

Análisis Técnico con algoritmos genéticos

Christian González Martel. (cristian@empresariales.ulpgc.es)
Universidad de Las Palmas de Gran Canaria.

Fernando Fernández Rodríguez. (fernando@empresariales.ulpgc.es)
Universidad de Las Palmas de Gran Canaria.

Palabras clave: Algoritmos genéticos, reglas técnicas, mercados de valores

Área temática: Métodos Cuantitativos

En este trabajo analizamos la rentabilidad de las reglas técnicas, basadas en medias móviles, en el índice General de la bolsa de Madrid. Estas reglas técnicas han sido optimizadas empleando algoritmos genéticos. Con objeto de averiguar la capacidad de realizar beneficios se compara la rentabilidad de las reglas técnicas frente a la estrategia de comprar y mantener, ajustada en el riesgo. En este sentido hemos considerado varios escenarios, con diferentes costes de transacción. Finalmente se ha dividido la muestra en varias submuestras para contrastar si, en la obtención de beneficios, es más importante la proximidad o la amplitud del periodo de entrenamiento.

Introducción

En estos últimos años, el desarrollo de nuevas tecnologías ha provocado grandes cambios en el mundo de las finanzas, tanto para el inversor como para el académico. El inversor, gracias a la aparición de canales temáticos, internet y de software especializado, está mejor informado y aconsejado en sus tomas de decisiones. Ello ha repercutido en que la bolsa haya experimentado una entrada importante de pequeños inversores. En el mundo académico, gracias al desarrollo de los ordenadores y de software más potente, puede plantearse métodos de cálculo impensables hasta hace unos años.

Dentro de la literatura financiera han resurgido trabajos que, de forma directa o indirecta, intentan rebatir la Hipótesis de Mercados Eficientes (HME), principio que se consideraba irrefutable en el mundo académico treinta años atrás. En su forma más débil la hipótesis de mercados eficientes establece que el movimiento de los precios en un instante t , es impredecible dada la información disponible hasta el instante $t-1$, siendo imposible la realización de beneficios superiores a los normales, obtenidos por la simple estrategia de comprar y mantener. Muchas han sido las investigaciones encaminadas a corroborar esta hipótesis, dando lugar a una larga controversia.

Como trabajo pionero destaca el trabajo de Alexander (1961), que aplicó una regla de filtro que consistía en comprar un activo cuando su precio se incrementaba por encima de un X por ciento desde su último soporte o venderlo cuando su precio bajaba un X por ciento desde su última resistencia. Alexander establecía los soportes y resistencia como los mínimos y los máximos respectivamente a partir de la serie histórica de precios desde la última transacción.

Fama (1965) y Fama y Blume (1966) presentaron un análisis, más detallado, de las reglas empleadas por Alexander, pero corregidas, incluyendo en éstas costes de transacción y reparto de dividendo. Sus resultados establecían que la capacidad de generar beneficios de estas reglas no superan a la simple estrategia de comprar y mantener. En la década de los noventa se produce todo un replanteamiento académico del Análisis Técnico. Así Brock et al. (1992) concluyen que diversas reglas usadas en el índice Dow-Jones eran capaces, bajo ciertas hipótesis, de generar beneficios frente a los

modelos econométricos nulos más empleados en finanzas como son el camino aleatorio y modelos GARCH. Bessembinder y Chan (1995), Mill (1996) y Fernández Rodríguez et al. (1999) presentan evidencias similares para los mercados asiáticos, británico y español, respectivamente.

Corrado y Lee (1992), Hudson et al. (1996), Bessembinder y Chan (1995), Brown et al. (1998) y Allen y Karjalainen (1999) encuentran que los modelos que utilizan reglas técnicas no son capaces de generar beneficios una vez descontado los costes de transacción y la prima de riesgo pero si que tienen capacidad predictiva.

Lo y MacKinley (1990), concluyeron que las especificaciones ad-hoc de todos estos modelos provocaban fisgoneo en los datos. Es decir, que la elección arbitraria, tanto de las reglas como de los parámetros seleccionados, producían desviaciones en los resultados. Asimismo, concluían que de haber empleados técnicas de optimización para la elección de dichos parámetros estas desviaciones se podían haber reducido e incluso, en algunos casos, eliminado. Neely et al. (1997) y Allen y Karjalainen (1999) se basaron en estas conclusiones para desarrollar modelos para los mercados cambiarios y de activos, respectivamente, basados en reglas técnicas que previamente habían sido optimizadas mediante programación genética.

Este trabajo pretende analizar los rendimientos de reglas técnicas, basadas en medias móviles, previamente optimizadas con algoritmos genéticos, en el índice General de la Bolsa de Madrid. Para ellos se ha considerado varios escenarios con distintos costes de transacción.

La estructura del trabajo es la siguiente. En la sección 2 se describirán las herramientas de las reglas técnicas por contratación. En la sección 3 detallamos el funcionamiento de los algoritmos genéticos. En la sección 4 explicamos el modelo empleado en este trabajo. Por último, expondremos las conclusiones en la sección 5.

Reglas Técnicas

El objetivo de todo inversor consiste en obtener posiciones recomendadas de compra y venta. Para ello utiliza varias técnicas que le ayuden en su análisis. Una de las más empleadas es el análisis técnico. Si atendiéramos a la HME la utilización de estas técnicas no conllevaría a la obtención de beneficios. Sin embargo, el análisis técnico está ampliamente extendido como método de predicción, a corto, dentro de los profesionales del sector. El análisis técnico es el estudio de la información pasada del

comportamiento del mercado con la finalidad de predecir tendencias futuras, independientemente del estudio de los bienes que se negocian en ese mercado. Para el analista técnico sólo importan la evolución de los precios y el volumen de negociación. Y esto se debe a que el análisis técnico se basa en tres premisas (Neely, 1997).

- El mercado lo descuenta todo, es decir, toda la información, sea fundamental, política, psicológica, etc..., disponible hasta ese momento, está reflejada en el precio, que no hace mas que seguir el comportamiento de la oferta y la demanda. El analista técnico supone que si los precios suben es porque la demanda es mayor que la oferta y viceversa, sin importarle las causas de esta conducta.
- El segundo principio establece que los precios se mueven, en el largo plazo, por tendencias de duraciones relativamente largas y delimitadas en el tiempo. El objetivo del analista es identificar tendencias que están en sus primeras etapas de desarrollo para tomar decisiones de inversión que sigan la misma línea.
- La tercera premisa establece que los patrones de comportamiento pasados se volverán a repetir en un futuro. Por lo que el mercado tiene memoria y los precios no se comportan como un camino aleatorio.

Las herramientas más utilizadas dentro del análisis técnico son el chartismo y las reglas técnicas. Mientras las primeras se basan en los gráficos de las series de precios y volúmenes, las segundas intentan eliminar el componente subjetivo de la interpretación de los gráficos a través de funciones matemáticas que indicarán al inversor posiciones de compra o venta, en función de los precios pasados. Dentro de estas reglas técnicas podemos destacar las basadas en órdenes estadísticos y las basadas en medias móviles

Reglas basadas en medias móviles

Uno de los métodos más extendidos, dentro del Análisis Técnico, son las reglas basadas en medias móviles, que resultan fácilmente programables para que generen señales de compra y de venta. Las medias móviles se utilizan, principalmente, para identificar tendencias. La media móvil suaviza la serie de precios eliminando de ella las fluctuaciones que se producen a corto plazo, con el fin de reconocer la tendencia subyacente.

Sea la serie temporal de precios $\{p_t\}_{t=1 \dots N}$, la media móvil de longitud θ en el instante t se define como

$$M_t(\theta) = \frac{1}{\theta} \sum_{i=0}^{\theta-1} p_{t-i}, \quad t = \theta, \theta + 1, \dots, N$$

De esta forma podemos generar señales de compra y venta estableciendo una regla técnica por la diferencia de dos medias móviles de distinta longitud θ . Si la media móvil de longitud más corta (media móvil a corto) es superior a la media móvil de longitud más larga (media móvil a largo), se genera una señal de compra, mientras que si ocurre lo contrario, se genera una señal de venta. Sin embargo, el uso de esta regla puede generar señales engañosas. Por este motivo se suele añadir un filtro para eliminar dichas señales, por lo que se genera una señal de compra si la media móvil a corto supera en un x% la media móvil a largo, mientras que si cae por debajo de un x% se genera una señal de venta.

Esta regla técnica generalizada se puede representar por la siguiente función binaria, donde una salida igual a 1 indicaría una señal de compra, mientras que una salida igual a cero reflejaría una señal de venta.

Utilizaremos la siguiente función como generador de señales:

$D(\Theta)_t = M(\theta_1)_t - (1 + (1 - 2S_{t-1})\theta_3)M(\theta_2)_t$, donde $\Theta = [\theta_1, \theta_2, \theta_3]$ representa el vector de parámetros utilizados en la regla. El parámetro θ_1 es la longitud de la media móvil a corto, que estará comprendida entre 1 y 250, mientras que θ_2 es la longitud de la media móvil a largo, y esta comprendida entre 2 y 250. El parámetro θ_3 representa el porcentaje en tanto por 10.000, que se emplea para eliminar las señales erróneas.

Las diferencias D_t generan una función binaria S_t que toma valores según el signo de D_t . Así si $D_t > 0 \Rightarrow S_t = 1$ y si $D_t \leq 0 \Rightarrow S_t = 0$

Mediante esta regla generalizada de media móvil podemos crear las reglas ampliamente utilizadas en la literatura, imponiendo restricciones a los distintos parámetros.

Media móvil simple: $\theta_1 = 1, \theta_2 > 1, \theta_3 = 0$

$$D(\Theta)_t = p_t - M(\theta_2)_t$$

Media móvil filtrada: $\theta_1 = 1, \theta_2 > 1, \theta_3 > 0$

$$D(\Theta)_t = p_t - (1 + (1 - 2S_{t-1})\theta_3)M(\theta_2)_t$$

Doble media móvil: $\theta_1 > 1, \theta_2 > \theta_1, \theta_3 = 0$

$$D(\Theta)_t = M(\theta_1)_t - M(\theta_2)_t$$

Si se eligen dos medias móviles a muy corto plazo (de 5 o 10 días) se producen muchos cortes entre ellas. Esto provoca una estrategia muy activa que eleva tremendamente los costes de transacción. En tal caso, puede ocurrir también que se generen muchas señales falsas debido al movimiento aleatorio del precio a corto plazo. Sin embargo, tiene la ventaja de que genera señales tempranas. Si se eligen dos medias móviles a largo plazo (de 150 o 200 días) provocarían la aparición de señales tardías en el tiempo. Existe un trade-off entre las falsas señales, con altos costes de transacción de las medias móviles cortas, y las señales tardías, con bajos costes de transacción, de las medias móviles largas. Hasta ahora la elección de los parámetros era arbitraria, sin embargo, en este trabajo usaremos un método de optimización para la elección de dichos parámetros.

Algoritmos genéticos

Los algoritmos genéticos (AG) constituyen una forma de búsqueda adaptativa, mediante técnicas de optimización basadas en la evolución natural. Fueron desarrollados por Holland (1962,1975) y a partir de ellos, se han desarrollado otros algoritmos evolutivos que incluyen las estrategias evolutivas (Rechenberg,1973; Schwefel, 1981), programación evolutiva (Fogel et al, 1966), sistemas de clasificación (Holland, 1976, 1980) y programación genética (Koza, 1992).

Para implementar un AG se comienza con una población inicial de parámetros, tomados al azar, que representan los posibles candidatos a la solución. Estos se evalúan a partir de una función objetivo, también llamada función de adaptación, que define el entorno para la evolución. De entre los candidatos se seleccionan aquellos más adaptados, es decir, aquellos con mayor valor en la función objetivo, si estamos maximizando, ya que existen otros problemas donde la adaptación se determina a través de otras estructuras genéticas. Los individuos seleccionados se cruzan entre ellos y se mutan para crear una nueva población, que es la que sigue con el proceso iterativo de selección, cruce y mutación. Estos operadores son los que establecen las diferencias entre unos algoritmos y otros.

En nuestro trabajo utilizaremos los algoritmos genéticos para hallar los valores de los parámetros, de la regla técnica, que optimice su capacidad de generar beneficios. Para ello, generaremos una población inicial de ternas de parámetros, elegidos al azar, para comenzar el proceso iterativo. Esta población se codifica como un vector de dígitos binarios, que se denominan cromosomas. Esta representación binaria es necesaria para después proceder a los procesos de cruce y mutación. En nuestro caso utilizaremos cromosomas de 23 elementos, donde sus ocho primeros elementos son los dígitos binarios necesarios para representar todos los posibles valores de θ_1 , los ocho siguientes los que representan θ_2 y los siete últimos representan los posibles valores θ_3 .

Observe que se necesitan ocho dígitos binarios para codificar todos los números comprendidos entre el rango de variación de θ_1 ($1 < \theta_1 < 250$) y de θ_2 ($1 < \theta_2 < 250$), mientras que sólo siete para representar todos los números comprendidos entre 0 y 100 que es el rango de variación de θ_3 . Así, el vector $\Theta = [2, 60, 51]$ se representaría mediante el cromosoma $\Theta = [00000010001111000110011]$. En nuestro trabajo comenzaremos con una población inicial de 150 individuos, número que Bauer (1994) también utiliza en otro trabajo similar. La elección del parámetro “número de cromosomas” siempre debe realizarse atendiendo al trade-off existente entre la exploración adecuada del espacio de soluciones y el tiempo deseado de las iteraciones. A continuación seleccionamos a los individuos que participarán en las operaciones de cruce y permutación. En este proceso de selección empleamos un método de selección de progenitores, basado en el ranking de los candidatos con respecto a la función objetivo, desarrollada por Whitley (1989). Se seleccionan todos los candidatos excepto el que peor valor ha obtenido en la función de adaptación, que se sustituye por el mejor. Posteriormente estos 150 individuos se cruzan entre ellos para dar lugar a descendencia a través del proceso de cruce.

El proceso de cruce es aquel por el cual se eligen dos cromosomas y se recombinan dando lugar a dos cromosomas hijos que tienen características de ambos progenitores. Por el cruce de los mejores candidatos se asegura que la búsqueda no sea aleatoria y esté dirigida hacia aquellas regiones del espacio de búsqueda más prometedoras. Aunque existen diversas variaciones sobre el procedimiento de cruce, en nuestro trabajo optamos por el de punto de cruce simple. Esta metodología consiste en seleccionar una pareja de cromosomas y establecer aleatoriamente un punto de corte. Entonces el código del cromosoma 1 y del cromosoma 2 que están a la izquierda y derecha del punto de

corte, respectivamente, pasan al primer hijo. El código del cromosoma 1 y del cromosoma 2 que están a la derecha e izquierda del punto de corte, respectivamente, pasan al segundo hijo. Así, el primer hijo tiene a la izquierda del punto de cruce parte del código del cromosoma 1 y a la derecha parte del código del cromosoma 2. De esta forma si los cromosomas padres son Θ_1 y Θ_2 y se establece un punto de corte se pueden dividir estos dos cromosomas en $\Theta_1 = [\Theta_{11}, \Theta_{12}]$ y $\Theta_2 = [\Theta_{21}, \Theta_{22}]$. A través del cruce se engendran dos hijos que contienen parte del código de los dos padres. $\Theta_{h1} = [\Theta_{11}, \Theta_{22}]$ y $\Theta_{h2} = [\Theta_{21}, \Theta_{12}]$

Así, a través de los procesos de selección y cruce, los mejores individuos van retransmitiendo sus genes a las siguientes generaciones.

El último proceso que interviene en la generación de nuevos individuos es de la mutación. Ésta garantiza la diversidad de la población y, de esta forma, la búsqueda puede encaminarse hacia regiones más prometedoras del espacio de cromosomas, evitando el estancamiento en óptimos locales. La mutación no es mas que la introducción de shocks aleatorios en los cromosomas a través de cambios en sus genes. Así si se ha seleccionado aleatoriamente el gen 3 del cromosoma 5, éste cambia a 0 si antes de la mutación era un 1 y viceversa. Sin embargo, la probabilidad de mutación en la población debe ser muy baja, con el fin de no destruir las buenas estructuras que han sido previamente obtenidas.

La nueva población creada tras los procesos de selección, cruce y mutación se evalúa mediante la función objetivo y vuelve a pasar por los tres procesos citados anteriormente. Este proceso iterativo continua hasta que se satisface una de las siguientes tres condiciones:

La población converge hasta un único individuo.

Se llega a un número máximo de iteraciones determinado.

Durante un número determinado de iteraciones no hay mejoras en el mejor individuo de la población.

Modelo

En este trabajo se ha utilizado una muestra de 4376 observaciones diarias del IGBM, al cierre, desde el 2 de Enero de 1972 hasta el 15 de Noviembre de 1997. Se ha establecido tres escenarios. En el primero de ellos el algoritmo se entrenara para un

periodo de 2188 datos (desde 02/01/79 hasta el 16/12/88) que posteriormente se validará con los 2188 datos posteriores. En el segundo se entrenara el algoritmo en dos periodos de 1094 datos (desde el 02/01/79 hasta el 10/07/84 y desde el 19/12/88 hasta el 20/05/93) para validarlos en los 1094 datos posteriores . En el tercero lo entrenaremos en cuatro periodos distintos (desde el 02/01/79 hasta el 08/10/81, desde el 11/07/84 hasta el 30/09/86, desde el 19/12/88 hasta el 04/03/91 y desde 24/05/93 hasta 02/08/95) para validarlos en los cuatro periodos posteriores. En las Ilustraciones I, II y III se muestran los datos utilizados para los tres escenarios.




Ilustración 2: Se ha dividido la muestra en cuatro periodos donde para cada uno se estableció un periodo de entrenamiento enumerados desde I4e hasta IV4e y otro de validación, enumerados desde I4v hasta IV4v.




Ilustración 1: Se ha dividido la muestra en dos periodos donde para cada uno se estableció un periodo de entrenamiento enumerados desde I2e hasta II2e y otro de validación enumerados desde I2v hasta II2v.




Ilustración 3: Se estableció un periodo de entrenamiento (I1e) y otro de validación (I1v).

La población inicial será de 150 individuos y se estableció la probabilidad de cruce y mutación al 6% y 0.5%, respectivamente. El número de iteraciones y de iteraciones sin mejoras se fijó en 300 y 300, respectivamente. Si la población seleccionada, la probabilidad de mutación, el número de iteraciones máxima y el número de iteraciones máxima sin repetición son pequeñas y la probabilidad de cruce alta, el algoritmo convergerá más rápidamente. Sin embargo, esto puede provocar una búsqueda ineficiente en el espacio de soluciones y que el algoritmo finalice en un óptimo local (Goldberg, 1989; Bauer, 1994), por lo que, como hemos dicho, para la elección de estos parámetros hay que establecer un equilibrio entre tiempo de computación y exploración del espacio de soluciones.

La función objetivo a maximizar viene dada por la siguiente expresión:

$$r_{tr} = \sum_{t=1}^N S_{t-1} rm_t + \sum_{t=1}^N (1 - S_{t-1}) rf_t - T * tc \quad [1]$$

donde N es el número de días, rm_t es el rendimiento del mercado obtenido a través de la diferencia logarítmica en los precios, $\ln\left(\frac{P_t}{P_{t-1}}\right)$, rf_t es el rendimiento de un mercado libre de riesgo, T el número de transacciones y tc el coste de transacción aplicado a la operación.

Si $S_{t-1} = 1$ la posición recomendada es la de estar en el mercado, el segundo sumando de [1] desaparece, obteniendo los rendimientos del mercado. Si $S_{t-1} = 0$ la posición recomendada es la de estar fuera del mercado, el primer sumando desaparece por lo que se obtendrá rendimientos sólo por medio del activo libre de riesgo, tomando como tal el tipo de interés a un día oficial del Banco de España.

Este algoritmo lo hemos ejecutado nueve veces para cada escenario, donde en las tres primeras ejecuciones se consideraron unos costes de transacción del 0.45%, que lo equiparamos al coste aplicado a operaciones con particulares. En las tres segundas los costes son del 0.25%, que es el que se aplicaría a clientes institucionales y por último las tres últimas donde se aplican costes de transacción nulos.

	mme	mml	filtro	rs	rma	dt	bha	rsval	rmaval	dtval	bhaval
I1e											
0.45	207	242	0	0.0072	33.1304	5	25.3620	0.0046	14.4539	6	10.8609
0.25	207	242	0	0.0072	33.3044	5	25.3620	0.0047	14.6343	6	10.8609
0	2	21	0	0.0104	38.2122	117	19.2140	0.0074	22.0491	139	10.055
I2e											
0.45	18	116	31	0.0111	26.5407	3	13.5246	0.0045	22.8608	12	33.2222
0.25	99	142	2	0.0112	26.7136	5	14.2332	0.005	28.0435	7	33.6682
0	42	197	6	0.0109	26.8497	5	16.6808	0.0054	31.2101	2	39.3405
II2e											
0.45	5	7	72	0.0052	15.887	21	4.9446	0.0032	9.6516	30	15.7928
0.25	6	8	51	0.0067	18.9935	27	5.5590	0.0048	15.2682	42	16.4705
0	2	20	15	0.0075	21.5244	52	5.1019	0.0075	23.411	65	15.8899
I4e											
0.45	180	250	25	0.0127	35.8846	1	30.7146	0.0155	35.9112	1	37.5125
0.25	153	250	54	0.0128	36.118	1	30.7146	0.0156	36.8866	1	37.7058
0	179	250	29	0.0129	36.4103	1	30.7146	0.0158	36.437	1	37.5125
II4e											
0.45	182	250	20	0.0155	115.811	0	115.8112	-0.0017	-9.4442	2	-3.692
0.25	188	250	13	0.0155	115.811	0	115.8112	-0.0007	-4.1264	2	-3.8064
0	171	250	19	0.0155	115.811	0	115.8112	-0.0025	-13.5028	2	-3.8064
III4e											
0.45	2	20	16	0.0092	22.9402	24	5.1692	0.0014	4.3157	28	3.8327
0.25	2	20	15	0.0104	25.8231	24	5.1692	0.0025	7.5162	28	3.7979
0	2	4	16	0.0108	30.149	70	6.5017	-0.0001	-0.1735	96	4.7364
IV4e											
0.45	73	89	28	0.0071	21.8369	4	8.7993	0.0083	35.7118	3	37.4407
0.25	74	89	20	0.0073	22.3798	4	8.7951	0.0084	35.8123	3	37.3593
0	12	16	0	0.0103	29.4421	43	9.4771	0.0091	32.4336	37	25.9707

Cuadro 1: Media móvil corto (mme); Media móvil a largo (mml); filtro; Ratio de Sharpe (rs); Rendimiento medio anualizado (rma); Días de transacción (dt); "Buy and hold" ajustado en el riesgo (bha); Ratio de Sharpe en el periodo de validación (rsval); Rendimiento medio anualizado en el periodo de validación (rmaval); Días de transacción en el periodo de validación (dtval); "Buy and hold" ajustado en el riesgo en el periodo de validación (bhaval)

El cuadro I muestra las mejores iteraciones calculadas para cada periodo de entrenamiento. En las tres primeras columnas aparece los parámetros optimizados para cada periodo. En la quinta columna se muestra los rendimientos medios anualizados para cada ejecución, en la sexta los días de transacción que hubo en el periodo de operación. La séptima columna contiene los rendimientos medios anualizados que se obtendría si utilizamos la estrategia "buy and hold" ajustada en el riesgo en lugar de la regla técnica. Estos rendimientos se han obtenido a través de la siguiente expresión:

$$r_{bh} = \alpha \sum_{t=1}^N r f_t + (1 - \alpha) \sum_{t=1}^N r m_t$$

En esta fórmula α expresa la proporción de días que la regla ha estado fuera del mercado. Este rendimiento es una media ponderada entre el rendimiento de tomar una posición a largo en el mercado y el rendimiento libre de riesgo obtenido por tomar una posición no inversora en una proporción de $(1-\alpha)$ días. Así este rendimiento “buy and hold” ajustado en el riesgo expresa el rendimiento obtenido de invertir, tanto en el mercado como en el activo libre de riesgo, ponderado por los días que se ha estado en el mercado y fuera de él, respectivamente.

La cuarta columna da los ratios de Sharpe que se ha obtenido a partir de la siguiente expresión:

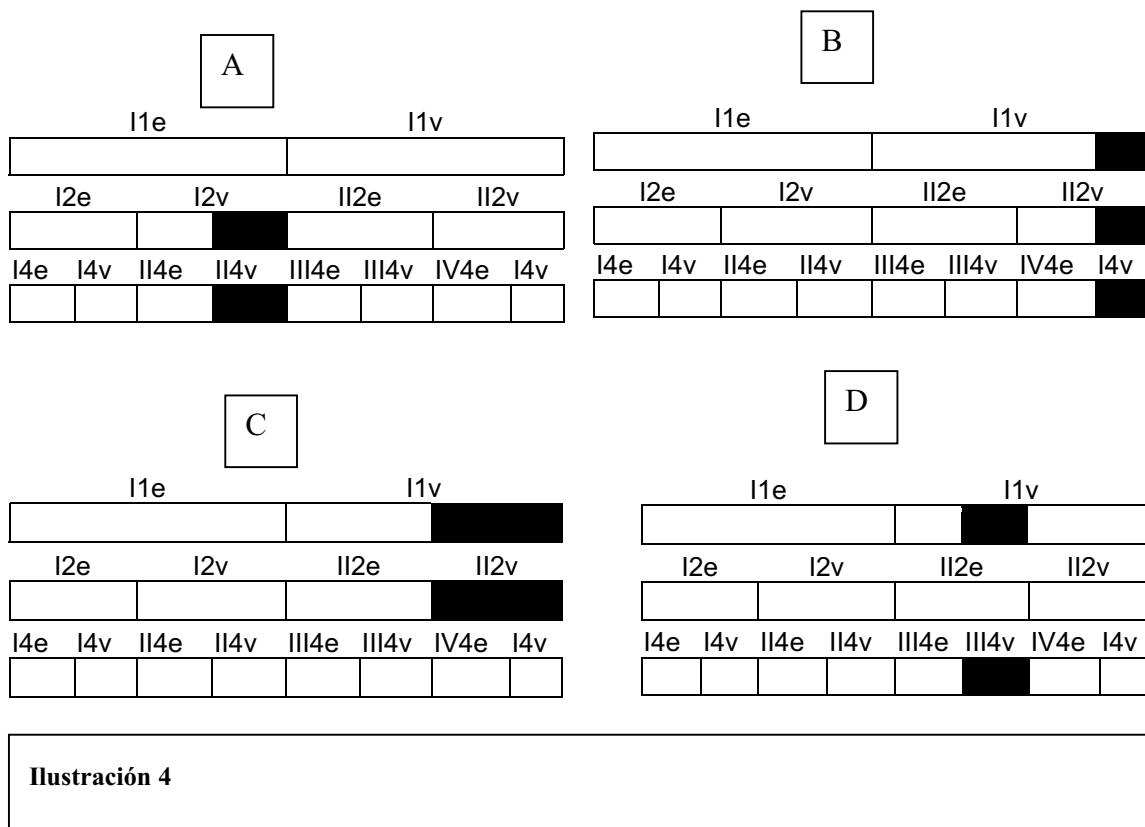
$$RS = \frac{\bar{r}}{\sigma \sqrt{Y}}, \text{ donde } \bar{r} \text{ es el rendimiento medio anualizado obtenido a través de las}$$

reglas técnicas, σ es la desviación típica de los rendimientos diarios, mientras que Y , es igual al número de días de transacción por año, que en nuestro caso es de 250. En las columnas 8,9,10 y 11 aparecen reflejados el ratio de Sharpe, el rendimiento medio anualizado, los días de transacción y el rendimiento “buy and hold” ajustado en el riesgo de aplicar la regla, con los parámetros obtenidos en el periodo de entrenamiento, al periodo de validación inmediatamente posterior.

Podemos destacar como en los periodos de entrenamiento los rendimientos obtenidos por nuestra reglas siempre superan o igualan al rendimiento “buy and hold” ajustado en el riesgo, que era nuestra marca a batir. Es decir, que el algoritmo genético es una excelente técnica de optimización para las reglas técnicas. Sin embargo, cuando comparamos los rendimientos de las reglas obtenidas fuera del periodo de entrenamiento la proporción baja, aunque en muchos de los casos se queda a sólo unos puntos por debajo.

Se puede observar que, para costes altos, el algoritmo emplea valores altos de los parámetros para suavizar las series de medias móviles y que, de esta forma, se producen pocos puntos de corte y, por lo tanto, bajos costes de transacción.

Otro objetivo que nos planteamos en este trabajo era contrastar si la proximidad de los datos de entrenamiento influían en la determinación óptima de los parámetros. Para ello se eligieron cuatro submuestras de distintos periodos de validación y que se muestran en la Ilustración IV.



Los resultados se han recogido en el cuadro II.

		Costes de transacción											
		0.45				0.25				0			
		Mmc	mml	fil	rma	Mmc	mml	fil	rma	Mmc	mml	fil	rma
Submuestras	A	18	116	31	-1.0508	99	142	2	1.8977	42	197	6	-15.3446
		182	250	20	-9.4442	188	250	13	-4.1264	171	250	19	-13.5028
	B	207	242	0	55.4478	207	242	0	55.4478	2	21	0	30.8725
		5	7	72	23.9851	6	8	51	32.2432	2	20	15	29.0958
		73	89	28	35.7118	74	89	20	35.8123	12	16	0	32.4336
	C	207	242	0	23.2858	207	242	0	23.433	2	21	0	24.3881
		5	7	72	9.6516	6	8	51	15.2682	2	20	15	23.411
	D	207	242	0	13.5776	207	242	0	13.5776	2	21	0	9.3065
		2	20	16	4.3157	2	20	15	7.5162	2	4	16	-0.1735

Cuadro 2

Se puede observar como en 10 de los 12 casos las medias móviles con un mayor número de datos batan a aquellas con menor amplitud pero más cercanas al periodo de validación.

Conclusiones

Las reglas técnicas optimizadas, por medio de AG, consiguen mejorar los rendimientos de la estrategia “buy and hold” ajustada en el riesgo, en los periodos de entrenamiento y para todos los escenarios de costes de transacción. No obstante, si consideramos los periodos de validación, el comportamiento de nuestras reglas técnicas óptimas es diverso según la longitud de los periodos de entrenamiento considerados. Así, cuando se emplean periodos de entrenamiento de 2188 observaciones, los rendimientos generados por nuestra regla son superiores a los de la estrategia “buy and hold” ajustada en el riesgo, para cualquier escenario de costes de transacción. Cuando los periodos de entrenamiento son de 1094 y 547 observaciones, las reglas óptimas obtenidas sólo son capaces de mejorar la estrategia de “buy and hold” ajustada, en casos ocasionales y con coste de transacción cero.

Los resultados obtenidos en el trabajo no son concluyentes y deben tomarse con cautela. En este sentido nuestros resultados no son capaces de confirmar ni desmentir la afirmación, que hacen muchos teóricos del mercado, de que las medias móviles son indicadores que siguen la curva de cotizaciones confirmando la tendencia en vigor, en ese momento, pero que no son capaces de anticipar los cambios de tendencia.

Se puede observar que las medias móviles más suavizadas (aquellas con parámetros altos) consiguen peor rendimiento que el “buy and hold” ajustado, dentro del periodo de validación, sin embargo, las medias móviles con parámetros cortos consiguen mejores resultados que la estrategia de comprar y mantener.

Los costes de transacción influyen decisivamente en la formación de las reglas técnicas. Con costes altos el AG suele encontrar reglas con parámetros altos, mientras que con costes bajos encuentra reglas mucho más activas, lo que se traduce en un incremento del rendimiento.

Por último, destacar que las reglas se comportan mejor mientras más amplia sea la fase de entrenamiento, con independencia de la cercanía de los periodos de entrenamiento. Parece ser que la regla optimiza su aprendizaje cuando el periodo de entrenamiento es suficientemente grande.

Bibliografía

Alexander, S.S. (1961): "Price movements in speculative markets: trends or random walks?", *Industrial Management Review* 2, pp. 7-26

Allen, F. and Karjalainen, R. (1999): "Using genetic algorithms to find technical trading rules", *Journal Finance Economics* 51 Vol 2, pp. 245-271

Bauer, R.J. Jr. (1994): "Genetic Algorithms and Investment Strategies", Wiley Finance Editors, John Wiley and Sons, New York

Bessembinder, H. y Chan, K (1995): "The profitability of technical trading rules in the Asian stock markets", *Pacific-Basic Finance Journal* 3, pp. 257-284

Brock, W.A.; Lakonishhock, J.; and LeBaron, B. (1992): "Simple technical trading rules and the stochastic of stock returns", *Journal of Finance* 47, pp. 1731-1764ç

Brown, S.; Goetzmann, W.; Kumar, A. (1998): "The Dow Theory: William Peter Hamilton's Track Record Reconsidered", Working paper, Stern school of Business, New York University.

Corrado, C.J. and Lee, S.H. (1992): "Filter rule test of the economic significance of serial dependence in daily stock returns", *Journal of Financial Research* 15 Vol. 4, pp. 369-387

Fama, E.F. (1965): "The behavior of Stock-Market Prices", *Journal of Business* 38, pp. 34-105

Fama, E.F. and Blume, M.E. (1966): "Filter rules and stock market trading", *Journal of Bussiness* 39, pp. 226-241

Fernandez, F., Sosvilla, S. Y Andrada J. (1999): "Technical analysis in the Madrid stock exchange", Documento de trabajo de 99-05 de la Fundación de Estudios de Economía Aplicada.

Fogel, I.J.; Owens, A.J.; Walsh, M.J. (1966): "Artificial intelligence through simulated evolution" Wiley, New York

Goldberg, D.E. (1989): "Genetic Algorithms in Search, Optimization, and Machine Learning", Addison Wesley, Reading, Mass

Holland, J.H. (1962): "Outline for a logical theory of adaptive systems", Journal of the Association for Computing Machinery 3, pp. 297-314

Holland, J.H. (1975): "Adaptation in natural and artificial systems", University of Michigan Press, Ann Arbor, Michigan

Holland, J.H. (1976): "Adaptation" en Rosen, R.; Snell, F.M. (Eds.), Progress in Theoretical Biology Vol. 4, Academic Press, New York, pp. 263-293

Holland, J.H. (1980): "Adaptive algorithms for discovering and using general patterns in growing knowledge-bases" International Journal of Policy Analysis and Information Systems 4, pp.217-240

Hudson, R.; Dempsey, M. and Keasey, K. (1996): "A note on the weak form of efficiency of capital markets: The application of simple technical trading rules to the U.K. stock markets-1935-1994", Journal of Banking and Finance 20 Vol. 6, pp.1121-1132

Koza, J.R. (1992): "Genetic Programming: On the Programming of Computers By the Means of Natural Selection", MIT Press, Cambridge, Mass

Lo, A.W. and MacKinley (1990): "Data snooping biases in test of financial asset pricing models", The Review of Financial Studies 3, pp. 431-467

Mills, T. (1996). "Technical analysis and the London Stock Exchange: Testing trading rules using the FT30", Department of Economics, Loughborough of Technology, Economic Research Paper No. 96/1

Neely, C.J.; Weler, P. and Dittmar, R. (1997): "Is technical analysis in the foreign exchange market profitable? A genetic programming approach", Journal of Financial Quantitative Analysis 32 Vol. 4, pp. 405-426

Pereira R. (1999): "Forecasting ability but no profit ability: An empirical evaluation of genetic algorithm-optimised technical trading rules" Discussion Papers, School of Business, La Trobe University

Rechenberg, I. (1973): "Evolutionsstrategie: Optimierung Technischer Systeme nach Prinzipien der Biologischen Evolution" Frommann-Holzboog Verlag, Stuttgart

Schwefel, H.P. (1981): "Numerical optimization of computer models" Wiley, New York

Taylor, M.P. and Allen, H. (1992): "The use of technical analysis in the foreign exchange market", *Journal of Money and Finance* 11, pp. 304-314

Whitley, D. (1989): "The GENITOR algorithm and selection pressure: why rank-based allocation of reproductive trials is best" en Schaffer, D.J. (Ed.), *Proceedings of the Third International Conference on Genetic Algorithms*, Morgan Kaufmann, San Mateo, California, pp 116-121