUEZ MARTÍNEZ<sup>1</sup>,  
FELIPE BAESLER ABUFARDE<sup>1</sup>, MILTON RAMÍREZ MONÁRDEZ<sup>1</sup>

## RESUMEN

El propósito del presente artículo es mostrar cómo un modelo de simulación y una heurística de inteligencia artificial pueden ser usados con el fin de optimizar un sistema simulado. La optimización de modelos de simulación puede ser definida como el proceso de ligar un método de optimización con un modelo de simulación para determinar los valores apropiados de ciertos parámetros de entrada de manera tal que se maximice el desempeño del sistema simulado. Un caso real correspondiente a la empresa Codelco fue estudiado y analizado utilizando esta técnica. Específicamente, un modelo de simulación representando el sistema en estudio fue integrado con una rutina de algoritmos genéticos con el fin de encontrar una solución "óptima" o cercana al óptimo. Los resultados muestran que al usar algoritmos genéticos como estrategia de optimización, es posible encontrar una "buena" solución al problema explorando solamente un 4.44% del total de espacio total de posibles combinaciones o escenarios. Finalmente se presentan algunos comentarios respecto a posibles alternativas de investigación futura.

PALABRAS CLAVES: Simulación, Optimización, Algoritmos genéticos, Modelo.

## 1. INTRODUCCION

Cuando el modelo matemático de un sistema es estudiado usando simulación, se denomina modelo de simulación. El comportamiento del sistema, de acuerdo a valores específicos de variables de entrada, se evalúa corriendo el modelo de simulación por un período de tiempo determinado. Un experimento de simulación se puede definir como una prue-

ba o una serie de pruebas, en las cuales se realizan cambios significativos a las variables de entrada de un modelo de simulación, de tal modo que se pueda observar e identificar las razones de los cambios en las variables de salida. Cuando el número de variables de entrada es grande y el modelo de simulación es complejo, el experimento de simulación puede llegar a ser computacionalmente prohibitivo. Aparte del alto costo computacional, se puede incurrir en un costo incluso mayor cuando se seleccionan valores sub-óptimos de valores de variables de entrada. La optimización de modelos de simulación

<sup>1</sup>Departamento de Ingeniería Industrial, Universidad del Bío-Bío, Av. Collao 1202, Concepción, Chile. Tel. 41-261381, Fax 41-321476, E-mail: fbaesler@ubiobio.cl

puede ser definida como el proceso de ligar un método de optimización con un modelo de simulación para determinar los valores apropiados de ciertos parámetros de entrada de manera tal que se maximice el desem-

peño del sistema simulado (Hall y Bowden, 1999).

En la figura siguiente se presenta un diagrama genérico de optimización de simulación.

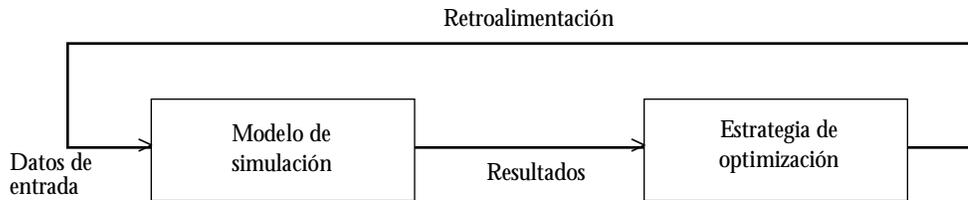


Figura 1. Diagrama de Optimización de Simulación.

La Figura 1 muestra las dos componentes principales del problema de optimización en simulación. La primera corresponde a un modelo de simulación que represente el sistema a ser estudiado. La segunda componente se refiere al método de optimización que será integrado con la simulación para que se realice la búsqueda de soluciones. Diversas técnicas pueden ser usadas en esta etapa. Las más tradicionales corresponden a heurísticas de búsqueda de vecindario que presentan como principal desventaja la incapacidad de realizar la búsqueda en un contexto global, lo cual se traduce en muchos casos en optimalidad local (Fu, 1994). Otras herramientas de optimización han sido usadas en este problema, de las cuales las más sofisticadas y que ofrecen mejores resultados corresponden a técnicas de inteligencia artificial. Dentro de estos métodos tenemos a los Algoritmos Genéticos, Temple Simulado y Búsqueda Tabú. Un completo resumen de estas y otras técnicas usadas en optimización en simulación puede ser encontrado en Carson y María (1997).

Dentro de las aplicaciones de optimización en simulación, se puede destacar el área

de manufactura. Algunas experiencias son reportadas por Pierreval (1997), Sammons y Cochran (1996), Azadivar Shu y Ahmad (1996) y Rosenblatt, Roll y Zyser (1993).

## 2. MATERIALES Y METODOS

El presente trabajo se realizó utilizando un modelo de simulación correspondiente al patio de embarques perteneciente a la empresa Codelco. Este modelo fue construido en el software de simulación Promodel. Posteriormente, este modelo fue integrado con una rutina de algoritmos genéticos con el fin de encontrar la mejor configuración de variables de entrada que permitan optimizar una función objetivo. A continuación se describe el sistema a estudiar y posteriormente se ofrece una breve explicación del funcionamiento de los algoritmos genéticos.

### 2.1. Descripción del sistema

El modelo a utilizar para este análisis corresponde al patio de manejo de materiales y

productos de la empresa Codelco, en su División de Chuquicamata. En dicho Patio de Embarque de la Planta E.W. (electrodeposición) se realizan las labores de lavado, selección según características, apilado, enzunchado y almacenamiento final a la espera de su embarque en el tren que los lleva a su destino fuera de la planta. Los cátodos

son cosechados al interior de la refinería y salen mediante una correa transportadora hacia el Patio de Embarque. Es desde este punto donde comienza el sistema modelado.

A continuación se muestra un diagrama de flujo de los distintos procesos que se realizan a los cátodos para sus circuitos de cátodos tradicionales y permanentes.

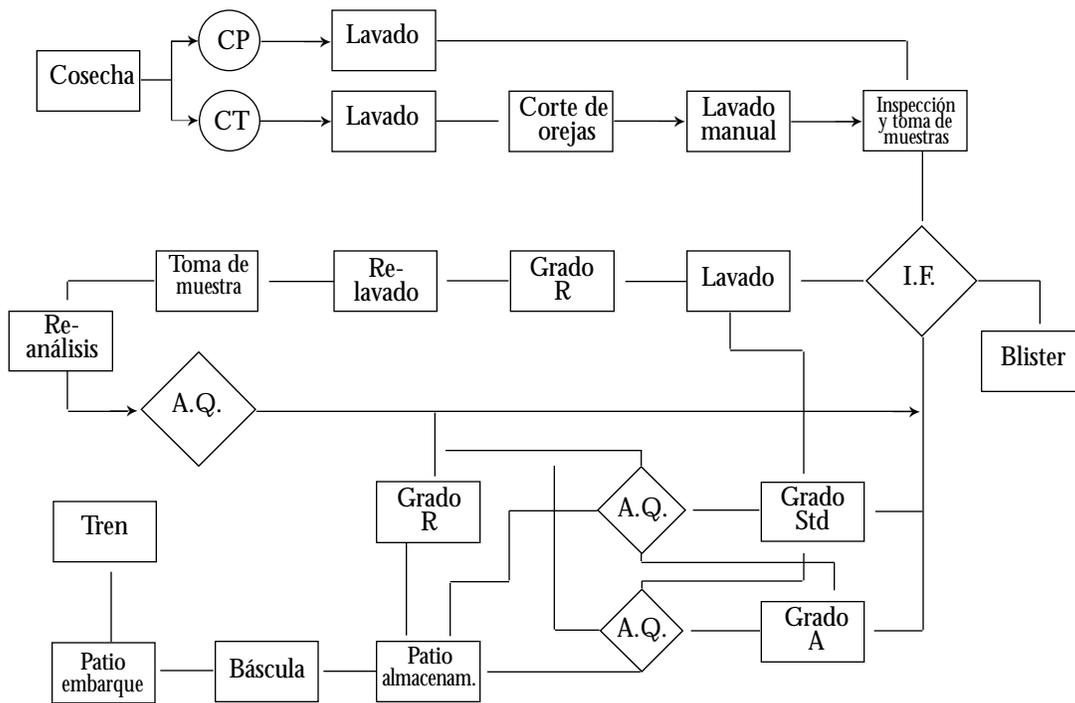


Figura 2. Procesos de los cátodos en el Patio de Embarque.

## 2.2. Algoritmos Genéticos (AG)

Un algoritmo genético es una estrategia de búsqueda que emplea selección aleatoria para guiar una búsqueda altamente exploratoria, logrando un balance entre la exploración de un dominio factible y la explotación de soluciones “buenas”. Fueron inicialmente desarrollados por Holland (1975) y popularizados por Goldberg (1989). Esta estrategia es si-

milar a la evolución biológica. Desde una perspectiva biológica, se conjetura que la estructura de un organismo y su capacidad de sobrevivir en su ambiente está determinada por su ADN. La descendencia, que es la combinación del ADN de ambos padres, hereda rasgos de sus dos padres y otros rasgos que sus padres quizás no tengan, debido a la recombinación. Estos rasgos pueden incrementar la adaptación de la descendencia,

otorgando una mayor probabilidad de sobrevivir más frecuentemente y de traspasar los rasgos a la siguiente generación. Con el paso del tiempo, la adaptación promedio de la población mejora.

En términos de AG, el ADN de un miembro de una población está representado por una cadena, en la cual cada posición puede tomar un conjunto finito de valores. Cada posición en la cadena representa una variable del sistema de interés; por ejemplo, una cadena de cinco interruptores en un dispositivo de caja negra, donde cada interruptor puede tomar el valor 1 (encendido) ó 0 (apagado); la cadena 11.100 indica que los primeros tres interruptores están encendidos y que los últimos dos están apagados.

La adaptación de un miembro de la población está dada por una función objetivo.

Los miembros de una población están sujetos a operadores para poder crear descendencia. Los operadores comúnmente utilizados incluyen selección, reproducción, cruzamiento, y mutación. Se tienen que evaluar varias generaciones antes de que se puedan apreciar mejoras significativas en la función objetivo. Los AG son notables por su robustez en la búsqueda en espacios complejos y están mejor capacitados para problemas de combinatoria (Azadivar y Tompkins, 1996).

El diagrama siguiente representa el proceso general de los algoritmos genéticos.

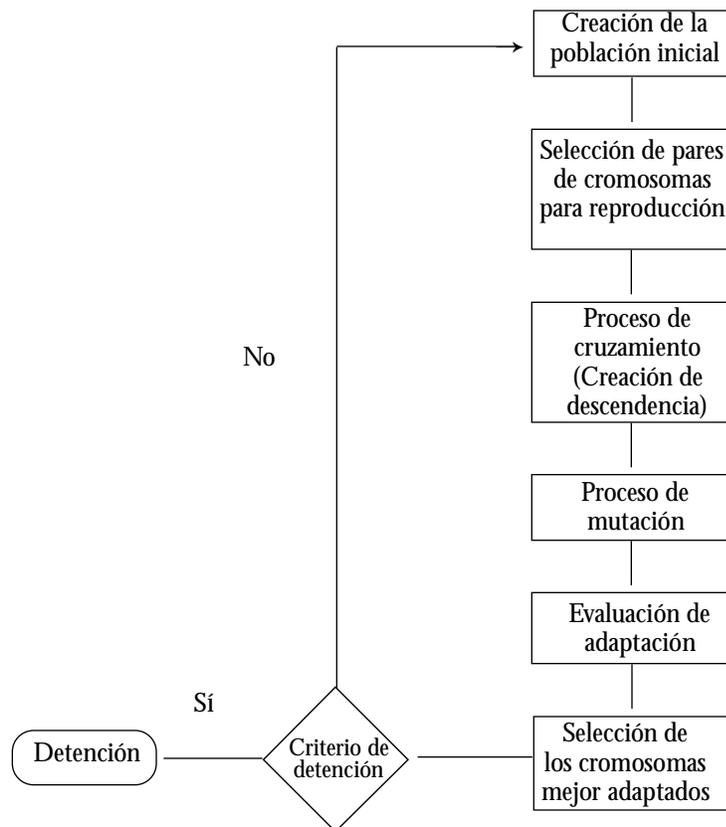


Figura 3. Proceso General de los Algoritmos Genéticos.

### 3. RESULTADOS DEL ESTUDIO

El estudio de optimización puede ser dividido en tres partes principales: primero, el ingreso de los denominados factores de entrada; segundo, el ingreso de los factores de salida, y, por último, la ejecución de la optimización en sí, con la consiguiente obtención de resultados. A continuación se describe con más detalle cada una de estas etapas.

#### 3.1. Factores de entrada

Lo primero que se debe definir al efectuar un proyecto de optimización en simulación son los factores de entrada. Estos son aquellos factores que se encuentran disponibles para probar cómo modificaciones efectuadas en ellos mejoran o empeoran el desempeño del modelo. Los factores de entrada (parámetros de control) que se utilizaron en el estudio fueron:

- Cantidad de carros (del tren), cuyos valores van de 15 a 20.
- Cantidad de montacargas para cátodos tradicionales (1 a 5).
- Cantidad de montacargas para cátodos permanentes (1 a 4).
- Cantidad de montacargas de contratistas (1 a 5).
- Capacidad de la báscula (1 a 3 paquetes dobles).

#### 3.2. Factores de salida

Una vez definidos los factores de entrada, se procede a definir los denominados factores (variables) de salida, lo que básicamente consiste en definir la función objetivo. Dicha función es una expresión usada para evaluar cuantitativamente el desempeño de un modelo de simulación.

Para el estudio realizado, se definió lo siguiente:

- Minimizar la capacidad ocupada de la zona de embarque de cátodos tradicionales.
- Minimizar la capacidad ocupada de la zona de embarque de cátodos permanentes.

#### 3.3. Optimización y análisis de resultados

Antes de proceder a la optimización se debe definir la cantidad de corridas de simulación por experimento. Con la ayuda de StatFit (software estadístico incluido con ProModel) se determinó que la cantidad de corridas, para un nivel de confianza del 95%, es de 1 (lo que indica que el sistema posee una varianza muy pequeña). Teniendo toda la información necesaria se realizó la optimización. El proceso tomó cerca de 8 horas, en las cuales se realizaron 80 experimentos (esto es, 80 corridas de simulación de 1.800 posibles, que equivalen a un 4.44%). Para realizar la optimización se utilizó un PC con un procesador AMD K6-2 de 500 Mhz y 196 Mb de memoria RAM. Se fijó esta cantidad de experimentos (80) como máximo aceptable debido a la escasez de tiempo de desarrollo. Los resultados obtenidos fueron los siguientes:

MEJOR SOLUCIÓN ENCONTRADA:

- Cantidad de carros: 17.
- Cantidad de montacargas cátodos tradicionales: 4.
- Cantidad de montacargas cátodos permanentes: 1.
- Cantidad de montacargas contratistas: 1.
- Capacidad de la báscula: 2.
- Mejor valor de la función objetivo encontrada: -368. Este valor es una representación de la unidad real la cual equivale a 331.2 m<sup>2</sup>.

La evolución de las variables minimizadas (funciones objetivo) se presenta en el siguiente gráfico:



Figura 4. Evolución de las funciones individuales objetivos estudiadas.

Las funciones objetivo se muestran por separado debido a que son representadas por dos variables diferentes, una para cada zona de embarque (cátodos tradicionales y cátodos permanentes).

Es interesante inspeccionar el efecto global que tuvo cada experimento, gráficamente se presenta en la Figura 5:

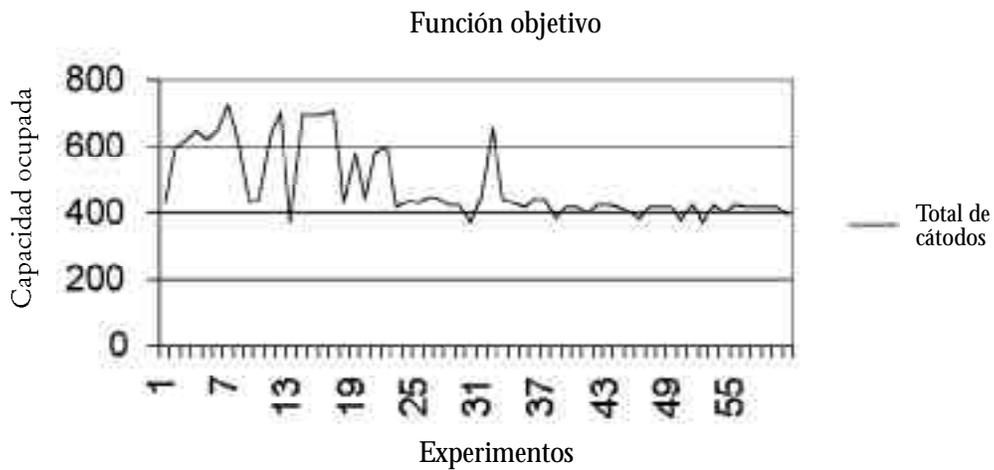


Figura 5. Evolución de la función objetivo estudiada.

El gráfico muestra cómo el valor de la función objetivo estudiada fue disminuyendo (mejorando) en promedio con cada experimento realizado al cambiar los valores de los parámetros de entrada. En otros términos, podemos decir que el gráfico muestra el proceso de evolución del AG, el cual comienza con una población de cromosomas bastante heterogénea y en promedio con un valor de la función objetivo alto. Finalmente, a partir del experimento 40 aproximadamente se aprecia la adaptación de la población, la cual comienza a converger en torno a una solución final. Cabe mencionar que el proceso podría haber continuado y posiblemente el valor de la función objetivo habría mejorado; sin embargo, el costo computacional asociado a este esfuerzo sería muy alto y con una mejoría de la función objetivo muy pequeña. Teóricamente no es posible comprobar que la solución alcanzada corresponde a la solución óptima del problema, sin embargo podemos decir que corresponde a una solución buena la cual difícilmente podría ser mejorada. Esta conclusión está basada en opinión de expertos. Una alternativa para comprobar si esta solución corresponde a la óptima, sería realizando una búsqueda exhaustiva, es decir, probar el 100% de las posibles configuraciones y seleccionar la mejor. Como se mencionó anteriormente, este esfuerzo requeriría realizar 1.800 experimentos, para lo cual sería necesario un esfuerzo computacional equivalente a aproximadamente 7.5 días. Sin duda, la alternativa que presenta el AG es una buena solución al problema, dado que representa un esfuerzo computacional de 8 horas, con un espacio explorado sólo del 4.44% de la región factible.

### 3.4. Interpretación de resultados

Los resultados mostraron que la primera mejor mitad de los experimentos consideró como valor igual a 2 la capacidad de la báscula (capacidad entre 1 y 3, denotado como

cantidad de paquetes dobles de cátodos tradicionales o permanentes), quedando en la peor mitad los experimentos que asumen el valor 1 para el mismo parámetro; por esto se considera como fundamental que la báscula posea una capacidad igual a dos. Esta medida sólo es de procedimiento operacional, dado que la báscula posee esa capacidad máxima.

Para determinar cuál es la solución más adecuada al caso en estudio, se revisaron las primeras 7 mejores soluciones entregadas por la heurística de AG, debido a que en las siguientes soluciones el número de recursos requeridos aumenta con respecto a la solución número 7. Las cuatro primeras mejores soluciones utilizan una mayor cantidad del recurso “montacargas para cátodos tradicionales” (siendo éste el encargado de trasladar los cátodos tradicionales cosechados a sus canchas de lavado) que las siguientes 3, esto es para un valor constante de los demás parámetros. Además, dado que la función objetivo no posee una diferencia considerable para los niveles de almacenamiento manejado (en paquetes dobles de cátodos), es que la decisión de la solución a implementar se reduce a elegir entre los experimentos 70, 65 y 58, correspondientes a las soluciones en quinto, sexto y séptimo lugar del ranking, respectivamente. Entre las tres opciones a analizar, dado que el valor de los parámetros es similar, la decisión final se inclina por la quinta en el ranking, debido a que es ésta la que presenta un valor menor para la función objetivo. Con todo lo anterior se presenta como la mejor alternativa la siguiente:

- Cantidad de carros: 15.
- Cantidad de montacargas cátodos tradicionales: 1.
- Cantidad de montacargas cátodos permanentes: 1.
- Cantidad de montacargas contratistas: 1.
- Capacidad de la báscula: 2.
- Mejor valor de la función objetivo encontrada: -378.

Esta elección se respalda en el hecho que, a pesar de no ser la alternativa con mejor resultado de la función objetivo, la diferencia con ésta no es significativa para los niveles de almacenamiento manejados. Además, para llegar al óptimo entregado, la necesidad de recurso (montacargas para transporte de cátodos tradicionales cosechados) es demasiada alta para el beneficio entregado.

#### 4. DISCUSION

Este trabajo ha presentado una breve descripción del concepto denominado optimización en simulación. Un caso real correspondiente a la empresa Codelco fue estudiado y analizado utilizando esta técnica. Específicamente, un modelo de simulación representando el sistema en estudio fue integrado con una rutina de algoritmos genéticos con el fin de encontrar una solución "óptima" o cercana al óptimo. Los resultados muestran que al usar algoritmos genéticos como estrategia de optimización, es posible encontrar una "buena" solución al problema explorando solamente un 4.44% del espacio total de posibles combinaciones o escenarios. Estos resultados nos hacen concluir que, al menos en esta aplicación en particular, la utilización de algoritmos genéticos representa una excelente alternativa para optimizar un sistema simulado.

Como investigación futura se propone continuar evaluando esta herramienta en distintos ambientes productivos y de servicios. Además, resulta de alto interés probar otras técnicas de inteligencia artificial, como son Temple Simulado, Búsqueda Tabú, Redes Neuronales, entre otras, con el fin de estudiar y comparar sus comportamientos

para eventualmente proponer qué estrategia de solución se comporta de mejor manera en ciertos ambientes industriales de interés para el desarrollo nacional.

#### 5. REFERENCIAS

- AZADIVAR, F. and TOMPKINS, G. (1996). "Simulation optimization with qualitative variables and structural model changes: A genetic algorithm approach". In: *European Journal of Operational Research*, Issue 113 (1999), pp 169-182.
- AZADIVAR, F., SHU, J. and AHMAD, M. (1996). "Simulation optimization in strategic location of semi-finished products in a pull-type production system". In: *Proceedings of the 1996 Winter Simulation Conference*, pp. 1123-1128, USA.
- CARSON, Y. and MARIA, A. (1997). "Simulation optimization: methods and applications". In: *Proceedings of the 1997 Winter Simulation Conference*, pp 118-125, USA.
- FU, M. C. (1994). "Optimization via Simulation: A Review". In: *Annals of Operations Research*. Vol. 53, pp. 199-247.
- GOLDBERG, D. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley, Reading, MA.
- HALL, J.D. and BOWDEN, R.O. (1999). "Simulation optimization research: transition methods for a two-phased strategy". In: *Proceedings of the 1996 Winter Simulation Conference*, pp 117-123, USA.
- HOLLAND, J. (1975). *Adaptation in Natural and Artificial Systems*, University of Michigan Press, Ann Arbor.
- PIERREVAL, H. (1997). "Using evolutionary algorithms and simulation for the optimization of manufacturing systems". In: *IIE Transactions*. Vol. 29, 3, pp. 181-190.
- ROSENBLATT, M.J., ROLL, M. and ZYSER, V. (1993). "A combined optimization and simulation approach for designing automated storage/retrieval systems". In: *IIE Transactions*. Vol. 25, pp. 25-50.
- SAMMONS, S. M. and COCHRAN, J.K. (1996). "The use of simulation in the optimization of a cellular manufacturing system". In: *Proceedings of the 1996 Winter Simulation Conference*. pp. 1129-1134, USA.