

Diseño e implementación de un algoritmo genético para la predicción de una variable

Hilda Avelar Uribe¹, Ludivina Gutiérrez Torres¹, Ismael Zúñiga Félix²,
Zindi Sánchez Hernández¹

¹ Instituto Tecnológico de Nogales, Nogales, Sonora, México

² Instituto Tecnológico de Agua Prieta, Agua Prieta, Sonora, México

hilda.au@nogales.tecnm.mx, ludivina.gt@nogales.tecnm.mx,
iazuniga@gmail.com, sanchezhz@gmail.com

Resumen. Este artículo describe la aplicación de un algoritmo genético para obtener una mejor precisión de pronóstico de cualquier variable utilizando datos históricos. Para medir esta precisión, se utilizó el tipo de cambio peso mexicano - dólar estadounidense en México en comparación con las predicciones calculadas por el método estadístico de promedios móviles. El problema consiste en obtener los valores que minimizan el error cuadrático promedio entre el valor real y el valor de pronóstico para obtener una predicción con un margen de error mínimo. La aplicación del algoritmo genético fue diseñada utilizando cromosomas de representación real, el operador BLX-0.5 de cruce y el operador de mutación no uniforme por ser los operadores que ofrecen una mejor capacidad de exploración y explotación, lo que da como resultado el algoritmo genético que proporciona un aumento de precisión del 14% en comparación con la precisión del método estadístico de media móvil.

Palabras clave: algoritmos genéticos, predicción, promedios móviles.

Design and Implementation of a Genetic Algorithm for the Prediction of a Variable

Abstract. This article describes the application of a genetic algorithm to obtain a better forecast precision of any variable using historical data. In order to measure this precision, the exchange rate Mexican Peso – US Dollar in Mexico was used in comparison with the predictions calculated by the statistical method moving averages. The problem consisted of obtaining the values that minimize the average quadratic error between the real value and the forecast value to obtain a prediction with a minimum error margin. The genetic algorithm application was designed using the following real representation chromosomes: the crossing BLX-0.5 operator as well as the non-uniform mutation operator. These operators offer a better capacity on exploration and exploitation resulting in the genetic algorithm that provides a precision increase of 14% in comparison to the precision of the statistical moving average method.

Keywords: genetic algorithms, prediction, moving averages.

1. Introducción

La predicción es un pronóstico de lo que ocurrirá en el futuro y esto implica un proceso incierto. A causa de esta incertidumbre, se puede deducir que la exactitud del pronóstico es un factor muy importante en adición a la importancia que tiene el resultado señalado por la predicción [1].

La elección e implementación de un método adecuado de pronóstico siempre ha sido de importancia relevante, pues un error significativo en la precisión del pronóstico puede ocasionar problemas críticos y de diversas índoles cuando éste está involucrado en la toma de decisiones.

Actualmente existen básicamente tres tipos de métodos para el cálculo de predicciones los cuales son: los métodos cualitativos, los modelos causales y finalmente los modelos de series de tiempo.

Los métodos de carácter cualitativo se basan primordialmente en opiniones de expertos.

Los modelos de pronóstico causales parten del supuesto de que las variables que afectan al comportamiento a predecir permanecen estables, para luego construir un modelo que relacione ese comportamiento con la variable que se estima. Los modelos de series de tiempo, que son los métodos estadísticos, miden valores de una variable en el tiempo a intervalos espaciados uniformemente con el objetivo de determinar el patrón que existe en su comportamiento para así proyectar en el futuro la variable deseada [1].

El método más utilizado actualmente para el cálculo de pronósticos es el método estadístico de los promedios móviles, pues se considera uno de los mejores y más fáciles de utilizar.

Los métodos anteriormente mencionados presentan varias desventajas, entre las que se pueden señalar que utilizan un número determinado de datos, son más útiles para validar un modelo sugerido y preexistente pero no para generarlo y son restrictivos. Desventajas que pueden ser superadas aplicando un algoritmo genético, pues estos tienen como características principales que permiten manejar grandes cantidades de datos y además no requieren conocer con anticipación los datos que serán introducidos al algoritmo, estas ventajas ofrecen mayor efectividad y confiabilidad para las predicciones.

El presente artículo propone comparar la precisión de los pronósticos calculados con método estadístico promedios móviles contra la precisión obtenida en las predicciones realizadas mediante la aplicación de un algoritmo genético.

2. Antecedentes

El algoritmo genético es una técnica que está basada en la teoría de la evolución de Darwin que se fundamenta en los elementos de selección que utiliza la naturaleza, de acuerdo a los cuales los individuos más aptos de una población son los que sobreviven al adaptarse a los cambios que se producen en su ambiente, esta adaptación ocurre, pues las formas de vida no son estáticas sino que evolucionan, lo que quiere decir que las especies cambian continuamente, unas se originan y otras más se extinguen irremediamente [2].

Un punto importante de explicar es que la adaptación natural se lleva a cabo en dos fases, la primera de ellas es la producción de variabilidad, que es la generación de modificaciones espontáneas en los individuos, la segunda fase es la supervivencia en la lucha por la vida donde los individuos mejor dotados, que son los que han nacido con características favorables para hacer frente al medio ambiente, van a contar con más posibilidades de sobrevivir, reproducirse y dejar descendencia.

Los algoritmos genéticos usan una analogía directa con el comportamiento natural, trabajan con una población de ejemplares, cada uno de los cuales representa una solución factible a un problema dado, a cada ejemplar se le asigna un valor relacionado con dicha solución, cuanto mayor sea la adaptación de un ejemplar al problema, mayor será la probabilidad de que el mismo sea seleccionado para reproducirse, cruzando su material genético con otro ejemplar seleccionado de igual forma. Este cruce producirá nuevos ejemplares descendientes de los anteriores los cuales comparten algunas de las características de sus padres.

Cuanto menor sea la adaptación de un ejemplar, menor será la probabilidad de que dicho individuo sea seleccionado para la reproducción, y por tanto de que su material genético se propague en sucesivas generaciones, de ésta manera se produce una nueva población de posibles soluciones. De tal forma que a lo largo de las generaciones las buenas características se propagan a través de la población, favoreciendo el cruce de los ejemplares mejor adaptados, van siendo exploradas las áreas más prometedoras del espacio de búsqueda.

Si el algoritmo genético ha sido bien diseñado, la población convergerá hacia una solución óptima del problema.

El método estadístico de Promedios Móviles (PM) calcula pronósticos eficaz y eficientemente cuando las series de tiempo son estacionarias tanto en media como en varianza. La fórmula (1) es utilizada para encontrar los promedios móviles de orden n , $PM(n)$ para un período $t+1$ [1]:

$$PM_{t+1} = [Dt + D_{t-1} + \dots + D_{t-n+1}] / N. \quad (1)$$

Donde N es el número de observaciones utilizadas en los cálculos y D es el dato observado en el tiempo t .

La principal desventaja que presenta es que se usa para hacer pronósticos a corto plazo, pero las ventajas que tiene es que requieren de pocos datos y los resultados son bastante aceptables. Las características de los promedios móviles son:

- El promedio móvil es calculado con cierto período de tiempo predefinido.
- Mientras más corto es el período, mayor es la probabilidad de una señal falsa.
- Mientras más largo es el período, menor es la sensibilidad del promedio móvil.

3. Planteamiento del problema

En la actualidad la información está afectando cada vez más a las sociedades, gobiernos, industrias, comunidades y personas. La era de la información está provocando transformaciones sorprendentes en la mayoría de las áreas de la actividad humana, como por ejemplo, ningún gerente o persona responsable de la toma de decisiones, puede ignorar la importancia de la información, ya que la mayor parte de

los éxitos provienen de ella, de hecho muchos de los fracasos empresariales son consecuencia de un uso indebido de la información, de una mala interpretación de la misma y en muchas ocasiones porque no se detecta información que se encuentra oculta dentro de los datos que se manejan día a día y que podrían ser de gran utilidad para la aplicación de nuevas estrategias o resolución anticipada de problemas que se pueden presentar en un determinado momento.

Uno de los aspectos más importantes es poder predecir cómo se desenvolverá una variable en el futuro, constituyendo una información muy valiosa y que representa una innegable ventaja competitiva, dicha información tiene un indiscutible interés, tanto desde el punto de vista comercial, como de servicios y control de procesos. El hecho de poder predecir el comportamiento de cierta variable puede ser útil en diversas áreas, que van desde la detección de oportunidades, prevención de problemas y gestión óptima del personal, por solo mencionar algunas.

Actualmente existen diversos métodos estadísticos para hacer predicciones, entre los más utilizados está el método de los promedios móviles que tiene como objetivo efectuar un cálculo estimativo sobre eventos futuros [3] pues se considera uno de los mejores y más fáciles de utilizar, las ventajas que tiene es que requieren de pocos datos y los resultados son bastante aceptables. Pero también presenta desventajas que son de gran peso al momento de realizar una predicción entre las que se pueden mencionar:

- Utilizan un número determinado de datos.
- Son más útiles para validar un modelo sugerido y preexistente, pero no para generarlo.
- Son restrictivos, es decir, puede ser que los datos no satisfagan los requerimientos del análisis.
- Sólo pronostica un período más.
- Si el comportamiento de las variables no es estable, los pronósticos calculados por este tipo de modelo dejan de ser acertados.

De esta forma surge el problema de cómo lograr conocer con anticipación y confiabilidad el comportamiento de una determinada variable que se encuentra en datos históricos, que indique una tendencia o problema que por el momento se encuentra oculto dentro de la gran cantidad de datos, pero que de una manera u otra, estos datos nos podrían guiar al descubrimiento de estas posibles tendencias y por lo tanto nos permita encontrar soluciones a tiempo o detectar oportunidades que nos ofrezcan una ventaja competitiva.

4. Estado del arte

Originalmente los algoritmos genéticos fueron diseñados para aplicaciones de búsqueda y optimización, pero en la actualidad existen algunos trabajos de investigación cuyo objetivo es mejorar la precisión en la predicción. Se plantea [4] que es posible aplicar algoritmos genéticos para predecir la variación en los precios del cobre, con el fin de mejorar el grado de certeza al incorporar la inversa del porcentaje de predicción de signo PPS.

En otra fuente [6], se sostiene que, aunque los algoritmos genéticos se diseñaron originalmente como método de optimización, también pueden ser utilizados, en el

contexto económico, como herramienta predictiva de los cambios en la composición de una población, en términos de las características individuales de los agentes que la componen. En este documento, se desarrolla un algoritmo genético específico capaz de predecir los cambios en las características de los turistas que visitan el sur de Tenerife. Los resultados obtenidos sugieren la conveniencia de sustituir los tradicionales operadores de cruce y mutación por la acción de una adecuada matriz de transición. Esta matriz dirige la dinámica de transformación de la población en el sentido de que permite introducir consideraciones económicas que otorgan mayores probabilidades a ciertas transformaciones en las características de los turistas que visitan la Isla.

La combinación de predicción de series temporales y la Programación Genética ha tomado fuerza debido a su capacidad de deducir la ecuación y aquellos parámetros que mejor aproximan la relación entre la variable de salida y el conjunto de variables de entrada [5], sin embargo, al ser esta aplicada en la predicción de series de tiempo presenta limitaciones que para ser superadas, es necesario modificar la estructura del algoritmo de programación genética original, la función de aptitud, los operadores de selección, intensificación, reproducción, mutación y cruce.

Inspirado en el proceso de evolución natural, el algoritmo genético está diseñado para resolver problemas de optimización y búsqueda mediante el uso de algunos operadores básicos, como la mutación, el cruce y la selección. Los algoritmos genéticos son usados como una herramienta de búsqueda global efectiva por lo que son usados en el campo de las ciencias aplicadas. Existen algunos estudios sobre los que se ha informado recientemente en el que se ha usado a los algoritmos genéticos para la predicción de la quiebra de empresas [11].

5. Metodología

El algoritmo genético desarrollado es de tipo elitista, es decir, incluye un proceso de selección que es mejorado con una estrategia con la cual se asegura la convergencia hacia el individuo con el valor más óptimo en cada generación.

Se utilizó un cromosoma formado por dos genes, donde cada gen es el valor A y el valor B de la función de la recta, la cual es utilizada para calcular los pronósticos, la representación utilizada fue la forma directa, consistiendo en un vector de números reales. Se utilizó la representación real, ya que, si se utilizaba la binaria, al momento de realizar conversiones se perdía precisión numérica y esto no es favorable ya que dicha precisión es un factor muy importante en las predicciones de este tipo, además que la representación de las soluciones potenciales del problema son puntos clave al trabajar con algoritmos genéticos.

Existen tres operadores básicos para el desarrollo de un algoritmo genético, el operador de selección el cual se asegura de la supervivencia de los individuos mejor adaptados dentro de la población, mientras que los operadores de cruce y mutación aseguran la combinación y la diversidad de los cromosomas seleccionados para generar nuevos individuos. El operador de selección utilizado en esta investigación fue el método de la ruleta mejorado, con este método la probabilidad que tiene un individuo de reproducirse es proporcional a su valor de función de evaluación, es decir, a su adaptación.

A causa de esta característica, se implementó este tipo de selección pues para realizar las predicciones se busca al individuo más apto de acuerdo a su ambiente. Una vez calculadas estas probabilidades, la selección de los individuos para reproducirse es aleatoria según estos valores. El método de selección se divide en dos pasos, en el primer paso se forma el espacio de selección acumulativa, utilizando el valor de aptitud de cada uno de los individuos de la población como se muestra en (2) [8]:

$$cul_j = \frac{\sum_{i=1}^j fit_{raw}}{\sum_{i=1}^{NPopSize} fit_{raw}}, 1 \leq j \leq NPopSize \quad (2)$$

donde:

fit: Valor de aptitud, el error de estimación calculado de cada cromosoma,
cul: Valor acumulado del total de fits.

Posteriormente, un coeficiente de adaptación es establecido, el cual tiene la finalidad de crear diferentes niveles de presión a los individuos de la población conforme aumenta el número de generaciones, fit_{max} representa el máximo, es decir el cromosoma con menor error de estimación y fit_{min} representa el mínimo valor de aptitud, es decir el cromosoma con mayor error, dentro de la misma generación. La aptitud escalada es calculada como en (3):

$$fit_{Scale} = \frac{fit_{max} - fit + \gamma}{fit_{max} - fit_{min} + \gamma} \quad (3)$$

Utilizada como función de optimización para minimizar. El valor γ se encontrará entre el rango que se muestra en (4):

$$2.5 \bullet (fit_{max} - fit_{min}) \text{ hasta } 0.25 \bullet (fit_{max} - fit_{min}), \quad (4)$$

conforme avance la generación desde 0 hasta N, para incrementar la presión de selección entre el mejor y el peor individuo dentro de una generación durante la evolución.

Después en el proceso de selección, se genera un valor aleatorio entre el rango de 0 y 1 que simulará el proceso de girar de la rueda, el cual está representado en (5):

$$r_k \in [0,1], 1 \leq k \leq NPopSize \quad (5)$$

El individuo X_n será seleccionado si satisface la regla (6):

$$cul_{n-1} \leq r_k \leq cul_n, 1 \leq n \leq NPopSize \quad (6)$$

El operador de cruce permite realizar una exploración de toda la información almacenada en la población y combinarla para crear mejores individuos. Existen diversos operadores de cruce que se utilizan según sea la representación que tenga el cromosoma. Para el desarrollo e implementación del algoritmo genético propuesto, se utilizó el operador de cruce BLX-0.5, debido a que con $\alpha=0.5$, BLX ofrece un mejor

balance entre explotación y exploración [8], además si el cromosoma tiene más de un gen, este operador puede ser aplicado a cada uno de los genes con una probabilidad de $P_{BLX-\alpha}$.

El Cruce BLX- α establece que un descendiente es generado: $H = (h_1, \dots, h_i, \dots, h_n)$, donde h_i es un número aleatorio uniforme escogido del intervalo $[c_{\min} - I \cdot \alpha, c_{\max} + I \cdot \alpha]$, donde $c_{\max} = \max(c_{1i}, c_{2i})$, $c_{\min} = \min(c_{1i}, c_{2i})$ e $I = c_{\max} - c_{\min}$.

El objetivo del operador de mutación es producir nuevas soluciones a partir de la modificación de un cierto número de genes de una solución existente, con la intención de fomentar la variabilidad dentro de la población. Existen muy diversas formas de realizar la mutación, desde la más sencilla conocida como puntual, donde cada gen muta aleatoriamente con independencia del resto de genes, hasta configuraciones más complejas donde se tienen en cuenta la estructura del problema y la relación entre los distintos genes [7].

En la presente investigación se implementó la mutación no uniforme por presentar la característica de que al inicio de la evolución explora de una manera más global en el espacio de búsqueda y de manera más local durante el avance de la evolución. Por el contrario, en la mutación uniforme la exploración siempre es de manera global, lo que puede ocasionar que la mutación nos provea un cromosoma que ya no es tan apto conforme el progreso del algoritmo genético avanza.

La mutación no-uniforme se define de la siguiente manera [8]:

Si este operador es aplicado en una generación t , y g_{\max} es el número máximo de generaciones, entonces se aplica (7):

$$c'_i = \begin{cases} c_i + \Delta(t, b_i - c_i) & \text{si } \tau = 0, \\ c_i - \Delta(t, c_i - a_i) & \text{si } \tau = 1, \end{cases} \quad (7)$$

donde τ es un número aleatorio el cual puede tener el valor de cero o uno, y se calcula con (8):

$$\Delta(t, y) = y \left(1 - r \left(1 - \frac{t}{g_{\max}} \right)^b \right), \quad (8)$$

donde r es un número aleatorio del intervalo de $[0, 1]$ y b es un parámetro que determina el grado de dependencia sobre el número de interacciones y usualmente tiene un valor entre 1 y 5. Esta función da un valor en el rango de $[0, y]$ tal que la probabilidad de regresar un número cercano a cero incrementa conforme avanza el algoritmo. El tamaño del intervalo de la generación del gen será menor conforme pasan las generaciones. Dicha propiedad causa que este operador realice una búsqueda uniforme en el espacio inicial cuando t es pequeña y muy local en estados posteriores.

Se establecieron probabilidades para que el algoritmo genético sea capaz de determinar si debe o no aplicar estos operadores, cabe mencionar que ambos operadores utilizan probabilidades independientes y esta probabilidad fue aplicada a nivel gen.

Finalmente, como función de aptitud se utilizó el error cuadrático medio, ya que este permite calcular la precisión del grado de correspondencia entre un valor pronosticado y un valor observado, donde por valor observado se entiende que es aquel valor que es el real.

El error cuadrático medio, está definido como (9) [9]:

$$ECM = \sqrt{\frac{\sum_{i=1}^N (\phi_i - \phi_{iObs})^2}{N}} \quad (9)$$

donde ϕ_i = Valor Pronosticado,
 ϕ_{iObs} = Valor Observado,
N = Número de valores analizados.

Cabe mencionar que el error cuadrático medio nos da la medida de las diferencias en promedio de los valores pronosticados y los observados.

6. Resultados

Para comprobar la certeza de las predicciones obtenidas con el algoritmo genético, se tomaron los datos históricos USD/MXN de Investing.com de febrero de 1976 a abril del 2019, por lo tanto, se obtuvo una población total de 514 datos [10].

Se tomaron dos muestras distintas en tiempo y cantidad de datos para comprobar la precisión del algoritmo genético diseñado, en ambas comprobaciones se tomaron los mismos 200 datos para entrenar al algoritmo, en la primera verificación se utilizaron 314 valores para comprobar los resultados de las predicciones y en la segunda verificación se tomó una muestra de 112 valores en un rango de fechas diferentes a la primera comprobación.

Los datos tomados para el entrenamiento del algoritmo genético se muestran en la tabla 1 y los pronósticos obtenidos en la primera comprobación se muestran en la tabla 2.

En la figura 1 se muestran los resultados del comportamiento de las predicciones realizadas por el algoritmo genético, los pronósticos calculados por el método de promedios móviles, así como los datos reales de la primera muestra utilizada de 314 valores para la comprobación de la precisión del algoritmo genético diseñado. En la figura 2 se muestran los resultados obtenidos con la segunda muestra de 112 datos.

En ambos casos es posible observar que la línea punteada color verde que representa los pronósticos calculados con los promedios móviles sigue solamente la tendencia de los datos originales que están representados por la línea punteada color negro, sin embargo, se puede observar claramente cómo la línea, color rojo, que representa las predicciones obtenidas con el algoritmo genético sigue muy de cerca la línea de los datos originales. Además, se puede notar que en los puntos de inflexión cuando las variaciones en el tipo de cambio son más abruptas, el algoritmo genético muestra mayor precisión en la predicción que las realizadas con el método estadístico de promedios móviles.

Las predicciones realizadas con el algoritmo genético diseñado con la muestra de 314 valores tienen un porcentaje de precisión del 91%, pues de los 314 datos que se predijeron se acertaron con un margen de error del $\pm 5\%$ 285 datos, además estos resultados se compararon con las predicciones hechas utilizando el método estadístico de los promedios móviles, en el cual se obtuvo un porcentaje de precisión del 77% al predecir con un margen de error del $\pm 5\%$ 241 datos de los 314.

En la muestra de 112 datos se obtuvo un porcentaje de precisión del 88%, pues de los 112 datos que se predijeron se acertaron con un margen de error del $\pm 5\%$ 99 datos, en las predicciones calculadas utilizando el método estadístico de los promedios

móviles, se obtuvo un porcentaje de precisión del 68% al predecir con un margen de error del $\pm 5\%$ 76 datos de los 112.

Tabla 1. Datos utilizados para el entrenamiento del algoritmo genético.

Fecha	Dato	Fecha	Dato	Fecha	Dato
7/3/1976	0.01250	7/2/1990	2.85990
8/1/1976	0.02050	8/1/1990	2.87730
9/4/1976	0.01980	9/3/1990	2.88830
10/2/1976	0.02541	10/1/1990	2.89670
11/1/1976	0.02125	11/5/1990	2.92070
12/1/1976	0.01998	12/3/1990	2.93270
1/2/1977	0.02263	1/2/1991	2.94470
10/1/1977	0.02274	10/1/1991	3.05350
.....
3/3/1987	0.02274	3/2/1992	3.06110
4/1/1988	0.02274	4/1/1992	3.06090
5/2/1980	0.02273	5/4/1992	3.08160

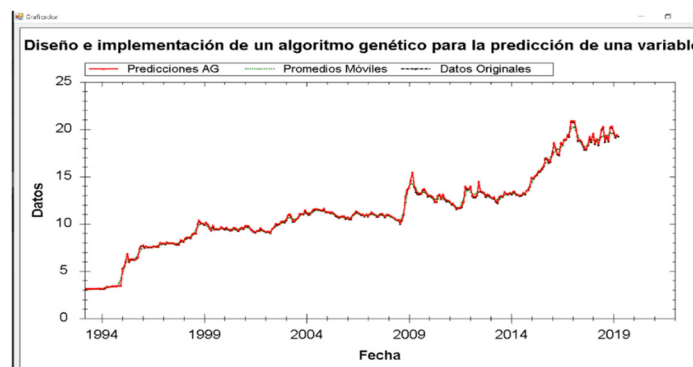


Fig. 1 Comportamiento del Algoritmo Genético comparado con el método de Promedios Móviles. Primera comprobación con una muestra de 314 datos.

Tabla 2. Datos utilizados para comparar los resultados del algoritmo genético y el método de los promedios móviles con la muestra de 314 datos.

Fecha	Real	AG	PM	Fecha	Real	AG	PM
3/1/1993	3.0939	0	0	7/2/2018	20.1453	19.98064955	18.90372
4/1/1993	3.094	3.118735155	0	8/1/2018	18.5899	20.26124078	19.2527
5/3/1993	3.1079	3.118835689	0	9/3/2018	19.2137	18.69753028	19.19848
6/1/1993	3.1264	3.132809957	0	10/1/2018	18.6531	19.32466325	19.38188
7/1/1993	3.1292	3.151408802	0	11/1/2018	20.1329	18.76106796	19.29364
8/2/1993	3.1162	3.154223763	3.11028	12/3/2018	20.2346	20.24877453	19.34698
9/1/1993	3.1137	3.141154304	3.11474	1/2/2019	19.5878	20.35101791	19.36484
10/1/1993	3.1163	3.138640946	3.11868	2/1/2019	19.1098	19.70076206	19.56442



Fig. 2 Comportamiento del Algoritmo Genético comparado con el método de Promedios Móviles. Segunda comprobación realizada con una muestra de 112 datos.

7. Conclusiones

De acuerdo con los resultados obtenidos en la presente investigación, se puede concluir que el algoritmo genético permite obtener una mayor precisión en las predicciones para una variable en una colección de datos históricos, que el método estadístico promedios móviles.

Uno de los aspectos más importantes, aunado al logro del incremento en la precisión del pronóstico es, como puede verse en la Fig. 1 y Fig. 2, el hecho de que el algoritmo genético sigue a los datos reales mucho más de cerca que el método estadístico de promedios móviles. Ya que el algoritmo genético alcanza a las subidas y bajadas de los precios del dólar tan de cerca que a veces se confunde con los datos reales. Como resultado de lo anterior se presenta una mayor precisión en la predicción.

Para realizar la predicción se utilizaron dos poblaciones una de 314 datos y otra de 112 datos. En la primera la precisión fue de 91%, comparada con la precisión obtenida por promedios móviles que fue de 77%. Obteniéndose un aumento en la precisión por el uso del algoritmo genético del 14%.

Sin embargo, cuando se disminuyó el tamaño de la población se obtuvieron otros resultados, donde la precisión disminuyó a 88%, y para promedios móviles se obtuvo un valor de 68%.

Por lo tanto, el mejor resultado se obtuvo para una población de datos mayor como puede apreciarse. En investigaciones posteriores puede explorarse este aspecto del tamaño de la población de tal forma que pueda buscarse un tamaño de población óptimo. Esto constituye una información muy valiosa ya que representa una innegable ventaja competitiva. Lo anterior tiene un indiscutible interés, tanto desde el punto de vista comercial, como de servicios y control de procesos, pues el hecho de poder predecir el comportamiento de una cierta variable con un alto grado de precisión puede ser muy útil en diversas áreas, que tengan un especial interés en una acertada predicción.

Referencias

1. University of Baltimore, <http://home.ubalt.edu/ntsbarsh/Business-stat/stat-data/Forecast.htm>. Último acceso: 2019/05/07
2. Jimenez-Builes, J., Arango-Sanchez R., Jimenez-Pinzón, J.: Métodos de búsqueda usando los algoritmos de enjambre de partículas y genético. *Lámpsakos*, no. 16, pp. 52–60 (2016)
3. Contreras Juárez, A., Atziry Zuñiga, C., Martínez Flores, J., Sánchez Partida, D.: Análisis de series de tiempo en el pronóstico de la demanda último de almacenamiento de productos perecederos. *Estudios Gerenciales* (32), pp. 387–396 (2016)
4. Carrasco, R., Soto, I., Adasme, P., Alfaro, M., Vargas, E.: Pronósticos de precios del cobre usando algoritmos genéticos: En: XXI Congreso ACCA 2014 Asociación Chilena de Control Automático, pp. 1–7 (2014)
5. Martínez, C.: Generación Automática de Modelos de Pronóstico usando Bloques Funcionales y Programación Genética. Universidad Nacional de Colombia, Facultad de Minas, Doctorado en Ingeniería–Ingeniería de Sistemas, Medellín, Colombia (2016)
6. Hernández-López, M.: Predicción mediante algoritmos genéticos con matriz de transición. Una aplicación a la demanda turística en Tenerife. Facultad de Ciencias Económicas y Empresariales, Tenerife. Islas Canarias. España (2015)
7. Sosa, H., Villagra, S., Villagra A.: Operadores de mutación en algoritmos genéticos celulares aplicados a problemas continuos. En: ICT-UNPA-86-2014, Caleta Olivia (2014)
8. Herrera, F., Lozano, M., Verdegay, J.: Tackling Real-Coded Genetic Algorithms: Operators and Tools for Behavioural Analysis. *Artificial Intelligence Review* 12(4), 265–319 (1998)
9. IArtificial.net Inteligencia Artificial y Machine Learning en Español, <https://iartificial.net/error-cuadratico-medio-para-regresion/>. Último acceso: 2019/05/07
10. Investing.com: <https://es.investing.com/currency/usd-mxn-historical-data>. Último acceso 2019/05/07
11. Chou, C.-H., Hsieh, S.-C., Qiu, C.-J.: Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, vol. 56, pp. 298–316 (2017)