

Autómatas Celulares en Índices Bursátiles de América del Norte: DJI, Nasdaq, IPC y TSE

Antonino Parisi F., Ph.D.¹

Franco Parisi F., Ph.D.²

¹ Profesor Asistente, Departamento de Administración, Universidad de Chile.

Chair Professor in Finance EuroAmerica

² Profesor Asociado, Departamento de Administración, Universidad de Chile.

Chair Professor in Finance EuroAmerica

Resumen

Esta investigación analiza las bondades de la *teoría de autómatas celulares* como modelamiento del comportamiento de los mercados accionarios de América del Norte. Los *autómatas celulares* son útiles para modelar cualquier sistema complejo. Pueden considerarse como una buena alternativa a las ecuaciones diferenciales y han sido utilizados para modelar sistemas físicos, sistemas biológicos a nivel celular, multicelular y poblacional. En este artículo se desarrolla una aplicación de esta teoría para proyectar la variación de los signos de los índices bursátiles DJI y Nasdaq (USA), IPC (México) y TSE (Canadá), entendiéndose que la predicción de la dirección del movimiento del índice accionario es relevante para desarrollar estrategias de transacción efectivas (Leung, Daouk & Chen, 2000; Parisi, Parisi & Cornejo, 2004). El desempeño relativo de los modelos fue medido por el número de predicciones correctas (*hits*) de la variación del signo del índice. Se encontró que el menor *porcentaje de predicción de signo* (PPS) fue de 60% y correspondió al índice Nasdaq; mientras que el más alto fue de 67% para el TSE. La capacidad predictiva de los *autómatas celulares* resultó estadísticamente significativa en cada uno de los índices analizados y, además, éstos superaron en rentabilidad al modelo ingenuo y a la estrategia *buy and hold*. Este estudio presenta evidencia de que los *autómatas celulares* podrían convertirse en una alternativa a las metodologías predictivas tradicionalmente utilizadas en la administración de portfolios de inversión.

CJEL: G10, G14 Y G15

Palabras Claves: Autómata Celular, Celda, Vecindario, Estado, Porcentaje de Predicción de Signo, Directional Accuracy Test.

Correspondencia:

Franco Parisi F., Ph.D.

Diagonal Paraguay 257, oficina 1103.

Santiago, Chile

fparisi@negocios.uchile.cl

Teléfono: 56-2-978-3366, fax 222-0639

I. Introducción

En el área de administración de portafolios de inversión, tanto los empiricistas como los académicos suelen realizar esfuerzos para modelar el comportamiento de los retornos accionarios, con el objetivo de obtener pronósticos confiables acerca de la rentabilidad futura de un instrumento de inversión en particular o del mercado en general. En esta labor, los analistas utilizan técnicas tales como modelos auto-regresivos, modelos multivariados dinámicos, modelos de redes neuronales y modelos de algoritmos genéticos, entre otros. En este contexto, los modelos de *autómata celular* ofrecen una aproximación distinta para modelar el comportamiento y realizar proyecciones de las variaciones futuras de precios accionarios e índices bursátiles.

Los *autómatas celulares* fueron introducidos por Ulam¹ a fines de la década de 1940, inmediatamente después de que aparecieron los computadores. Los *autómatas celulares* son modelos concebidos como algoritmos matemáticos, y permiten simular consecuencias globales sobre la base de las interacciones locales que se producen entre los individuos que pertenecen a una población. De manera más específica, un *autómata celular* es un modelo discreto que consiste en un panel con un conjunto finito de *celdas* (células), donde cada una de ellas adopta un *estado* dentro de un número finito de estados posibles. Como señalan Malamud & Turcotte (2000), cada estado de la celda es actualizado en etapas que ocurren en tiempo discreto, de acuerdo a una *regla local* o a un *conjunto de reglas*. Estas reglas pueden depender del estado de la celda en el período anterior ($t-1$) y/o del estado de sus *vecinos* más cercanos. Cada vez que las reglas son aplicadas en el panel, se produce una nueva generación de celdas o –en nuestro caso– una nueva proyección.

A principios de los '70, el matemático inglés Conway introdujo un *autómata celular* bidimensional conocido como *Life Game*. Para entender este *autómata celular*, considere un tablero de ajedrez sin límites donde las celdas tienen dos posibles estados, estar *vacías* u *ocupadas*: *vacía*, sigue vacía en la próxima generación, excepto si 3 (de las 8) celdas vecinas están ocupadas, en cuyo caso pasa a estar ocupada; *ocupada*, permanece ocupada si 2 o 3 de sus celdas vecinas están ocupadas; en caso contrario, *ocupada* aparecerá vacía en la próxima generación. Este *autómata celular* es considerado una buena metáfora para una situación en que, por ejemplo, la celda representa una célula y los dos posibles estados son *muerta* o *viva*. Así, *Life Game* simula en el tablero la evolución de “criaturas” vivas muy básicas, en que es necesario tener 3 vecinos vivos para

¹ Colaborador de John von Neumann y pionero en el desarrollo de los métodos Monte Carlo.

que se produzca un nacimiento, y un sujeto necesita de 2 o 3 vecinos para sobrevivir (si tiene menos muere de soledad y si tiene más muere de hacinamiento). De este modo, la población en el sistema cambia de generación en generación. El futuro está contenido en la condición inicial, nada se deja al azar y, a pesar de que las reglas son básicas, sencillas y locales —lo que pasa en una celda depende de las vecinas—, el comportamiento emergente es complejo. Los ejemplos muestran lo sencillo que es predecir generación tras generación, pero cuanto más se juega, se hace evidente el carácter impredecible que tiene el resultado general. Así, se entiende que un *autómata celular* es un sistema dinámico discreto cuya evolución es consecuencia de reglas locales. En la práctica: (1) sus elementos pueden ocupar las celdas de una red, (2) sus elementos pueden adoptar un número finito de estados discretos; y (3) las reglas locales especifican cómo pasar de un estado a otro.

Wolfram² plantea que el código de computación más sencillo puede revelar patrones complejos del comportamiento de la naturaleza. En otras palabras, un sistema cuya conducta parece simple, lo es, o al menos es tan simple como cualquier sistema computacional. Ésta es la manera en que Wolfram explica el *principio de equivalencia computacional*, según el cual reglas simples generan contra-intuitivos resultados complejos, es decir, los sistemas complejos tienen un comportamiento que muchas veces parece contrario al sentido común. De acuerdo a lo anterior, los cálculos computacionales necesarios para producir comportamientos complejos serían, en potencia, los mismos, y la complejidad de los sistemas se debería solamente a la gran cantidad de componentes simples que interactúan de manera simultánea. Así, el *principio de equivalencia computacional* plantea que las herramientas computacionales son tan complicadas como el sistema a estudiar. Lo anterior lleva a la conclusión de que habría límites a la misma ciencia, ya que muchas cuestiones serían imposibles de responder debido a que la única manera de descubrir las consecuencias de muchos procesos de gran complejidad sería, simplemente, dejar que ocurran. Esta nueva ciencia tiene en cuenta la propia *irreducibilidad computacional*, en que las reglas subyacentes a un sistema no siempre pueden predecir el complejo comportamiento que resulta de ellas. Por ejemplo, según este autor, el problema del *libre albedrío* podría analizarse desde esta perspectiva, como el producto de una complejidad resultante de reglas simples en el nivel básico, que deriva luego en cálculos irreducibles y complejos que difícilmente pueden ser simplificados por lo que, finalmente, son considerados el “producto de la libre voluntad”.

En resumen, los *autómatas celulares* son herramientas útiles para modelar cualquier sistema complejo. Pueden considerarse una buena alternativa a las ecuaciones diferenciales y han sido

² Doctor en Filosofía en la Física Teórica, autor del libro “*A New Kind of Science*” (2002).

utilizados para modelar sistemas físicos –tales como interacciones entre partículas, formación de galaxias, cinética de sistemas moleculares y crecimiento de cristales–, así como diversos sistemas biológicos a nivel celular, multicelular y poblacional³. En el ámbito de las finanzas, Zhou et al (2004) utilizaron el método de modelamiento de *autómata celular* para establecer un mercado accionario artificial. En dicho estudio, las celdas fueron usadas para representar a los accionistas, quienes tienen la capacidad para aprender de sí mismos y son afectados por el historial de inversiones de sus vecinos. En este estudio, la metodología de *autómata celular* será utilizada para modelar el comportamiento de las variaciones de los valores de cierre semanales de los índices bursátiles norteamericanos Dow Jones Industry (DJI), Nasdaq, Índice de Precios y Cotizaciones (IPC) y Toronto Stock Exchange (TSE), para luego –en función de las proyecciones de las variaciones futuras– desarrollar estrategias de *trading*.

El artículo está estructurado de la siguiente forma: la sección II presenta la metodología y los datos utilizados en el estudio; la sección III muestra los resultados del análisis; y, finalmente, la sección IV entrega las conclusiones.

II. Metodología y Datos

En esta sección se desarrolló un modelo de *autómata celular* para proyectar el signo de las variaciones de los índices bursátiles DJI y Nasdaq (USA), IPC (México) y TSE (Cánada), entendiendo que la predicción de la dirección del movimiento del índice accionario (alza o baja) es relevante para desarrollar estrategias de transacción efectivas (Leung, Daouk & Chen, 2000; Parisi, Parisi & Cornejo, 2004). Los datos corresponden a valores de cierre semanales del período entre el 08 de noviembre de 1991 y el 12 de diciembre de 2005. A partir de estos valores se calcularon las variaciones de precios semanales, las cuales constituyen los *inputs* del modelo. A continuación, se adaptó el modelo de *autómata celular* con el objetivo de modelar el comportamiento de las variaciones de cada uno de los índices accionarios ya señalados, para luego predecir el signo de la variación que éstos experimentarán en el período (semana) siguiente. Finalmente, en función de esas proyecciones, se elaboró una estrategia de inversión.

El modelo de *autómata celular* proyecta las variaciones de un determinado índice bursátil modelando de manera simultánea el comportamiento de los mercados accionarios que interactúan

³ Para una revisión del estado del arte en esta área, ver F. Schweitzer (2002), “Applications of Cellular Automata in Complex Systems”, *Advances in Complex Systems*, vol. 5, pp. 101-337.

entre sí. Los índices fluctuarán de acuerdo a las variaciones que han presentado en el pasado y al comportamiento experimentado por los otros índices bursátiles. El modelo de *autómata celular* presenta las siguientes características:

- Cada observación –es decir, cada variación semanal– es considerada como una *celda*.
- Cada *celda* puede adoptar dos posibles *estados*: positivo o negativo.
- Las *condiciones iniciales* del modelo están dadas por las variaciones –de cada uno de los índices analizados– correspondientes a la primera semana de la serie histórica de observaciones.
- Las *celdas* fueron agrupadas de manera de estructurar un tablero de ajedrez, tal como se muestra en la Figura 1.

[Insertar Figura 1]

El resultado de este ordenamiento fue una matriz de 4 filas y 4 columnas, donde cada *celda* puede tener un máximo de 8 *celdas vecinas*. Las *celdas*, que en un comienzo contienen las variaciones de los índices correspondientes a la primera semana, fueron ordenadas de acuerdo a las covarianzas entre los retornos de los índices bursátiles con respecto al DJI⁴ –considerado el principal índice accionario–, de mayor a menor. Esta matriz se generó para cada semana.

- El *estado futuro* de la *celda* está representado por el signo de la variación proyectada del índice para el período (semana) $t+1$, el cual constituye nuestro futuro inmediato.
- El *estado futuro* de una *celda* depende de su *estado actual* (correspondiente a la semana t) y del *estado actual* de las *celdas vecinas*.

Con la matriz descrita anteriormente se aplicó la *teoría de propagación*, utilizando reglas obtenidas principalmente del juego ideado por Conway (*Life Game*). Además, con el objetivo de optimizar el proceso, se probaron todas las reglas posibles a través de un algoritmo, analizando todas las relaciones que podían generarse combinando cada celda con sus vecinas. Considerando

⁴ Se utilizaron diferentes índices como base y los resultados no variaron significativamente.

que cada celda puede tener un máximo de 8 vecinos, el total de combinaciones asciende a $8 \cdot (8-1) = 56$. En consecuencia, se probaron 56 reglas básicas de modelamiento, donde cada una de estas reglas dio origen a un *autómata celular*.

Aplicando estas reglas a cada una de las celdas, se proyectó para la semana siguiente el signo de la variación de cada uno de los 4 índices bursátiles analizados, comenzando desde la semana $t+1$. Este proceso se repitió para las siguientes semanas. Debido a que la muestra de datos contiene 736 observaciones –es decir, 736 variaciones de valores de cierre semanales–, se realizaron 735 proyecciones. Cabe señalar que las proyecciones son extramuestrales.

A continuación se evaluó la capacidad predictiva de cada una de las 56 reglas, es decir, se evaluó la capacidad predictiva de cada uno de los 56 *autómatas celulares* utilizados para modelar y proyectar el comportamiento de las variaciones de los índices bursátiles. La evaluación se realizó en función del *porcentaje de predicción de signo* (PPS) extramuestral alcanzado. Para calcular el PPS, se comparó el signo de la variación proyectada con el signo de la variación observada, en cada t -ésimo período –donde $t=1, 2, \dots, n$ –, comenzando desde $t+1$. Si los signos de la variación proyectada y la variación observada coinciden, entonces se anota “1”, lo cual representa un acierto o *hit*. En caso contrario, se anota “0”, lo que señala un error de predicción del modelo. El porcentaje de predicción de signo logrado en cada i -ésimo índice bursátil por cada j -ésimo *autómata celular* (PPS_{i,j}) se calculó como se muestra en las ecuaciones (1) y (2):

$$PPS_{i,j} = \frac{1}{n-1} \sum_{t=1}^n p_{i,t+1}^j, \quad \text{con } i = 1, \dots, 16; j = 1, \dots, 56; t = 1, \dots, n. \quad (1)$$

$$p_{i,t+1}^j = \begin{cases} 1, & \text{si } \Delta P_{i,t+1} * \hat{\Delta P}_{i,t+1}^j > 0 \\ 0, & \text{en otro caso} \end{cases} \quad (2)$$

donde $p_{i,t+1}^j$ representa el acierto o error del j -ésimo *autómata celular* en la predicción del signo de la variación del i -ésimo índice bursátil, para la semana $t+1$; $\Delta P_{i,t+1}$ representa la variación observada del i -ésimo índice en el período $t+1$; y $\hat{\Delta P}_{i,t+1}^j$ corresponde a la variación del i -ésimo índice en el período $t+1$, proyectada por el j -ésimo *autómata celular*.

Al momento de evaluar la capacidad predictiva, con el objeto de evitar el problema de *data snooping*⁵ –y despejar las dudas respecto de si la capacidad de proyección se debe a la bondad del modelo, a las características de la muestra de observaciones sobre la que ha sido aplicado, o simplemente al factor suerte–, cada *autómata celular* se evaluó sobre un total de 710 subconjuntos extramuestrales de 26⁶ semanas cada uno. Estos 710 subconjuntos extramuestrales surgieron a partir de 710 períodos de 26 semanas, generados desde el conjunto extramuestral original. Además, en esta etapa se aplicó el *test de acierto direccional*⁷ (DA) de Pesaran & Timmermann (1992), con el objetivo de medir la significancia estadística de la capacidad predictiva de los modelos analizados. El test DA prueba la hipótesis nula de que las variaciones observadas están independientemente distribuidas de las variaciones proyectadas. Por ello, si se rechaza la hipótesis nula, se dice que existe evidencia estadística de que el modelo tiene capacidad para predecir la evolución futura de la variable observada.

A continuación se analizó si la capacidad predictiva evidenciada por los 56 *autómatas celulares* se traduce o no en mayores beneficios económicos, durante el período analizado. Para ello se calculó la rentabilidad acumulada *ex-post* que habría logrado un inversionista de haber seguido las recomendaciones de inversión del modelo: “comprar” si la variación proyectada es positiva (al alza), y “vender” si la variación proyectada es negativa (a la baja). Para ello se asumió que el índice bursátil puede ser transado como una acción y se consideró una inversión inicial de US\$100.000⁸. Al momento de calcular la rentabilidad de la estrategia de transacción, basada en las proyecciones realizadas por cada uno de los *autómatas celulares* analizados, se consideró un costo fijo de transacción de US\$9⁹ (independientemente del volumen transado). Cabe señalar que, para que un modelo predictivo desempeñe su función, éste debe generar un retorno que exceda la suma de los costos de transacción más la rentabilidad negativa originada por sus señales falsas¹⁰.

⁵ El término *data snooping* (también conocido como *data mining*), “ocurre cuando un determinado conjunto de datos es usado más de una vez para propósitos de inferencia o selección de modelos. Cuando esta re-utilización de datos ocurre, siempre existe la posibilidad de que cualquier resultado satisfactorio que se haya obtenido pueda deberse simplemente a la suerte, en vez de a algún mérito inherente al modelo que generó aquellos resultados.” (White, 2000).

⁶ El tamaño de los subconjuntos busca conformar períodos semestrales de *trading* (26 semanas).

⁷ Directional Accuracy Test.

⁸ La inversión inicial es de US\$100.000. No se pueden adquirir más unidades del índice que las que permite la inversión inicial, aun cuando el modelo de proyección siga recomendando “comprar”. De igual manera, sólo puede venderse aquello que ha sido comprado.

⁹ El costo de transacción en el mercado bursátil estadounidense es fijo y depende del *broker* utilizado. Puede fluctuar entre US\$7 y US\$20 por transacción. Para los fines de este estudio, se consideró un costo de US\$9 por transacción.

¹⁰ No se realizaron ventas cortas.

Los resultados del mejor *autómata celular* fueron comparados con un modelo *naive* o AR(1)¹¹, cuya forma funcional general se muestra en la ecuación (3).

$$\Delta Indice_{i,t+1} = \alpha_0 + \alpha_1 \cdot \Delta Indice_{i,t} + \varepsilon_{t+1} \quad (3)$$

donde $\Delta Indice_{i,t+1}$ representa la variación del i -ésimo índice bursátil proyectada para la semana $t+1$; $\Delta Indice_{i,t}$ representa la variación del i -ésimo índice bursátil correspondiente a la semana t ; α_0 es un término constante; α_1 es el coeficiente que acompaña a la variable explicativa; y ε_{t+1} es un término de error. Además, los resultados fueron comparados con los de una estrategia de inversión pasiva o *buy and hold*. Finalmente, para analizar si existen diferencias estadísticamente significativas entre los PPS del mejor *autómata celular* y del modelo *naive*, y entre los retornos de las estrategias de *trading*, se realizaron pruebas no paramétricas de hipótesis de diferencias de medianas y de medias (test de Friedman y de Tukey, respectivamente).

III. Resultados

Al analizar las series de valores de cierre semanales –en primera diferencia– de los 4 índices bursátiles analizados, se encontró que el test de Jarque-Bera rechaza la hipótesis de que las variaciones semanales de estos índices siguen una distribución normal, con un nivel de significancia del 5%. Además, existe evidencia de autocorrelación negativa entre las variaciones del DJI correspondientes a los períodos t y $t-1$. También se observa una autocorrelación positiva entre las variaciones del IPC correspondientes a los períodos t y $t-1$. En el caso del índice TSE se encontró una correlación negativa entre las variaciones en t y $t-1$, y una correlación positiva entre las variaciones de los períodos t y $t-2$. Al respecto, cabe señalar que el hallazgo de autocorrelación ha sido ampliamente verificado en la literatura financiera. Finalmente, los test de Wald-Wolfowitz (de corridas) y de Cox-Stuart (de signos no ponderados) no rechazan la hipótesis nula de aleatoriedad en las variaciones experimentadas por los índices DJI, Nasdaq y TSE. En el caso del IPC, los test presentan evidencia de que la serie de variaciones semanales del índice no se comporta de manera aleatoria durante el período de estudio (ver Cuadro 1).

[Insertar Cuadro 1]

¹¹ El modelo *naive* o AR(1) es un modelo lineal auto-regresivo de orden uno, estimado a través del método de *mínimos cuadrados ordinarios*.

Se probó la robustez de los resultados a fin de evitar el problema de *data snooping*. Para ello, se evaluó cada *autómata celular* sobre un total de 710 subconjuntos extramuestrales de 26 observaciones semanales cada uno. El Cuadro 2 resume el *porcentaje de predicción de signo* (PPS) promedio registrado por el mejor *autómata celular*¹² —considerando los 710 períodos extramuestrales analizados¹³—, y el número de períodos en los cuales éste resultó ser estadísticamente significativo¹⁴. Además, el Cuadro 2 muestra la desviación estándar del PPS y la rentabilidad acumulada promedio que habría logrado un inversionista de haber seguido las recomendaciones de compra-venta del mejor *autómata celular*, del modelo *naive* y de la estrategia *buy and hold*.

[Insertar Cuadro 2]

Al analizar el PPS promedio del mejor *autómata celular*, encontramos que éste fue superior al 55% en todos los índices estudiados. En el caso del modelo *naive*, el PPS promedio fue superior al 50%. Luego, al comparar la capacidad predictiva de ambos modelos, tenemos que el mejor *autómata celular* superó al modelo *naive* en los 4 índices analizados. Al aplicar el test DA sobre los 710 subconjuntos extramuestrales, encontramos que la capacidad predictiva del mejor *autómata celular* resultó ser significativa sobre el 80% de las veces, en los 4 índices analizados: DJI, Nasdaq, IPC y TSE. Lo anterior muestra que la capacidad predictiva de estos modelos varía a través del tiempo, por lo que no existiría un único modelo explicativo de la evolución de los índices bursátiles, situación que también se observó en estudios previos con modelos de redes neuronales (Parisi, Parisi & Guerrero, 2003) y con modelos contruidos en base a algoritmos genéticos (Parisi, Parisi & Cornejo, 2004). Por otra parte, al analizar la estabilidad de la capacidad predictiva de los modelos, se encontró que la desviación estándar¹⁵ del PPS del mejor *autómata celular* resultó menor que la del modelo *naive* en todos los índices estudiados. En otras palabras, la capacidad predictiva del mejor *autómata celular* evidencia mayor estabilidad que la del modelo *naive*.

El Cuadro 3 muestra la frecuencia con que el mejor *autómata celular* superó en rentabilidad al modelo *naive*, y la frecuencia con que los modelos (*autómata celular* y *naive*) generaron un retorno mayor al de la estrategia *buy and hold*, considerando en ambos casos los 710 subconjuntos

¹² Los resultados de los demás modelos pueden ser solicitados a aparisi@unegocios.cl.

¹³ El mejor *autómata celular* fue identificado con el N°10, de un total de 56. Cabe señalar que para cada uno de los subperíodos extramuestrales se calculó el *porcentaje de predicción de signo*, el test DA, el retorno acumulado de los *autómatas celulares* y del modelo *naive*, así como la rentabilidad acumulada de la estrategia *buy and hold*, los cuales están disponible para los interesados. Para ello comunicarse con alguno de los autores.

¹⁴ Se usó un nivel de significancia del 10%.

¹⁵ Esta desviación estándar fue calculada sobre los PPS de los 710 subconjuntos extramuestrales.

extramuestrales. Se observó que, en todos los índices que conforman la muestra, el mejor *autómata celular* superó en rentabilidad al modelo *naive* con una frecuencia igual o superior al 80%. Puede concluirse entonces que una capacidad predictiva relativamente alta, acompañada por una baja desviación estándar, podría generar, como en este caso, una mayor rentabilidad promedio.

[Insertar Cuadro 3]

Además, considerando nuevamente los 710 períodos extramuestrales, la frecuencia con que los modelos de proyección superaron la rentabilidad de la estrategia *buy and hold* fluctuó entre 85% y 96%. Así, pudo observarse que, independientemente de si la capacidad predictiva de los modelos es significativa o no, ambas técnicas –*autómatas celulares* y modelos *naive*– permitirían elevar la rentabilidad o reducir las pérdidas asociadas a las inversiones en índices bursátiles o portfolios indexados.

Los resultados del test de Friedman (presentados en el Cuadro 4) indican que existen diferencias estadísticamente significativas entre los PPS y los retornos generados por los modelos analizados. De manera más específica, el test de Tukey señala que hay diferencias significativas entre los resultados del modelo de *autómata celular* y del modelo *naive*, en términos de PPS y de rentabilidad, donde el primero supera al segundo. Además, las rentabilidades de los modelos predictivos son estadísticamente superiores al retorno de la estrategia *buy and hold*.

[Insertar Cuadro 4]

IV. Conclusión

Los resultados de la aplicación de la *teoría de autómatas celulares* al modelamiento del comportamiento de los índices bursátiles Dow Jones Industry Average (USA), Nasdaq (USA), Índice de Precios y Cotizaciones (México) y Toronto Stock Exchange (Canadá), indican que esta metodología tendría una capacidad estadísticamente significativa para predecir el signo de las variaciones de los índices analizados. Lo anterior entregaría una señal positiva con respecto al potencial de esta herramienta para administrar portfolios de inversión en dichos mercados.

En términos de capacidad predictiva, el mejor *autómata celular* superó al modelo *naive* en los 4 índices analizados. Por otra parte, al analizar la estabilidad de la capacidad predictiva de los

modelos, se encontró que la desviación estándar del PPS del mejor *autómata celular* resultó menor que la del modelo *naive* en todos los índices estudiados. En otras palabras, la capacidad predictiva del mejor *autómata celular* evidencia mayor estabilidad que la del modelo *naive*.

También se observó que la capacidad predictiva de los modelos se tradujo en beneficios económicos. En todos los índices que forman la muestra, el mejor *autómata celular* superó en rentabilidad al modelo *naive* con una frecuencia igual o superior al 80%. Además, la frecuencia con que los modelos de proyección superaron la rentabilidad de la estrategia *buy and hold* fluctuó entre 85% y 96%. Así, pudo observarse que, independientemente de si la capacidad predictiva de los modelos es significativa o no, ambas técnicas –*autómatas celulares* y modelos *naive*– permitirían elevar la rentabilidad o reducir las pérdidas asociadas a las inversiones en índices bursátiles o portafolios indexados.

De esta manera, este estudio presenta evidencia de que los *autómatas celulares* podrían convertirse en una alternativa a las metodologías predictivas tradicionalmente utilizadas en la administración de portafolios de inversión, tales como modelos auto-regresivos, modelos multivariados dinámicos, modelos de redes neuronales, modelos de algoritmos genéticos y modelos de lógica borrosa, entre otros.

Referencias Bibliográficas

- Leung Mark T., Daouk Hazem, Chen An-Sing (2000).** “Forecasting stock indices: a comparison of classification and level estimation models”. *International Journal of Forecasting* 16, 173-190.
- Malamud, B. & Turcotte, D. (2000).** “Cellular-Automata Models Applied to Natural Hazard”. *Computing in Science and Engineering*, Vol. 2, N°3, pp. 42-51, May-June, 2000.
- Parisi, A., F. Parisi & J. L. Guerrero (2003).** “Modelos predictivos de Redes Neuronales en índices bursátiles internacionales”. *El Trimestre Económico*, N°280, vol. LLX (4), p.p. 721-744. México.
- Parisi, A., F. Parisi & E. Cornejo (2004).** “Algoritmos genéticos y modelos multivariados recursivos en la predicción de índices bursátiles de América del Norte: IPC, TSE, Nasdaq y DJI”. *El Trimestre Económico*, N°284, vol. LXXI (4), p.p. 789-809. México.
- Pesaran, M.H. & Timmermann A. (1992).** “A simple nonparametric test of predictive performance”. *Journal of Business and Economic Statistics* 10, 461-465.
- Schweitzer, F. (2002).** “Applications of Cellular Automata in Complex Systems”. *Advances in Complex Systems*, vol. 5, pp. 101-337.
- White, H. (2000).** “A reality check for data snooping”. *Econometría*, Vol. 68, No. 5, 1097-1126.
- Wolfram, S. (2002).** “A New Kind of Science”.
- Zhou, T., Zhou, P., Wang, B., Tang, Z. & Liu, J. (2004).** “Modeling Stock Market Based on Genetic Cellular Automata”. *International Journal of Modern Physics*.

Figura 1: Representación del *autómata celular*.

Matriz de 4 filas y 4 columnas. Las *celdas* contienen las variaciones semanales de los índices y fueron ordenadas de acuerdo a las covarianzas entre los retornos de los índices bursátiles con respecto al DJI, de mayor a menor. Las *celdas* en color negro representan variaciones negativas del índice, y las *celdas* en color blanco representan variaciones positivas. Esta matriz se generó para cada semana.

Bovespa	Merval	IGPA	STI
Hang Seng	IGBM	CAC40	IPC
Nikkei 225	DJI	DAX	FTSE 100
KLSE	TSE	S&P 500	Nasdaq

Cuadro 1:

Estadísticos descriptivos para las series de valores de cierre semanales, en primera diferencia, de los índices bursátiles DJI y Nasdaq (USA), IPC (México) y TSE (Canadá). Entre paréntesis se entrega el test *t* de *Student*. Período comprendido entre el 08 de noviembre de 1991 y el 12 de diciembre de 2005.

Estadísticos	DJI	NASDAQ	IPC	TSE
Media	10.653	2.319	22.202	10.306
Mediana	18.440	4.110	22.100	20.600
Máximo	666.410	608.270	826.920	818.800
Mínimo	-1370.040	-1125.160	-1224.180	-991.680
Desviación Estándar	187.640	88.452	192.927	163.971
Skewness	-0.783	-2.815	-0.514	-0.780
Kurtosis	8.797	44.304	6.906	9.035
Jarque-Bera ¹	1104.361	53218.160	499.730	1189.937
AR(1) ¹	-0.065 (-1.767)**	-0.032 (-0.867)	0.107 (2.882)*	-0.089 (-2.432)*
AR(2) ¹	0.048 (1.293)	0.043 (1.158)	0.007 (0.191)	0.109 (2.965)*
Wald-Wolfowitz ²	-0.39	-1.60	-1.64**	-0.18
Cox-Stuart ²	-0.47	-0.99	3.81*	0.68

¹Los valores críticos de los estadísticos Jarque-Bera y *t* de *Student* son 4.43 y 1.96, respectivamente, para un $\alpha=5\%$.

²Los valores críticos de los estadísticos Wald-Wolfowitz y Cox-Stuart son de 1.96 y 1.64 para $\alpha=5\%$ y $\alpha=10\%$, respectivamente.

(*): Significativo al 5%; (**): Significativo al 10%.

Cuadro 2:

Resultados promedio, considerando 710 subconjuntos extra-muestrales de 26 semanas cada uno. Se presenta el porcentaje de predicción de signo (PPS) promedio del mejor modelo de *autómata celular* (AC) y del modelo *naive*, la desviación estándar (σ) del PPS, la proporción de períodos en los cuales la capacidad predictiva fue significativa de acuerdo al test DA, el retorno acumulado promedio del mejor modelo de *autómata celular* y del modelo *naive*, y la rentabilidad acumulada promedio de la estrategia *buy and hold* (B&H).

Índice Bursátil	Modelo	PPS Promedio	σ PPS	Períodos Significativos¹ (%)	Retorno Acumulado Prom.	Retorno Acumulado Prom. B&H
DJI	AC 10	64%	4.3%	84%	10.55%	4.75%
	Naive	52%	5.1%	50%	6.70%	
Nasdaq	AC 10	60%	6.2%	86%	15.78%	6.42%
	Naive	51%	7.4%	53%	8.17%	
IPC	AC 10	65%	4.5%	83%	19.64%	10.06%
	Naive	51%	6.3%	47%	14.48%	
TSE	AC 10	67%	2.6%	85%	13.92%	4.66%
	Naive	52%	3.9%	50%	8.24%	

(*): Número de períodos extramuestrales (de un total de 710) en los cuales la capacidad predictiva de los modelos resultó ser estadísticamente significativa (usando un $\alpha=10\%$), de acuerdo al test DA.

Cuadro 3:

Frecuencia con que el mejor *autómata celular* superó en rentabilidad al modelo *naive* y frecuencia con que los modelos superaron en rentabilidad a la estrategia Buy & Hold (B&H), considerando 710 períodos extramuestrales.

Índices Bursátiles	Autómata Celular v/s Naive	Modelos v/s B&H
DJI	83%	87%
Nasdaq	80%	85%
IPC	89%	96%
TSE	94%	94%

Cuadro 4:
Resultados Test de Friedman y Test de Tukey.

	DJI	Nasdaq	IPC	TSE
Test de Friedman	Estadístico	Estadístico	Estadístico	Estadístico
PPS	84.72	95.08	89.91	92.10
Retorno Modelos	43.18	56.05	67.94	58.20
Test de Tukey: PPS	P-Value	P-Value	P-Value	P-Value
Autómata Celular – Naive	0.7385	0.8540	0.9474	0.9786
Test de Tukey: Retorno Modelos	P-Value	P-Value	P-Value	P-Value
Autómata Celular – Naive	2.9522	1.9463	2.094	3.157
Autómata Celular – Buy and Hold	4.9879	2.7199	4.003	3.136
Naive – Buy and Hold	0.3844	0.5682	0.798	0.729

Para el caso del PPS, el valor crítico de χ^2 fue de 3.841, para 1 grado de libertad y un nivel de significancia de 0.05. Para el caso de la rentabilidad de los modelos, el valor crítico de χ^2 fue de 5.991, para 2 grados de libertad y un nivel de significancia de 0.05. El nivel de significancia con el cual es comparado el *p-value* es de 0.05.