



Optimización de Portafolios de Inversión con Algoritmos Genéticos

Vanessa Fernandez Cortez

[va fe co @hotmail.com](mailto:va_fe_co@hotmail.com)

Universidad Autónoma del Estado de México

David Valle Cruz

davacr@gmail.com

Universidad Autónoma del Estado de México

Pedro Enrique Lizola Margolis

plizola@gmail.com

Universidad Autónoma del Estado de México

Resumen

Los inversionistas buscan maximizar el rendimiento de sus acciones con el mínimo riesgo, situación que se torna compleja. El objetivo del trabajo de investigación, es generar portafolios de inversión conformados por acciones de las empresas nacionales emisoras que participan en la Bolsa Mexicana de Valores para el segundo semestre de 2018. La metodología se basa en aplicar algoritmos genéticos, a un modelo matemático lineal, para conformar portafolios eficientes que establezcan el monto óptimo de inversión en cada uno de los instrumentos financieros seleccionados, además de generar diversificación. Después de varias pruebas con el algoritmo genético, el portafolio optimizado quedó conformado por acciones de las empresas: Alsea, Arca Continental, Autlan, Banco del Bajío, Banorte, Cemex, G México, Mexichem, Peñoles, Pinfra y Vitro. Al invertir las cantidades calculadas en cada una de las acciones, de las emisoras, se obtiene un rendimiento óptimo con diversificación.

Palabras Clave: Optimización, Portafolio eficiente, Algoritmos genéticos, Bolsa de valores.

Portfolio optimization with Genetic algorithms

Abstract

Investors try to maximize the return on their stock-market actions with minimal risk, this situation is complexed. The aim of this research is to generate investment portfolios made up of stock market actions of the companies that participate in the Mexican Stock-Market (BMV in the Spanish language) for the second half of the 2018 year. The methodology is based on applying genetical algorithms to a linear mathematical model, in order to create efficient portfolios that establish the optimal amount of investment in each of the selected financial instruments, in addition to generating diversification. After several tests with the genetical algorithm, the optimized portfolio was made up of the companies: Alsea, Arca Continental, Autlan, Banco del Bajío, Banorte, Cemex, G Mexico, Mexichem, Peñoles, Pinfra, and Vitro. The result was an investment portfolio with an optimum performance and diversification.

Keywords: Optimization, Efficient Portfolio, Genetical Algorithms, Stock-Market.



1. Introducción

La selección de un portafolio de inversión eficiente no es una tarea fácil, aunque existen aplicaciones y software que ayudan a elegir las mejores acciones siempre hay riesgos. La variabilidad de los precios de las acciones ocasionada por diversos eventos económicos ocasionan que los inversionistas tengan comportamientos adversos al riesgo que les brindan rendimientos mínimos (Epstein & Zin, 1989; Pratt, 1964).

De manera que, los inversionistas se enfrentan al problema de seleccionar las acciones que conforman su portafolio (Cohn, Lewellen, Lease, & Schlarbaum, 1975; Edesess, 1999; Giansante & Dragun, 2001). En el caso de la Bolsa Mexicana de Valores (BMV) participan 114 empresas emisoras, lo que genera complejidad en la elección.

Otro problema a considerar es el porcentaje idóneo que se destinará, del monto a invertir, a cada una de las acciones seleccionadas para lograr obtener el mayor rendimiento posible a un mínimo riesgo (Brinson, Hood, & Beebower, 1995; Friend & Blume, 1970; Grinblatt & Titman, 1989). La diversificación es importante, ya que permite reducir el riesgo de inversión.

Por tal motivo el uso de técnicas de optimización evolutivas (como los algoritmos genéticos) en problemas complejos, permiten encontrar buenas soluciones sin necesidad de ser experto en inversiones o para apoyar la toma de decisiones al conformar el portafolio de inversión. Otro problema emerge cuando el inversionista toma comportamientos conservadores que sólo obtiene el mínimo rendimiento (Aranha & Iba, 2009; Chang, Yang, & Chang, 2009; Soleimani, Golmakani, & Salimi, 2009; Yang, 2006).

El objetivo del documento es diseñar un portafolio de inversión, por medio algoritmos genéticos, con un rendimiento óptimo y diversificación. El documento está dividido en cinco secciones incluyendo la introducción. La segunda parte presenta una revisión de la literatura sobre trabajos referidos al modelo de Markowitz, y el cómputo evolutivo. La tercera sección muestra la metodología basada en un algoritmo genético modelado en el lenguaje de programación “R”. La cuarta sección muestra los resultados, y finalmente se

presentan las conclusiones del estudio. A continuación, se presenta la revisión de la literatura.

2. Revisión de la Literatura

2.1. Modelo Markowitz

Harry Markowitz planteó el término diversificación en los años 50. En su tesis doctoral, mencionó, que los inversionistas no solo se deben medir el riesgo de cada activo en forma individual, sino que, deberían evaluar el riesgo de toda la cartera (Markowitz, 1991).

En 1952 Harry Markowitz desarrolló la teoría moderna del portafolio que se refiere a la selección de los activos que conforman un portafolio de inversiones. De acuerdo a esta teoría se busca maximizar el rendimiento a un determinado nivel de riesgo o minimizar el riesgo a un determinado rendimiento, es decir, optimizar el portafolio de inversión. Así pues, para poder determinar portafolios eficientes se deben analizar los dos elementos que los integran: rendimiento y riesgo (Medina, Cruz & Restrepo, 2008).

A partir de ésta idea, se han diseñado distintos modelos de selección de instrumentos de inversión para conformar un portafolio, como son: modelo media – varianza, modelo media – semivarianza, costos por transacción y restricciones de enteros, por mencionar algunos, que consideran instrumentos con distintos niveles de riesgo a fin de asegurar un máximo rendimiento a un mínimo de riesgo.

Estos modelos son útiles para diseñar los portafolios de inversión, pero no se define cuál es la cantidad a invertir en cada acción, ni de qué forma se diversifica el portafolio. Las técnicas evolutivas de cómputo son útiles para resolver problemas complejos, de esta manera, modelos como el de Markowitz, pueden complementarse con técnicas evolutivas de cómputo para mejorar los resultados y hacer más sencilla la conformación de un portafolio de inversión.

2.2. Computación Evolutiva: Algoritmos Genéticos.

La programación evolutiva fue creada en la década de 1960 por L. J. Fogel (Streichert, Ulmer, & Zell, 2003; Tomassini, 1999). Este desarrollo comenzó como un esfuerzo



encaminado a crear inteligencia artificial basada en la evolución de máquinas de estado finito (Dachille, 2007).

El cómputo evolutivo es una técnica basada en la teoría de la evolución de las especies de Darwin, la teoría corpuscular de la herencia de Mendel y la herencia de caracteres adquiridos de Lamarck, además utiliza modelos computacionales de procesos evolutivos como elemento clave en el diseño e implementación de sistemas que resuelven problemas en una computadora (Palma & Marín, 2008).

Las estrategias evolutivas fueron propuestas por Ingo Rechenberg y Hans-Paul Schwefel en la década de 1970, su principal objetivo era resolver problemas de optimización de parámetros (Dachille, 2007), en general encontrar máximos, mínimos, identificar rutas críticas, optimizar estructuras o rutas, etc.

Las técnicas más conocidas del cómputo evolutivo son: los procesos de búsqueda evolutiva, las estrategias evolutivas, la programación evolutiva, los algoritmos genéticos y la programación genética. La diferencia entre cada técnica evolutiva consiste en la representación computacional de las soluciones candidatas o individuos.

Para el presente trabajo, se utiliza la técnica de algoritmos genéticos (Santana & Coello, 2006), ya que su naturaleza adaptativa, así como su implementación en diferentes lenguajes de programación (como “R”), permite que sean fáciles de usar. Por otro lado, existen diferentes modelos evolutivos aplicados a las finanzas basados en algoritmos genéticos, el presente trabajo es sólo una aproximación más.

Los algoritmos genéticos fueron desarrollados por John H. Holland en la década de 1975 y su motivación inicial fue proponer un modelo general de proceso adaptable (Davis, 1991; Goldberg & Holland, 1988).

Es importante resaltar que la capacidad evolutiva de los algoritmos genéticos, permite optimizar funciones en espacios adaptativos complejos. En particular, la amplia gama de instrumentos financieros de la Bolsa Mexicana de Valores (BMV), representa un espacio adaptativo amplio y complejo ideal para ser estudiado por medio de técnicas evolutivas.



La técnica de los algoritmos genéticos, ampliamente utilizada en ramas importantes de la ciencia, representan una alternativa de aplicación relativamente sencilla y novedosa para la resolución de problemas de naturaleza combinatoria (Dachille, 2007).

El funcionamiento de los algoritmos genéticos se basa en seis parámetros: 1) tamaño de la población, 2) selección, 3) función de fitness, adaptación o calidad, 4) cruza, 5) mutación y 6) condición de paro. Las soluciones candidatas o individuos se configuran, generalmente, en código binario, de manera que, el fenotipo de los cromosomas se recombina para crear nuevas generaciones. Los cromosomas se codifican como cadenas binarias, números enteros, o números con punto decimal. Todo depende del problema de optimización (Santana & Coello; 2006).

3. Metodología.

Esta sección se divide en tres partes, en primer lugar, se describe el caso de estudio (BMV). En la segunda parte se describe el modelo matemático basado en Markowitz y que sirve para diseñar el algoritmo genético. En la tercera parte se explica el algoritmo genético que se utiliza para conformar el portafolio de inversión eficiente y con diversificación.

3.1 Descripción del Caso de Estudio Seleccionado.

En este trabajo se presenta una metodología para conformar un portafolio de inversión eficiente con acciones de las emisoras nacionales que participan en el mercado de capitales de la BMV y establecer el monto óptimo que se invertirá en cada una de ellas con la implementación del método de computacional de optimización: algoritmos genéticos.

Se presenta una investigación no experimental, transversal y descriptiva, basada en un estudio de caso, ya que se basa en precios que se generaron entre agosto 2017 y julio 2018 de las emisoras nacionales de acciones del mercado de capitales que participan en la BMV.

Para el desarrollo de este trabajo se consideraron datos secundarios, ya que son los precios diarios durante agosto 2017 y julio 2018 de las acciones de cada una de las emisoras nacionales que participan en la BMV y se obtendrán de las páginas de la Bolsa Mexicana de Valores (www.bmv.com.mx) y del Banco de México (www.banxico.org.mx).



En el periodo a analizar participaron 114 emisoras (BMV 2018), según expertos de diversas casas de bolsa y analistas bursátiles las empresas con mejores rendimientos (Arteaga, 2017) son: a) El Director General Adjunto Grupo Financiero BX+, recomienda Alsea, Arca Continental, Fomento Económico Mexicano (Femsa), Banco del Bajío, Promotora y Operadora de Infraestructura (Pinfra) y Vitro. b) Por su parte, Grupo Financiero Monex coincide dentro de sus emisoras favoritas por su potencial de rendimiento en seleccionar a Alsea, Femsa y Arca Continental, mientras que suma a empresas como Peñoles, Autlán, Mexichem, Grupo Financiero Banorte, Banregio, y Grupo México. b) Finalmente Francisco Javier Orozco, del Tec de Monterrey, considera que Cementos Mexicanos (Cemex) puede ofrecer una oportunidad de inversión por su estrategia de pagos de deuda y la reactivación de la construcción en el vecino país del norte, lo que reeditarán en el valor de la firma.

Por tal motivo, las empresas que se han seleccionados para diseñar el modelo matemático a probar con algoritmos genéticos son: Alsea, Arca Continental, Autlán, Banco del Bajío, Cementos Mexicanos (Cemex), Grupo Financiero Banorte, Grupo México, Mexichem, Peñoles, Promotora y Operadora de Infraestructura (Pinfra) y Vitro.

Para diseñar el modelo matemático, basado en Markowitz, se obtuvo el rendimiento esperado, a partir de los precios de cada una de las acciones, de las emisoras publicados en la BMV y Banco de México (BANXICO), dichos precios se analizaron diariamente para el periodo agosto 2017 y julio 2018.

Ya obtenidos los rendimientos diarios de cada una de las acciones, se calculó la desviación estándar y el coeficiente de variación de dichos rendimientos, para establecer el riesgo asociado a cada instrumento, teniendo en cuenta que el instrumento con mayor desviación estándar es el más riesgoso del portafolio.

Una vez determinados el rendimiento y riesgo individuales, se desarrolló la función objetivo que resuelve el método de algoritmos genéticos para obtener el monto óptimo que se asigna a los instrumentos de inversión y lograr maximizar el rendimiento. La herramienta con la que se corre el algoritmo es “R”.

Ya optimizado el portafolio de acciones se calcula el rendimiento y riesgo, para después compararlo con los rendimientos y riesgos individuales

3.2. Determinación del Rendimiento Esperado y Riesgo por Acción.

Las empresas que se seleccionaron para conformar el portafolios de inversión son: Asea, Arca Continental, Autlán, Banco del Bajío, Cementos Mexicanos (Cemex), Grupo Financiero Banorte, Grupo México, Mexichem, Peñoles, Promotora y Operadora de Infraestructura (Pinfra) y Vitro. Por lo anterior el número total de emisoras consideradas son 11.

De acuerdo a los precios diarios de agosto 2017 a julio 2018 obtenidos, se calculó el rendimiento diario de cada uno de los instrumentos que conforman el portafolio, a continuación, se obtuvo su promedio y desviación estándar para calcular el riesgo (tabla 1).

Tabla 1. Rendimiento y desviación estándar para medir el riesgo.

Emisora	Rendimiento Promedio o Esperado	Desviación estándar
ALSEA	-0.0156%	0.0140
ARCA CONTINENTAL	-0.0117%	0.0119
AUTLAN	0.0520%	0.0135
BBAJÍO	0.0844%	0.0125
BANORTE	0.0649%	0.0164
CEMEX	-0.0156%	0.0159
GMEXICO	0.0300%	0.0166
MEXICHEM	0.1178%	0.0135
PE&OLES	-0.0969%	0.0197
PINFRA	0.0114%	0.0109
VITRO	-0.1031%	0.0174

Fuente: Elaboración propia.

Un ejemplo de inversión se muestra a continuación, al considerar un monto total de la inversión de \$1,000,000. Por lo anterior, la ecuación que describe la distribución de los instrumentos que conforman el portafolio queda de la siguiente forma:

$$Y1+Y2+Y3+Y4+Y5+Y6+Y7+Y8+Y9+Y10+Y11=1,000,000$$

donde:

Y1 = Alsea, **Y2** = Arca Continental, **Y3** = Autlan, **Y4** = BBajío, **Y5** = Banorte, **Y6** = Cemex, **Y7** = GMéxico, **Y8** = Mexichem, **Y9** = Pe&oles, **Y10** = Pinfra y **Y11** = Vitro.

Se calculan los rendimientos esperados con los precios diarios de agosto 2017 a julio 2018 de cada una de las acciones y se obtiene el rendimiento promedio, por lo que la función objetivo a optimizar es:

$$Z = -0.00015576Y1 + -0.00011687Y2 + 0.00052016Y3 + 0.00084352Y4 + 0.00064934Y5 + -0.00015576Y6 + 0.00029955Y7 + 0.00117849Y8 + -0.00096882Y9 + 0.00011396Y10 + -0.00103149Y11$$

La ecuación objetivo está sujeta a:

Y1, Y2, Y3, Y4, Y5, Y6, Y7, Y8, Y9, Y10 y Y11 no pueden ser negativas, ni mayores a 1,000,000

Y1 + Y2 + Y3 + Y4 + Y5 + Y6 + Y7 + Y8 + Y9 + Y10 + Y11 no puede ser mayor A 1,000,000.

El siguiente paso es dar solución a dicha ecuación para poder determinar los valores de las variables y así establecer la cantidad ideal para cada instrumento, logrando maximizar el rendimiento. La herramienta utilizada para realizar el cálculo es “R”

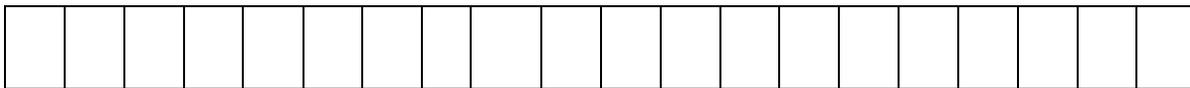
3.3. Algoritmo Genético en “R”.

Para realizar la simulación por medio del algoritmo genético, se utilizó el módulo “genalg” de R para diseñar el algoritmo genético adecuado a la función objetivo y restricciones propuestas.

Una de las principales características de los algoritmos genéticos es que su operación abstrae cualquier detalle de la estructura del problema. Ya que las variables de decisión se reducen a un cromosoma.

La forma estándar de trabajo es mediante cromosomas con genes binarios. Por tal motivo cada una de las variables consiste de un cromosoma de 20 bits (figura 1).

Figura 1. Cromosoma de 20 bits



Fuente: elaboración propia

Cada gen del cromosoma (casilla) puede tomar un valor binario (0 o 1), en una cadena binaria de 20 bits el valor mínimo es 0 y el mayor es 1,048,576 (figura 1), suficiente para los valores del problema de maximización con algoritmos genéticos.

Los algoritmos genéticos permiten recombinar los genes para buscar una solución máxima o mínima. La forma en como los algoritmos genéticos encuentran dichos valores es por medio de los operadores genéticos y la condición de paro.

Para el algoritmo genético utilizado en este trabajo los operadores genéticos son:

1. Tamaño de la población: indica cuantos cromosomas o individuos se utilizarán en cada generación, en este algoritmo el tamaño de la población por generación es de 100.
2. Selección: indica el número de individuos que se utilizarán para ser recombinados genéticamente y que representan a los padres de la siguiente generación, para este algoritmo se tiene una selección del 10%, por lo que el número de individuos seleccionados de forma elitista será de 200.
3. Fitness: es la función generada para optimizar el portafolios de inversión $Z = -0.00015576Y_1 + -0.00011687Y_2 + 0.00052016 Y_3 + 0.00084352Y_4 + 0.00064934Y_5 + -0.00015576Y_6 + 0.00029955Y_7 + 0.00117849Y_8 + -0.00096882Y_9 + 0.00011396Y_{10} + -0.00103149Y_{11}$

4. Tasa de cruza: en cada generación los hijos heredan un porcentaje determinado de genotipo de los padres, lo más usado es 50%, sin embargo, el cambiar valor de este operador genera resultados variados.
5. Tasa de mutación: en cada generación un porcentaje de la nueva población muta (como resultado del proceso evolutivo), en este caso la tasa de mutación es de 0.05%.
6. Condición de paro: se define de acuerdo a los resultados en cada prueba. El máximo alcanzado para este trabajo fue de 1000 generaciones.

De manera que, el número de generaciones, máximas, para este algoritmo genético fue de 1000, aunque se hicieron pruebas con diversos números de generaciones (100, 500), con esta cantidad de generaciones se obtuvieron los mejores resultados. Es importante hacer notar que mientras más generaciones se ejecutan en el algoritmo genético, mayor es el tiempo invertido para obtener resultados. En la siguiente sección se muestran los resultados obtenidos con el algoritmo genético.

4. Resultados.

Después de 100 generaciones en el algoritmo genético, los valores obtenidos para cada una de las variables son:

Para obtener el mejor rendimiento, dadas las condiciones del problema, se debe invertir las siguientes cantidades: $Y1 = 512$; $Y2 = 528$; $Y3 = 5128$; $Y4 = 303104$; $Y5 = 278530$; $Y6 = 258$; $Y7 = 2048$; $Y8 = 401408$; $Y9 = 2048$; $Y10 = 4230$; $Y11 = 768$.

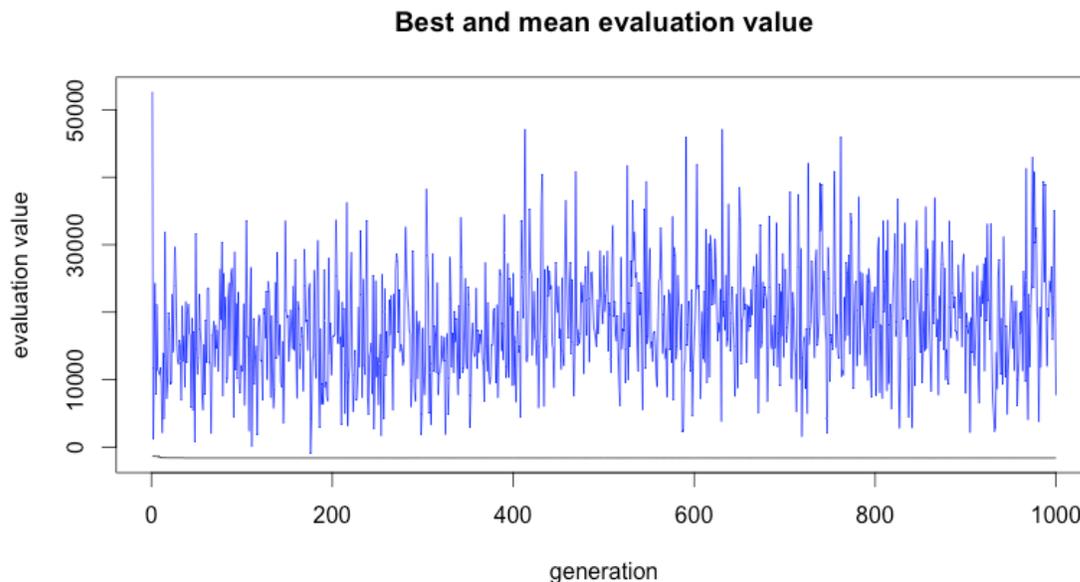
El portafolio optimizado quedará conformado por acciones de las empresas: Alsea, Arca Continental, Autlán, Banco del Bajío, Cementos Mexicanos (Cemex), Grupo Financiero Banorte, Grupo México, Mexichem, Peñoles, Promotora y Operadora de Infraestructura (Pinfra) y Vitro.

Se propone invertir \$512 en acciones de Alsea, \$528 en Arca Continental, \$5,128 en Autlán, \$303,104 en Banco del Bajío, \$278,530 en Cementos Mexicanos (Cemex), \$258 en

Grupo Financiero Banorte, \$2,048 en Grupo México, \$401,408 en Mexichem, \$2,048 en Peñoles, \$4,230 en Promotora y Operadora de Infraestructura (Pinfra) y \$768 en Vitro.

El Gráfico 1 muestra el comportamiento adaptativo de los mejores individuos en las 1000 generaciones obtenidas. Como puede notarse el algoritmo presenta un comportamiento adaptativo que se va regulando a lo largo del tiempo. En este ejemplo sólo se presenta el resultado de 100 generaciones.

Gráfico 1. Comportamiento del algoritmo genético



Fuente: Elaborado con el módulo “genalg” de R

En particular al invertir las cantidades óptimas calculadas en cada una de las acciones de las emisoras se obtiene un rendimiento mayor (0.1621%) al de los activos por individual, excepto Alsea cuyo rendimiento es igual al del portafolio optimizado. En la tabla 2 se presentan los rendimientos individuales y del portafolio optimizado.

Tabla 2. Rendimiento obtenido.

Emisora	Rendimiento individual	Mayor / menor	Rendimiento del portafolio
ALSEA	-0.0156%	MENOR	0.0912%
ARCA CONTINENTAL	-0.0117%	MENOR	0.0912%
AUTLAN	0.0520%	MENOR	0.0912%
BBAJÍO	0.0844%	MENOR	0.0912%
BANORTE	0.0649%	MENOR	0.0912%
CEMEX	-0.0156%	MENOR	0.0912%
GMEXICO	0.0300%	MENOR	0.0912%
MEXICHEM	0.1178%	MENOR	0.0912%
PE&OLES	-0.0969%	MENOR	0.0912%
PINFRA	0.0114%	MENOR	0.0912%
VITRO	-0.1031%	MENOR	0.0912%

Fuente: Elaboración propia.

5. Conclusiones

En el presente trabajo se muestra una propuesta del uso de los algoritmos genéticos para optimizar un portafolio de inversión basado en empresas emisoras de la BMV para el segundo semestre de 2018. De manera que, la aplicación de los algoritmos genéticos sirve como apoyo a los inversionistas en la selección óptima de acciones que conforman un portafolio de inversión diversificado, con la finalidad de obtener el máximo rendimiento posible.

Particularmente al invertir las cantidades óptimas calculadas en cada una de las acciones de las emisoras, se obtiene un rendimiento mayor (0.0912%) al de los activos por individual. De manera que el algoritmo genético utilizado sugiere invertir la mayor cantidad de la inversión total para maximizarlo.

El portafolio optimizado con algoritmos genéticos quedó conformado por acciones de las empresas: Alsea, Arca Continental, Autlán, Banco del Bajío, Cementos Mexicanos (Cemex), Grupo Financiero Banorte, Grupo México, Mexichem, Peñoles, Promotora y Operadora de Infraestructura (Pinfra) y Vitro.

Se propone invertir \$512 en acciones de Alsea, \$528 en Arca Continental, \$5,128 en Autlán, \$303,104 en Banco del Bajío, \$278,530 en Cementos Mexicanos (Cemex), \$258 en



Grupo Financiero Banorte, \$2,048 en Grupo México, \$401,408 en Mexichem, \$2,048 en Peñoles, \$4,230 en Promotora y Operadora de Infraestructura (Pinfra) y \$768 en Vitro. Por lo anterior, se puede observar en los resultados que el portafolio determinado está debidamente diversificado, al invertir en todas las emisoras recomendadas por los expertos. Se propone para futuros trabajos considerar a la totalidad de emisoras que participan en la BMV, e incluso en emisoras de mercados internacionales. Como trabajo futuro se mejorará la función objetivo y las restricciones tratadas para este caso, se considerarán otros factores o variables que mejoren la optimización del portafolio.

Es importante resaltar que el algoritmo genético propuesto, diversifica la inversión y obtiene los mejores resultados, sin embargo, depende del número de generaciones y los valores de los operadores genéticos. Por tal motivo será necesario realizar más pruebas para obtener mejores resultados.

Referencias

- Aranha, C., & Iba, H. (2009). The memetic tree-based genetic algorithm and its application to portfolio optimization. *Memetic Computing*, 1(2), 139–151.
- Arteaga, J. R. (2017) Las 5 empresas favoritas de la BMV para invertir en 2018, Alto nivel. Disponible en: <https://www.altonivel.com.mx/empresas/las-5-empresas-favoritas-la-bmv-invertir-en-2018/> (Consultado: 14 May 2018).
- Brealey, R., Myers, S. (1993). Principios de finanzas corporativas, Cuarta edición, 1202 páginas, Mc Graw Hill, Madrid.
- Brinson, G. P., Hood, L. R., & Beebower, G. L. (1995). Determinants of portfolio performance. *Financial Analysts Journal*, 51(1), 133–138.
- Chang, T.-J., Yang, S.-C., & Chang, K.-J. (2009). Portfolio optimization problems in different risk measures using genetic algorithm. *Expert Systems with Applications*, 36(7), 10529–10537.
- Cohn, R. A., Lewellen, W. G., Lease, R. C., & Schlarbaum, G. G. (1975). Individual investor risk aversion and investment portfolio composition. *The Journal of Finance*, 30(2), 605–620.
- Dacchille, C. (2007). Portafolios eficientes de inversion en la bolsa de valores.



- Davis, L. (1991). Handbook of genetic algorithms. Retrieved from <http://cumincad.scix.net/cgi-bin/works/Show?eaca>
- Edesess, M. (1999). *System and method for generating and displaying risk and return in an investment portfolio*. Google Patents. Retrieved from <https://www.google.com/patents/US5884287>
- Epstein, L. G., & Zin, S. E. (1989). Substitution, risk aversion, and the temporal behavior of consumption and asset returns: A theoretical framework. *Econometrica: Journal of the Econometric Society*, 937–969.
- Friend, I., & Blume, M. (1970). Measurement of portfolio performance under uncertainty. *The American Economic Review*, 60(4), 561–575.
- Giansante, J. E., & Dragun, B. C. (2001). *Investment portfolio selection system and method*. Google Patents. Retrieved from <https://www.google.com/patents/US6275814>
- Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine Learning*, 3(2), 95–99.
- Grinblatt, M., & Titman, S. (1989). Portfolio performance evaluation: Old issues and new insights. *Review of Financial Studies*, 2(3), 393–421.
- Markowitz, H. M. (1991). Foundations of portfolio theory. *The Journal of Finance*, 46(2), 469–477.
- Medina, V., Cruz, T., Restrepo, C. (2008). Portafolio de inversión en acciones un enfoque estocástico. *Scientia Et Technica*, XIV() 235-240. Recuperado de <http://www.redalyc.org/articulo.oa?id=84920503042>
- Palma, J., Marín, R. (2008). Inteligencia Artificial. Técnicas, métodos y aplicaciones. Editorial Mac Graw Hill. Primera edición. España. Pág. 433-437
- Pratt, J. W. (1964). Risk aversion in the small and in the large. *Econometrica: Journal of the Econometric Society*, 122–136.
- Santana, L., Coello, C. (2006)“Una introducción a la computación evolutiva y algunas de sus aplicaciones en Economía y Finanzas”, *Revista de Métodos Cuantitativos Para la Economía y la Empresa*, <http://www.upo.es/RevMetCuant/art4.pdf>, Consultado el 15/04/2007.



- Soleimani, H., Golmakani, H. R., & Salimi, M. H. (2009). Markowitz-based portfolio selection with minimum transaction lots, cardinality constraints and regarding sector capitalization using genetic algorithm. *Expert Systems with Applications*, 36(3), 5058–5063.
- Streichert, F., Ulmer, H., & Zell, A. (2003). Evolutionary algorithms and the cardinality constrained portfolio selection problem. In *Operations Research Proceedings 2003, Selected Papers of the International Conference on Operations Research (OR 2003)*. Citeseer. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.135.4263>
- Tomassini, M. (1999). Parallel and distributed evolutionary algorithms: A review. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.18.924>
- Yang, X. (2006). Improving portfolio efficiency: A genetic algorithm approach. *Computational Economics*, 28(1), 1–14.