



UNIVERSIDAD DE CHILE
FACULTAD DE ECONOMÍA Y NEGOCIOS
ESCUELA DE ECONOMÍA Y ADMINISTRACIÓN

**UN MODELO NO LINEAL PARA LA PREDICCIÓN DE LA
VARIACIÓN DEL ÍNDICE IPSA CONSIDERANDO
VOLATILIDADES EN CLUSTERING**

Seminario para optar al título de Ingeniero Comercial
Mención Administración

Profesor guía: Dr. Antonino Parisi Fernández
Autor: Daniel Nicolas Lanyon Rioseco

Diciembre de 2007 Santiago de Chile

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

*Gracias al esfuerzo de mis padres
al apoyo de mi esposa
y dedicada a mi hijo,
Gracias Señor.*

UN MODELO NO LINEAL PARA LA PREDICCIÓN DE LA VARIACIÓN DEL ÍNDICE IPSA CONSIDERANDO VOLATILIDADES EN CLUSTERING

Profesor guía: Dr. Antonino Parisi Fernández

Autor: Daniel Nicolas Lanyon Rioseco

Resumen

El estudio evalúa la capacidad de un modelo GARCH, optimizado por algoritmo genético, para predecir la dirección del cambio del precio de un índice financiero, particularmente el IPSA.

La particularidad de esta tesis es que incorpora en el modelo eventos o episodios de volatilidad pasados y así verificar la capacidad de estos modelos para modelar el comportamiento del IPSA y mejorar la capacidad de acertar a los cambios de variación de signo del índice. A modo de comparación se evaluó este modelo con modelos GARCH simples que no incorporan estos episodios de volatilidad.

El índice utilizado fue el IPSA y los datos se tomaron desde una serie histórica de datos semanales, periodo que corresponde al 01 de Enero de 1995 y 28 de Diciembre del 2007. Los resultados arrojados mostraron que en general los modelos GARCH (p, q) no obtienen un buen PPS arrojando una media del 53,93% dentro de un intervalo al 95% de confianza en 53,13% y 54,73%. Sin embargo, al incluir los episodios de volatilidad como clusters y optimizar la función de máxima verosimilitud minimizando el error cuadrático medio ECM, se logran mejores resultados y muestra que, si bien la optimización de una estructura GARCH (p, q) no garantiza un buen PPS, en la medida que el ajuste aumenta, disminuyendo el ECM, se obtiene un mejor PPS. Sin duda que los mejores resultados tanto

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

en ECM como en PPS fueron canalizados por un mejor ajuste de la estimación que además permitió acertar mas veces al signo de la variación. Es posible que al incorporar al modelo la capacidad de los “traders” de reconocer episodios que alguna vez se dieron en el pasado para ajustar sus predicciones haya incorporado mayor realismo y por ende un mejor ajuste.

INDICE

1	Introducción.....	6
2	Marco Teórico.....	8
	2.1 Optimización de Estructura con Algoritmo Genético	
	2.2 Modelos de Volatilidad Estocástica	
3	Metodología.....	12
	3.1 Aspectos generales.	
	3.2 Especificación del Modelo	
	3.3 Desarrollo de Algoritmo Genético	
	3.4 Implementación	
4	Resultados y Análisis.....	18
5	Conclusiones.....	21
	Bibliografía	22
	Anexos.....	23

1- Introducción

Cuando un agente diseña sus estrategias normalmente considera información pasada. Sin embargo, la información que considera puede ser no solo información reciente sino también eventos o episodios anteriores que, por su impacto, deban ser considerados como antecedentes para escenarios similares futuros. La memoria del inversionista podría recordar estos episodios especiales que son similares a escenarios en el presente y entonces la información a utilizar se sitúa en extremos temporales lejos del comportamiento actual que presenta el activo.

Este estudio pretende investigar, como hipótesis de trabajo, que los agentes consideran para la formulación de sus estrategias la volatilidad pasada recordada como episodios de volatilidad.

Los modelos de volatilidad GARCH (1, 1) consideran la varianza a sobre en un componente autorregresivos y un componente de media móvil. Estimamos que a esta estructura clásica pueden incorporarse variables que estén asociadas a estos “episodios de volatilidad” de manera de no mejorar la predicción de la variación del sentido del precio del índice IPSA. El algoritmo se formula como la optimización de estructura mediante la técnica de bajo algoritmo genético, estimando h_t por el método de máxima verosimilitud y evaluando los modelos resultantes en su porcentaje de predicción de signo o PPS.

Con el fin de encontrar una mejora significativa en PPS para los modelos encontrados y en especial para el modelo optimo de a cuerdo a ECM se estudia la serie histórica sobre el índice que se basa el estudio, el IPSA, periodo correspondiente al 01 de Enero de 1995 al 28 de Diciembre del 2007 tomando datos semanales. Se seleccionan periodos en los que se aprecian volatilidades sobre el promedio y se les denomina clusters de volatilidad para ser ingresados al modelo GARCH obteniendo un modelo modificado en el cual se evalúan los mismos output.

Se determinara entonces el poder del modelo GARCH (p, q) optimizado bajo algoritmo genético para obtener un buen PPS y bajo el modelo modificado se espera

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

encontrar un mejor resultado sobre el mismo indicador dejando en segundo plano su impacto dentro del ECM.

2- Marco Teórico

2.1- Optimización de Estructura con Algoritmo Genético

El algoritmo genético (AG) como proceso de optimización tiene su origen en la selección natural propuesta por Charles Darwin en 1859 en su obra magna “El origen de las especies” que hace de una especie un ente que tiene la capacidad de adaptarse al medio y sobrevivir por su mejora constante y diversidad. Este algoritmo simula la creación de un individuo a nivel genético que proviene de otros dos individuos que en un proceso de cross-over comparten e intercambian genes, dando como resultado una estructura genética distinta pero que guarda mucho en común con sus orígenes.

El proceso consiste en tomar una estructura y asociar a cada variable independiente un gen representado por ceros o unos que excluyen o incluyen respectivamente la variable a la estructura. El resultado es una cadena de ceros y unos obtenidos de forma aleatoria que determina la estructura a utilizar, esta es evaluada y se repite el proceso hasta obtener una base de estructuras que llamamos población inicial o progenitores. La optimización ocurre cuando solo los mejores se reproducen entre si y obtenemos un individuo que probablemente sea bueno y mejor que sus padres. El conjunto de estos individuos se le denomina primera generación. El proceso culmina obteniendo varias generaciones que dan como resultado al mejor individuo. Hasta el momento el proceso cumple con optimizar la estructura, sin embargo la diversidad también es una característica importante mas allá del tipo de cross-over que se aplique, esta es fortalecida por la mutación aleatoria de algunos genes para un porcentaje pequeño de cada generación.

Los algoritmos genéticos tienen su primera aplicación con John Holland (1975) de la Universidad de Michigan. Aplicaciones sucesivas las podemos encontrar en distintos campos como la ingeniería industrial por Goldberg (1985), biología molecular por James D. Watson (1987) y sobre créditos bancarios Davis (1994).

Una de las últimas aplicaciones en finanzas elaboradas por Parisi, Parisi y Cornejo (2004), aplica algoritmo genético a modelos multivariados con criterio de optimización PPS encontrando estructuras con mejores resultados.

Las ventajas de la utilización de algoritmo genético radican principalmente en su eficiencia sobre la fuerza bruta (FB), donde los costos de tiempo y recursos son

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

extremadamente elevados para encontrar la estructura óptima, mientras que AG es capaz de llegar a una solución muy cercana al óptimo en FB con menores costos. Según explica A. Parisi en la actualidad AG tiene su atractivo sobre FB pero en un futuro muy cercano la tecnología nos permitirá hacer fuerza bruta a bajo costo, entonces AG empieza a perder su fortaleza en eficiencia.

2.2- Modelos de Volatilidad Estocástica

Cuando observamos el comportamiento de la volatilidad en el tiempo podemos observar que esta se agrupa en períodos de alta y baja volatilidad dando origen a lo que conocemos como “Clusters de Volatilidad” por lo que se hace difícil aceptar que tanto la varianza condicional como incondicional se mantienen estables. El modelo tipo ARCH (heterocedasticidad condicional autorregresiva) propuesto por Engle (1982) logra estimar de forma simultánea la varianza y media condicional bajo la siguiente propuesta:

$$\begin{aligned}R_t &= u + \varepsilon_t \\ \varepsilon_t &= \mu_t \cdot \sqrt{h_t} \\ h_t &= \alpha_0 + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2\end{aligned}$$

De esta forma el modelo apunta a explicar el segundo momento, es decir, utiliza rezagos del error al cuadrado. Entonces la volatilidad condicional esta descrita por h_t y μ_t es ruido blanco que puede distribuir $N(0, 1)$ u otra distribución conocida. El proceso de estimación de u puede llevarse a cabo con un muestreo extramuestral reiterado con tal de obtener una media para este valor.

En cuanto a los coeficientes de h_t , estos deben cumplir ciertas condiciones que aseguren la no negatividad y valores finitos tanto para la varianza condicional como para la varianza incondicional, que son:

$$\begin{aligned}\alpha_0 &> 0 \\ \alpha_j &\geq 0 \\ \sum_{j=1}^q \alpha_j &< 1\end{aligned}$$

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Además et a pesar de no presentar correlación serial, si lo hace en sus segundos momentos por tanto:

$$\text{Cov}(\varepsilon_j^2, \varepsilon_{j-1}^2) \neq 0$$

Entonces en la medida que el error se incrementa en t, podemos observar que en t+1 la varianza condicional aumenta.

Podemos decir que:

La varianza condicional estará dada por:

$$h_t = \alpha_0 + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2$$

La varianza incondicional estará dada por:

$$E(E_t^2) = \frac{\alpha_0}{1 - \sum_{j=1}^q \alpha_j}$$

El modelo ARCH(q) revisado anteriormente incorpora q rezagos de ε^2 . La estructura que propone Bollerslev (1986) incorpora componentes autorregresivos de h al incorporar rezagos de h_t en la definición de un modelo GARCH (p, q) de la siguiente forma:

$$r_t = \mu + \varepsilon_t$$

$$\varepsilon_t = \mu_t \cdot \sqrt{h_t}$$

$$h_t = \alpha_0 + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2 + \sum_{i=1}^p \beta_i h_{t-i}$$

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Nótese que el modelo ARCH (q) es un derivado del modelo GARCH (q, p) que incorpora cero rezagos de h con p=0.

Podemos decir que:

La varianza condicional estará dada por:

$$h_t = \alpha_0 + \sum_{j=1}^q \alpha_j \varepsilon_{t-1}^2 + \sum_{i=1}^p \beta_i h_{t-i}$$

Por tanto varía en el tiempo al igual que en el caso anterior.

La varianza incondicional estará dada por:

$$E(E_t^2) = \frac{\alpha_0}{1 - \sum_{j=1}^q \alpha_j - \sum_{i=1}^p \beta_i}$$

En cuanto a los coeficientes de h_t , estos deben cumplir ciertas condiciones que aseguren la no negatividad y valores finitos tanto para la varianza condicional como para la varianza incondicional, que son:

$$\alpha_0 > 0$$

$$\alpha_j \geq 0$$

$$\beta_i \geq 0$$

$$\sum_{j=1}^q \alpha_j < 1$$

$$\sum_{i=1}^p \beta_i < 1$$

$$\sum_{j=1}^q \alpha_j + \sum_{i=1}^p \beta_i < 1$$

La gran incógnita de este tipo de modelos es cuantos rezagos incluir. Para los modelos ARMA existen técnicas de selección como lo es Akaike (1973) que utiliza un criterio de selección. Pero mas allá de cuantos rezagos la pregunta es cuales rezagos incluir en la estructura. Como estos criterios no son capaces de responder esta interrogante entonces se recurre a una optimización de la estructura a través de algoritmo genético, proceso iterativo explicado en el punto anterior. A diferencia de un estudio econométrico

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

que apunta a encontrar causalidad, la utilización de AG nos brinda la capacidad de ajustarnos a lo que esta sucediendo en un momento determinado, es decir pretende capturar la tendencia en un instante otorgándonos la capacidad de tomar decisiones de corto plazo.

3- Metodología

3.1- Aspectos generales.

La puesta en marcha del estudio tiene como foco principal optimizar una estructura de modelo de volatilidad a través de algoritmo genético a fin de encontrar un modelo con el menor ECM posible, involucrando en el modelo la opción de utilizar información de algún cluster de alta volatilidad cuando esta se presente, por tanto el primer objetivo es evaluar la capacidad del modelo original en PPS y luego incorporar los clusters de volatilidad para encontrar una mejora en los resultados.

Los datos a utilizar es una serie histórica del índice IPSA comprendida entre enero del 2002 y diciembre del 2007 como datos diarios del last price. Las rentabilidades se obtienen de la siguiente manera $(P_t - P_{t-1}) / P_{t-1}$, donde P es el last price asociado al periodo t y t-1. Se emplean 677 observaciones.

El estudio se realiza en dos etapas, una de ellas es la evaluación de resultados de una optimización por Algoritmo genético sobre el modelo clásico expuesto en el marco teórico, es decir utilizar un GARCH (p, q) y en la segunda etapa se incorporan al modelo los clusters de volatilidad históricos para contrastar los resultados.

3.2- Especificación del Modelo con Clusters de Volatilidad Históricos

El modelo propuesto por esta tesis es un modelo GARCH modificado para ser capaz de incluir volatilidades pertenecientes a clusters de alta volatilidad históricos de la serie solo para aquellos valores de error que escapan a la media intramuestral.

$$\begin{aligned}
 r_t &= \mu + \varepsilon_t \\
 \varepsilon_t &= \mu_t \cdot \sqrt{h_t} \\
 h_t &= \alpha_0 + \sum_{j=1}^3 \alpha_j \varepsilon_{t-j}^2 + \sum_{i=1}^3 \beta_i h_{t-i} + D \sum_{m=1}^3 \delta_s C_{t'-m}
 \end{aligned}$$

Donde....

$$D = \begin{cases} 1 & \Leftrightarrow \varepsilon_{t-1} > \frac{1}{n} \sum_{i=1}^n \varepsilon_i \\ 0 & \end{cases}$$

Sea C_{t-m} rezago promedio de ε^2 perteneciente a un cluster de alta volatilidad en un tiempo t' determinado.

Sea δ_s parámetros a estimar sobre $C_{t'-m}$.

Sea D variable dummy que activa $C_{t'-m}$ solo cuando se presentan errores asociados a alta volatilidad.

Sea $\frac{1}{n} \sum_{i=1}^n \varepsilon_i$ el promedio de los errores de base intramuestral de observaciones “n”.

3.3- Desarrollo de Algoritmo Genético

Se asocia a cada variable explicativa un valor de celda que puede tomar valores 0 o uno y pondera su valor para activar o desactivar su participación en la estructura del modelo. Al conjunto de celdas con valores 0 o 1 que completan el número de variables propuestas en el modelo para una estructura dada se le denominará genotipo. La longitud de cada uno de ellos está dada por el número de rezagos a incluir que son; tres rezagos de ε^2 , tres rezagos de h_t y tres clusters de volatilidad más una constante.

Se crean entonces al menos 100 genotipos distintos de manera aleatoria que serán nuestra población de origen. La población es evaluada y jerarquizada por ECM para seleccionar los 10 mejores genotipos que entrarán en proceso de cross-over. El proceso de cross-over combina los genotipos de tal forma de obtener al menos dos individuos con un cruce simple. El proceso de elección de genotipos a cruzar también es aleatorio, este proceso ocurre hasta obtener 20 genotipos nuevos que entran en proceso de mutación y luego de evaluación para ser jerarquizados y repetir el cruce para obtener más generaciones. El proceso culmina hasta obtener la cuarta generación.

3.4- Evaluación

La evaluación del modelo bajo PPS medirá el resultado extramuestral de cada acierto en el signo de la rentabilidad como consecuencia de la predicción en volatilidad con h_t . Este proceso aplicará una selección de datos con rolling que incorpora información tomando los x datos anteriores en una iteración e incorporando la observación siguiente para estimar en una nueva iteración abandonando la información del último rezago utilizado en la predicción anterior, de tal forma de mantener x observaciones como muestra para la estimación por máxima verosimilitud, siendo x igual a 477.

$$Max_{\alpha_0, \alpha, \beta, \delta} \ln(f(\varepsilon_1, \dots, \varepsilon_T)) = -\frac{T}{2} \ln(2\pi) - \frac{T}{2} \ln(h_t) - \frac{1}{2h_t} \sum_{t=1}^T \varepsilon_t^2$$

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

La evaluación se hizo para el modelo especificado de forma general por:

$$\begin{aligned}r_t &= \mu + \varepsilon_t \\ \varepsilon_t &= \mu_t \cdot \sqrt{h_t} \\ h_t &= \alpha_0 + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2 + \sum_{i=1}^p \beta_i h_{t-i}\end{aligned}$$

Luego se llevo a cabo sobre el modelo propuesto.

$$\begin{aligned}r_t &= \mu + \varepsilon_t \\ \varepsilon_t &= \mu_t \cdot \sqrt{h_t} \\ h_t &= \alpha_0 + \sum_{j=1}^3 \alpha_j \varepsilon_{t-j}^2 + \sum_{i=1}^3 \beta_i h_{t-i} + D \sum_{m=1}^3 \delta_s C_{t'-m}\end{aligned}$$

Posteriormente para cada modelo se evalúa su ECM para la selección y se observa el PPS de cada modelo para ver su capacidad de predicción de signo.

3.4- Implementación modelo modificado.

Al igual que el modelo original se calculan las rentabilidades de cada semana de la forma $(P_t - P_{t-1}) / P_{t-1}$ y luego determinamos el error $\varepsilon_t = r_t - (1/477 \cdot \sum_1^{477} r_t)$ para un total de 477 datos correspondientes al tamaño de observaciones intramuestrales. Con los valores de μ_t intramuestrales se lleva cabo un bootstrapping donde se reordenan los datos en bloques de 4 de manera aleatoria hasta formar una nueva muestra pero esta vez del tamaño de nuestro conjunto extramuestral, es decir de 200 datos. Este proceso se repite 100 veces y se obtiene el promedio de cada fila para obtener el vector μ_t para el conjunto extramuestral. El bootstrap se hace para cada estructura evaluada por el algoritmo genético. Al maximizar la función de máxima verosimilitud expresada anteriormente se encuentran los parámetros de

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

la función h_t por lo que se obtiene r_t y se compara con el valor real obteniéndose un error por estimación que nos entrega al final del rolling un ECM y un PPS por cada modelo.

Hasta ahora el proceso es el mismo para cada modelo, la diferencia descansa en el análisis de la serie para obtener los clusters de volatilidad históricos, proceso que se detalla a continuación.

El análisis de la serie de retornos del IPSA consistió en identificar errores cuadráticos que estuviesen sobre el promedio del conjunto intramuestral, el promedio se elaboro con 477 datos semanales correspondientes a 8.5 años bajo la recomendación que se utilice un periodo representativo del ciclo económico que se esta viviendo, asumiendo que las volatilidades entre ciclos de expansión y ciclos recesivos pueden ser distintas. Cuando se encontraban cuatro datos seguidos sobre el promedio involucraba que durante un mes se obtuvieron altas volatilidades de manera persistente por lo que era posible calificarlo como un cluster de volatilidad, por tanto periodos en que se encontraban más de cuatro datos sobre el promedio pertenecían a un clusters de volatilidad. A su vez si estos clusters se encontraban próximos y separados únicamente por un valor que estaba dentro del promedio, entonces los clusters eran fusionados inclusive el valor que los separaba. Esta medida se tomo bajo la intuición de la existencia de shocks dentro de la volatilidad que pudo haber tornado ese valor a un nivel no representativo del periodo también era necesario descartar valores que a pesar de estar sobre el promedio no eran persistentes en el tiempo, con esto se aísla aquellos aumentos de volatilidad causados por manipulación directa de un solo agente sobre el IPSA, donde estos efectos son transitorios y de corta duración.

Cluster de Volatilidad			
IPSA		DURACIÓN	e² prom
13-01-1995	07-04-1995	84	0,0025
03-01-1997	24-01-1997	21	0,0017
07-08-1998	25-09-1998	49	0,0067
14-09-2001	30-11-2001	77	0,0013

Fig. 1. * Detalles del periodo se presenta en anexos.

El análisis encontró varios periodos susceptibles de ser calificados como clusters de alta volatilidad de acuerdo al criterio anteriormente establecido por lo que solo se tomaron

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

en cuenta los cuatro clusters de periodos mas prolongados de alta volatilidad (ver Fig. 1), de estos se tomo el promedio de sus errores cuadráticos para ser incluidos dentro de las variables para el calculo de h_t .

Entonces el modelo cuando evaluaba el periodo extramuestral podía incluir estos valores solo si el error cuadrático del periodo anterior estaba sobre el promedio. A través de una variable dummy fueron activadas las variables para que el algoritmo genético tuviera la opción de escoger entre ellas

4- Resultados y Análisis

4.1- Predicción de Signo bajo modelo GARCH (p, q).

Los resultados encontrados para la evaluación del modelo original en cuanto a su capacidad de predicción de signo fueron los siguientes.

	MEDIA	IC		Desv
PPS	53,93%	53,13%	54,73%	0,02813978
* 95% de Confianza				

De los mejores modelos obtenidos por algoritmo genético se observo que la media obtenida no es un buen valor como porcentaje de predicción de signo, incluso el modelo óptimo tan solo obtiene un 59% de PPS. Era de esperarse este resultado sabiendo que la obtención de un ECM mínimo garantiza un buen ajuste en magnitud del valor estimado sin estar dentro de sus objetivos el acertar al signo.

Esta evaluación aclara que la optimización de este tipo de modelos para el índice IPSA no conlleva un buen nivel de predicción de signo.

	<i>Columna 1</i>	<i>Columna 2</i>
<i>Columna 1</i>	1	
<i>Columna 2</i>	-0,50460749	1

Si observamos el coeficiente de correlación entre PPS y ECM podemos ver que de existir una relación lineal esta seria negativa sobre la muestra de 100 modelos obtenidos por el algoritmo genético además la tabla siguiente nos muestra el resultado de covarianza entre las variables.

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

	Columna 1	Columna 2
Columna 1	5,6565E-11	
Columna 2	-1,6824E-07	0,00128643

Los resultados muestran que mas allá de no obtener un buen nivel de predicción de signo bajo este modelo, puede llegarse a un mejor desempeño en la medida que obtenemos un ECM cada vez mas bajo. En la medida que el ajuste sea bueno aumentamos las probabilidades de encontrar un mejor PPS.

4.2- Modelo GARCH (p, q) modificado.

Los resultados obtenidos de la evaluación de los modelos optimizados por algoritmo genético aplicados al índice IPSA fueron los siguientes.

Optimo	GARCH (P ,Q)											PPS	ECM	Desv
ECM	1	0	0	0	0	0	0	1	0	0	0	54%	0,000400401	0,020
PPS	1	1	0	1	0	0	0	1	0	0	0	59%	0,000404324	0,020

$$ECM_OPT \gg h_t = \alpha_0 + \beta_2 h_{t-2}$$

$$PPS_OPT \gg h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_3 \varepsilon_{t-3}^2 + \beta_2 h_{t-2}$$

Optimo	GARCH (P ,Q) Clusters de Volatilidad											PPS	ECM	Desv
ECM	1	0	0	0	0	0	1	1	1	1	0	57%	0,000394143	0,020
PPS	1	0	0	1	0	0	1	1	1	0	1	62%	0,000400195	0,020

$$ECM_OPT \gg h_t = \alpha_0 + \beta_3 h_{t-3} + D\delta_1 C_{t-1} + D\delta_2 C_{t-2} + D\delta_3 C_{t-3}$$

$$PPS_OPT \gg h_t = \alpha_0 + \alpha_3 \varepsilon_{t-3}^2 + \beta_3 h_{t-3} + D\delta_1 C_{t-1} + D\delta_2 C_{t-2} + D\delta_4 C_{t-4}$$

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Los datos que se pueden observar son las estructuras de modelo óptimas que el algoritmo genético pudo encontrar, por cada tabla se encuentra la estructura con menor ECM y mayor PPS. Se puede observar que tanto para el modelo con menor ECM y mayor PPS al incluir los clusters de volatilidad mejoran en su desempeño tanto en PPS como en ECM.

5- Conclusiones

La inclusión de “*clusters*” de volatilidad históricos en el modelo logró encontrar mejores resultados tanto en PPS como en ECM al momento de encontrar una estructura óptima a través de algoritmo genético.

Esto puede ser explicado por la forma en que los agentes enfrentan los episodios de alta volatilidad donde la incertidumbre sobre la tendencia que tomará el mercado, la duración del periodo y la magnitud de las rentabilidades esperadas se hacen difícil de estimar sin un precedente similar por lo que buscan comportamientos parecidos a lo largo del tiempo con el fin de dar respuestas a sus incógnitas y poder tomar decisiones de trading.

Se encontró que los modelos GARCH (p, q) óptimos en ECM no entregan un buen porcentaje de predicción de signo (PPS) en relación al modelo que incluye los clusters.

Se estima que existe una relación lineal entre el ECM y PPS negativa en cuanto a que en la medida que aumenta el ajuste de la estimación obteniendo un menor ECM podemos encontrar mejores PPS. Esto ofrece la oportunidad de encontrar modelos que obtengan un PPS que acote cada vez más la pérdida cuando se da el porcentaje de error posible (1-PPS). Esto es consistente con la formulación de modelos GARCH en que la magnitud de error, entre la estimación y el valor real, es un objetivo dentro de la función de optimización la que encuentra ECM mínimos que garantizan un buen ajuste.

Se espera que esta investigación pueda ser aplicada en otros índices a fin de confirmar más extensivamente estos resultados, particularmente en lo que se refiere al éxito del PPS. Se sabe que el porcentaje de error de predicción de signo PPS puede disminuir e incluso deteriorar la rentabilidad esperada. Esto tiene lugar pues el proceso de optimización no considera la magnitud del cambio del valor del precio sino solo su dirección. Sin embargo, este estudio abre la opción de que muestra que un equilibrio o conciliación podría ser posible en la medida que se pueda enriquecer el modelo al incorporar “*clusters*” de volatilidad históricos susceptibles de ser observados por los agentes para la toma de decisiones.

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Bibliografía

Bollerslev, T. año 1986. “Generalized Autorregresive Conditional Heterocedasticity”, Journal of Econometrics

Davis, Lawrence año 1994. “Genetic Algorithms and Financial Applications, in: Deboeck”

De Arce, Rafael año1998. “ Introducción a los Modelos Autorregresivos con Heterocedasticidad Condicional”

Engle, año 1982. “Autorregresive Conditional Heterocedasticity with Estimates of the Variance of the U.K. Inflation”

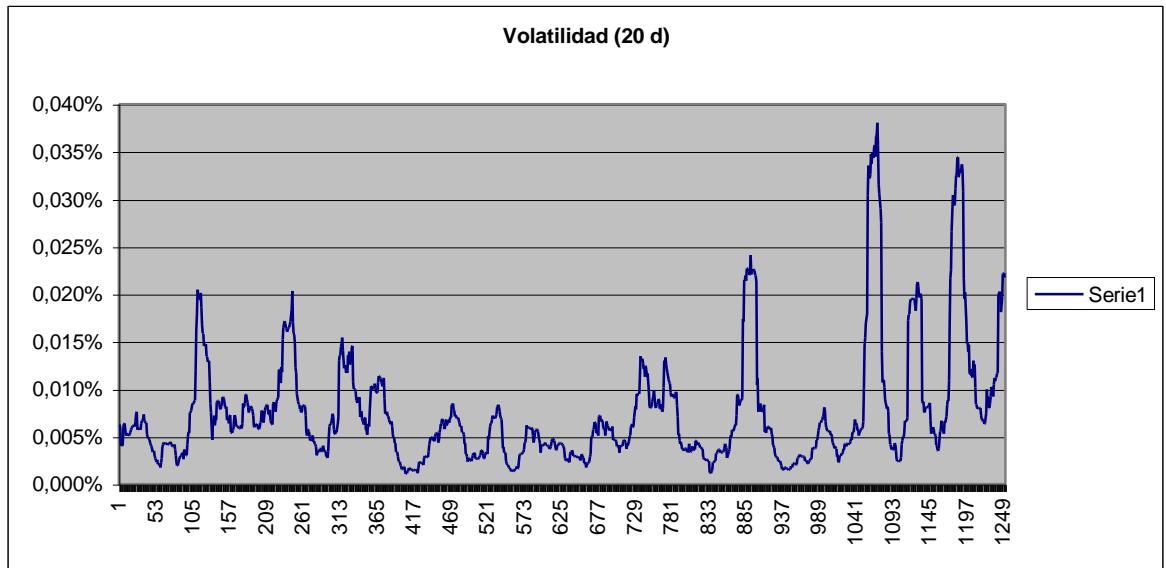
Engle, R. año2001. “GARCH 101: The Use of ARCH/GARCH Models in Applied Econometrics, Journal of Economic Perspectives”

Holland, John H. año 1975. “Adaptation in Natural and Artificial Systems”, The University of Michigan

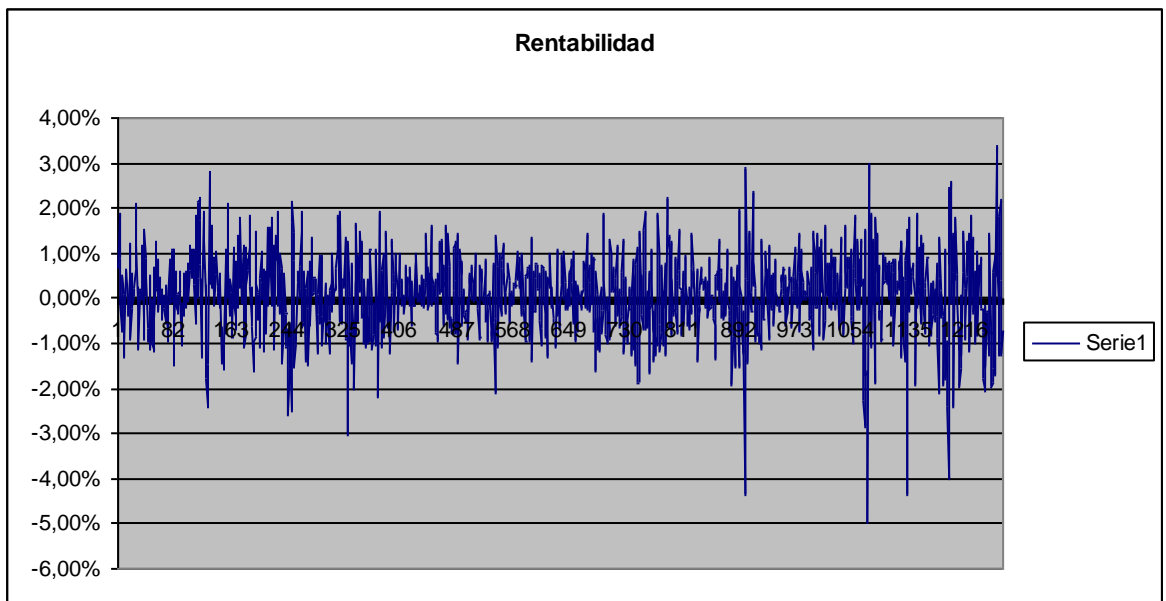
Parisi, A., Parisi, F. y E. Cornejo año 2004. “Algoritmos Genéticos y Modelos Multivariados Recursivos en la Predicción de Índices Bursátiles de América del Norte: IPC, TSE, NASDAQ Y DJI”

Anexos

IPSA Volatilidad



IPSA Retorno



“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Datos

IPSA	PX	IPSA	PX	IPSA	PX	IPSA	PX
06-01-1995	983,53	13-12-1996	910,14	20-11-1998	821,45	27-10-2000	1.049,28
13-01-1995	1.014,47	20-12-1996	905,19	27-11-1998	836,63	03-11-2000	1.100,58
20-01-1995	962,07	27-12-1996	906,24	04-12-1998	769,65	10-11-2000	1.104,96
27-01-1995	956,31	03-01-1997	929,57	11-12-1998	740,03	17-11-2000	1.100,29
03-02-1995	982,68	10-01-1997	971,01	18-12-1998	784,35	24-11-2000	1.103,31
10-02-1995	941,23	17-01-1997	1.019,45	25-12-1998	799,26	01-12-2000	1.088,25
17-02-1995	901,73	24-01-1997	975,82	01-01-1999	786,66	08-12-2000	1.088,38
24-02-1995	947,44	31-01-1997	995,51	08-01-1999	785,01	15-12-2000	1.094,49
03-03-1995	884,62	07-02-1997	1.043,64	15-01-1999	705,80	22-12-2000	1.066,68
10-03-1995	822,03	14-02-1997	1.042,51	22-01-1999	740,70	29-12-2000	1.084,41
17-03-1995	887,37	21-02-1997	1.043,60	29-01-1999	810,50	05-01-2001	1.097,91
24-03-1995	935,78	28-02-1997	1.044,42	05-02-1999	817,70	12-01-2001	1.102,21
31-03-1995	908,62	07-03-1997	1.053,17	12-02-1999	869,29	19-01-2001	1.134,33
07-04-1995	950,84	14-03-1997	1.045,27	19-02-1999	899,77	26-01-2001	1.131,16
14-04-1995	939,99	21-03-1997	1.016,94	26-02-1999	859,60	02-02-2001	1.130,43
21-04-1995	949,99	28-03-1997	1.031,53	05-03-1999	898,19	09-02-2001	1.109,06
28-04-1995	972,34	04-04-1997	1.045,43	12-03-1999	905,84	16-02-2001	1.098,58
05-05-1995	1.000,15	11-04-1997	1.065,54	19-03-1999	919,54	23-02-2001	1.089,10
12-05-1995	1.053,54	18-04-1997	1.057,48	26-03-1999	917,48	02-03-2001	1.094,65
19-05-1995	1.050,33	25-04-1997	1.054,62	02-04-1999	938,98	09-03-2001	1.105,69
26-05-1995	1.052,02	02-05-1997	1.074,76	09-04-1999	971,20	16-03-2001	1.062,49
02-06-1995	1.061,28	09-05-1997	1.086,13	16-04-1999	998,87	23-03-2001	1.042,66
09-06-1995	1.058,43	16-05-1997	1.079,37	23-04-1999	955,45	30-03-2001	1.062,44
16-06-1995	1.037,25	23-05-1997	1.127,75	30-04-1999	939,82	06-04-2001	1.053,14
23-06-1995	1.038,34	30-05-1997	1.169,73	07-05-1999	958,55	13-04-2001	1.052,43
30-06-1995	1.076,52	06-06-1997	1.176,10	14-05-1999	965,49	20-04-2001	1.083,06
07-07-1995	1.099,31	13-06-1997	1.226,07	21-05-1999	930,98	27-04-2001	1.102,42
14-07-1995	1.102,45	20-06-1997	1.196,88	28-05-1999	903,10	04-05-2001	1.126,49
21-07-1995	1.072,35	27-06-1997	1.185,44	04-06-1999	922,37	11-05-2001	1.158,22
28-07-1995	1.047,30	04-07-1997	1.235,93	11-06-1999	948,79	18-05-2001	1.166,03
04-08-1995	1.040,25	11-07-1997	1.212,70	18-06-1999	984,93	25-05-2001	1.179,56
11-08-1995	997,50	18-07-1997	1.170,54	25-06-1999	972,74	01-06-2001	1.205,55
18-08-1995	1.030,72	25-07-1997	1.212,33	02-07-1999	1.048,83	08-06-2001	1.194,23
25-08-1995	977,58	01-08-1997	1.221,96	09-07-1999	1.074,12	15-06-2001	1.206,73
01-09-1995	993,78	08-08-1997	1.207,52	16-07-1999	1.059,52	22-06-2001	1.181,87
08-09-1995	973,92	15-08-1997	1.190,79	23-07-1999	1.030,43	29-06-2001	1.169,20
15-09-1995	983,13	22-08-1997	1.181,96	30-07-1999	1.014,01	06-07-2001	1.181,44
22-09-1995	967,29	29-08-1997	1.145,99	06-08-1999	1.030,29	13-07-2001	1.152,32
29-09-1995	969,90	05-09-1997	1.185,69	13-08-1999	1.002,19	20-07-2001	1.163,55
06-10-1995	970,46	12-09-1997	1.177,87	20-08-1999	978,41	27-07-2001	1.190,97
13-10-1995	983,26	19-09-1997	1.182,82	27-08-1999	1.007,75	03-08-2001	1.203,81
20-10-1995	992,98	26-09-1997	1.155,33	03-09-1999	1.046,12	10-08-2001	1.229,70
27-10-1995	1.023,06	03-10-1997	1.142,99	10-09-1999	1.069,62	17-08-2001	1.236,47
03-11-1995	984,74	10-10-1997	1.118,43	17-09-1999	1.030,55	24-08-2001	1.235,23
10-11-1995	940,91	17-10-1997	1.090,11	24-09-1999	1.014,85	31-08-2001	1.239,25
17-11-1995	957,87	24-10-1997	1.086,11	01-10-1999	985,04	07-09-2001	1.222,50
24-11-1995	965,39	31-10-1997	1.065,03	08-10-1999	978,14	14-09-2001	1.144,61
01-12-1995	974,49	07-11-1997	1.033,60	15-10-1999	930,01	21-09-2001	1.104,50
08-12-1995	982,21	14-11-1997	1.015,20	22-10-1999	971,62	28-09-2001	1.071,28
15-12-1995	1.023,46	21-11-1997	1.035,22	29-10-1999	987,69	05-10-2001	1.033,96
22-12-1995	1.038,10	28-11-1997	1.037,45	05-11-1999	1.023,54	12-10-2001	1.071,95
29-12-1995	1.021,01	05-12-1997	1.047,39	12-11-1999	1.029,03	19-10-2001	1.100,11
05-01-1996	1.042,88	12-12-1997	1.017,16	19-11-1999	1.045,91	26-10-2001	1.136,95
12-01-1996	1.040,67	19-12-1997	987,88	26-11-1999	1.043,58	02-11-2001	1.115,08
19-01-1996	1.044,68	26-12-1997	979,54	03-12-1999	1.093,21	09-11-2001	1.177,17
26-01-1996	1.009,25	02-01-1998	1.025,69	10-12-1999	1.076,71	16-11-2001	1.215,14
02-02-1996	1.042,77	09-01-1998	917,68	17-12-1999	1.098,26	23-11-2001	1.226,61
09-02-1996	1.024,82	16-01-1998	904,92	24-12-1999	1.119,64	30-11-2001	1.192,07
16-02-1996	999,01	23-01-1998	890,04	31-12-1999	1.125,30	07-12-2001	1.195,61
23-02-1996	1.014,80	30-01-1998	907,31	07-01-2000	1.127,58	14-12-2001	1.189,00
01-03-1996	1.021,38	06-02-1998	909,07	14-01-2000	1.214,33	21-12-2001	1.187,53
08-03-1996	985,90	13-02-1998	915,01	21-01-2000	1.208,18	28-12-2001	1.183,12
15-03-1996	994,45	20-02-1998	974,76	28-01-2000	1.163,14	04-01-2002	1.203,40
22-03-1996	989,24	27-02-1998	1.001,46	04-02-2000	1.214,15	11-01-2002	1.154,09
29-03-1996	973,45	06-03-1998	1.039,34	11-02-2000	1.223,39	18-01-2002	1.142,21
05-04-1996	946,98	13-03-1998	1.061,39	18-02-2000	1.135,79	25-01-2002	1.154,90

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

IPSA	PX	IPSA	PX	IPSA	PX
04-10-2002	951,29	10-09-2004	1.608,01	18-08-2006	2.168,31
11-10-2002	910,27	17-09-2004	1.658,55	25-08-2006	2.158,13
18-10-2002	918,78	24-09-2004	1.690,75	01-09-2006	2.207,96
25-10-2002	930,21	01-10-2004	1.731,16	08-09-2006	2.197,80
01-11-2002	958,51	08-10-2004	1.703,44	15-09-2006	2.232,58
08-11-2002	949,81	15-10-2004	1.700,04	22-09-2006	2.231,91
15-11-2002	974,40	22-10-2004	1.749,38	29-09-2006	2.280,48
22-11-2002	966,62	29-10-2004	1.768,20	06-10-2006	2.312,43
29-11-2002	960,31	05-11-2004	1.768,21	13-10-2006	2.356,97
06-12-2002	971,09	12-11-2004	1.740,98	20-10-2006	2.365,87
13-12-2002	965,34	19-11-2004	1.749,09	27-10-2006	2.372,86
20-12-2002	1.004,85	26-11-2004	1.773,94	03-11-2006	2.345,07
27-12-2002	998,14	03-12-2004	1.806,77	10-11-2006	2.442,24
03-01-2003	1.008,46	10-12-2004	1.783,55	17-11-2006	2.494,05
10-01-2003	1.030,20	17-12-2004	1.797,95	24-11-2006	2.542,70
17-01-2003	1.012,91	24-12-2004	1.811,35	01-12-2006	2.561,70
24-01-2003	994,00	31-12-2004	1.796,48	08-12-2006	2.585,48
31-01-2003	1.001,99	07-01-2005	1.764,46	15-12-2006	2.668,17
07-02-2003	1.015,24	14-01-2005	1.745,31	22-12-2006	2.692,08
14-02-2003	1.011,29	21-01-2005	1.753,34	29-12-2006	2.693,36
21-02-2003	1.008,27	28-01-2005	1.799,67	05-01-2007	2.723,48
28-02-2003	1.014,94	04-02-2005	1.815,54	12-01-2007	2.741,08
07-03-2003	1.035,26	11-02-2005	1.825,34	19-01-2007	2.827,14
14-03-2003	1.017,52	18-02-2005	1.838,44	26-01-2007	2.853,04
21-03-2003	1.022,98	25-02-2005	1.887,33	02-02-2007	2.951,55
28-03-2003	1.009,34	04-03-2005	1.920,72	09-02-2007	3.019,63
04-04-2003	1.018,79	11-03-2005	1.910,55	16-02-2007	3.107,40
11-04-2003	1.052,40	18-03-2005	1.936,29	23-02-2007	2.919,84
18-04-2003	1.086,48	25-03-2005	1.942,75	02-03-2007	2.832,33
25-04-2003	1.109,69	01-04-2005	1.955,89	09-03-2007	2.875,62
02-05-2003	1.183,96	08-04-2005	1.992,53	16-03-2007	2.916,85
09-05-2003	1.200,82	15-04-2005	1.963,66	23-03-2007	2.954,35
16-05-2003	1.206,53	22-04-2005	1.982,20	30-03-2007	2.929,00
23-05-2003	1.197,06	29-04-2005	1.956,98	06-04-2007	2.996,09
30-05-2003	1.231,01	06-05-2005	1.993,43	13-04-2007	3.083,89
06-06-2003	1.270,85	13-05-2005	1.949,96	20-04-2007	3.150,51
13-06-2003	1.277,89	20-05-2005	1.953,90	27-04-2007	3.149,19
20-06-2003	1.245,38	27-05-2005	1.951,01	04-05-2007	3.214,18
27-06-2003	1.228,08	03-06-2005	2.012,91	11-05-2007	3.247,27
04-07-2003	1.257,53	10-06-2005	2.017,49	18-05-2007	3.257,23
11-07-2003	1.256,70	17-06-2005	2.065,54	25-05-2007	3.210,31
18-07-2003	1.248,75	24-06-2005	2.063,51	01-06-2007	3.304,57
25-07-2003	1.301,84	01-07-2005	2.062,90	08-06-2007	3.288,52
01-08-2003	1.333,51	08-07-2005	2.061,33	15-06-2007	3.380,13
08-08-2003	1.335,45	15-07-2005	2.091,43	22-06-2007	3.447,45
15-08-2003	1.398,51	22-07-2005	2.151,86	29-06-2007	3.470,18
22-08-2003	1.367,35	29-07-2005	2.175,06	06-07-2007	3.425,28
29-08-2003	1.369,62	05-08-2005	2.152,19	13-07-2007	3.385,09
05-09-2003	1.354,45	12-08-2005	2.107,27	20-07-2007	3.366,39
12-09-2003	1.364,71	19-08-2005	2.089,08	27-07-2007	3.292,29
19-09-2003	1.370,04	26-08-2005	2.124,87	03-08-2007	3.314,86
26-09-2003	1.415,21	02-09-2005	2.065,33	10-08-2007	3.192,84
03-10-2003	1.475,70	09-09-2005	2.101,03	17-08-2007	3.033,55
10-10-2003	1.519,15	16-09-2005	2.121,57	24-08-2007	3.252,47
17-10-2003	1.560,32	23-09-2005	2.158,25	31-08-2007	3.310,14
24-10-2003	1.551,21	30-09-2005	2.152,82	07-09-2007	3.200,85
31-10-2003	1.515,96	07-10-2005	2.160,43	14-09-2007	3.167,87
07-11-2003	1.419,83	14-10-2005	2.131,97	21-09-2007	3.220,31
14-11-2003	1.469,60	21-10-2005	2.100,32	28-09-2007	3.249,00
21-11-2003	1.414,19	28-10-2005	2.056,94	05-10-2007	3.361,10
28-11-2003	1.458,34	04-11-2005	2.036,00	12-10-2007	3.414,67
05-12-2003	1.485,62	11-11-2005	2.023,76	19-10-2007	3.414,02
12-12-2003	1.464,85	18-11-2005	2.083,46	26-10-2007	3.496,18
19-12-2003	1.440,13	25-11-2005	2.069,49	02-11-2007	3.388,45
26-12-2003	1.471,92	02-12-2005	2.056,91	09-11-2007	3.240,88
02-01-2004	1.484,60	09-12-2005	2.004,37	16-11-2007	3.236,28

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Extracto Clusters

Errores		
IPSA		
Promedio		
0,0210		
0,030	0,034	0,099
0,053	0,035	0,000
0,008	0,006	0,015
0,026	0,007	0,017
0,044	0,001	0,082
0,044	0,024	0,040
0,049	0,043	0,058
0,068	0,048	0,017
0,072	0,045	0,017
0,078	0,018	0,004
0,053	0,047	0,103
0,031	0,003	0,048
0,045	0,001	0,093
0,013	0,001	0,007
0,009	0,007	0,061
0,022	0,009	0,033
0,027	0,029	0,046
0,052	0,013	0,043
0,005	0,012	0,007
0,000	0,018	0,013
0,007	0,009	0,004
0,004	0,004	0,022
0,022	0,017	0,033
0,001	0,009	0,027
0,035	0,008	0,045
0,019	0,043	0,018
0,001	0,036	0,018
0,029	0,004	0,006
0,025	0,041	0,037
0,008	0,026	0,032
0,043	0,011	0,020
0,032	0,041	0,027
0,053	0,021	0,036
0,015	0,036	0,014
0,022	0,034	0,077
0,008	0,006	0,022
0,018	0,014	0,015
0,001	0,016	0,029
0,001	0,009	0,018
0,011	0,032	0,014
0,008	0,033	0,029
0,029	0,008	0,025
0,039	0,002	0,028
0,046	0,025	0,036
0,016	0,012	0,021
0,006	0,023	
0,008	0,027	
0,006	0,005	
0,040	0,021	
0,013	0,031	
0,018	0,020	
0,020	0,018	
0,004	0,000	
0,002	0,008	
0,036	0,031	
0,031	0,031	
0,019	0,010	
0,027	0,045	
0,014	0,107	
0,005	0,016	
0,036	0,018	
0,007	0,018	
0,007	0,000	

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Cross-Over Algoritmo Genético

Genes Originales de proceso aleatorio										
Individuo 1	0	1	0	1	0	1	1	1	1	0
Individuo 2	1	0	1	1	1	0	0	0	1	0
Cross-Over Simple										
Nvo. Individuo	0	1	0	1	0	0	0	0	1	0
Nvo. Individuo	1	0	1	1	1	1	1	1	1	0
Matriz de Individuos Producidos										
Ind 1	0	0	0	0	0	1	1	1	1	0
Ind 2	1	0	1	1	1	0	0	0	1	0
Ind 3	0	0	0	1	0	1	0	0	1	0
Ind 4	0	1	1	0	0	0	0	1	1	0
Ind 5	0	0	1	0	0	1	1	1	0	1
Ind 6	1	1	1	0	0	0	1	0	0	0
Ind 7	0	0	0	0	0	1	0	1	0	0
Ind 8	1	1	0	0	1	1	1	1	0	1
Ind 9	1	1	0	0	1	0	0	1	1	1
Ind 10	1	0	0	0	0	0	1	0	0	0
Ind 11	0	0	0	1	1	0	1	1	0	0
Ind 12	1	1	0	1	0	0	0	1	0	0
Ind 13	1	0	0	0	0	0	1	0	0	1
Ind 14	1	0	1	0	0	0	0	0	1	1
Ind 15	1	0	0	1	1	0	1	0	0	0
Ind 16	1	0	0	1	0	1	0	1	1	0
Ind 17	0	0	0	0	0	0	1	0	1	1
Ind 18	1	1	0	1	0	0	0	0	1	1
Ind 19	1	0	1	1	0	0	0	1	1	1
Ind 20	1	1	0	0	1	0	1	1	0	0

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Estructura de 50 Mejores Modelos (Clúster de Volatilidad)

0	0	0	0	0	1	1	1	1	0	57%	0,000394143
1	0	1	1	1	0	0	0	1	0	55%	0,000395448
0	0	0	1	0	1	0	0	1	0	55%	0,00039638
0	1	1	0	0	0	0	1	1	0	55%	0,000399953
0	0	1	0	0	1	1	1	0	1	62%	0,000400195
1	1	1	0	0	0	1	0	0	0	58%	0,000400456
0	0	0	0	0	1	0	1	0	0	52%	0,000401421
1	1	0	0	1	1	1	1	0	1	57%	0,000402062
1	1	0	0	1	0	0	1	1	1	56%	0,000402127
1	0	0	0	0	0	1	0	0	0	57%	0,000402361
0	0	0	1	1	0	1	1	0	0	53%	0,00040246
1	1	0	1	0	0	0	1	0	0	58%	0,000402501
1	0	0	0	0	0	1	0	0	1	53%	0,000402555
1	0	1	0	0	0	0	0	1	1	48%	0,000402833
1	0	0	1	1	0	1	0	0	0	54%	0,000403477
1	0	0	1	0	1	0	1	1	0	52%	0,000403478
0	0	0	0	0	0	1	0	1	1	53%	0,000404071
1	1	0	1	0	0	0	0	1	1	49%	0,000404113
1	0	1	1	0	0	0	1	1	1	55%	0,000407608
1	1	0	0	1	0	1	1	0	0	53%	0,000407654
0	1	0	1	1	1	0	0	0	1	52%	0,000407847
1	1	0	1	1	1	1	0	1	0	53%	0,000407888
1	1	1	0	1	0	0	0	1	0	55%	0,00040813
0	1	0	0	0	0	1	0	0	1	47%	0,000409152
0	0	1	1	0	0	1	0	1	0	51%	0,000409575
1	1	0	0	1	1	0	0	1	1	54%	0,00040988
0	0	0	1	0	0	0	1	0	0	48%	0,000410344
1	1	0	1	1	0	0	0	1	1	57%	0,000410481
0	0	0	0	1	0	1	1	0	0	56%	0,000410639
1	0	0	1	0	0	0	0	0	1	55%	0,000410664
0	0	1	0	0	0	1	0	1	0	47%	0,000411128
1	0	0	0	1	1	1	0	1	1	53%	0,000412039
1	0	1	1	0	0	1	0	1	0	47%	0,000413221
0	0	1	1	1	1	0	0	1	1	51%	0,00041332
0	0	0	1	0	1	1	1	0	1	52%	0,000413895
0	1	1	0	0	1	0	1	1	0	50%	0,000414418
1	1	0	0	0	0	0	0	1	0	51%	0,000414655
0	1	0	1	0	0	1	1	1	0	54%	0,00041496
0	1	1	0	1	0	0	0	0	0	52%	0,000415883
1	1	1	0	0	1	1	0	1	0	54%	0,000415932
0	1	1	0	0	1	0	1	1	1	48%	0,000416345
1	1	0	1	1	0	0	1	0	1	45%	0,00041816
1	0	1	0	1	0	1	0	0	1	56%	0,000420269
0	0	0	0	1	1	0	1	1	0	49%	0,000420309
0	0	0	0	0	0	0	1	0	1	53%	0,00042041
1	0	0	1	0	0	1	1	0	1	52%	0,000420861
1	1	0	1	0	0	0	1	0	0	45%	0,00042351
0	0	1	0	1	0	1	1	1	1	50%	0,000425188
0	1	1	0	0	1	0	1	1	1	52%	0,000426586
0	0	0	0	0	0	0	1	0	0	47%	0,000436704

“Un modelo no lineal para la predicción de la variación del índice IPSA considerando volatilidades en clustering”

Estructura de 50 Mejores Modelos (Modelo Original)

0	1	1	1	1	1	0	1	1	0	54%	0,0004
1	0	0	1	1	0	1	0	1	0	57%	0,0004
0	0	1	0	0	0	1	1	1	1	58%	0,0004
1	0	0	1	1	1	0	0	1	1	57%	0,0004
1	1	0	1	0	0	1	0	0	0	58%	0,0004
0	1	0	1	1	1	0	0	1	1	57%	0,0004
0	0	0	1	1	1	0	1	0	1	58%	0,0004
0	1	0	1	1	1	1	0	0	1	59%	0,0004
0	1	1	1	0	1	0	1	1	1	56%	0,0004
1	0	0	1	0	1	1	1	0	0	55%	0,0004
0	1	0	1	1	1	1	1	0	0	57%	0,0004
1	1	1	0	0	1	0	0	1	0	57%	0,0004
0	0	1	1	1	1	1	0	0	1	58%	0,0004
1	1	1	0	1	0	1	0	0	0	54%	0,0004
1	0	0	1	1	0	1	1	1	1	55%	0,0004
0	0	0	1	1	1	1	0	1	0	49%	0,0004
1	0	0	0	0	1	1	1	1	0	51%	0,0004
0	1	1	1	0	1	0	0	0	0	54%	0,0004
0	0	0	0	1	1	0	0	1	1	56%	0,0004
0	1	1	1	1	1	1	1	1	1	53%	0,0004
1	0	0	1	0	1	0	1	0	1	53%	0,0004
1	0	1	1	0	0	0	0	1	1	50%	0,0004
0	1	1	1	0	1	0	1	0	1	53%	0,0004
1	0	1	0	0	0	1	0	0	0	59%	0,0004
1	0	0	0	0	0	1	0	1	1	56%	0,0004
0	1	1	0	0	0	0	1	0	0	54%	0,0004
1	1	0	1	1	0	0	1	1	0	52%	0,0004
0	1	1	0	1	1	1	0	1	1	54%	0,0004
1	1	0	1	1	0	0	0	1	1	53%	0,0004
0	0	1	1	0	0	0	1	1	1	53%	0,0004
1	0	0	0	1	1	0	0	0	0	50%	0,0004
1	1	1	0	1	1	0	1	1	0	48%	0,0004
0	1	1	1	1	1	0	0	1	0	54%	0,0004
0	0	1	1	1	1	0	1	0	0	53%	0,0004
0	1	0	1	1	1	0	0	0	1	50%	0,0004
0	0	1	0	1	0	1	1	1	1	51%	0,0004
0	0	0	1	1	1	1	0	1	0	52%	0,0004
1	0	0	0	1	0	1	0	0	1	56%	0,0004
1	0	0	0	0	0	1	0	1	0	55%	0,0004
1	1	0	0	0	1	1	1	0	0	52%	0,0004
0	0	1	0	1	0	1	0	1	1	52%	0,0004
0	0	1	1	0	0	0	1	0	1	51%	0,0004
1	1	1	1	0	0	0	1	0	0	51%	0,0004
1	0	1	1	0	1	1	1	0	1	52%	0,0004
0	1	0	0	1	0	1	0	1	1	53%	0,0004
0	1	0	0	1	1	0	0	1	1	58%	0,0004
0	1	1	0	1	1	0	1	0	0	56%	0,0004
0	0	1	1	1	1	1	0	1	1	54%	0,0004
0	1	1	0	1	1	1	0	0	1	55%	0,0004
0	1	0	1	1	1	1	0	0	0	58%	0,0004