

# PREDICCIÓN DE VARIACIONES EN EL PRECIO DEL PETRÓLEO CON EL MODELO DE OPTIMIZACIÓN ARIMA, INNOVANDO CON FUERZA BRUTA OPERACIONAL

Prediction of oil price variations with ARIMA optimization model, innovating with gross operating force

Tec Empresarial, Abril - Julio 2019,  
Vol 13 Núm 1 / p. 53-70

**Antonino Parisi Fernández**  
aparisi5555@gmail.com

Doctor en Economía y Finanzas por la Universidad Complutense de Madrid, España. Académico en la Facultad de Ingeniería y Negocios, Universidad Adventista de Chile.

**Luis Améstica Rivas**  
lamestica@ubiobio.cl

Doctor en Administración y Dirección de Empresas por la Universidad Politécnica de Cataluña, España. Académico en el Departamento de Gestión Empresarial, Facultad de Ciencias Empresariales, Universidad del Bío-Bío, Chile.

**Óscar Chileno Trujillo**  
elielchileno@gmail.com

Ingeniero Comercial, Facultad de Ingeniería y Negocios, Universidad Adventista de Chile.

- Recepción del artículo: 9 junio, 2017.
- Aprobación del artículo: 25 marzo, 2018.

## ABSTRACT

The present study evaluates the effectiveness of the multivariable ARIMA model with brute force for the case of the oil price, predicting the behavior of the shares in the following week of a last analyzed date. The objective is to construct a predictive model with a percentage of prediction higher than 50% and, therefore, to improve the decision making for the investors. We used the available information on the oil quotation and shares of the financial web site of three companies, Exxon Mobil, Gazprom and Ros-

Keywords: Arima, brute force, oil, return, price.

neft, during the period from February 4th, 2011, to February 4th, 2016. It was possible to observe the variation of prices, and to compare the actual data with the variations predicted with the model. We used 12 variables, generating 100,000 random iterations with brute force, without simplex and/or solver optimization, which limited the obtaining results. With the brute-force technique, a prediction capacity of more than 60% could be established for the case of oil prices and oil company stocks.

## RESUMEN

La presente investigación evalúa la eficacia del modelo ARIMA multivariable optimizado con fuerza bruta para el caso del precio del petróleo, con el fin de predecir el comportamiento de las acciones a la semana siguiente de una última fecha analizada. El objetivo es construir un modelo predictivo con un porcentaje de predicción de signo superior al 50% y, por consiguiente, mejorar la toma de decisiones para los inversionistas. Se utilizó la información disponible de la cotización del petróleo y acciones del portal web de finanzas de tres empresas, Exxon Mobil, Gazprom y Rosneft, comprendidos en el pe-

Palabras clave: Arima, fuerza bruta, petróleo, retorno, precio.

riodo del 4 de febrero de 2011 al 4 de febrero de 2016, durante el cual se pudo observar la variación de los precios, y así poder comparar los datos reales con las variaciones pronosticadas a través del modelo. Se utilizaron 12 variables, generando 100.000 iteraciones aleatorias con fuerza bruta, dado que la optimización por *simplex* o *solver* limitaba la obtención de algún resultado. Con la técnica de fuerza bruta se pudo establecer una capacidad de predicción superior al 60% para el caso del precio del petróleo y las acciones de empresas petroleras.

## » INTRODUCCIÓN

En las finanzas, predecir el cambio de precio de los valores es un tema que ha concentrado el interés de muchos actores; analistas, inversionistas individuales e institucionales, académicos, aficionados, entre otros. Sin embargo, hasta hoy se han adoptado distintos modelos o procedimientos que buscan la certeza total en los comportamientos accionarios, difícilmente encontrando una solución para predecir las situaciones futuras e inciertas.

En esta investigación se construye y se aplica un Modelo Autorregresivo Integrado de Promedio Móvil (ARIMA), al cual se agregan variables exógenas y se le adapta un método de fuerza bruta operacional (Parisi, 2015; Parisi, Améstica y Chileno, 2016), que permitirían construir infinitos escenarios aleatorios, encontrando un coeficiente sintético después de alcanzar la máxima capacidad de trabajo de un ordenador en ambiente Excel, con el objetivo de predecir los cambios en los signos del precio de un activo financiero y que, para el caso de este estudio, se circunscribe al comportamiento del precio del petróleo y de las acciones de tres empresas representativas del sector, como son Exxon Mobil, Gazprom y Rosneft, las cuales se tranzan en el mayor mercado de valores del mundo, como es el New York Stock Exchange (NYSE). Es bien sabido que analizar el sector del petróleo es de gran importancia por su contribución a la economía mundial y su carácter estratégico en todo el proceso de globalización (Haro del Rosario, Saraite, Caba y Gálvez, 2016).

Han sido muchos los autores que han realizado una revisión de los métodos para predecir índices bursátiles, que van desde aquellos que logran capturar las características lineales, pasando por los que se enfocan en las características no lineales y, finalmente, métodos híbridos (García, Jalal, Garzón

y López, 2013); sin embargo, aquellos menos tradicionales han sido menos citados. Asimismo, cada vez más, hallazgos recientes en finanzas indican la necesidad de una colaboración interdisciplinaria de profesionales de economía, matemáticas, física, econometría, psicología, neurociencia, entre otros (Hernández, 2010), especialmente en las decisiones financieras.

El concepto de técnica de fuerza bruta en mercados financieros fue acuñado hace poco tiempo (Parisi, 2015; Parisi, Améstica y Chileno, 2016) como método predictor, se puede considerar una continuación y desarrollo lógico a partir de investigaciones anteriores basadas en autores como: Arango, Velásquez y Franco (2013), quienes utilizan técnicas de lógica difusa para predecir índices accionarios; Atsalakis (2016), quien innova en un modelo que busca predecir los precios del carbono usando inteligencia computacional; y Fan, Wang y Li (2016), quienes establecen un modelo de red de percepción multicapa para hacer predicciones a corto plazo después de identificar las características caóticas del precio del carbón. Asimismo, encontramos a Pierdzioch, Risse y Rohloff (2015), quienes utilizan métodos artificiales para la predicción en la fluctuación del precio del oro, de manera muy parecida a los investigadores Shafiee y Topal (2010), quienes anteriormente trataron de prever el precio del oro. Según Parisi (2015), las técnicas antes mencionadas cada vez han ido mejorando en su capacidad predictiva gracias a los avances computacionales en velocidad y tratamiento de datos, lo cual no justifica buscar los llamados “atajos” y se hace atingente la no utilización de algoritmos en primera diferencia, sino que es mejor usar directamente fuerza bruta en primera diferencia, es decir, las variables alcanzarían valores cero si es que el coeficiente generado a través de números aleatorios llega a valor del coeficiente cero.

**La presente investigación evalúa la eficacia del modelo ARIMA multivariable optimizado con fuerza bruta para el caso del precio del petróleo, con el fin de predecir el comportamiento de las acciones a la semana siguiente de una última fecha analizada**

Tal como se señaló anteriormente, los comportamientos en el mercado no son 100% impredecibles, aunque en cierta medida sí lo son, alrededor de un 60% y 70%, en la variación de signo (Fama y French, 1992), y según lo evidenciado en trabajos posteriores para algunos mercados (Parisi, Parisi y Díaz, 2006).

Es en este contexto que este estudio explica, en una primera parte, los modelos actuales según distintos autores contemporáneos, que buscan la mejor predicción de variaciones de precios; luego se establecen los objetivos y alcances metodológicos por uso de la técnica de fuerza bruta de estudio para el caso del sector petrolero; se concluye con los resultados y conclusiones finales.

## REVISIÓN DE LITERATURA

El estudio se ha limitado a caracterizar los modelos de predicción de precios en base a inteligencia artificial, los cuales tienen adeptos y detractores, y están en constante revisión y desarrollo.

### Algoritmos genéticos

Los algoritmos genéticos consisten en una función matemática o una rutina que simula el proceso evolutivo de las especies, teniendo como objetivo encontrar soluciones a problemas específicos de maximización o minimización (Holland, 1975). Así, el algoritmo genético recibe como entrada una generación de posibles soluciones para el problema que se trate, y arroja como salida los especímenes más aptos (es decir, las mejores soluciones) para que se apareen y generen descendientes, los que deberían tener mejores características que las generaciones anteriores.

Los algoritmos genéticos trabajan con códigos que representan a cada una de las posibles soluciones al problema. Por ello, es necesario establecer una codificación para todo el rango de soluciones antes de comenzar a utilizar el algoritmo. Al respecto, Davis (1994) señala que la codificación más utilizada es la representación de las soluciones por medio de cadenas binarias (conjuntos de ceros y unos).

Según Bauer (1994), este método puede ser utilizado fácilmente en aplicaciones financieras. Davis (1994) muestra una aplicación de algoritmos genéticos en la calificación de



créditos bancarios que resultan mejor que otros métodos, como las redes neuronales, debido a la transparencia de los resultados obtenidos. Kingdon y Feldman (1995) usaron algoritmos genéticos para hallar reglas que pronosticaran la bancarrota de las empresas, estableciendo relaciones entre las distintas razones financieras. Bauer (1994) utilizó algoritmos genéticos para desarrollar técnicas de transacción que indicaran la asignación mensual de montos de inversión en dólares y marcos; Pereira (1996) los utilizó para encontrar los valores óptimos de los parámetros usados por tres reglas de transacción distintas para el tipo de cambio de dólar estadounidense/dólar australiano; los parámetros obtenidos mostraron resultados intramuestrales positivos, los cuales disminuyeron al aplicar las reglas fuera de la muestra, aun cuando continuaron siendo rentables.

En tanto, Allen y Karjalainen (1999) usaron algoritmos genéticos para aprender reglas de transacción para el índice S&P 500 y emplearlas como un criterio de análisis técnico y, una vez cubiertos los costos de transacción, encontraron que el exceso de rendimiento calculado sobre una estrategia >>



» buy and hold durante el periodo de prueba extramuestral no era congruente. Kim y Han (2000) mostraron que los algoritmos genéticos pueden ser usados para reducir la complejidad y eliminar factores irrelevantes, lo que resultó mejor que los métodos tradicionales para predecir un índice de precios accionario. Por otra parte, Feldman y Treleaven (1994) señalaron que la mayor desventaja de los algoritmos genéticos es la dificultad que presentan para escoger una técnica de codificación manejable y para determinar el tipo de selección y las probabilidades de los operadores genéticos, ya que no hay reglas fijas en esta materia. En investigaciones recientes de predicción de precios de granos en China, se ha utilizado un modelo estocástico híbrido optimizado por algoritmo genético con buenos resultados predictivos (Zhao, Zhang, Shi y He, 2017).

## Modelos ARIMA

Por sus siglas en inglés *Auto Regressive Integrated Moving Average* (ARIMA). Es un modelo econométrico propuesto por los investigadores Box y Jenkins en los años 70 para predecir series de tiempo. Popularmente es conocido como metodología Box-Jenkins aunque también es conocido como metodología o modelos ARIMA. Consta de tres componentes:

- **Proceso Autorregresivo (AR):** se define como modelo autorregresivo si la variable endógena de un periodo  $t$  es explicada por sí misma en las observaciones o datos pasados, multiplicados por un coeficiente que le da un peso específico a la información pasada.
- **Proceso Integrado (I):** se refiere al estado de la variable, es decir, si se va a trabajar sobre el valor sin modificación sobre su primera o segunda diferencia, entendiendo la primera diferencia simplemente como la primera variación de la serie en estudio. Por ejemplo, una serie de precios se entiende como integración en cero. Es decir, se trabajará con la variable pura, lo cual en términos generales no es recomendable dado que tienen tendencia y no se pueden modelar en esas condiciones. Un grado de integración 2 significa que el modelo se construirá sobre la variación de la serie en estudio, o sea, no se modela el precio sino la variación del precio, pero sí se obtiene un modelo para la

variación de precios, se le suma el precio anterior y se obtiene la proyección de precios, es decir, en niveles ARIMA y cero.

- **Proceso de Media Móvil (MA):** Es aquel que explica el valor de una determinada variable en un periodo  $t$  en función de un término independiente y una sucesión de errores correspondientes a periodos precedentes, ponderados convenientemente.

A continuación se muestra la simbología y componentes de un modelo ARIMA:

### ARIMA (p, d, q)

**P = AR ( )** autorregresivo como variable explicativa

**D=** Integrado

**Q=** Error como variable explicativa  
(media móvil de los errores)

## Autómatas celulares

Los autómatas celulares son un mecanismo artificial que trata de imitar las propiedades o sistemas similares a la de los seres vivos a través de la interacción entre individuos simples de dichos sistemas. Se basa en un panel con un conjunto finito de células o autómatas simples, donde cada una de ellas puede adoptar un estado posible de un conjunto finito de estados, determinado por su estado anterior y el estado de las células vecinas. Es así, como los estados de las células van evolucionando en tiempo discreto, de acuerdo a una regla local o un conjunto de reglas, las cuales pueden ser basadas en el estado anterior de la célula, o en el de sus vecinos. En cada período, la regla se le aplica al conjunto de células, entregando una nueva generación de autómatas (Malamud y Turcotte, 2000).

Cada autómata simple genera una salida a partir de varias entradas, modificando su estado de acuerdo con una función de transición a través de generaciones. Por lo tanto, en un autómata celular, el estado de una célula en una generación determinada depende únicamente de su propio estado y el de las células vecinas de la generación anterior.

Estos son usados para modelar sistemas complejos de cualquier índole, por lo que no sorprende que en las finanzas

y la economía los expertos hayan hecho lo mismo. Varios especialistas han hecho investigaciones y han utilizado a los autómatas celulares para predecir los cambios en los signos de los precios de las acciones y los resultados han sido positivos.

## Redes neuronales

De acuerdo con Martin del Brio y Sanz (2001), las redes neuronales artificiales "son sistemas de procesamiento que copian esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades" (p. 387). En consecuencia, son una clase de modelos no lineales flexibles, que se caracterizan por ser sistemas paralelos, distribuidos y adaptativos, todo lo cual se traduce en un mejor rendimiento y en una mayor velocidad de procesamiento. Las redes neuronales pueden entenderse como modelos multiecuacionales o multietapas, en que el *output* de unas constituye el *input* de otras. En el caso de las redes multicapas, existen etapas en las cuales las ecuaciones operan en forma paralela. Los modelos de redes neuronales, al igual que, por ejemplo, los modelos de suavizamiento exponencial y de análisis de regresión, utilizan *inputs* para generar un *output* en la forma de una proyección. La diferencia radica en que las redes neuronales incorporan inteligencia artificial en el proceso que conecta los *inputs* con los *outputs* (Kuo y Reitsch, 1995).



Herbrich, Keilbach, Graepel, Bollmann-Sdorra y Obermayer (2000) señalan que la característica más importante de las redes neuronales es su capacidad para aprender dependencias basadas en un número finito de observaciones, donde el término aprendizaje significa que el conocimiento adquirido a partir de la muestra de observaciones históricas puede ser empleado para proporcionar una respuesta correcta ante datos no utilizados en el entrenamiento de la red y, por lo tanto, no conocidos por esta. La literatura sugiere que las redes neuronales poseen varias ventajas potenciales sobre los métodos estadísticos tradicionales, destacándose el que estas pueden ser aproximadoras de funciones universales, aún para funciones no lineales (Homik, Stinchcombe y White, 1989), lo que significa que ellas pueden aproximar automáticamente cualquier forma funcional (lineal o no lineal) que mejor caracterice los datos, permitiéndole a la red extraer más señales a partir de formas funcionales subyacentes complejas (Hill, Marquez, O'Connor y Remus, 1994). Cabe señalar que algunos investigadores han encontrado que, en general, los mercados financieros se comportan de una forma no lineal, cuestión que ha favorecido el empleo de modelos de redes neuronales ya que, como se dijo anteriormente, estas han evidenciado un buen desempeño en modelamientos no lineales.

Es posible distinguir al menos dos importantes aplicaciones de las redes neuronales en las áreas de economía y finanzas: primero, la clasificación de agentes económicos, por ejemplo, para obtener una estimación de la probabilidad de quiebra (Wilson y Sharda, 1994); segundo, la predicción de series de tiempo (Tang, de Almeida y Fishwick, 1991). Cabe destacar que el propósito de un modelo de predicción es capturar patrones de comportamiento en datos multivariados que distinguen varios resultados, cosa que es bien realizada por los modelos no paramétricos de redes neuronales, los cuales han sido desarrollados para predecir valores de índices bursátiles y de activos individuales, por lo que se ha situado la mayoría de las primeras investigaciones y aplicaciones en >>

» mercados establecidos en Estados Unidos, Gran Bretaña y Japón. Dichos modelos han sido empleados para predecir el nivel o el signo de los retornos de índices bursátiles, entre otras aplicaciones relacionadas a la toma de decisiones en las áreas de finanzas e inversión.

### La técnica de la “Fuerza Bruta”

La técnica fuerza bruta (Parisi, 2015; Parisi, Améstica y Chileno, 2016) utiliza la capacidad de las computadoras para poder encontrar la mejor solución a un problema de optimización. Esta técnica aplicada a los modelos ARIMA simula la inteligencia humana, puesto que genera escenarios diferentes en los cuales cada uno de ellos brinda una solución única al problema. La función de este modelo ARIMA con fuerza bruta es comparar los nuevos escenarios generados con los anteriores y elegir el mejor. Dicho de otra manera, recuerda al igual que un humano el comportamiento que tuvo para darle una mejor solución a determinado problema, y si ese comportamiento solucionó el problema, cada vez que suceda un escenario parecido el humano utilizará dicho comportamiento. De la misma manera, ARIMA con fuerza bruta utiliza el mejor modelo.

En los modelos ARIMA, que son modelos de regresión, la técnica fuerza bruta permite generar infinitos coeficientes de un universo establecido, para darle un peso a cada variable establecida y evaluada en el modelo. Incluso se puede afir-

mar que al usar fuerza bruta se puede contemplar todos los escenarios del universo establecido, lo cual sería una mejora a los algoritmos genéticos, los cuales sólo buscan alrededor de un punto en el universo que ofrece una solución de primera instancia óptima.

Como afirma Durán (2006), la fuerza bruta consiste en enlistar todos los casos y para cada uno calcular la solución, identificando de este modo el caso que ofrezca la mejor solución. Asimismo, Riveros (2015), en un estudio para encontrar la solución óptima al problema del camino más corto para una empresa de logística, comenta que la solución más directa es con fuerza bruta, es decir, evaluar todas las posibles combinaciones (de recorridos) y quedarse con el trayecto que utiliza una menor distancia.

Los métodos mencionados anteriormente sirven para resolver los mismos problemas de optimización simulando la inteligencia humana. Muchos científicos y expertos en ciencias sociales a lo largo de los años han estado tratando de desarrollar cada vez mejores métodos para la solución de problemas. Lo curioso es que el primer método empleado para resolver problemas es el conocido como “fuerza bruta”. Desde tiempos antiguos el hombre utiliza la fuerza bruta para resolver los problemas. Pero ¿por qué se crearon nuevos métodos si con este se podía? Sencillo, los problemas cada vez alcanzaron dimensiones mayores y complejas, lo cual hacía prominente crear métodos que demoraran menos en resolver un problema.

Como se ha dicho, la fuerza bruta lo que hace es probar una a una las diferentes condiciones y características de un sistema para resolver el problema. Una vez que se encuentra la solución, se queda con dicho sistema. Se dejó de usar fuerza bruta puesto que no existía la capacidad para resolver problemas que requerían la evaluación de una cantidad de variables considerada demasiado grande. Sin embargo, hoy en día, la tecnología ha vuelto a superar los problemas, y cualquier persona puede contar con un computador con recursos altamente efectivos capaces de procesar información mucho más rápido que aquellas computadoras diez años atrás. Por lo tanto, ahora es prudente e incluso más eficaz volver a utilizar la técnica fuerza bruta utilizando la capacidad de una computadora de alta tecnología.



## METODOLOGÍA

### Tipo de investigación y diseño

Se ha establecido como una investigación de carácter exploratoria que busca validar, a partir de un modelo ARIMA, la incorporación de la técnica de fuerza bruta (Parisi, 2015; Parisi, Améstica y Chileno, 2016) para obtener un porcentaje de predicción de signo significativo respecto a otros modelos en el precio del petróleo, y también es correlacional puesto que utiliza la relación entre el precio pasado como base de proyección del precio futuro de un valor, necesariamente determinando la relación en específico.

La población para este estudio son los precios del petróleo y de las acciones de empresas petroleras que transan en el New York Stock Exchange (NYSE), a partir de una muestra de precios de cierre semanales<sup>1</sup> para el petróleo, obtenido de la base de datos de precios históricos del portal web es.investing.com., y las acciones de las empresas Exxon Mobil, Gazprom y Rosneft Oil Company, obtenidos de la base de datos de precios históricos del portal *web* yahoo.com, sección finanzas, correspondiente al periodo del 4 de febrero de 2011 al 4 de febrero del 2016. Por la naturaleza de este estudio se utilizó la recopilación documental o datos secundarios, que implica la revisión de documentos, registros públicos y archivos físicos o electrónicos (Hernández, 2010), utilizando el nemotécnico de cada acción: Exxon Mobil (nemotécnico XOM); Gazprom (nemotécnico GAZP.ME) y Rosneft Oil Company (nemotécnico ROSN.ME), que da un total de 262 observaciones por variable (véase ejemplo en anexos 1 al 5).

### Análisis estadístico de datos

Para efectos de evaluar el poder predictivo para frecuencias semanales, los modelos ARIMA utilizados son modelos de series de tiempo que expresan el comportamiento de una variable en función de sus valores rezagados, de variables exógenas rezagadas y de los rezagos de los residuos (errores) del modelo. La variable exógena incluida es el DJI<sup>2</sup>, considerada un indicador líder de lo que ocurre en los mercados bursátiles internacionales, sobre todo en una región integrada geográ-

fica y comercialmente como América del Norte y resume el comportamiento del mercado.

Los modelos ARIMA usados para predecir el signo de las fluctuaciones semanales del precio del petróleo y las acciones de las empresas evaluadas se presentan en las ecuaciones 1 a 4 en el siguiente orden: petróleo y los nemotécnicos de Exxon, Gazprom y Rosneft Oil:

$$\Delta P = \alpha_1 \cdot \Delta P_{t-1} + \dots + \alpha_{AR} \cdot \Delta P_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (1)$$


$$\Delta XOM = \alpha_1 \cdot \Delta XOM_{t-1} + \dots + \alpha_{AR} \cdot \Delta XOM_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (2)$$

$$\Delta GAZP.ME = \alpha_1 \cdot \Delta GAZP.ME_{t-1} + \dots + \alpha_{AR} \cdot \Delta GAZP.ME_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (3)$$

$$\Delta ROSN.ME = \alpha_1 \cdot \Delta ROSN.ME_{t-1} + \dots + \alpha_{AR} \cdot \Delta ROSN.ME_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (4)$$

En los que  $E_t$  corresponde al término de error del modelo; P, XOM, GAZP.ME y ROSN.ME al precio del petróleo y a los nemotécnicos de las acciones de Exxon Mobil, Gazprom y Rosneft Oil respectivamente, que son las variables de la ecuación; y los subíndices AR, MA y X representan el máximo orden de rezagos de las variables independientes. Los coeficientes  $\alpha$ ,  $\beta$  y  $\theta$  son los coeficientes mejor adaptados que, de acuerdo a su valor, le dan un peso determinado, por el modelo, a las variables. Estos últimos indican qué tanto afecta la variable incluida en el precio del valor en estudio.

### Evaluación de la predicción

En concordancia con el punto anterior, se evaluó la calidad de cada modelo en función del porcentaje de predicción de signo alcanzado (PPS). La evaluación se realizó sobre la base de un conjunto extramuestral de 262 datos semanales, por medio de un proceso recursivo, correspondiente a la ventana de datos entre el 4 de febrero de 2011 y el 4 de febrero de 2016. Metodológicamente, la recursividad ha sido empleada para medir el desempeño de modelos de redes 

<sup>1</sup> Se usaron los valores de cierre semanales debido a que los administradores de fondos de inversión tienden a recomponer sus carteras en función de pronósticos semanales.

<sup>2</sup> Dow Jones Industrial, es el índice que agrupa a las treinta empresas más grandes y representativas que transan en el mercado de Estados Unidos.



» neuronales que buscan predecir periodos de recesión en los Estados Unidos (Qi, 2001; Estrella y N'lishkin, 1998) y para proyectar el signo de las variaciones de índices bursátiles Internacionales (Parisi, Parisi y Guerrero, 2003; Parisi, Parisi y Díaz, 2006).

Se utilizó la muestra total tanto para estimar los coeficientes  $\alpha$ ,  $\beta$  y  $\theta$  de cada modelo por medio de la minimización de la suma del cuadrado de los residuos del modelo, como para evaluar la capacidad predictiva de los modelos. Para realizar esto se comparó el signo de la proyección con el signo de la variación observada en cada  $i$ -ésimo periodo, en el que  $i = 1, 2, \dots, m$ . Si los signos entre la proyección y el observado coinciden, entonces se puede señalar que aumenta la efectividad del modelo analizado y, en caso contrario, disminuye su capacidad predictiva.

Una vez proyectado el signo de la variación del precio para el periodo  $n+1$ , la variación observada correspondiente se incluye en la muestra de tamaño de  $n$  con objeto de reestimar los coeficientes del modelo, contando ahora con una observación más. Así, el mismo modelo pero con sus coeficientes recalculados es utilizado para realizar la proyección correspondiente al periodo  $n+2$ . Este procedimiento recursivo se efectuó una y otra vez hasta acabar con las observaciones del conjunto extramuestral. Finalmente, el PPS de cada modelo se calculó de la siguiente forma, según ecuación (5):

$$\text{Porcentaje} = \frac{\sum_{i=n+1}^{n+m} p_i}{m} \quad (5)$$

$$p_i = \begin{cases} 1, & \text{si } \Delta \text{Index}_i * \hat{\Delta} \text{index}_i > 0 \\ 0, & \text{en otro caso} \end{cases}, i = [n + 1, \dots, n + m]$$

En la que  $\Delta$  representa la variación observada,  $\hat{\Delta}$  la variación estimada,  $n=0$  y  $m=262$ . De esta manera, los modelos ARIMA construidos con la técnica fuerza bruta fueron evaluados en función de su capacidad para predecir el signo de los movimientos de los precios del petróleo y las acciones. Además, en esta etapa se aplicó la prueba de acierto direccional de Pesaran y Timmermann (1992), con objeto de medir la significancia estadística de la capacidad predictiva de cada uno de los modelos analizados.

Luego, para analizar si la capacidad predictiva de los modelos se traduce en beneficios económicos, se calculó la rentabilidad acumulada que se habría obtenido si se hubiese comprado o vendido los valores en estudio siguiendo las recomendaciones de compra-venta del modelo de predicción. Para ello, la proyección de una variación positiva de los precios (un alza del mercado) fue interpretada como una señal de compra, mientras que el pronóstico de una variación negativa (una caída del mercado) fue interpretado como una señal de venta. Se supuso una inversión inicial de 100.000 dólares, y la rentabilidad acumulada se calculó sobre un conjunto extramuestral de 262 semanas. Al momento de calcular la rentabilidad, los costos de transacción no fueron considerados.

Por lo demás, con el objetivo de evitar el problema de data snooping<sup>3</sup> (White, 2000) y de despejar las dudas respecto a si la capacidad predictiva se debe a la bondad del modelo, a las características de la muestra de observaciones a la que ha sido aplicado o sencillamente al factor suerte, se tomó el mejor modelo de proyección para cada valor (el de mayor PPS) y se lo evaluó sobre un total de 100 conjuntos extramuestrales de 262 datos de cierre semanales cada uno. Estos 100 conjuntos extramuestrales fueron generados a partir del conjunto extramuestral original utilizando un proceso de block bootstrap<sup>4</sup>.

<sup>3</sup> El término data snooping (también conocido como data minig) "ocurre cuando un determinado conjunto de datos es usado más de una vez para propósito de inferencia o selección de modelos. Cuando [se da] esta reutilización de datos, siempre existe la posibilidad de que cualquier resultado satisfactorio que se haya obtenido pueda deberse sencillamente a la suerte, en vez de algún mérito inherente al modelo que generó los resultados" (White, 2000).

<sup>4</sup> Una manera de probar la bondad de los modelos y la validez de sus resultados, independientemente de la muestra de datos a los que han sido aplicados, es utilizar un proceso de bootstrap. El bootstrap es un proceso de generación de observaciones ficticias a partir de datos históricos, a fin de resolver el problema de escasez de datos y, de este modo, obtener suficiente información para elaborar diferentes conjuntos extramuestrales en los cuales probar la validez de los modelos.



## RESULTADOS

Al desarrollar la estructura para el modelo ARIMA utilizando fuerza bruta, se utilizó la capacidad de un computador para realizar la evaluación de cada valor estudiado (anexo 6). La función de los modelos ARIMA consistió en evaluar cada coeficiente para cada variable considerada que aumente el PPS, quedándose al final de la evaluación con el mejor modelo.

A continuación se presentan los mejores modelos ARIMA, de acuerdo con el PPS:

$$\Delta P = \alpha_1 \cdot \Delta P_{t-1} + \dots + \alpha_{AR} \cdot \Delta P_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (6)$$

$$\Delta XOM = \alpha_1 \cdot \Delta XOM_{t-1} + \dots + \alpha_{AR} \cdot \Delta XOM_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (7)$$

$$\Delta GAZP.ME = \alpha_1 \cdot \Delta GAZP.ME_{t-1} + \dots + \alpha_{AR} \cdot \Delta GAZP.ME_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (8)$$

$$\Delta ROSN.ME = \alpha_1 \cdot \Delta ROSN.ME_{t-1} + \dots + \alpha_{AR} \cdot \Delta ROSN.ME_{t-AR} + \beta_1 \cdot E_{t-1} + \dots + \beta_{MA} E_{t-MA} + \theta_1 \cdot \Delta DJI_{t-1} + \dots + \theta_x \cdot \Delta DJI_{t-x} + E_t \quad (9)$$

En la Tabla 1 se muestra los mejores coeficientes  $\alpha$ ,  $\beta$  y  $\theta$  obtenidos por el modelo que maximicen el PPS para cada valor estudiado.

Posteriormente, en la tabla 2, se muestran los mejores modelos producidos por ARIMA con fuerza bruta, los cuales arrojaron un PPS de un 62,5%, 63,8%, 64,09% y 62,93%, para los valores P, XOM, GAZP.ME Y ROSN.ME, respectivamente, y la rentabilidad acumulada que se obtiene al seguir las recomendaciones de compra y venta del modelo. Esta capacidad predictiva, estimada en un conjunto extramuestral de 262 datos semanales, resultó estadísticamente significativa en cada uno de los valores de acuerdo con la prueba de acierto direccional, comprobándose así la hipótesis de que sí existe capacidad predictiva en los modelos ARIMA con fuerza bruta para el caso del precio del petróleo.

Se pudo observar que la capacidad predictiva de los modelos se tradujo en beneficios económicos. Los modelos ARIMA construidos con fuerza bruta obtuvieron el PPS esperado superior al 60%. Además, independientemente de la significación estadística de la capacidad predictiva de los  $\gg$

Tabla 1: Resumen de los parámetros estimados

Petróleo		Exxon Mobil		Gazprom		Rosneft Oil	
Variable	Coef.	Variable	Coef.	Variable	Coef.	Variable	Coef.
$\Delta P_{t-1}$	-0,41	$\Delta XOM_{t-1}$	-0,36	$\Delta GAZP,ME_{t-1}$	-0,36	$\Delta ROSN,ME_{t-1}$	-0,77
$\Delta P_{t-2}$	-0,20	$\Delta XOM_{t-2}$	-0,79	$\Delta GAZP,ME_{t-2}$	0,12	$\Delta ROSN,ME_{t-2}$	0,78
$\Delta P_{t-3}$	-0,57	$\Delta XOM_{t-3}$	-0,41	$\Delta GAZP,ME_{t-3}$	0,89	$\Delta ROSN,ME_{t-3}$	0,49
$\Delta P_{t-4}$	-0,92	$\Delta XOM_{t-4}$	-0,67	$\Delta GAZP,ME_{t-4}$	-0,66	$\Delta ROSN,ME_{t-4}$	-0,10
$E_{t-1}$	0,37	$E_{t-1}$	-0,89	$E_{t-1}$	-0,31	$E_{t-1}$	0,43
$E_{t-2}$	0,10	$E_{t-2}$	-0,40	$E_{t-2}$	0,01	$E_{t-2}$	-0,45
$E_{t-3}$	0,33	$E_{t-3}$	0,61	$E_{t-3}$	0,49	$E_{t-3}$	-0,55
$E_{t-4}$	-0,97	$E_{t-4}$	0,39	$E_{t-4}$	-0,21	$E_{t-4}$	-0,51
$\Delta DJI_{t-1}$	-1,00	$\Delta DJI_{t-1}$	-0,88	$\Delta DJI_{t-1}$	-0,15	$\Delta DJI_{t-1}$	0,28
$\Delta DJI_{t-2}$	-0,02	$\Delta DJI_{t-2}$	0,93	$\Delta DJI_{t-2}$	-0,54	$\Delta DJI_{t-2}$	0,63
$\Delta DJI_{t-3}$	0,03	$\Delta DJI_{t-3}$	-0,64	$\Delta DJI_{t-3}$	-0,23	$\Delta DJI_{t-3}$	-0,86
$\Delta DJI_{t-4}$	-0,27	$\Delta DJI_{t-4}$	-0,56	$\Delta DJI_{t-4}$	0,08	$\Delta DJI_{t-4}$	0,11

Fuente: Elaboración propia.

**Tabla 2: Resumen de los resultados (porcentaje)**

Modelo	PPS	Rentabilidad acumulada
Petróleo	62,55	44,21%
Exxon Mobil	63,85	81,03%
Gazprom	64,09	425,98%
Rosneft Oil	62,93	129,53%

Fuente: Elaboración propia.

» modelos, estos superaron en rentabilidad a la estrategia de inversión pasiva o *buy and hold*, la cual evidenció una rentabilidad negativa en cada uno de los valores analizados.

Se probó la solidez de estos resultados a fin de evitar el problema de *data snooping*. Para ello se tomó el mejor modelo de proyección para cada valor y se lo evaluó en un total de 100 conjuntos extramuestrales de 262 datos de cierre semanales cada uno. Estos 100 conjuntos extramuestrales fueron generados a partir del conjunto extramuestral original utilizando un proceso de *block bootstrap*.

Al analizar la rentabilidad acumulada que se habría obtenido siguiendo las recomendaciones de compra-venta de los modelos ARIMA se encontró que, de los 100 conjuntos extramuestrales, estos superaron el rendimiento de una estrategia *buy and hold* en 86,8%, 464,55%, 135,3% y 106,45% de los casos en los valores Exxon Mobil, Gazprom, Rosneft Oil y Petróleo respectivamente. En Gazprom la magnitud con que el modelo ARIMA superó en rentabilidad a la estrategia pasiva fue más de lo esperado (464,55%).

En este estudio, para la selección del mejor modelo ARIMA del universo infinito de combinaciones, la computadora demoró cerca de dos días en conseguir el mejor resultado. Por lo tanto, se comprueba que utilizar fuerza bruta con un equipo de alta tecnología es un método altamente eficiente.

## CONCLUSIONES

La subida o baja del precio del barril de petróleo se le asocia a las condiciones internacionales del mercado y a la especulación, siendo como *commodity* un instrumento de inversión altamente atractivo; por ello, encontrar un buen modelo predictivo que permita proyectar el cambio de signo en el precio es un desafío permanente para distintos actores que participan de los mercados. Por tal razón se ha observado una



Shutterstock.com

creciente utilización de modelos predictivos, unos más exitosos que otros, y es así como el modelo propuesto de ARIMA con fuerza bruta es una innovación reciente a partir de modelos más tradicionales y que aprovecha las tecnologías existentes. Es en este contexto que los resultados obtenidos en esta investigación permiten inferir que sí es factible construir un modelo predictivo con una capacidad de predicción superior al 60%, tanto para el caso del petróleo como para las acciones de empresas petroleras. Los modelos se construyeron con un millón de iteraciones con fuerza bruta, dado que la optimización por *simplex* o *solver* no alcanzó el resultado esperado.

Los modelos ARIMA elaborados a partir de las variables endógenas (precios históricos del valor) y exógenas (variación del valor del DJI) con fuerza bruta obtuvieron una gran capacidad para predecir el signo de las variaciones semanales de los valores del petróleo, Exxon Mobil, Gazprom y Rosneft Oil. Los resultados de la prueba de acierto direccional de Pesaran y Timmermann (1992) indicaron que los modelos ARIMA presentaron una capacidad predictiva estadísticamente significativa. A su vez, estos modelos obtuvieron la mayor rentabilidad acumulada en el periodo extramuestral para Gazprom con un 64,09% de PPS.

Al analizar la rentabilidad acumulada que se habría obtenido siguiendo las recomendaciones de compra-venta de los modelos ARIMA, se encontró que, de los 100 conjuntos extramuestrales, estos superaron el rendimiento de una estrategia *buy and hold* en 86,8%, 464,55%, 135,3% y 106,45% de los casos en los valores de Exxon Mobil, Gazprom, Rosneft Oil y Petróleo respectivamente. En Gazprom, la magnitud con que el modelo ARIMA superó en rentabilidad a la estrategia pasiva fue más de lo esperado (464,55%). De esta manera, este estudio presenta evidencia de que los modelos ARIMA optimizados con fuerza bruta pueden ser utilizados como otra metodología para mejorar los modelos de proyección de series de tiempo, en función de su capacidad de predicción de signo, siendo un modelo útil para tomadores de decisiones o inversionistas de este sector.

Finalmente, es necesario señalar que el carácter seminal de este estudio obliga a una búsqueda constante de mejoras al modelo, integrando nuevas variables que ayuden a generar una mayor capacidad de predicción. Por otro lado, se recomienda nuevas líneas futuras de investigación en la aplicación del modelo propuesto, ya sea comparándolo con otros



modelos predictivos o replicando su aplicación en distintos activos y mercados, *commodities* transables, opciones financieras y, por ende, en acciones de compañías en diferentes bolsas de valores.

### Referencias bibliográficas

- Allen, F. y Karjalainen, R. (1999). Using genetic algorithms to find technical trading rules. *Journal of financial Economics*, 51(2), 245-271.
- Arango, A., Velásquez, J. y Franco, C. (2013). Técnicas de lógica difusa en la predicción de índices de mercados de valores: una revisión de literatura. *Revista Ingenierías Universidad de Medellín*, 12(22).
- Atsalakis, G. (2016). Using computational intelligence to forecast carbon prices. *Applied Soft Computing*, 43, 107-116.
- Bauer, R. (1994). *Genetic algorithms and investment strategies* (Vol. 19). Nueva York: John Wiley & Sons.
- Davis, L. (1994). Genetic algorithms and financial applications. *Trading on the edge*, 133-147.
- Durán, G. (2006). *Investigación de operaciones, modelos matemáticos y optimización*. En Seminario JUNAEB-DII, Universidad de Chile. Santiago, Chile. Disponible en <http://mate.dm.uba.ar/~gdu-> >>

» ran/docs/charlas/junaeb\_willy\_8.pdf.

Estrella, A., & Mishkin, F. S. (1998). Predicting US recessions: Financial variables as leading indicators. *Review of Economics and Statistics*, 80(1), 45-61.

Fama, E. y French, K. (1992). The cross section of expected stock returns. *The Journal of Finance*, 47(2), 427-465.

Fan, X., Wang, L. y Li, S. (2016). Predicting chaotic coal prices using a multi-layer perceptron network model. *Resources Policy*, 50, 86-92.

Feldman, K. y Treleaven, P. (1994). Intelligent systems in finance. *Appl. Mathematical Finance*, 1(2), 195-207.

García, M., Jalal, A., Garzón, L. y López, J. (2013). Methods for Predicting Stock Indexes. *Ecos de Economía*, 17(37), 51-82.

Haro del Rosario, A., Saraite, L., Caba, C. y Gálvez, M. (2016). Las empresas latinoamericanas del sector del petróleo y gas ante la información sobre sostenibilidad. *Tec Empresarial*. 10(1), 39-49.

Herbrich, R., Keilbach, M., Graepel, T., Bollmann-Sdorra, P. y Obermayer, K. (1999). Neural networks in economics. *Computational techniques for modelling learning in economics*, 169-196.

Hernández, M. (2010). Neurofinanzas: Cuando las decisiones financieras no son racionales. *TEC empresarial*, 4(3), 21-30.

Hernández, R., Fernández, C. y Baptista, P. (2010). Metodología de la investigación. México, D.F.: McGraw-Hill Interamericana.

Hill, T., Marquez, L., O'Connor, M., & Remus, W. (1994). Artificial neural network models for forecasting and decision making. *International journal of forecasting*, 10(1), 5-15.

Holland, J. (1975). *Adaptation in natural and artificial systems. An introductory analysis with application to biology, control, and artificial intelligence*. Ann Arbor, MI: University of Michigan Press.

Hornik, K., Stinchcombe, M. y White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366

Kim, K. y Han, I. (2000). Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert systems with Applications*, 19(2), 125-132.

Kingdon, J. y Feldman, K. (1995). Genetic Algorithms and Applications to Finance. *Applied Mathematical Finance*, 2(2), 89-116.

Kuo, C. y Reitsch, A. (1995). Neural networks vs. conventional methods of forecasting. *The Journal of Business Forecasting*, 14(4), 17.

Malamud, B. y Turcotte, D. (2000). Cellular-automata models applied to natural hazards. *Computing in Science & Engineering*, 2(3), 42.

Martin del Brio, B. y Sanz, A. (2001). *Redes neuronales y sistemas borrosos: introducción, teórica y práctica*. Madrid: Ra-ma.

Parisi, A. (2015). *Modelo predictivo de precio accionario adoptando fuerza bruta. (Documento de trabajo Programa Magíster Dirección de Empresas [MDE])*, Universidad del Bío-Bío, Chile.

Parisi, A., Améstica, L. y Chileno, O. (2016). Modelo predictivo de precio accionario adoptando fuerza bruta, En *XVI International Finance Conference 2016, Innovando en Finanzas*. Llevado a cabo en Viña de Mar, Chile.

Parisi, A., Parisi, F. y Guerrero, J. (2003). Modelos predictivos de redes neuronales en índices bursátiles. *El Trimestre Económico*, 70(280 [4]), 721-744.

Parisi, A., Parisi, F. y Díaz, D. (2006). Modelos de Algoritmos Genéticos y Redes Neuronales en la Predicción de Índices Bursátiles Asiáticos. *Cuadernos de economía*, 43(128), 251-284.

Pesaran, M. y Timmermann, A. (1992). A simple nonparametric test of predictive performance. *Journal of Business & Economic Statistics*, 10(4), 461-465.

Pereira, R. (1996). Selecting parameters for technical trading rules using genetic algorithms. *Journal of Applied Finance and Investment*, 1(3), 27-34.

Pierdzioch, C., Risse, M. y Rohloff, S. (2015). Forecasting gold-price fluctuations: a real-time boosting approach. *Applied Economics Letters*, 22(1), 46-50.

Qi, M. (2001). Predicting US recessions with leading indicators via neural network models. *International Journal of Forecasting*, 17(3), 383-401.

Riveros, D. (2015). *Aplicación de la investigación de operaciones al problema de la distribución a una empresa de logística*. Disponible en [http://cybertesis.unmsm.edu.pe/bitstream/cybertesis/4365/1/Riveros\\_vd.pdf](http://cybertesis.unmsm.edu.pe/bitstream/cybertesis/4365/1/Riveros_vd.pdf)

Shafiee, S. y Topal, E. (2010). An overview of global gold market and gold price forecasting. *Resources Policy*, 35(3), 178-189.

Tang, Z., de Almeida, C. y Fishwick, P. (1991). Time series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57(5), 303-310.

Wilson, R. y Sharda, R. (1994). Bankruptcy prediction using neural networks. *Decision support systems*, 11(5), 545-557.

Zhao, Y., Zhang, X., Shi, Z. y He, L. (2017). Grain Price Forecasting Using a Hybrid Stochastic Method. *Asia-Pacific Journal of Operational Research*, 34(5), 1-24. ①



## ANEXOS

## ANEXO 1: Precios históricos del petróleo

Fecha	Último	Apertura	Máximo	Mínimo	Volumen	Var. %
30-01-2011	89.03	89.97	92.84	88.4	1,79M	-0.35%
06-02-2011	85.58	89.06	89.54	85.1	1,91M	-3.88%
13-02-2011	86.2	85.5	87.88	83.85	1,23M	0.72%
20-02-2011	97.88	86.38	103.41	86.25	1,34M	13.55%
27-02-2011	104.42	98.5	105.17	96.37	1,78M	6.68%
06-03-2011	101.16	104.65	106.95	99.01	1,95M	-3.12%
13-03-2011	101.07	100.31	103.66	96.22	1,52M	-0.09%
20-03-2011	105.4	102.12	106.69	101.43	884,12K	4.28%
27-03-2011	107.94	105.43	108.47	102.7	1,28M	2.41%
03-04-2011	112.79	108.29	113.21	107.5	1,39M	4.49%
10-04-2011	109.66	113.28	113.46	105.31	1,95M	-2.78%
17-04-2011	112.29	109.43	112.48	105.5	777,27K	2.40%
24-04-2011	113.93	112.34	114.18	110.71	1,29M	1.46%
01-05-2011	97.18	113.89	114.83	94.63	2,22M	-14.70%
08-05-2011	99.65	98.11	104.6	95.25	2,32M	2.54%
15-05-2011	99.49	99.36	100.99	95.02	1,20M	-0.16%
22-05-2011	100.59	99.68	101.9	96.37	1,54M	1.11%
29-05-2011	100.22	100.69	103.39	98.12	1,44M	-0.37%
05-06-2011	99.29	100.42	102.44	97.74	1,91M	-0.93%
12-06-2011	93.01	98.77	99.95	91.84	1,82M	-6.32%
19-06-2011	91.16	92.8	95.7	89.69	1,30M	-1.99%
26-06-2011	94.94	91.16	95.84	89.61	1,45M	4.15%
03-07-2011	96.2	94.98	99.42	94.34	1,25M	1.33%
10-07-2011	97.24	96.1	99.21	93.55	1,68M	1.08%
17-07-2011	99.87	97.37	100.19	94.69	894,54K	2.70%
24-07-2011	95.7	99.76	100.62	94.95	1,36M	-4.18%
31-07-2011	86.88	96.2	98.6	82.87	2,13M	-9.22%
07-08-2011	85.38	85.71	87.37	75.71	2,50M	-1.73%
14-08-2011	82.26	85.59	89	79.17	1,49M	-3.65%
21-08-2011	85.37	82.42	86.59	81.13	1,32M	3.78%
28-08-2011	86.45	85.33	89.9	85.11	1,43M	1.27%
04-09-2011	87.24	86.46	90.48	83.2	1,32M	0.91%
11-09-2011	87.96	86.7	90.52	85	1,56M	0.83%
18-09-2011	79.85	87.75	87.99	77.55	1,35M	-9.22%
25-09-2011	79.2	79.64	84.77	77.11	1,64M	-0.81%
02-10-2011	82.98	78.92	84	74.95	1,92M	4.77%
09-10-2011	26.8	82.75	87.42	82.75	1,56M	4.60%
16-10-2011	87.4	87.48	89.51	84.1	870,90K	0.69%
23-10-2011	93.32	87.05	94.65	87	1,99M	6.77%

## ANEXO 2: Precios históricos de Exxon Mobil

Date	Open	High	Low	Close	Volume	Adj. Close
04-02-2011	83.25	83.52	82.85	83.28	16558300.00	72.61
07-02-2011	83.45	84.00	81.61	82.82	17140500.00	72.59
14-02-2011	82.07	85.11	81.89	84.50	23231800.00	74.06
22-02-2011	84.97	88.23	84.73	85.34	30503100.00	74.80
28-02-2011	85.87	86.56	83.75	85.08	20422900.00	74.57
07-03-2011	85.84	86.08	80.10	82.12	18526100.00	71.98
14-03-2011	81.67	82.64	78.80	80.85	24761600.00	70.86
21-03-2011	81.87	83.93	81.86	83.62	16662700.00	73.29
28-03-2011	83.86	84.94	82.61	84.68	15501000.00	74.22
04-04-2011	84.26	86.22	84.07	85.95	15101600.00	75.33
11-04-2011	85.95	86.15	82.38	84.29	16196900.00	73.88
18-04-2011	83.11	86.43	82.44	86.36	14030700.00	75.69
25-04-2011	86.29	88.00	85.89	87.98	16315000.00	77.11
02-05-2011	88.10	88.13	81.59	82.69	22748200.00	72.48
09-05-2011	83.01	83.76	79.42	80.87	19924800.00	71.28
16-05-2011	80.22	82.58	79.60	81.57	17338400.00	71.90
23-05-2011	80.22	83.13	80.07	82.63	16029100.00	72.83
31-05-2011	83.28	83.75	80.18	81.18	19653600.00	71.56
06-06-2011	80.93	81.87	79.72	79.78	18468100.00	70.32
13-06-2011	80.00	80.82	78.33	79.02	20098000.00	69.65
20-06-2011	78.65	81.12	76.78	76.78	23731700.00	67.68
27-06-2011	76.88	82.09	76.72	82.01	19184100.00	72.29
05-07-2011	81.30	82.60	80.85	82.42	17654400.00	72.65
11-07-2011	81.30	83.46	81.12	83.00	20898000.00	73.16
18-07-2011	82.29	85.41	82.08	85.22	16217800.00	75.12
25-07-2011	84.20	85.13	79.76	79.79	20244100.00	70.33
01-08-2011	80.82	81.18	72.07	74.82	33887900.00	65.95
08-08-2011	72.74	73.44	67.03	72.00	49465300.00	63.88
15-08-2011	73.04	74.75	69.67	69.80	27678400.00	61.93
22-08-2011	72.15	73.92	67.58	72.64	29182800.00	64.45
29-08-2011	73.33	74.87	71.50	72.14	23011600.00	64.01
06-09-2011	70.14	74.34	69.91	71.01	24732100.00	63.01
12-09-2011	70.34	74.75	69.87	74.55	26316900.00	66.15
19-09-2011	72.91	74.98	67.93	61.31	26770900.00	61.50
26-09-2011	70.01	74.59	69.50	72.63	28337900.00	64.44
03-10-2011	72.05	74.52	69.21	73.56	28837500.00	65.27
10-10-2011	74.73	78.23	74.65	78.11	19595500.00	69.30
17-10-2011	77.87	80.19	77.02	80.13	22741700.00	71.10
24-10-2011	79.92	82.20	79.05	81.48	25541500.00	72.29

## ANEXO 3: Precios históricos de Gazprom

Date	Open	High	Low	Close	Volume	Adj. Close
04-02-2011	208.31	213.75	207.70	213.29	112683300	170.61
07-02-2011	213.90	216.65	205.22	208.90	80270800	167.10
14-02-2011	210.00	211.48	194.12	195.58	79606900	156.44
22-02-2011	196.31	211.25	194.85	209.07	87749800	167.23
28-02-2011	210.30	215.30	207.25	212.66	73447600	170.10
07-03-2011	214.40	216.12	204.00	208.60	67071500	166.86
14-03-2011	208.01	226.89	207.91	223.91	129251100	179.10
21-03-2011	225.02	226.15	219.20	223.06	61910700	178.42
28-03-2011	224.14	235.40	222.51	234.76	68394100	187.78
04-04-2011	236.00	243.70	235.17	242.98	76570800	194.36
11-04-2011	243.52	274.47	226.90	227.71	88779600	182.14
18-04-2011	228.20	237.27	217.00	236.73	68044500	189.36
25-04-2011	235.36	239.77	228.15	231.74	59002500	185.37
02-05-2011	231.60	232.00	204.70	211.92	99589800	172.64
09-05-2011	214.88	217.19	200.62	201.97	74455500	164.53
16-05-2011	199.24	206.16	195.60	196.81	71281400	160.33
23-05-2011	195.00	202.50	190.05	201.48	73559100	164.13
31-05-2011	201.80	207.75	195.11	195.84	63536700	159.54
06-06-2011	196.50	212.49	194.07	209.16	79124100	170.39
13-06-2011	210.58	211.25	198.18	201.37	67281300	164.04
20-06-2011	199.30	202.87	195.90	199.12	59768600	162.21
27-06-2011	198.54	506.31	195.60	204.45	49733700	166.55
05-07-2011	205.94	208.78	201.21	206.52	4952000	168.24
11-07-2011	203.88	204.46	198.08	200.79	5075400	163.57
18-07-2011	201.48	204.90	197.79	203.38	4591100	165.68
25-07-2011	200.98	203.04	198.40	199.90	4404400	162.85
01-08-2011	202.50	204.67	176.68	182.01	8208400	148.27
08-08-2011	175.26	179.45	153.11	160.04	33537900	130.37
15-08-2011	171.67	176.43	161.51	165.53	8199500	134.85
22-08-2011	166.96	175.43	165.39	170.59	6963600	138.97
29-08-2011	174.80	179.40	170.65	172.99	5953600	140.92
06-09-2011	169.13	175.98	167.08	171.32	5852000	139.59
12-09-2011	166.15	170.05	162.02	165.10	7124000	134.50
19-09-2011	163.49	167.25	145.50	149.90	8392100	122.11
26-09-2011	148.76	160.20	146.33	154.88	8326500	126.17
03-10-2011	152.50	155.18	139.40	151.38	8005200	123.32
10-10-2011	151.99	164.52	149.12	161.40	7772500	131.48
17-10-2011	164.47	168.36	157.09	163.55	7334700	133.23
24-10-2011	167.04	190.24	166.08	186.20	9739300	151.69

### ANEXO 4: Precios históricos de Gazprom

Date	Open	High	Low	Close	Volume	Adj. Close
04-02-2011	254.8	259.84	254.78	257.34	18109000	221.309
07-02-2011	257.34	258.87	245.83	247.01	12202900	212.425
14-02-2011	257.01	260.65	252.52	254.67	11511300	219.013
22-02-2011	255.5	272.2	252.8	271.84	17137900	233.779
28-02-2011	272.73	276.2	264.27	265.15	11931100	228.025
07-03-2011	268.5	270.98	250.6	253.08	16875600	217.645
14-03-2011	252.9	262.21	248.13	256.42	15009300	220.518
21-03-2011	258.52	269.79	215.66	267.83	12223100	230.33
28-03-2011	266.13	271.34	258.25	264.04	12579400	227.071
04-04-2011	265.75	271.19	261.55	264.94	10967500	227.845
11-04-2011	265.94	266.29	241.5	247.48	17148900	212.829
18-04-2011	247.86	256.24	237.26	251.56	12978400	218.759
25-04-2011	25.14	254.52	240.85	244.16	12378700	212.324
02-05-2011	243.05	243.6	223.65	235.73	13374400	204.993
09-05-2011	234.55	240.39	227.02	230.19	10391800	200.175
16-05-2011	228.02	233.39	225.13	227.13	9947500	194.514
23-05-2011	225	241.5	220.1	240.56	11850500	209.193
31-05-2011	240.05	245.44	234	234.61	9666400	204.019
06-06-2011	235.3	252.27	232.62	248.28	11527200	215.906
13-06-2011	249.65	251.85	240.68	241.64	11064000	210.132
20-06-2011	239.98	240	228.22	231.15	8130800	201.01
27-06-2011	230.02	239.03	226.81	235.04	7042300	204.393
05-07-2011	236.56	243.5	234.57	240.21	815400	208.889
11-07-2011	237.37	237.83	231.5	234.32	806200	203.767
18-07-2011	233.39	242	228.21	240.17	1001400	208.854
25-07-2011	239.54	244.51	233.02	235.63	726200	204.906
01-08-2011	239.3	240.41	215	219.19	1286600	190.61
08-08-2011	213.46	216.98	181.98	193.58	5728000	168.339
15-08-2011	204.85	212.3	192.1	196.99	1456400	171.304
22-08-2011	195.46	206.3	194.35	201.92	1405700	175.591
29-08-2011	209	232.47	209	227.68	2324300	197.993
06-09-2011	224.94	230	219.25	223	1285100	193.923
12-09-2011	219	221.88	212.63	215.99	1764400	187.827
19-09-2011	211.73	215.7	176.3	184.38	2031200	160.338
26-09-2011	180	197.3	177.3	190.89	1855600	166
03-10-2011	185.52	195.19	171.04	191.67	1788200	166.678
10-10-2011	193.71	201.36	188.85	197.74	1757600	171.956
17-10-2011	201.35	202.36	190.8	198.07	1567600	172.243
24-10-2011	201.85	228	201.22	224.13	1803600	194.905



## ANEXO 5: Tabla de proyección de signo del modelo ARIMA para el petróleo

Variación del Precio	Proyección del Precio	Predicción	Error	Error <sup>2</sup>	Variación DJI
-3.45			3.4		181.11
0.62	176.2911205	1	175.671121	30860.34258	117.99
11.68	325.0032526	1	313.323253	98171.4606	-260.8
6.54	-163.6545487	0	-170.194549	28966.18441	39.43
-3.26	-377.9564557	1	-374.696456	140397.4339	-125.48
-0.09	-203.1616781	1	-203.071678	41238.10644	-185.88
4.33	-601.7018168	0	-606.031817	367274.563	362.07
2.54	55.53365777	1	52.9936578	2808.327763	156.13
4.85	934.6672175	1	929.817217	864560.0579	3.33
-3.13	237.3758757	0	330.505876	109234.1339	-38.22
2.63	389.4241473	1	386.794147	149609.7124	164.16
1.64	434.1475594	1	432.507559	187062.7889	304.55
-16.75	-143.349178	1	-126.599178	16027.35186	-171.8
2.47	-205.7905905	0	-208.260591	43372.47358	-42.99
-0.16	-860.1589261	1	-859.998926	739598.153	-83.71
1.1	-999.269067	0	-1000.36907	1000738.27	-70.46
-0.37	-363.3112619	1	-362.941262	131726.3596	-290.32
-0.93	-557.0390243	1	-556.109024	309257.2469	-199.35
-6.28	-49.23941028	1	-42.9594103	1845.510932	52.45
-1.85	945.098054	0	946.948054	896710.617	-69.78
3.78	862.5581106	1	858.778111	737499.8432	648.19
1.26	1611.664648	1	1610.40465	2593403.129	74.43
1.04	1654.001752	1	1649.96175	2722373.784	-177.47
2.63	-422.7622692	0	-425.392269	180958.5827	201.43
-4.17	-786.6549861	1	-728.484986	612282.7535	-537.92
-8.82	-1616.088424	1	-1607.26842	2583311.787	-698.63
-1.5	-3534.852164	1	-3533.35216	12484577.51	-175.59
-3.12	-1777.677277	1	-1774.55728	3149053.528	-451.37
3.11	-405.6808851	0	-408.790885	167109.9877	466.89
1.08	806.6797447	1	805.599745	648990.9487	-44.28
0.79	3904.945458	1	3904.15546	15242429.84	-248.13
0.72	2807.132378	1	2806.41238	7875950.437	516.96
-8.11	2069.152129	0	2077.26213	4315017.952	-737.61
-0.65	1495.656111	0	1496.30611	2238931.979	141.9
3.78	-2761.997577	0	-2765.77758	7649522.605	189.74
3.82	-2415.669506	0	-2419.48951	5853929.471	541.37
0.6	-1571.673931	0	-1572.27393	2472045.313	164.3

## ANEXO 6: Códigos programación Visual Basic. Modelo ARIMA con fuerza bruta

```

Sub prediccionexxon()
'
' prediccionexxon Macro
'
Max = 0
For x = 1 To 1000000
Cells (1, 5) = x

If Cells (1, 12) > Max Then alpha1 = Cells (1, 10)
If Cells (2, 12) > Max Then alpha2 = Cells (2, 10)
If Cells (3, 12) > Max Then alpha3 = Cells (3, 10)
If Cells (4, 12) > Max Then alpha4 = Cells (4, 10)
If Cells (5, 12) > Max Then alpha5 = Cells (5, 10)
If Cells (6, 12) > Max Then alpha6 = Cells (6, 10)
If Cells (7, 12) > Max Then alpha7 = Cells (7, 10)
If Cells (8, 12) > Max Then alpha8 = Cells (8, 10)
If Cells (9, 12) > Max Then alpha9 = Cells (9, 10)
If Cells (10, 12) > Max Then alpha10 = Cells (10, 10)
If Cells (11, 12) > Max Then alpha11 = Cells (11, 10)
If Cells (12, 12) > Max Then alpha12 = Cells (12, 10)
If Cells (1, 12) > Max Then Max = Cells (12, 10)

Cells (1, 8) = alpha1
Cells (2, 8) = alpha2
Cells (3, 8) = alpha3
Cells (4, 8) = alpha4
Cells (5, 8) = alpha5
Cells (6, 8) = alpha6
Cells (7, 8) = alpha7
Cells (8, 8) = alpha8
Cells (9, 8) = alpha9
Cells (10, 8) = alpha10
Cells (11, 8) = alpha11
Cells (12, 8) = alpha12
Cells (1, 14) = Max

Next x

```