

## A genetic algorithm to solve one mining selection problem

Orlando Belete-Fuentes<sup>a</sup>; Rafael Zamora-Matamoros<sup>b</sup> & Daimel Caballero-Echevarría<sup>b</sup>

<sup>a</sup> Facultad de Geología y Minería, Instituto Superior Minero Metalúrgico de Moa, Cuba. [orlandobelete@gmail.com](mailto:orlandobelete@gmail.com)

<sup>b</sup> Centro de Investigación del Níquel, Cuba. [rzamora@cil.moa.minem.cu](mailto:rzamora@cil.moa.minem.cu), [dcaballero@cil.moa.minem.cu](mailto:dcaballero@cil.moa.minem.cu)

Received: June 9<sup>th</sup>, de 2017. Received in revised form: October 10<sup>th</sup>, 2017. Accepted: October 24<sup>th</sup>, 2017

### Abstract

Based on the decision to automate the solution of an optimization problem related to the selection of an "N" number of geological exploration wells in a reservoir, which reflects the general characteristics of the well and having the mathematical models created for that purpose, arises the need to look for some alternative that allows to obtain the solutions of the raised problem. The mathematical models created generate a system formed by an objective function, several constraints in the form of inequalities and an additional restriction, in the form of equality: a classic problem of selection. This type of problem has solutions of non-polynomial computational complexity; for this reason, instead of implementing complex algorithms, it was decided to design an automated tool based on the use of genetic algorithms. An automated application was created for the solution of the problem of selection of a described mining sample, being able to implement a low complexity computational solution.

**Keywords:** Genetic algorithm; mathematical modeling; mining, programming.

## Técnicas genéticas en la solución de un problema minero

### Resumen

A partir de la decisión de automatizar la solución de un problema de optimización vinculado a la selección de una cantidad "N" de pozos de un yacimiento, que refleje las características generales estudiadas del mismo y disponiendo de los modelos matemáticos creados a tal efecto, surge la necesidad de buscar alguna alternativa que permita obtener las soluciones del problema planteado. Los modelos matemáticos creados generan un sistema formado por una función objetivo, varias restricciones en forma de desigualdades y una restricción adicional, en forma de igualdad: un problema clásico de selección. Este tipo de problema tiene soluciones de complejidad computacional no polinomial; por tal motivo, en lugar de implementar algoritmos complejos, se decidió diseñar una herramienta automatizada basada en el empleo de algoritmos genéticos. Se creó una aplicación automatizada para la solución del problema de selección de una muestra minera descrito, lográndose implementar una solución computacional de baja complejidad.

**Palabras claves:** Algoritmo genético; minería; programación; yacimiento.

### 1. Introducción

En la industria del níquel, en el oriente de Cuba, es frecuente la realización de pruebas metalúrgicas con el material extraído de los diferentes yacimientos lateríticos. Estas pruebas son realizadas con el objetivo de estimar y ajustar la recuperación metalúrgica a nivel industrial. Como el mineral empleado en estas pruebas debe ser representativo de cada uno de los yacimientos, la "industria" se formula el siguiente problema:

"Problema de selección minero": Dados "n" pozos de la red de exploración/explotación minera, cómo seleccionar

"N" de ellos que sean representativos de las características de todo el yacimiento.

Actualmente la industria del níquel cubana da respuesta a esta interrogante:

- Utilizando métodos tradicionales basados en modelos matemáticos (sustentados por métodos geoestadísticos).
- Utilizando el modelado Markoviano: "El modelo Markoviano" para yacimientos constituye una secuencia de cadenas de Markov [6], que genera un sistema de matrices de transferencia, cada una de las cuales se corresponde con una dirección en el yacimiento sobre la red de exploración, se construye sucesivamente de un pozo de la red de

exploración al inmediato y también a saltos. Los eventos que se modelan constituyen clases de comportamientos en el yacimiento; las matrices de transferencias contienen las probabilidades con que puede aparecer una clase en un punto, dada la ocurrencia de otra en el punto que se considera inmediato anterior, se apoya en una función de georeferencia para construir las distribuciones probabilísticas de las clases sobre el yacimiento” [5].

En el proceso de modelado de los yacimientos y en la construcción de su “Modelo Markoviano” son empleadas varias herramientas automatizadas; entre ellas la denominada SWORE (desarrollada por investigadores del Centro de Investigación del Níquel (CEDINIQ) que, en base a algoritmos de alta complejidad paralelizados para disminuir su tiempo de corrida, produce los coeficientes del siguiente modelo lineal binario:

Función objetivo:

$$\max \left\{ z \sum_{j=1}^n C_j X_j \right\} \tag{1}$$

Restricciones:

$$\sum_{j=1}^n a_{ij} X_j \leq b_i \tag{2}$$

$$\sum_{j=1}^n X_j \leq N \tag{3}$$

$n, N \in 4, N < n$   
 $\forall i = 1..n, n \in N$   
 $\forall j = 1..m, m \in N$

$$C_j \in R, C_j \geq 0 \tag{4}$$

$X_j \in \{0,1\}$   
 $b_i \in R, b_i \geq 0$   
 $a_{i,j} \in R, a_{i,j} \geq 0$

Las ecuaciones (1), (2) y (3) pueden escribirse en forma vectorial de la siguiente manera:

Función objetivo:

$$\max\{C\vec{X}\} \tag{5}$$

Restricciones:

$$A\vec{X} \geq \vec{b} \tag{6}$$

$$|\vec{X}|N \tag{7}$$

Debido a que las variables  $X_j$  ( $j= 1..n$ ) sólo toman valores cero o uno (son variables binarias), el problema no puede ser resuelto directamente con el empleo del conocido método SIMPLEX de la “Investigación de Operaciones”. Surge entonces la necesidad de emplear otras técnicas de optimización y por tanto investigar cómo solucionar este problema.

## 2. Materiales y métodos

Este trabajo investigativo parte de la necesidad de resolver un problema concreto surgido de otras investigaciones en el campo de la modelación matemática de problemas mineros: “el problema de selección minero” descrito anteriormente. Se desarrolló una búsqueda bibliográfica sobre el tema y en especial sobre la técnica de los algoritmos genéticos y sus aplicaciones.

### 2.1. Motivación

La investigación comenzó intentando responder una pregunta muy simple: cuál es la magnitud del problema a que nos enfrentamos?. Para brindar una idea clara formulemos un posible problema de selección de pozos mineros de forma muy concreta: “Se dispone de abundante información geoquímica y geofísica de cada uno de los 1500 pozos perforados en una red del yacimiento “Y” y se desea seleccionar 10 pozos que sean representativos de las características medidas del yacimiento, con el objetivo de realizar una prueba metalúrgica que aporte información sobre la eficiencia de extracción de níquel y cobalto en la industria operando con mineral proveniente del yacimiento “Y”.

Aunque no es nuestra intención detallar todo el proceso, es bueno aclarar que la cantidad de pozos a seleccionar no debe ser muy pequeña, porque se afectaría la representatividad de la muestra y tampoco puede ser muy grande por el impacto económico de la prueba.

La cantidad de formas en que podemos seleccionar 10 pozos de una red formada por 1500 es 15420310928028700000000000. Imagine qué tiempo le tomaría a una computadora personal evaluar cada una de esas posibles soluciones en cada una de las “m” restricciones del modelo lineal binario propuesto para determinar cuáles las satisfacen e ir evaluándolas en la función objetivo para tomar la que maximiza su valor.

La Tabla 1 ilustra la magnitud de las cantidades de soluciones a evaluar a partir de la cantidad de pozos estudiados en las redes del yacimiento y asume que se pretenden seleccionar 10 pozos representativos del yacimiento (“N” = 10):

Tabla 1. Relación “Cantidad de pozos – formas de seleccionar grupos de 10 pozos”

Cantidad de pozos	Cantidad de soluciones a evaluar
30	30045015
40	847660528
50	10272278170
60	75394027566
70	396704524216
80	1646492110120
90	5720645481903
100	17310309456440
200	22451004309013300
300	1398320233241700000
500	245810588801891000000
1000	26340956046197000000000
1100	68603434539032000000000
1200	164331279610894000000000
1300	366944570586638000000000
1400	771838035061633000000000
1500	<b>1542031092802870000000000</b>

Fuente: Elaboración propia

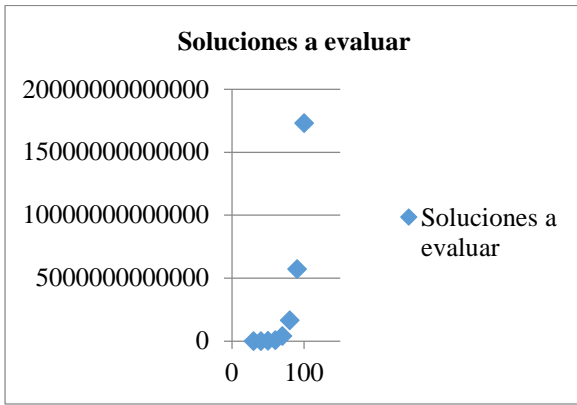


Figura 1. Relación cantidad de pozos - soluciones posibles (N=10). Fuente: Elaboración propia.

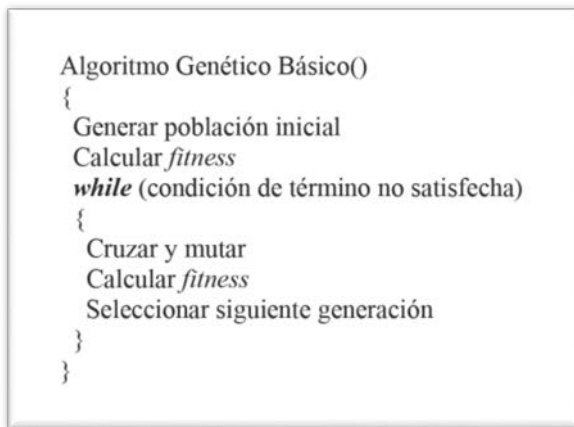


Figura 2. Esquema básico de un algoritmo genético (Salazar y Sarzuri, 2015). Fuente: Elaboración propia.

El gráfico mostrado en la Fig. 1, confeccionado con datos de la Tabla 1 brinda una mejor idea de la magnitud del problema a resolver, ya que permite apreciar cómo se dispara la cantidad de soluciones a evaluar al incrementar la cantidad de pozos de 30 a 100 (Fig. 1):

Un estimado del tiempo que tardaría una computadora personal aceptable actualmente aportó el increíble resultado de unos cuantos años. Indiscutiblemente hay que buscar una alternativa diferente para resolver el problema planteado. La Fig. 2 resume varios métodos empleados en la solución de problemas de este tipo:

Tras rechazar el empleo de algunos métodos determinísticos y otros probabilísticos, algunos de forma práctica y otros de forma teórica, surge la idea de incursionar en el mundo de los algoritmos genéticos con el desarrollo de una aplicación para resolver el problema de programación lineal binaria.

Dado que gran parte de los problemas prácticos que se necesitan resolver son de los denominados NP-hard, los algoritmos heurísticos o de aproximación desempeñan un papel importante en la resolución de problemas de optimización discreta con la idea de encontrar buenas soluciones factibles de manera rápida [8].

## 2.2. Los algoritmos genéticos

Un algoritmo genético (AG) es una técnica de optimización y búsqueda basada en los principios de la genética y la selección natural. Un AG permite que una población compuesta de muchos individuos evolucione bajo reglas de selección específicas a un estado que maximice o minimice la adaptabilidad [2].

“Un algoritmo genético, desde el punto de vista de la optimización, es un método poblacional de búsqueda dirigida basada en probabilidad. Bajo una condición muy débil (que el algoritmo mantenga elitismo, es decir, guarde siempre al mejor elemento de la población sin hacerle ningún cambio), se puede demostrar que el algoritmo converge en probabilidad al óptimo” [4].

“La terminología del algoritmo genético tiene una mezcla de términos naturales y artificiales. El conjunto de posibles soluciones se llama población. La población inicial evoluciona de generación en generación. Cada individuo de la población se llama cromosoma y cada código presente en el cromosoma se conoce como gen (el cromosoma es una cadena de genes)” [7].

Este esquema muestra los operadores genéticos básicos: Cruzamiento, mutación y selección correspondientes a procesos observados en los seres vivos: reproducción, mutación (cambios aleatorios no explicados en uno o varios individuos) y la selección natural. Cada uno de estos operadores, descritos por Rincón [6], puede ser concebido de diferentes formas, dando lugar a diversas variantes; por sólo citar un ejemplo: entre los métodos de selección clásicos se encuentran: la selección por ruleta, por torneo, etc.

Zbigniew [9] realiza una interesante descripción de qué son los algoritmos genéticos, cómo trabajan y por qué funcionan [9]. Mientras que en el capítulo catorce de Practical Optimization [1] podrá descubrir los secretos de los operadores genéticos básicos y algunas de las ventajas de los algoritmos genéticos entre ellas: la de trabajar con la solución completa y la facilidad de su implementación computacional.

### 2.3 Propuesta de algoritmo genético

El problema planteado y la ecuación (3) del modelo lineal binario desarrollado sugieren de forma natural la siguiente codificación para la creación de un algoritmo genético:

- Cromosoma o individuo: cualquier vector binario  $\vec{x} \in \{0,1\}^{n,1}$ .
- Gen: cualquier componente del vector binario; por ejemplo:  $\vec{x}_1$

En esta codificación un individuo representa exactamente una de las posibles formas de seleccionar un subconjunto de “N” pozos representativos de las características estudiadas en los “n” pozos del yacimiento: una combinación de pozos candidata; mientras que cada gen (de un individuo) representa la pertenencia o no de cada pozo del yacimiento al subconjunto de “N” pozos representativos de las características del yacimiento.

En esta codificación un individuo representa exactamente una de las posibles formas de seleccionar un subconjunto de “N” pozos representativos de las características estudiadas en los “n” pozos del yacimiento: una combinación de pozos candidata; mientras que cada gen (de un individuo) representa la pertenencia o no de cada pozo del yacimiento al

subconjunto de “N” pozos representativos de las características del yacimiento.

**Ejemplo #1:** Supongamos que se estudia un yacimiento en busca de níquel, cobalto y manganeso. Para este estudio han sido perforados y analizados 1000 pozos (P1, P2, P3, ..., P1000) deseándose obtener un subconjunto de 8 pozos representativos del yacimiento con vista a la realización de una prueba metalúrgica. Aquí la cantidad de combinaciones posibles es:

$$\text{cant} = \binom{1000}{8} = \frac{1000!}{8! (1000-8)!} = 24115080524699400000 \quad (8)$$

El vector (1,1,1,1,1,1,1,0,...0), con los 8 primeros componentes en uno y el resto en cero, representa la hipótesis: 8 primeros pozos (P1, P2, P3, ..., P8) son representativos de las características estudiadas del yacimiento.

Análogamente el vector (0,0,...0,1,1,1,1,1,1,1), con 992 ceros al inicio y 8 unos al final, corresponde a la hipótesis de que los 8 últimos pozos del yacimiento (P993, P994, P995, ..., P1000) son representativos del yacimiento.

Como hemos calculado en (8) tenemos 24115080524699400000 posibles combinaciones; en términos genéticos: una población de 24115080524699400000 individuos de los que deberíamos elegir el mejor adaptado a su entorno (el que cumpla con los requisitos exigidos: restricciones (6), (7) y (4) maximizando la función objetivo (5)). Lo que antes llamamos función objetivo en el modelo pasa a ser la *función de adaptabilidad* o “*fitness*” en el modelo genético.

Es conocido que todos los algoritmos genéticos son diferentes pero comparten una idea central, mostrada en la Fig. 3, basada en generar aleatoriamente una población inicial de individuos y aplicarle operadores genéticos para obtener una nueva población, manteniendo con una probabilidad conocida los mejores individuos de la generación anterior.

La población inicial puede ser obtenida por diversos métodos. Una clasificación interesante es definida teniendo en cuenta si se emplea o no información acerca del problema que se intenta resolver. En el *ejemplo #1* a la población inicial podría ser generada por ejemplo:

- Asignado unos y ceros aleatoriamente a las componentes de vectores de orden 1000 (sin conocimiento alguno del problema).
- Construyendo vectores de orden 100 con exactamente 8 componentes en uno (haciendo uso de la restricción (7) del modelo binario en forma vectorial) y el resto en cero.

En el algoritmo y aplicación objetos de este artículo fueron concebidos a partir de las ideas básicas de los algoritmos genéticos por lo que heredan su esquema básico.

La población inicial es construida con vectores generados aleatoriamente con una probabilidad conocida de obtener un vector que satisfaga la restricción (7) con el objetivo de mejorar controladamente la población inicial.

Antes de elegir este método de generación de la población inicial se analizaron las siguientes variantes:

1. Generar aleatoriamente la población. La ventaja de esta variante está dada por la diversidad de la población inicial, pero tiene la desventaja de un bajo elitismo de sus

individuos, pues no garantizan el cumplimiento de la restricción más sencilla: la restricción (7).

2. Generar una población inicial que satisfaga la restricción de la cantidad de pozos a seleccionar. Esto es posible dado que la evaluación de la restricción (7) es extremadamente menos costosa que la evaluación de las restricciones (6). Esta variante incrementa notoriamente el elitismo de los individuos de la población, pues todos sus miembros ya satisfacen una de las restricciones del problema, pero simultáneamente, provoca que la siguiente generación de individuos (después de un proceso de reproducción o cruce) sea menos elitista que la de sus ancestros. Esta pérdida de elitismo viene dada porque, en la práctica, “N” es mucho menor que “n” y por tanto, los cromosomas de cada individuo tienen muchos genes con valor cero; por tal motivo los operadores de cruces genéticos clásicos tienden, en estos casos, a eliminar los genes en uno.
3. La variante híbrida o intermedia entre las dos anteriores elimina en cierta medida las desventajas de cada una de ellas, pero adiciona la complejidad de la elección adecuada del balance entre pozos que satisfacen la restricción (7) y pozos que no la satisfacen. Este equilibrio fue determinado de forma experimental y se piensa ajustar automáticamente según los resultados de cada corrida de la aplicación.

Como función de adaptabilidad se escogió la propia función objetivo ajustada con algunos pesos determinados en base a factibilidad de cumplimiento de cada una de las “m” restricciones descritas en (2). Estos pesos son generados a partir de un ordenamiento ascendente de los sumandos en cada restricción y la cantidad de  $X_j$  en uno necesarios para satisfacer cada restricción.

La reproducción fue planificada por el método clásico de un corte simple de genes pero con elección aleatoria del punto de corte para evitar la pérdida de diversidad de la población que este método genera en segundos descendientes. La introducción de un corte aleatorio hace que las nuevas generaciones tengan una probabilidad mayor de ser no homogéneas y por tanto incrementa la posibilidad de que el método continúe trabajando en busca del individuo óptimo. Adicionalmente el algoritmo propuesto incluye un operador genético denominado BigBang que es equivalente a generar una población inicial nueva y cuya ejecución es parametrizable, siendo recomendable su ajuste en base a la cantidad de ejecuciones del operador de reproducción y el de mutación empleados (la aplicación desarrollada brinda valores por defecto para cada parámetro configurable, pero permite su variación y afinamiento para problemas específicos).

El operador de mutación es el encargado, al igual que en la naturaleza, de mantener la diversidad de la población y generar individuos “atípicos”, pero es importante no abusar de él, porque su incremento implica un aumento de la aleatoriedad de la población. De incrementarse excesivamente la frecuencia de las mutaciones, el algoritmo genético se convertiría en un algoritmo de búsqueda aleatoria de soluciones.

El proceso de selección de los mejores individuos ha sido desarrollado a partir del método clásico de selección por

torneo, dividiendo la población generada por la reproducción (algunas ocasiones mutada) en dos grupos y enfrentando a cada individuo de un grupo con uno del otro en pequeños torneos. En este operador genético desarrollado, no siempre tomamos el mejor individuo en cada torneo (algo que parece una contradicción con la ideabásica de método genético, pero que mantiene la diversidad en la población). En esta variante de solución genética se ha introducido un coeficiente de probabilidad para la elección del mejor individuo en cada pequeño torneo; naturalmente si acercamos este coeficiente a cero, estaremos bajando la probabilidad de mejorar cualitativamente la población y si lo acercamos mucho a uno, estaremos disminuyendo la calidad de la población. Adicionalmente se ha introducido un coeficiente, denominado coeficiente de remplazo, para garantizar un mínimo de aleatoriedad en cada nueva generación obtenida por este algoritmo genético.

Es importante mantener la diversidad de la población porque, por ejemplo: el cruce de dos individuos de poca aptitud (bajo valor de la función de aptitud y por tanto individuos que no constituyen un óptimo en el problema minero), puede generar un nuevo individuo con mejor aptitud; sabemos que la naturaleza es sabia y ha probado la eficiencia de sus métodos.

Aunque es conocido que algunas herramientas que emplean actualmente métodos genéticos de solución, finalizan generalmente al dejar de encontrar soluciones, al disminuir la frecuencia de sus hallazgos o al alcanzar un umbral prefijado de la función de aptitud; el algoritmo desarrollado finaliza por tiempo de corrida dada la magnitud de la población total y la simplicidad computacional de su implementación.

### 3. Resultados y discusión

Se desarrolla una aplicación para la solución del “problema minero” descrito al inicio, la cual fue modelada según el paradigma de la orientación a objetos y programada en lenguaje C# empleándose algunas características de este lenguaje orientadas al paralelismo. La Fig. 4 muestra la pantalla de configuración de la aplicación para su corrida:

- En color rojo se han destacado los parámetros a fijar comúnmente para las corridas: la cantidad de pozos a seleccionar, la ubicación del fichero con los datos a procesar y la duración máxima para la corrida en minutos, horas o días.
- En color negro aparecen algunos parámetros que rigen el comportamiento del algoritmo genético implementado: tamaño de la población, coeficiente de remplazo, coeficiente de mutación y coeficiente BigBang. Los valores por defecto se consideran adecuados para problemas de selección de hasta un 10% en yacimientos con redes de hasta 2000 pozos.

La aplicación es capaz de detectar, como se muestra en la Fig. 5 soluciones triviales; esto significa que antes de iniciar la corrida del algoritmo genético se realizan un conjunto de validaciones de los datos y un análisis de soluciones triviales del problema.

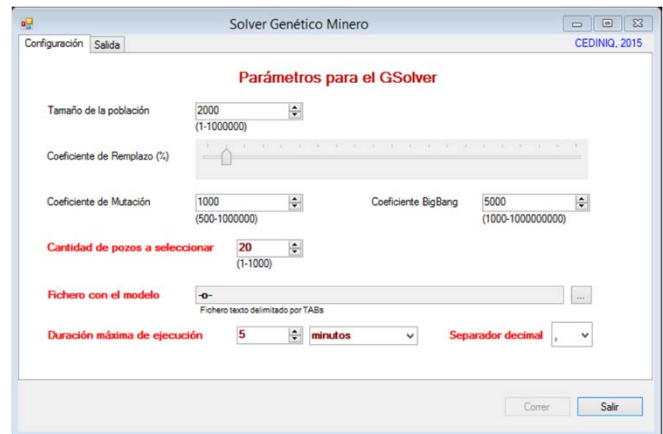


Figura 4. Pantalla de configuración de la aplicación.  
Fuente: Elaboración propia.

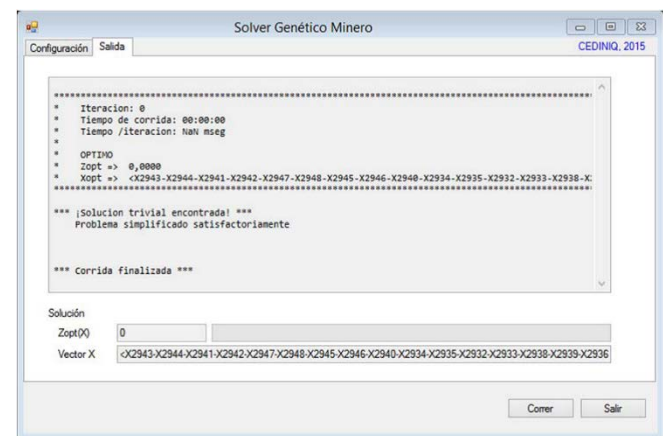


Figura 5. Pantalla de resultados o salida de la aplicación.  
Fuente: Elaboración propia.

La solución mostrada tiene dos componentes:

1.  $Z_{opt}(X) \Leftrightarrow$  Valor de la función de aptitud que puede ser útil para comparar la calidad soluciones aportadas por corridas diferentes de la aplicación.
2. Vector  $X \Leftrightarrow$  El mejor individuo encontrado en el tiempo de corrida prefijado. La representación de este vector binario sólo incluye sus componentes con valor uno, por lo que puede interpretarse como el listado de pozos seleccionados; por ejemplo, en la corrida cuyo resultado se muestra en la Fig. 4, los pozos a minar para la extracción de mineral destinado a la prueba metalúrgica son los siguientes: 2943, 2944, etc.

### 4. Conclusiones

Se ha desarrollado un algoritmo y una aplicación automatizada para la solución del problema de selección de una muestra minera para una prueba metalúrgica descrito, en base a principios genéticos y de selección presentes en la naturaleza. Se logra implementar una solución a un problema de gran complejidad computacional empleando un método de solución no exacto, pero de convergencia teórica garantizada,

que ha sido automatizado de forma tal que puede emplearse en ordenadores personales.

A pesar de la complejidad computacional, con este trabajo se logra automatizar la última etapa del modelado de yacimientos mineros para la industria cubana del níquel elaborado por investigadores del Centro de Investigación del Níquel y el Instituto Superior Minero Metalúrgico de Moa, siguiendo una clasificación sustancial multivariada y con el empleo del modelo de Márkov para procesos estocásticos discretos.

El trabajo puede perfeccionarse con el empleo de técnicas de aprendizaje de forma tal que el algoritmo se auto ajuste manejando metadatos de cada corrida: un tema abierto para futuras investigaciones.

## Bibliografía

- [1] Chinneck, J., Practical optimization: A gentle introduction [online]. [Consulted July 3 of 2015]. Available at: <http://www.sce.carleton.ca/faculty/chinneck/po.html>
- [2] Haupt, L. and Haupt, S.E., Practical genetics algorithms. 2da. ed. New Jersey: John Wiley & Sons, Inc. 2004.
- [3] López, J., Optimización multi-objetivo. Aplicaciones a problemas del mundo real. Tesis de Doctorado, Universidad Nacional de La Plata, Argentina, 2013.
- [4] Melián-Batista, B., Moreno-Pérez, J.A. y Moreno-Vega, J.M., Algoritmos genéticos. Una visión práctica. 71. 2009. [en línea]. [Consultado: 10 de junio 2015]. Disponible en: [http://www.sinewton.org/numeros/numeros/71/Darwin\\_03.pdf](http://www.sinewton.org/numeros/numeros/71/Darwin_03.pdf)
- [5] Peña-Abreu, R.E. y Sampalanco, C.M., Optimización del muestreo tecnológico en yacimientos lateríticos cubanos. Ciencias de la Tierra y el Espacio, 14, pp. 38-50, 2013.
- [6] Rincón, J.C., Aplicación de los algoritmos genéticos en la optimización del sistema de abastecimiento de agua de Barquisimeto-Cabudare. Avances en Recursos Hidráulicos [En línea], 14, 2006. [Consultado 10 de junio 2015]. Disponible en: <http://www.revistas.unal.edu.co/index.php/%20arh/article/viewFile/9328/9972>
- [7] Salazar-Horning, E. y Sarzuri-Guarachi, R.A. Algoritmo genético mejorado para la minimización de la tardanza total en un flowshop flexible con tiempos de preparación dependientes de la secuencia. Ingeniare. Revista Chilena de Ingeniería [En línea], 23. 2015. [Consultado 10 de junio 2015]. Disponible en: <http://www.scielo.cl/pdf/ingeniare/v23n1/art14.pdf>.
- [8] Vidal-Esmorís, A., 2013. Algoritmos heurísticos en optimización. Tesis de Maestría, Universidad de Santiago de Compostela, España.
- [9] Zbigniew, M., Genetic Algorithms+ data Structures = Evolution Programs, Berlin, Springer-Verlag.1996.

**R. Zamora-Matamoros**, es Lic. en Matemática en 1987, de la Universidad de Oriente, Cuba. MSc. en Informática Aplicada a la Ingeniería y la Arquitectura (CREPIA3). Ha tomado cursos de postgrado en Argentina, Canadá, Cuba, Ecuador, y España. Trabajó como: profesor en el Instituto Superior Minero Metalúrgico de Moa por más de 10 años, especialista principal en sistemas informáticos en Moa Nickel S.A., Consultor Informático en AITIPICI del Ecuador. Actualmente ocupa la plaza "Especialista B en Investigaciones" en el CEDINIQ.  
ORCID: 0000-0002-9068-5001

**O. Belete-Fuentes**, es graduado de Ing. de Minas en 1986 y de Dr. En Ciencias Técnicas en 1999, ambos del Instituto Superior Minero Metalúrgico de Moa "Dr. Antonio Núñez Jiménez", en Holguín, Cuba. Se desempeña como profesor de topografía minera y máquinas mineras en la Facultad de Minas del ISMMM desde 1979, con 38 años de experiencia en la docencia. Ha publicado varios artículos relacionados con la topografía minera, y específicamente en el cálculo de los errores que afectan el volumen de mineral extraído. Ha participado en proyectos nacionales e

internacionales. Es coordinador de la maestría topografía minera y ha obtenido varios premios en investigación otorgados por la Academia de Ciencias Provincial de Cuba. Es miembro del tribunal nacional de defensa de doctorado. Ha dirigido varios doctorados y maestrías.

ORCID: 0000-0002-2491-8030

**D. Caballero- Hechavarría**, es graduado de Ingeniería en Minas en 2013, en el Instituto Superior Minero Metalúrgico de Moa, Cuba. Trabaja como técnico en adiestramiento en la unidad de Proyectos de Investigaciones del Centro de Investigaciones del Níquel. Ha recibido entrenamientos en las áreas de: geología, topografía y planificación minera de la empresa productora de níquel Comandante Ernesto Che Guevara y varios cursos de Informática. Actualmente cursa estudios en la maestría en minería en el ISMM. Ha presentado trabajo en eventos universitarios en el CINAREM 2013.

ORCID: 0000-0003-0054-5476



UNIVERSIDAD NACIONAL DE COLOMBIA

SEDE MEDELLÍN  
FACULTAD DE MINAS

Área Curricular de Ingeniería  
Geológica e Ingeniería de Minas y Metalurgia

Oferta de Posgrados

Especialización en Materiales y Procesos  
Maestría en Ingeniería - Materiales y Procesos  
Maestría en Ingeniería - Recursos Minerales  
Doctorado en Ingeniería - Ciencia y Tecnología de  
Materiales

Mayor información:

E-mail: [acgeomin\\_med@unal.edu.co](mailto:acgeomin_med@unal.edu.co)  
Teléfono: (57-4) 425 53 68