

---

# Colocación táctica de activos y estrategias "long-short" con árboles de clasificación

**Juan Laborda Herrero.**

Director de Estrategia y Análisis de Mercado.  
Barclays Bank España.

**Resumen:** Se propone, teniendo en cuenta las características estadísticas de las series financieras, una metodología que permita predecir adecuadamente los rendimientos relativos entre activos financieros, e implementar estrategias de colocación táctica de activos (TAA), dentro de un esquema básico de gestión de carteras (bolsa, bonos, y liquidez), y estrategias "long-short" (L-S) en mercados de acciones, bonos y divisas. Nos centraremos en aquella línea de investigación que, implicando predictibilidad en las series de rendimientos, permita en función de variables fundamentales explotar el conjunto de información que éstas ofrecen a la hora de segmentar y clasificar zonas homogéneas en las que podamos esperar un exceso de rentabilidad positiva de un activo frente a otro. La técnica propuesta corresponde a los árboles de regresión y clasificación. Una vez calculados los rendimientos relativos previstos, se desarrolla un sistema de TAA, y posiciones L-S, de donde se deriva la estructura de los factores de agresividad óptimos para las diferentes apuestas, que nos permita, a partir de una cartera benchmark, en el caso de TAA, o de un objetivo de rentabilidad anual adicional a la ofrecida por un depósito a plazo, en el caso L-S, calcular las ponderaciones a mantener en cada uno de los activos.

**Palabras Clave:** Colas Gordas, Procesos Causales, Memoria a Largo Plazo, Colocación Táctica de Activos, Estrategias "Long-Short", Factores de Agresividad Óptimos, Árboles de Clasificación y Regresión.

## 1. INTRODUCCIÓN

Los productos sobre colocación táctica de activos (TAA) existen desde hace más de dos décadas. Sin embargo, su definición nunca ha sido clara, ya que los mismos términos se aplican a diversas estrategias con diferentes propósitos. Siguiendo a Philips, Rogers, y Capaldi (1996), bajo una definición evidentemente práctica, que es la que nos interesa, "el objetivo de inversión de un gestor que hace TAA es obtener rendimientos mejores que el benchmark con una volatilidad más baja, mediante la previsión de una manera sistemática de los rendimientos de dos o más clases de activos, modificando de acuerdo con ello la exposición a las clases de activos". Teniendo en cuenta las características estadísticas de las series financieras, se trata de justificar y desarrollar una metodología que permita predecir adecuadamente los rendimientos relativos

entre activos financieros, e implementar estrategias de colocación táctica de activos (TAA), dentro de un esquema básico de gestión de carteras (bolsa, bonos, y liquidez).

El proceso tradicional de colocación táctica de activos (TAA), que incluye índices de referencia o benchmark rígidos, según el perfil del cliente, en numerosos casos se ha traducido en posiciones de cartera que no siempre han sido óptimas. La colocación en diferentes zonas geográficas, en bolsa, bonos o liquidez, sobre la base de previsiones de rendimientos esperados puede constituir una aproximación excesivamente simplista para un mundo cada vez más complejo. El problema básico reside en que se tiene un número relativamente pequeño de apuestas, con diversas restricciones sobre niveles de inversión mínima y máxima en los diferentes activos, y puede resultar bastante caro rebalancear la cartera. Una estrategia global debería eliminar restricciones innecesarias, permitiendo el uso de posiciones largas y cortas en bolsa, bonos, y divisas. Por lo tanto, en este trabajo, también detallaremos el diseño de estrategias “long-short” (L-S), especialmente desde una visión “Global Macro”, e introduciremos el papel de las divisas como generadoras de rentabilidad absoluta. Para ello utilizaremos la misma metodología que en TAA.

La metodología más adecuada está claramente condicionada por el objetivo que se persigue. Es por ello que, dentro de las líneas de investigación existentes, nuestro interés se centrará en aquella que implique predictibilidad en las series de rentabilidad. De las diversas alternativas propuestas en la literatura, se optará por aquella que permita definir un equilibrio no dinámico, teniendo en cuenta variables fundamentales, y explotar el conjunto de información que éstas ofrecen a la hora de segmentar y clasificar zonas homogéneas en las que podemos esperar un exceso de rentabilidad positivo de un activo frente a otro. El problema claramente está en determinar las variables fundamentales que definen estas zonas homogéneas, y como una misma variable puede tener una influencia distinta en el sistema, según, en que zona homogénea nos encontremos.

El objetivo fundamental de la metodología que se quiera emplear en la definición de estrategias TAA y estrategias L-S, es permitir simultáneamente respetar las características básicas del comportamiento de las series financieras, y eliminar en la medida de lo posible arbitrariedades en cuanto a las variables a incluir, ó en cuanto a la forma funcional más adecuada. Además, y en contra de una buena parte de la literatura reciente de predicción de variables financieras, consideramos que los algoritmos que se propongan deben establecer relaciones entre variables con una interpretación económica.

Uno de los enfoques más extendidos en métodos cuantitativos de gestión de carteras es identificar zonas homogéneas de comportamiento de los activos. Aunque es posible tratar de identificar estas zonas a través de técnicas de filtrado, éstas no son suficientes si no se incluyen dentro de la metodología multivariante, que permiten evitar arbitrariedades en cuanto a qué variables incluir y qué peso asignarles en la definición de estas áreas homogéneas. Dentro de las técnicas multivariantes más utilizadas con este objetivo, diversas de ellas tienen una orientación marcadamente predictiva, las más importantes de las cuales se pueden recoger en tres grandes grupos: el análisis discriminante, la metodología basada en kernels, y los métodos de redes neuronales. Ninguno de ellos cumple con los requisitos deseados para nuestro objetivo. El análisis discriminante, por estar basado en supuestos de normalidad multivariante, que no se ajustan a las características de las series financieras, los métodos kernel, por las dificultades en determinar la forma funcional del kernel, lo que introduce un elemento de arbitrariedad, y los métodos de redes neuronales, porque constituyen cajas negras, con difícil interpretación en términos económicos.

---

Una alternativa a las técnicas anteriores son los métodos de partición recursiva dentro de los cuales se incluyen, como aplicación específica, los árboles de clasificación y regresión. Globalmente estas técnicas de partición se caracterizan por clasificar las observaciones de forma binomial y secuencial, con un fuerte componente jerárquico. Su principal ventaja, por tanto, radica en identificar la jerarquía no lineal de las variables determinantes ó explicativas, de forma que se maximice una función de ordenación jerárquica. La jerarquía es estimada en la forma de un árbol binomial que produce una combinación de condiciones, del tipo "si  $x > a$ ", que reducen la dimensionalidad de los datos y mejoran la capacidad de predicción. Como resultado se obtiene un árbol basado en un conjunto de reglas del tipo "si..." que ayudan en el proceso de decisión. Es importante volver a destacar que lo más característico es que las variables se organizan de acuerdo con una jerarquía que interactúan, y que su efecto es distinto según la posición en el árbol, determinada por el conjunto de variables y condiciones previas.

Además, presenta otra serie de ventajas. En concreto, no se trata de una caja negra. Al contrario, las variables input y la variable dependiente son equiparables a cualquier conjunto de datos que se utilice en un análisis de regresión múltiple ó en análisis discriminante. A este respecto, las variables utilizadas para hacer la clasificación deben responder a unas relaciones de causalidad y racionalidad, previamente establecidas.

Como conclusión, junto con los dos aspectos de la metodología de árboles que ya hemos destacado, estructura jerárquica y dependencia libre entre las variables, hay que recalcar su capacidad para generar funciones de probabilidad condicional, no sujetas a supuestos arbitrarios. Este tipo de características son especialmente apropiadas tanto en estrategias cross-section, véase las relacionadas con el mecanismo de elección de acciones, como en estrategias basadas en series temporales, tal como puede ser la elección entre bolsa bono y liquidez, que constituyen el objetivo de este trabajo.

Un paso adicional en nuestro análisis es la definición de un modelo para integrar las técnicas de árbol descritas dentro de un método general de gestión de carteras basado en TAA, o estrategias L-S. Al tratar estas técnicas de evaluar las oportunidades de rendimiento de distintos tipos de activos, los métodos de árbol descritos, pueden ser ampliamente utilizados a la hora de predecir los rendimientos relativos por activos, lo que nos permite simultáneamente obtener un predictor de la varianza de los mismos.

Con este input es posible en una segunda etapa la elección de la composición óptima de la cartera. La decisión final sobre la combinación de activos óptima dependerá de nuevo del criterio de optimización/decisión utilizado: rendimiento total ó una combinación de rendimiento/riesgo. Aunque una parte de la literatura de TAA infravalora la importancia de diversificación del riesgo, creemos que son más apropiados procedimientos de decisión que tengan en cuenta también este factor a través de la matriz de correlaciones cruzadas.

Esta opción introduce claramente dos tipos de problemas adicionales en el diseño del programa de optimización: la estimación de la matriz de covarianzas, y la dependencia entre las covarianzas. La complejidad de los procedimientos que permiten una estimación simultánea de rendimientos, varianzas y covarianzas, nos lleva a optar por procedimientos de estimación secuenciales, para los rendimientos, varianzas y correlaciones. Centrándonos ya en la estimación de estas últimas, los procedimientos posibles van desde la estimación de la varianzas y covarianzas históricas, a la introducción de algún tipo de proceso estocástico, en base al cual poder

obtener previsiones de estas variables. Nuestra experiencia de que las varianzas históricas no constituyen una referencia apropiada, nos lleva a preferir procedimientos en los que se permita que esta matriz sea distinta en cada periodo  $t$ , en el que hay que tomar la decisión de carteras.

Por razones de coherencia y simplicidad, hemos considerado apropiado estimar también la matriz de riesgo utilizando árboles de decisión. El objetivo es determinar la estructura jerárquica que está presente en la dinámica de interacción entre los activos que forman parte de nuestra cartera.

El trabajo se organiza de la siguiente manera. En la sección 2 se recogen las características de las series financieras y los modelos desarrollados en torno a las mismas. En la sección 3 se plantea una panorámica sobre la colocación táctica de activos (TAA), centrándonos en el diseño del problema que nos permita definir las estrategias, y se presentan los árboles de regresión y clasificación como una nueva aproximación a la colocación táctica de activos (TAA), con una aplicación práctica para el caso de tres activos (bolsa, bonos y liquidez) en Estados Unidos. En la sección 4 se introducen el diseño de estrategias “long-short” (L-S), y se detalla el papel de las divisas en la colocación táctica de activos, también a través de árboles de regresión. En la sección 5 se recogen las conclusiones.

## 2. CARACTERÍSTICAS DE LAS SERIES FINANCIERAS. COMPARATIVA DE LOS MODELOS DESARROLLADOS

En la práctica una gran parte del análisis relacionado con variables financieras todavía se realiza utilizando el supuesto de que las rentabilidades de los activos siguen distribuciones gaussianas. Los argumentos utilizados para justificar este tipo de prácticas, tienen que ver con el efecto que la agregación temporal de los datos tiene en la de la distribución de las rentabilidades, de tal forma, que con series mensuales, ó con grados de agregación temporal mayores, el supuesto de linealidad seguiría siendo válido.


Este tipo de razonamientos ha hecho que la idea de la consistencia temporal se haya convertido en un factor clave en el análisis de cuestiones relacionadas con la forma de la distribución de las rentabilidades de los activos y que cuestionan que incluso con series con un grado de agregación elevado sea adecuado utilizar modelos lineales.

Para comprender mejor esta problemática sería conveniente analizar con más detalle las características de las series financieras y los problemas de agregación temporal. En la práctica, si no se utilizan modelos que impliquen consistencia temporal, la elección de una determinada escala temporal en los datos, constituye una restricción adicional sobre el problema de identificación de la distribución de los precios de los activos.

### 2.1. Características de las series financieras

En primer lugar, las series financieras, incluso con agregaciones temporales amplias, se caracterizan por ser no gaussianas. Por una parte, el histograma de las series de precios financieras presenta un típico problema de “fat tails” con respecto a una distribución de tipo Gauss, es decir tienen una tendencia mayor de lo normal a grandes fluctuaciones en los precios. El gráfico 1 adjunto representa el histograma de las rentabilidades del S&P 500.

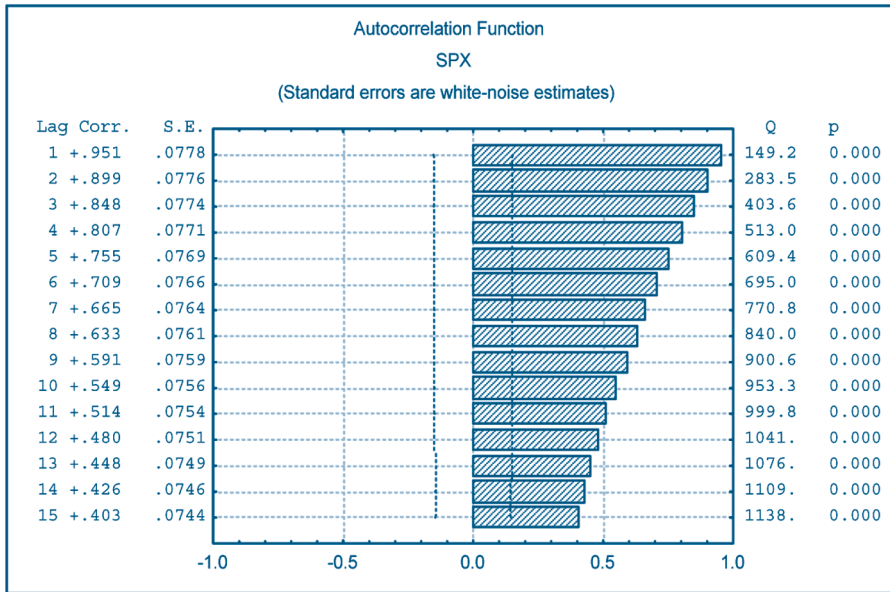
**Gráfico 1.**  
**Histograma de las rentabilidades del S&P 500.**



Por otro, y relacionado con lo anterior, las series financieras tienden a presentar una alternancia entre periodos con grandes fluctuaciones en precios y periodos de relativa estabilidad, que son característicos de los procesos causales. En la medida que esta alternancia de periodos de fuertes oscilaciones con otros de relativa estabilidad no ocurre aleatoriamente, es necesario prestar una especial atención a la dependencia temporal entre ambos tipos de secuencias, que tienden a repetirse a lo largo del intervalo muestral. Esta dependencia temporal con distintas amplitudes de onda tiende a producirse tanto en las series de rentabilidad como en las de volatilidad, y en conjunto sugieren que las series financieras se caracterizan por tener memoria a largo plazo. La existencia de memoria a largo plazo se traduce en una elevada persistencia en la dependencia temporal entre observaciones separadas por un amplio intervalo de tiempo. Técnicamente este tipo de característica puede identificarse bien por la presencia de funciones de autocorrelación que decaen hiperbólicamente ó por distribuciones espectrales de frecuencia baja. Como ejemplo de este decaimiento hiperbólico, basta ver el análisis de autocorrelaciones del S&P 500 en el gráfico 2.

Hay varias cuestiones que tienen que ver con esta característica de memoria a largo plazo, que presentan las series financieras y de las cuales la más importante es que la presencia de memoria a “long memory” es equivalente a la existencia de dinámicas no lineales, y esto es así al margen del grado de agregación temporal ó de la escala de tiempo, lo que implica que los modelos lineales no son aplicables ni siquiera a datos mensuales ó trimestrales.

**Gráfico 2. Autocorrelaciones S&P 500.**



## 2.2. Comparativa de los modelos desarrollados

Dentro de esta nueva línea de análisis de no linealidad, dos tipos de corrientes han tendido a imponerse. Por una parte, los modelos en los que la existencia de long memory se traduce en predictibilidad en el precio, y aquellos en los que long memory, y volatility clustering son compatibles con que los precios financieros sigan una martingala, respetando la hipótesis básica de eficiencia del mercado, y que tratan de predecir otras características de los precios de los activos, como puede ser la volatilidad, especialmente importante en el cálculo de precio de derivados.

Dentro de la primera corriente, la llegada de nueva información al mercado no puede ser arbitrada completamente. Como resultado, la información sobre el pasado puede ayudar a predecir la rentabilidad futura, lo que se traduce en la existencia de oportunidades de beneficios especulativos duraderas. Dentro de esta línea de análisis, la predicción de las rentabilidades es el factor clave, y para ello se han utilizado distintos tipos de enfoques.

El enfoque más extendido sigue siendo el de series temporales, especialmente con datos con frecuencias diarias ó intradía. Dentro de esta línea, el refinamiento más inmediato para poder captar adecuadamente esta característica de memoria a largo plazo en las series financieras, han sido los modelos ARFIMA, y la introducción de la idea de “fractional differencing”. Posteriormente, y para hacer frente al problema de la consistencia temporal, se han desarrollado los FBM (Fractional Brownian models)

Alternativamente, y especialmente cuando se trata con agregaciones temporales más amplias, como son datos mensuales ó trimestrales, es posible realizar el análisis, utilizando un conjunto de información más amplio que la propia serie a fin de identificar el equilibrio dinámico no lineal que caracteriza a los rendimientos financieros. De acuerdo con este enfoque las

variaciones de precios en un momento del tiempo podrían explicarse por la existencia de una particular dinámica e interacción entre las variables fundamentales, que contribuyen a definir este equilibrio. Si considerásemos el ejemplo del SPX, los movimientos y secuencias de rentabilidades en el proceso de crecimiento de los sesenta, tiene algo en común con los movimientos de recuperación observados en el 83 y posteriormente en el 93.

Dentro de la segunda línea de análisis, y al margen de los modelos de equilibrio global definidos por variables fundamentales, la literatura dominante ha estado dominada por los modelos GARCH. La adaptación de éstos para incluir memoria a largo plazo, ha sido el detonante para el desarrollo de los FIGARCH. La principal diferencia con respecto a los modelos ARFIMA y FBM es que el operador de diferenciación fractal afecta a los errores al cuadrado y no al término de error en sí mismo. De nuevo, el problema surge por la intuición de que debe existir algún tipo de relación entre las distintas representaciones FIGARCH para diferentes escalas temporales (“consistencia temporal”). Para conseguir simultáneamente esta consistencia se han desarrollado paralelamente los modelos MMAR (Multifractal Models of asset-returns). La tabla adjunta resume las principales propiedades y ventajas de los modelos hasta ahora comentados.

<b>Modelización volatilidad implica precios predecibles</b>	<b>Modelización volatilidad compatible con Martingala</b>	<b>Propiedades</b>
ARMA	GARCH	Memoria corto plazo. No consistencia en escala temporal
ARFIMA	FIGARCH	Memoria a LP. No consistencia en escala temporal
FBM	MMAR	Memoria Largo Plazo. Consistente en escala temporal

Del análisis realizado se deduce que la metodología más adecuada esta claramente condicionada por el objetivo que se persigue. En nuestro análisis, el objetivo básico es predecir adecuadamente rentabilidades relativas de activos, dentro de un esquema básico de gestión de carteras, con tres grandes activos básicos: bolsa, bonos, liquidez

Es por ello que dentro de las líneas de investigación descritas nuestro interés se centra en aquella que implica predictibilidad en las series de rentabilidad. De las dos alternativas propuestas, y al margen de modelos fractales, cuya estimación puede resultar en ocasiones excesivamente compleja, creemos que puede ser interesante definir el equilibrio no dinámico, teniendo en cuenta variables fundamentales y explotar el conjunto de información que estas ofrecen a la hora de segmentar y clasificar zonas homogéneas en los que podemos esperar un exceso de rentabilidad positivo de la bolsa (por ejemplo, con respecto a otro tipo de activos). El problema claramente está en determinar las variables fundamentales que definen estas zonas homogéneas, y como una misma variable puede tener una influencia distinta en el sistema, según en que zona homogénea nos encontremos.

### **3. COLOCACIÓN TÁCTICA DE ACTIVOS: APROXIMACIÓN A TRAVÉS DE ÁRBOLES DE CLASIFICACIÓN**

Si bien los productos sobre colocación táctica de activos (TAA) existen desde hace más de dos décadas, su definición nunca ha sido clara. La razón fundamental radica en que en los mismos términos se aplican a diversas estrategias con diferentes pr opósitos. Por ejemplo, el térmi-

no colocación dinámica de activos se puede utilizar no sólo para referirse a TAA sino también a la estrategia de aseguramiento de carteras. En diferentes ocasiones, por otro lado, TAA se define como un tipo de estrategia de inversión basada en valor diseñada con el fin de realinear el perfil de rendimiento y riesgo de una cartera benchmark estratégica de largo plazo. Bajo esta definición TAA sería una estrategia diseñada para comprar activos baratos y vender activos caros. Sin embargo, Perold y Sharpe (1988) muestran como una estrategia de mezcla constante requiere la compra de activos cuando caen en valor dado un diagrama de pagos convexo. Además, no todas las estrategias de TAA compran acciones cuando estas caen, como por ejemplo cuando los gestores utilizan señales de momentum como parte de su modelo, en cuyo caso es muy probable que compren acciones cuando el precio sube.

TAA se puede definir desde un punto de vista positivo, o de aplicación práctica, o desde un punto de vista normativo, más teórico, que analizaremos cuando veamos una perspectiva de carteras a la hora de explicar el papel e importancia de TAA. Desde un punto de vista práctico TAA entra en funcionamiento una vez que se han tomado las decisiones de colocación estratégica de activos. En primer lugar, se elige una cartera benchmark basada en los supuestos de equilibrio de largo plazo del perfil de riesgo y rendimiento del universo de inversión, así como las actitudes hacia el riesgo de los inversores. Sin embargo, diferentes fuerzas económicas y/o de mercado pueden dirigir el estado actual hacia el equilibrio o alejarlo de él, de tal manera que el balance óptimo implícito entre rendimiento y riesgo de la cartera benchmark estratégica desaparezca. Como resultado, será necesario ser capaz de cambiar dinámicamente las composiciones de la cartera de manera que la optimalidad se restaure. La manera en que ello se haga dependerá del conjunto de información, es decir, del modelo de TAA.

Arnott y Fabozzi (1992), desde este punto de vista positivo, definen TAA de la siguiente manera: “TAA se refiere de manera amplia a estrategias activas que buscan aumentar el resultado modificando de manera oportunista la mezcla de activos de una cartera en respuesta a los patrones cambiantes de beneficios/recompensas disponibles en los mercados de capitales. De manera notable, TAA tiende a hacer referencia a procesos disciplinados que evalúan las tasas de rendimientos previstos sobre varias clases de activos, y establecen una respuesta en la colocación de activos con la intención de capturar los beneficios o recompensas más altos. En las diversas implementaciones de TAA existen diferentes horizontes de inversión y diversos mecanismos para evaluar las decisiones de colocación”.

En esta definición amplia que engloba prácticamente todas las estrategias de TAA no queda, sin embargo, claramente definidos los términos “aumentar el resultado” o “recompensa”.

Si una estrategia en particular es o no una estrategia de TAA depende de como se mida el resultado y la recompensa, sea en rendimiento, volatilidad, ratio de Sharpe, o eficiencia media-varianza.

Philips, Rogers, y Capaldi (1996), recogiendo este problema introduce una definición más práctica: “El objetivo de inversión de un gestor que hace TAA es obtener rendimientos mejores que el benchmark con una volatilidad más baja, mediante la previsión de una manera sistemática de los rendimientos de dos o más clases de activos, modificando de acuerdo con ello la exposición a las clases de activos”.

En la práctica, bajo esta definición, el resultado de los gestores de TAA se mide siempre contra las carteras benchmark pasivas. Si el gestor bate al benchmark, de forma que el



rendimiento de la cartera TAA es mayor que el de la cartera benchmark, se dice que el gestor ha repartido un “alpha” positivo. Además de ser capaz de batir al benchmark, también es muy importante la consistencia en la obtención de rendimientos. En términos generales, un gestor que es capaz de ofrecer de manera consistente mayores beneficios, frecuentemente medido a través de la volatilidad de alpha y conocido como “tracking error”, se considera más hábil. De manera similar al ratio de Sharpe, que tiene en cuenta riesgo y rendimiento, una medida típica que compara el resultado de diferentes gestores de TAA es el “Ratio de Información”, definido como el cociente entre “alpha” y el “tracking error”. Cuanto más alto sea el ratio de información, mejor.

Siguiendo este planteamiento de Philips, Rogers, y Capaldi (1996), TAA tiende a poner excesivo énfasis en el rendimiento, mientras que se infravalora la importancia del riesgo. Sin embargo, TAA no tiene porqué ser consistente con maximizar la eficiencia media-varianza de la cartera. La razón es que los clientes suelen ser inversores institucionales que no consideran inaceptables algo de volatilidad adicional, pero que sí rechazan la obtención de alphas negativas de una manera continuada.

Recogiendo, como síntesis, todas las ideas expuestas, Lee (2000) define TAA de la siguiente manera: “Las estrategias de TAA son estrategias que intentan entregar un ratio de información positivo mediante cambios sistemáticos en la colocación de activos”.

Veamos cómo formalizar las medidas que permiten evaluar a los gestores que hacen TAA, que permitan explicar, siguiendo a Lee (2000), cómo derivar la estructura de los factores de agresividad óptimos, de forma que, dadas las expectativas de las alphas y la matriz de covarianzas entre las diferentes señales y apuestas, se puede alcanzar el máximo del ratio de información global de la cartera final de TAA.

### 3.1. Cómo evaluar a los Gestores que hacen TAA

Se trata de ver cómo formalizar las medidas que permiten evaluar a los gestores que hacen TAA: “alpha”, “tracking error”, y “ratio de información”.

#### Alpha

El rendimiento en exceso debido a decisiones activas tomadas por el gestor se conoce como alpha. Sea  $\mathbf{Bet}$  el vector  $N \times 1$  de apuestas tácticas entre pares de activos. Si definimos  $E[\mathbf{R}]$  como el vector de los rendimientos en exceso esperados entre los diferentes pares de activos, tenemos que

$$E[\alpha] = \mathbf{Bet}' E[\mathbf{R}] \quad [1]$$

El tamaño de la apuesta táctica entre cada par de activos se determina como un múltiplo de la señal, que en nuestro caso se basará en la diferencia de los rendimientos esperados, es decir,

$$Bet_i = F_i x_i \quad \forall i = 1, 2, \dots, N \quad [2]$$

, donde  $x_i$  es la señal para la apuesta  $i$  y  $F_i$  es un múltiplo de esta señal, denominado factor de agresividad.

### Tracking Error

El tracking error,  $TE$ , se define como la desviación estándar del alpha total, y viene dado por la siguiente expresión

$$TE^2 = Var(\alpha) = \mathbf{Bet}' \mathbf{\Omega} \mathbf{Bet} \quad [3]$$

donde  $\mathbf{\Omega}$  nos recoge la matriz de covarianzas entre las primas de riesgo.

### Ratio de Información

El ratio de información,  $IR$ , se define como el ratio de alpha respecto al tracking error, y viene dado por la siguiente expresión

$$IR = \frac{Alpha}{Tracking\ Error} = \frac{\mathbf{Bet}' E[\mathbf{R}]}{\mathbf{Bet}' \mathbf{\Omega} \mathbf{Bet}} \quad [4]$$

## 3.2 Construcción de las Carteras: Factores de Agresividad Óptimos

Se trata de explicar cómo se deriva la estructura de los factores de agresividad óptimos, de forma que dadas las expectativas de las alphas y la matriz de covarianzas entre las diferentes señales y apuestas, se puede alcanzar el máximo del ratio de información global de la cartera final de TAA.

El problema de construcción de las carteras en TAA se puede expresar de dos maneras distintas. Por un lado, dado  $n$  activos hay  $\frac{n(n-1)}{2}$  diferentes pares de apuestas, de forma que

habrá que entender como combinar óptimamente estas apuestas para formar la cartera táctica final. Alternativamente, se puede plantear considerando las diferentes señales que se pueden utilizar para hacer apuestas tácticas. Cada señal da lugar a distintas apuestas. La apuesta táctica final se puede entender como una combinación de todas las apuestas hechas de acuerdo con cada señal individual, o bien como una apuesta táctica basada en una señal compuesta donde todas las señales se combinan en una única antes de que la apuesta táctica sea hecha. Existen diversos procedimientos para combinar diferentes señales en una señal compuesta: análisis factorial o componentes principales; regresión múltiple de las primas de riesgo sobre un conjunto de señales distintas; preespecificar un conjunto de diferentes ponderaciones a asignar a las distintas señales para construir la señal compuesta, lo que a menudo se denomina *Probabilidades a priori Bayesianas de los Gestores* (“Bayesian Priors of the Managers”). En los casos más complicados se permite que dichas ponderaciones se modifiquen con el paso del tiempo o ser función de un conjunto de variables, de forma que el modelo resultante sea altamente no lineal. Un ejemplo sería un modelo estocástico con parámetros variantes en el tiempo, utilizando ecuaciones aparentemente no relacionadas con elasticidades basadas en recogida de información, utilizando para la predicción modelos de dinámica bayesiana. Otro ejemplo, sería utilizar redes neuronales.

El objetivo es analizar cómo se debería combinar las diferentes apuestas para formar la cartera táctica final, bien sean hechas para diferentes pares de activos, o por diferentes señales para la misma apuesta, de forma que se maximice el ratio de información total de

la cartera táctica. Se trata, por lo tanto, de buscar una combinación óptima de la información con el fin de maximizar dicho ratio de información global, para lo cual se introducen los factores de agresividad que juegan un papel similar a las ponderaciones de cartera.

### *Formulación del problema*

En primer lugar va a ser muy importante formarse una visión sobre el atractivo relativo de cada clase de activos a través de la diferencia entre los rendimientos esperados, o la diferencia entre los rendimientos esperados menos el valor de equilibrio, que es lo que se conoce como señal. Mientras que la dirección y magnitud de las apuestas tácticas, o desviaciones respecto al benchmark, se determinan en base a la señal, es necesario establecer la agresividad relativa a la hora de hacer apuestas con el objetivo de minimizar el total de tracking error

Sean

$N$  número de pares de apuestas

$\mathbf{x}$  un vector  $N \times 1$  de señales compuestas

$\mathbf{F}$  un vector  $N \times 1$  de factores de agresividad

$\bar{\alpha}$  un vector  $N \times 1$  de alphas para los  $N$  pares de apuestas cuando todos los factores de agresividad sean iguales a 1

$\mathbf{Q}$  matriz  $N \times N$  de covarianzas de los elementos de  $\bar{\alpha}$

**Bet** vector  $N \times 1$  de apuestas tácticas

El tamaño de la apuesta táctica entre cada par de activos se determina como un múltiplo de la señal según [2]. Si la señal se basa en la diferencia de los rendimientos esperados, como en nuestro caso,  $\bar{\alpha}_i$  será el cuadrado de los rendimientos en exceso esperados entre los dos activos implicados en la apuesta  $i$ .

Se trata de determinar el vector óptimo de factores de agresividad  $\mathbf{F}$ , que permita determinar los rangos de trading óptimos para cada activo de acuerdo con el rango de cada señal. El problema de derivar formalmente los factores de agresividad se puede plantear como

$$\begin{aligned} \underset{\mathbf{F}}{\text{Min}} \quad & \frac{1}{2} \mathbf{F}' \mathbf{Q} \mathbf{F} \\ \text{s.a.} \quad & \mathbf{F}' \bar{\alpha} = \alpha \\ & F_i \geq 0, i = 1, 2, \dots, N \end{aligned} \quad [5]$$

En [5], dado un nivel de alpha total objetivo,  $\alpha$ , para la asignación completa de activos en la cartera, se minimiza la mitad de la varianza de  $\alpha$ .

El vector óptimo de factores de agresividad<sup>1</sup> viene dado por

$$\mathbf{F}^* = \frac{\alpha}{\mathbf{a}' \mathbf{Q}^{-1} \mathbf{a}} \mathbf{Q}^{-1} \mathbf{a} \quad [6]$$

de forma que el mínimo del tracking error total será

$$TE^* = \sqrt{\mathbf{F}^{*'} \mathbf{Q} \mathbf{F}^*} = \frac{\alpha}{\sqrt{\mathbf{a}' \mathbf{Q}^{-1} \mathbf{a}}} \quad [7]$$

, y el ratio de información máximo alcanzado será

$$IR^* = \sqrt{\mathbf{a}' \mathbf{Q}^{-1} \mathbf{a}} \quad [8]$$

Si graficamos el alpha total objetivo contra el mínimo tracking error se obtiene la *Frontera Eficiente Alpha-Tracking Error* (A-TE), en torno a la cual se pueden hacer una serie de consideraciones:

- Cualquiera de las carteras tácticas óptimas a lo largo de la Frontera Eficiente están positivamente correlacionadas.
- La Frontera Eficiente A-TE es una línea recta en el espacio A-TE.
- Grinold (1989, 1994), y Grinold y Kahn (1995) establecieron la Ley Fundamental De Gestión de Activos, según la cual en una cartera activa de acciones el ratio de información es aproximadamente igual al producto del coeficiente de información de cada apuesta y la raíz cuadrada del total del número de apuestas hechas en las carteras. Ello implica, por un lado, asumir que los ratios de información de todas las apuestas son los mismos, y, por otro, sus alphas son independientes. Sin embargo, desde que las decisiones de colocación de activos tienen que ver con una amplia clase de activos que están bien diversificados, sus rendimientos están dirigidos por conjuntos de factores comunes, de forma que es imposible que las alphas de las decisiones o señales sean independientes, es decir, la Ley Fundamental De Gestión de Activos no es aplicable a TAA. ¡Se debe utilizar la expresión de los Factores de Agresividad Óptimos!.

Una vez definido el problema, se trata de buscar una metodología que, recogiendo las características básicas del comportamiento de los mercados financieros, analizadas en la sección 2, permita implementar un algoritmo no lineal en el diseño de las estrategias de TAA. Deberá, por un lado, permitir que los pesos relativos de las variables “input” no sean constantes en el tiempo, incorporando, además, el hecho de que la influencia relativa de cada variable “input” depende de su interrelación con otras variables. Se tratará, por lo tanto, de un sistema dinámico no lineal. Por otro lado, el algoritmo deberá dividir las series en zonas homogéneas según las categorías de variables “input” consideradas. Las zonas homogéneas dependen de la presencia de factores comunes: primero se elige la variable con mayor poder para discriminar entre zonas homogéneas, y a continuación se repite el algoritmo para buscar zonas homogéneas secundarias.

La técnica propuesta, que se engloba dentro de los Modelos de Reconocimiento de Pautas (“Pattern Recognition”), se denomina Árboles de Regresión y Clasificación (“Classification and Regression Trees”).

### 3.3. Árboles de Clasificación y Regresión: una nueva aproximación a TAA

Los árboles de clasificación se utilizan para predecir el número de casos u objetos presentes en las distintas clases de una variable dependiente categórica, a partir de las mediciones en una o más variables predictoras. El objeto de los árboles de clasificación es predecir o explicar respuestas o reacciones en una variable dependiente categórica. Como tal, las técnicas disponibles tienen mucho en común con las utilizadas en los métodos tradicionales de análisis discriminante, análisis cluster, estimación no lineal, y estimación no paramétrica. Sin embargo, si bien todos los métodos de clasificación estándar existentes producen clasificadores adecuados, no permiten hacerse una idea sobre la estructura predictiva del problema, presentando cada uno de ellos, además, dificultades específicas de cara a su implementación. Véase Gehrke y Loh (1999). Frente a estos métodos estándar, los árboles de regresión y clasificación reúnen las propiedades exigidas a los modelos de clasificación (alta exactitud, estructura comprensible e intuitiva, inferencia insesgada, y aprendizaje rápido), incorporando dos características muy deseables, naturaleza jerárquica y flexibilidad. Por un lado, se plantean una jerarquía de preguntas, y la decisión final que se toma depende de las respuestas a todas las cuestiones previas. Ello supone considerar niveles o “thresholds”, y ecuaciones de decisión. Por otro, los árboles de decisión presentan la capacidad de examinar los efectos de una variable predictora en un momento temporal, en vez de todo de una vez. Además, se pueden añadir decisiones adicionales para explotar cualquier información nueva procedente de una categoría adicional. Finalmente, los árboles de clasificación se pueden computar para predictores categóricos, predictores continuos, o cualquier mezcla de los dos tipos.

A continuación, explicaremos la estructura básica de un árbol de clasificación, detallando las etapas en el proceso de cómputo del mismo, y terminaremos detallando dos métodos de construcción de árboles de clasificación: CART y QUEST.

Las referencias básicas son Breiman et al. (1984), Buntine (1992), Loh y Shih, (1997), y Gehrke y Loh (1999).

La estructura básica, ampliamente aceptada en estadística aplicada e inteligencia artificial, supone construir un árbol “top-down” utilizando el principio estándar de búsqueda ávida (“greedy search principle”): tomar siempre el que se percibe como mejor movimiento y no preocuparse por encontrar otro mejor.

Sean:

$t$  denota un nodo

$T$  denota un árbol

$\tilde{T}$  es el conjunto de nodos terminales de  $T$

$|\tilde{T}|$  es el número de nodos terminales de  $T$

$T_t$  es un subárbol de  $T$  con nodo raíz  $t$

$\{t\}$  es un subárbol de  $T_t$  que contiene solo el nodo raíz  $t$

, entonces el *Esquema de Inducción “Top-Down” de un Arbol de Decisión*<sup>2</sup> se puede formalizar según el cuadro 1:

2 Véase Gehrke y Loh (1999)

**Cuadro 1.**  
**Esquema de Inducción “Top-Down” de un Árbol de Decisión.**

**INPUT:** nodo  $n$  (origen), datos a particionar  $D$ , método de selección para particiones  $Cl$ .

**OUTPUT:** árbol de decisión para  $D$ , cuyo origen está en el nodo  $n$ .

**Arbol Construido** (nodo  $t$ ,  $D$ ,  $Cl$ .)

- (1) Aplicar  $Cl$  a  $D$  para encontrar el criterio de partición
- (2) Sea  $k$  el número de subnodos de  $t$
- (3) **Si**  $k > 0$
- (4) Crear  $k$  subnodos  $t_1, \dots, t_k$  de  $n$
- (5) Utilizar la mejor división para particionar  $D$  en  $D_1, \dots, D_k$
- (6) **para** ( $i = 1; i \leq k$ )
- (7) Arbol Construido (nodo  $t_i; D_i; Cl_i$ )
- (8) **Fin Para**
- (9) **Fin Si**

Los componentes algorítmicos presentes en la construcción del árbol, se recogen en el cuadro 2<sup>3</sup>.

**Cuadro 2.**  
**Componentes Algorítmicos de un Árbol de Decisión.**

1. Criterio para medir la exactitud del pronóstico.
2. Método de selección de las divisiones o escisiones, “**Splitting Rule**”: (C45, CART, CHAID, GUIDE, QUEST).
3. Cuando se para el proceso de división de datos, “**Stopping Rule**”.
4. Método de reducción del tamaño del árbol: “**Pruning Rule**” (contrastos estadísticos, error de “cross-validación”, coste - complejidad...).

3 Véase Buntine (1992), y Gehrke y Loh (1999)

### 3.4. Árboles de Clasificación y Regresión y TAA: cómo integrarlos en la práctica

En Laborda y Munera (2001) se describe en detalle los árboles de regresión y clasificación como una nueva aproximación a la colocación táctica de activos, mientras que en Laborda y Munera (2002), y Laborda (2003, 2004) se aplica a la rotación táctica de sectores bursátiles (TSR), a la rotación táctica a lo largo de la curva del Tesoro (TYCR), y a estrategias “Long-Short”.

A continuación se describe la implementación en dos fases de los árboles de clasificación, con los correspondientes algoritmos no lineales empleados en su construcción (CART y/o QUEST), para el diseño de las estrategias de TAA.

*Fase I. Se utilizarán los algoritmos no lineales QUEST o CART para obtener zonas homogéneas de los rendimientos en exceso.*

Las variables dependientes categóricas propuestas serán los rendimientos en exceso de bolsa frente a bonos, bolsa frente a liquidez, y bonos frente a liquidez, los cuales se agruparán en dos clases: mayores o iguales que cero (“positivos”), y menores que cero (“negativos”).

A partir de las mediciones en una o más variables predictoras, que describiremos a continuación, se tratará, utilizando datos mensuales referentes al mes  $t$  y alguno de los algoritmos no lineales propuestos para cada una de las variables dependientes, de buscar zonas homogéneas de los rendimientos en exceso que nos permitan predecir a 3 meses,  $t+3$ , la media y varianza del rendimiento en exceso, así como la probabilidad de que un mercado (bolsa, bonos, o liquidez) supere al otro.

Todas las variables predictoras propuestas serán de ordenación, y se expresarán en niveles y en “momentum” (variaciones a 3, 6, 9, y 12 meses). La justificación de cada una de ellas se encuentra en la literatura de Economía Financiera, y se pueden agrupar en seis categorías:

- (i) Tipos de interés.
- (ii) Primas de riesgo.
- (iii) Ciclo económico.
- (iv) Precios de materias primas.
- (v) Divisas (tipos de cambio efectivos reales ajustados por comercio).
- (vi) “Momentum”, o variación a 3, 6, 9, y 12 meses de cada una de las variables anteriores.

Por lo tanto, en esta primera fase, obtenemos la predicción de los rendimientos en exceso esperados a 3 meses:

Bolsa (S) – liquidez (C).

$$y_{SC} = E[R_{S,t+3}] - E[R_{C,t+3}] \quad [9]$$

Bolsa (S) – bonos (B).

$$y_{SB} = E[R_{S,t+3}] - E[R_{B,t+3}] \quad [10]$$

Bonos (B) – liquidez (C).

$$y_{BC} = E[R_{B,t+3}] - E[R_{C,t+3}] \quad [11]$$

Fase II. Como hacer TAA.

Se trata de obtener los factores de agresividad (bolsa frente a bonos:  $F_{SB}$ , bolsa frente a liquidez:  $F_{SC}$ , bonos frente a liquidez:  $F_{BC}$ ), a través de la resolución del problema [5], que nos permitan determinar el tamaño de la apuesta táctica entre cada par de activos:

$$\text{Bolsa frente a bonos: } - \quad Bet_{SB} = F_{SB} \text{ Signal}_{SB} = F_{SB} y_{SB}$$

$$\text{Bolsa frente a liquidez: } - \quad Bet_{SC} = F_{SC} \text{ Signal}_{SC} = F_{SC} y_{SC} \quad [12]$$

$$\text{Bonos frente a liquidez: } - \quad Bet_{BC} = F_{BC} \text{ Signal}_{BC} = F_{BC} y_{BC}$$

Dada la cartera “benchmark” ( % bolsa =  $\omega_S$ , % bonos =  $\omega_B$ , % liquidez =  $\omega_C$  ), y determinado el tamaño de las apuestas tácticas, obtendremos las ponderaciones en cada activo:

$$\text{Bolsa S} = \omega_S + Bet_{SC} + Bet_{SB} \quad [13]$$

$$\text{Bonos B} = \omega_B + Bet_{BC} - Bet_{SB}$$

$$\text{Liquidez C} = \omega_C - Bet_{SC} - Bet_{BC} = 1 - \omega_S - \omega_B - Bet_{SC} - Bet_{BC}$$

Veamos como se hace. De la Fase I hemos obtenido las predicciones de los rendimientos en exceso esperados a 3 meses. Con ello deduciremos las predicciones de las alphas cuando los factores de agresividad son iguales a 1, así como de sus varianzas, que son dos de los componentes del problema [5] :

Bolsa (S) – liquidez (C).

$$\begin{aligned} \bar{\alpha}_{SC} &= \text{Signal}_{SC} y_{SC} = y_{SC} y_{SC} = y_{SC}^2 \\ \text{Var}(\bar{\alpha}_{SC}) &= \text{Var}(y_{SC}^2) \end{aligned} \quad [14]$$

Bolsa (S) – bonos (B).

$$\begin{aligned} \bar{\alpha}_{SB} &= \text{Signal}_{SB} y_{SB} = y_{SB}^2 \\ \text{Var}(\bar{\alpha}_{SB}) &= \text{Var}(y_{SB}^2) \end{aligned} \quad [15]$$

Bonos (B) – liquidez (C).

$$\begin{aligned} \bar{\alpha}_{BC} &= \text{Signal}_{BC} y_{BC} = y_{BC}^2 \\ \text{Var}(\bar{\alpha}_{BC}) &= \text{Var}(y_{BC}^2) \end{aligned} \quad [16]$$

Para implementar [5] nos queda por conocer las covarianzas entre las alphas de cada apuesta táctica cuando los factores de agresividad son iguales a 1, para lo cual va a ser necesario prever las correlaciones entre los cuadrados de los rendimientos en exceso esperados de las diferentes apuestas tácticas, es decir,



$$\begin{aligned}
 (Bolsa - Liquidez) \& (Bolsa - Bonos): \rho(\bar{\alpha}_{SC}, \bar{\alpha}_{SB}) &= \rho(y_{SC}^2, y_{SB}^2) \\
 (Bolsa - Liquidez) \& (Bonos - Liquidez): \rho(\bar{\alpha}_{SC}, \bar{\alpha}_{BC}) &= \rho(y_{SC}^2, y_{BC}^2) \\
 (Bolsa - Bonos) \& (Bonos - Liquidez): \rho(\bar{\alpha}_{SB}, \bar{\alpha}_{BC}) &= \rho(y_{SB}^2, y_{BC}^2)
 \end{aligned}
 \tag{17}$$

Para la obtención de las correlaciones entre los cuadrados de los rendimientos en exceso esperados de las diferentes apuestas tácticas, emplearemos las señales que los diferentes algoritmos nos dan sobre los rendimientos en exceso previstos a 3 meses. Supongamos, por ejemplo, que los algoritmos de bolsa frente a bonos, y de bolsa frente a liquidez, prevén, respectivamente, unos rendimientos en exceso positivos, en el primer caso, y negativos en el segundo. En este ejemplo, utilizaríamos como previsión las correlaciones entre los cuadrados de los rendimientos en exceso de la bolsa frente a los bonos y los de la bolsa frente a la liquidez, correspondientes a los casos en los que los rendimientos en exceso a 3 meses de la bolsa frente a los bonos hayan sido positivos y, al mismo tiempo, los de la bolsa frente a la liquidez hayan sido negativos. Y así en todos los demás casos. Véanse los resultados en el cuadro 3.

**Cuadro 3.**

**Correlaciones entre los cuadrados de los rendimientos en exceso de las diferentes apuestas tácticas, según sean + ó - los rendimientos en exceso de las distintas apuestas.**

		Bolsa vs Bonos		Bolsa vs Cash		Bonos vs Cash	
		+	-	+	-	+	-
Bolsa vs Bonos	+			0,77394	-0,13116	-0,02661	0,67470
	-			0,27716	0,96590	0,09797	-0,07395
Bolsa vs Cash	+					0,00280	-0,01682
	-					0,31264	0,06893
Bonos vs Cash	+						
	-						

Como ejemplo práctico detallaremos cómo se refleja la información obtenida a finales de julio de 2000, aplicando [5], en las ponderaciones de cartera, dada una cartera benchmark. Para ello, en primer lugar, utilizando los árboles de clasificación, se detallan las zonas homogéneas detectadas para cada apuesta táctica, que nos permiten predecir los rendimientos en exceso esperados a tres meses, así como la varianza de los mismos. Posteriormente, utilizando [14]-[17] e implementando [5], obtenemos los factores de agresividad que nos permiten determinar el tamaño de la apuesta táctica entre cada par de activos, dado por la expresión [12]. Una vez elegida la cartera benchmark y calculado [12], se obtienen las ponderaciones en cada activo utilizando [13].

Con la información de finales de julio de 2000 se detectan las siguientes zonas homogéneas, recogidas en los cuadros 4 – 6, para cada apuesta táctica:

**Cuadro 4.**  
**Zona Homogénea Bolsa & Liquidez detectada en julio 2000.**

1. Pendiente de la curva del Tesoro  $\left( \frac{\text{TIR } T\text{-Bond } \geq 10 \text{ años}}{\text{TIR } T\text{-Bill } 3 \text{ meses}} \right) \leq 1,1716$
2. Variación 9 meses diferencial de crédito  $\left( \frac{\text{TIR Bonos Corporativos BAA}}{\text{TIR Bonos Corporativos AAA}} \right) \leq 3,707\%$
3. Variación 12 meses (Dow Jones Utilities - Dow Jones Industrials)  $> -10,14\%$
4. Variación 12 meses Dow Jones Transportation  $\leq -5,080\%$

*Número de casos:* 54.

*Rendimientos en exceso esperados a 3 meses:* -2,02%

*Probabilidad Bolsa supere a Liquidez:* 33%

**Cuadro 5.**  
**Zona Homogénea Bolsa & Bonos detectada en julio 2000.**

1. Variación 12 meses diferencial de crédito  $\left( \frac{\text{TIR Bonos Corporativos BAA}}{\text{TIR Bonos Corporativos AAA}} \right) \leq 1,619\%$
2. Pendiente curva monetaria  $\left( \frac{\text{TIR } T\text{-Bill } 12 \text{ meses}}{\text{TIR } T\text{-Bill } 3 \text{ meses}} \right) \leq 0,97415$

*Número de casos:* 27.

*Rendimientos en exceso esperados a 3 meses:* -5,19%

*Probabilidad Bolsa supere a Bonos:* 11%

**Cuadro 6.**  
**Zona Homogénea Bonos & Liquidez detectada en julio 2000.**

1. Variación 3 meses CRB Industrials  $\leq 3,185\%$
2. Variación 12 meses Dow Jones Transportation  $\leq -9,340\%$

*Número de casos:* 61.

*Rendimientos en exceso esperados a 3 meses:* +1,88%

*Probabilidad Bonos superen a Liquidez:* 82%

El utilizar la fecha de julio de 2000 no ha sido caprichosa, sino que trata de demostrar el error en que puede incurrir un gestor que implementa TAA si utiliza de manera mecánica una determinada técnica cuantitativa, sin entender la dinámica de mercado. Es frecuente observar como diversos

gestores utilizan como proxy del diferencial de crédito el ratio  $\left( \frac{\text{TIR Bonos Corporativos BAA}}{\text{TIR T-Bond}} \right)$ .

Si éste repuntara mucho, de forma que la variación a 9 ó 12 meses fuera muy alta, como sucedió a finales de julio de 2000, sería indicativo de futuras e intensas bajadas de tipos de interés que, por ejemplo, en el algoritmo Bolsa & Liquidez, en un contexto donde la pendiente de la curva estaba por debajo de 1,1716 nos hubiera llevado a una zona homogénea de rendimientos en exceso previstos a 3 meses bolsa versus liquidez claramente positivos, mientras que en el algoritmo Bolsa & Bonos, donde el diferencial de crédito es la primera variable en particionar, también hubiésemos obtenido rendimientos en exceso previstos a 3 meses bolsa versus bonos claramente positivos. ¿Qué error se estaba cometiendo? La reducción de papel de deuda pública estaba distorsionando el significado y poder predictivo de dicha variable, ofreciendo señales

erróneas. Si hubiésemos utilizado el ratio  $\left( \frac{\text{TIR Bonos Corporativos BAA}}{\text{TIR Bonos Corporativos AAA}} \right)$  tal variación a 9 ó 12

meses no hubiese sido suficientemente alta como para situarnos en zona homogénea positiva, y hubiésemos obtenido los resultados recogidos en los cuadros 4 y 5.

Un comentario similar se puede extraer de la implementación del algoritmo Bonos & Liquidez si se hubiese utilizado como variable proxy de demanda global el Índice CRB Total y no el Índice CRB Industrials. El algoritmo nos hubiese llevado, con una ordenación diferente, a zonas homogéneas donde el rendimiento en exceso esperado a 3 meses de bonos versus liquidez hubiese sido negativo.

Utilizando [14]-[17], implementando [5], y considerando como únicas restricciones que no se pueden mantener ponderaciones negativas en los activos, se obtienen los factores de agresividad óptimos y la Frontera Eficiente Alpha-Tracking Error, que se muestran en el gráfico 3.

Si, por ejemplo, hubiésemos considerado un alpha objetivo anualizado del 3%, se hubiesen obtenido los siguientes factores de agresividad:

Bolsa frente a bonos:  $F_{SB} = 2,4$

Bolsa frente a liquidez:  $F_{SC} = 0$

Bonos frente a liquidez:  $F_{BC} = 2,7$

que nos hubiesen dado los siguientes tamaños de las apuestas tácticas entra cada par de activos:


Bolsa frente a bonos:  $Bet_{SB} = -12\%$

Bolsa frente a liquidez:  $Bet_{SC} = +0\%$

Bonos frente a liquidez:  $Bet_{BC} = +5\%$

Por lo tanto, para un alpha objetivo anualizado del 3%, dada una determinada cartera benchmark neutral (55% en bolsa, 40% en bonos y 5% en liquidez), y considerando como únicas res-

**Gráfico 3.**  
**Factores de Agresividad Óptimos, y Frontera Eficiente Alpha-Tracking Error,**  
**con las restricciones de ponderaciones no negativas en los activos.**



tricciones que no se pueden mantener ponderaciones negativas en los activos, las ponderaciones derivadas de hacer TAA según la metodología propuesta, y las diferencias respecto a la cartera benchmark se recogen en el cuadro 7:

**Cuadro 7.**  
**Ponderación en % en Bolsa, Bonos, y Liquidez, para un alpha objetivo del 3% anualiza-**  
**do, con las restricciones de ponderaciones no negativas en los activos.**

	Benchmark	TAA	Sobreponderar (+) Infraponderar (-) Neutral (0)
<b>Bolsa</b>	55%	43%	-12%
<b>Bonos</b>	40%	57%	+17%
<b>Liquidez</b>	5%	0%	-5%

¿Qué ocurre, sin embargo, y como es habitual, si incluimos restricciones respecto al rango máximo y mínimo de ponderación en cada activo? Obviamente, los resultados cambian. Para nuestra cartera benchmark neutral (55% en bolsa, 40% en bonos y 5% en liquidez), supongamos que se propone como rangos máximos y mínimos de ponderación en cada activo los siguientes:

Bolsa: 30%-75%.

Bonos: 20%-50%.

Liquidez: 0%-25%.

En este caso, utilizando [14]-[17], e implementando [5], con estas restricciones, se obtienen los factores de agresividad óptimos y la Frontera Eficiente Alpha-Tracking Error, que se muestran en el gráfico 4.

Si, por ejemplo, hubiésemos considerado un alpha objetivo del 3% anual, se hubiesen obtenido los siguientes factores de agresividad:

Bolsa frente a bonos:  $F_{SB} = 1,9$

Bolsa frente a liquidez:  $F_{SC} = 5,5$

Bonos frente a liquidez:  $F_{BC} = 0,0$

que nos hubiesen dado los siguientes tamaños de las apuestas tácticas entra cada par de activos:

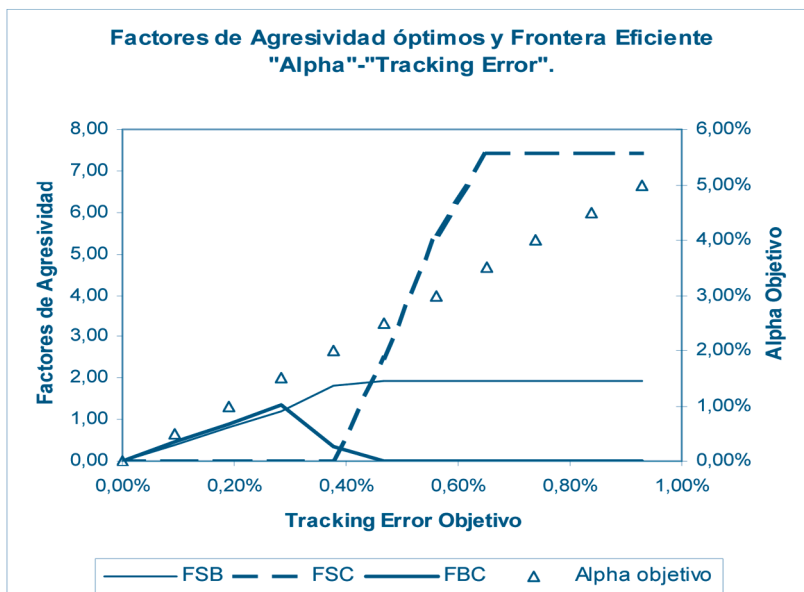
Bolsa frente a bonos:  $Bet_{SB} = -10\%$

Bolsa frente a liquidez:  $Bet_{SC} = -11\%$

Bonos frente a liquidez:  $Bet_{BC} = 0\%$

**Gráfico 4.**

**Factores de Agresividad Óptimos, y Frontera Eficiente Alpha-Tracking Error con restricciones en los rangos máximos y mínimos de ponderación en cada activo.**



Por lo tanto, para un alpha objetivo anualizado del 3%, dada una determinada cartera benchmark neutral (55% en bolsa, 40% en bonos y 5% en liquidez), y considerando las restricciones propuestas respecto al rango máximo y mínimo de ponderación en cada activo, las ponderaciones derivadas de hacer TAA según la metodología propuesta, y las diferencias respecto a la cartera benchmark se recogen en el cuadro 8:

**Cuadro 8.**  
**Ponderación en % en Bolsa, Bonos, y Liquidez para un alpha objetivo del 3% anualizado, con restricciones en las ponderaciones en los activos.**

	Benchmark	Rangos permitidos	TAA	Sobreponderar (+) Infraponderar (-) Neutral (0)
<b>Bolsa</b>	55%	30%-75%	34%	-21%
<b>Bonos</b>	40%	20%-50%	50%	+10%
<b>Liquidez</b>	5%	0%-25%	16%	+11%

El “track record”, medido por el valor añadido mensual y el alpha anual obtenido, de nuestra metodología de TAA para un alpha anual objetivo del 3%, desde el inicio de su implementación, se recoge en los gráficos 5, con las únicas restricciones de ponderaciones no negativas en los activos, y el gráfico 6, donde además hay restricciones adicionales de rangos máximos y mínimos de ponderación en cada activo.

**Gráfico 5.**  
**Valor añadido mensual y alpha anual obtenido, con las únicas restricciones de ponderaciones no negativas en los activos.**





Gráfico 6.

Valor añadido mensual y alpha anual obtenido, con restricciones adicionales de rangos máximos y mínimos de ponderación en cada activo.



A través de los gráficos 5 y 6 se detecta que en el caso donde sólo se imponen restricciones de no negatividad, y no de rangos máximos y mínimos en cada activo, se obtiene un mayor alpha. La razón hay que buscarla en que en 15 de los 46 meses en los que hasta ahora se ha implementado la metodología, la inclusión de restricciones de rangos mínimos y máximos, lleva a soluciones no óptimas, en el sentido de que el alpha objetivo establecido del 3% no se puede alcanzar con las previsiones obtenidas de rendimientos en exceso, alphas, y matriz de varianzas y covarianzas forward estimadas. A partir de esta conclusión cabría una reflexión: en España es muy frecuente establecer perfiles de riesgo del inversor que llevan asociados, bajo criterios “ad-hoc”, índices de referencia o benchmarks para los diferentes activos, con niveles mínimos y máximos de inversión en cada uno de ellos. Frente a esta aproximación generalizada, y en función de los resultados obtenidos, se propone definir como índice de referencia una cartera neutral de mercado, e implementar una gestión táctica 0%-100% entre los diferentes activos (bolsa, bonos y liquidez).

#### 4. ESTRATEGIAS “LONG-SHORT”. EL PAPEL DE LAS DIVISAS EN LA GENERACIÓN DE ALPHA

El proceso tradicional de colocación táctica de activos (TAA), que incluye índices de referencia o benchmark rígidos, según el perfil del cliente, en numerosos casos se ha traducido en posiciones de cartera que no siempre han sido óptimas. Una estrategia global debería eliminar restricciones innecesarias, permitiendo el uso de posiciones largas y cortas en bolsa, bonos, y divisas. En este apartado detallaremos el diseño de estrategias “Long-Short” (L-S), especialmente desde una visión “Global Macro”, e introduciremos el papel de las divisas como generadoras de rentabilidad absoluta. Para ello utilizaremos la misma metodología que en TAA.

El diseño de posiciones L-S se encuadra dentro de la gestión alternativa. La caída de los mercados bursátiles en los últimos años, unido a los bajos tipos de interés nominales ofrecidos en las tres áreas geográficas más desarrolladas (Estados Unidos, Europa y Japón), han forzado a los inversores a buscar nuevas fuentes de rentabilidad y oportunidades de diversificación en sus inversiones. Como resultado se está produciendo una generalización de lo que en el lenguaje financiero se denomina gestión alternativa.

La gestión alternativa hace referencia a estrategias de inversión que ofrecen la oportunidad de generar rendimientos al margen de los movimientos experimentados por los mercados de capitales en su conjunto. El objetivo ideal inicial sería producir altos rendimientos, como las acciones, pero con un menor riesgo, similar a los activos de renta fija, y con una baja correlación con los mercados de bonos y acciones, de manera que aunque la bolsa, por ejemplo, experimente fuertes pérdidas, la gestión alternativa pueda ofrecer importantes beneficios. El eje de la gestión alternativa son los rendimientos absolutos, en oposición a los rendimientos relativos respecto al mercado ofrecido por las inversiones tradicionales. En este sentido diversos fondos de gestión alternativa tienen como objetivo el conseguir una rentabilidad adicional a la ofrecida por un depósito a plazo o una letra del Tesoro, al margen de lo que hagan los mercados, combinando diversas estrategias de inversión. Obviamente la rentabilidad adicional a ofrecer sobre la ofrecida por el depósito a plazo o la letra del Tesoro, va a determinar el riesgo que se va a asumir, y que además se va a controlar, es decir, que aunque exista un objetivo de rentabilidad absoluta, por ejemplo, la ofrecida por el Euríbor a 12 meses más un 4% anualizada, éste no se consigue de cualquier manera, sino que se establecen restricciones de riesgo que se deben de cumplir, por ejemplo, el “tracking error” no debe superar el 4% anualizado. En este ejemplo se está trabajando con un ratio de información en torno a 1, que es muy usual.

Los fondos de gestión alternativa, de cara a conseguir sus objetivos de rentabilidad absoluta con restricciones sobre el nivel de riesgo asumido, utilizan no sólo la compra de un activo financiero para luego venderlo (lo que se denomina en el lenguaje financiero posición larga), sino que pueden directamente vender un activo (posición corta) sin tenerlo, o financiar la compra de uno con la venta de otro (estrategias de diferenciales), o asumir, mediante la utilización de instrumentos de los mercados derivados (futuros y opciones) posiciones apalancadas, es decir, de riesgo subyacente superior al patrimonio del fondo. Estas estrategias sólo se pueden implementar mediante un procedimiento robusto, basado en la aplicación a lo largo del tiempo de un proceso de inversión altamente disciplinado, que implica la utilización de herramientas cuantitativas, es decir, modelos matemáticos.

Si bien las estrategias de los fondos de gestión alternativa son muy amplias y diversas, se pueden clasificar en dos grandes grupos. Por un lado, las no direccionales, donde el rendimiento a obtener sobre nuestro objetivo se produce al margen de lo que hagan los mercados financieros, y, por otro, las direccionales, donde el rendimiento a conseguir sobre nuestro objetivo se asocia a cambios de oportunidad en las exposiciones a los diversos mercados, es decir, tratando de sincronizar de manera adecuada los mercados que en cada momento ofrecen mayor rentabilidad, solventando los problemas derivados de la aproximación clásica a la colocación táctica de activos. Nos centraremos en este segundo grupo.

De las diversas estrategias L-S existentes, cabría citar las siguientes:

- Estrategias L-S con los diferentes tramos de una misma curva del Tesoro.



— Estrategias L-S entre diversos sectores bursátiles, distintas acciones, y/o distintos estilos activos (“Value” frente a “Growth”, “Small-Medium Caps” frente a “Large” Caps).

— Estrategias L-S con índices bursátiles, índices de bonos, y divisas.

En Laborda y Munera (2002), y Laborda (2003) se aplica la metodología de árboles de clasificación a estrategias L-S entre sectores bursátiles, y entre los diferentes tramos de la curva del Tesoro, respectivamente. En el presente artículo, vamos a detallar como podríamos formular el problema de un fondo “global macro” utilizando índices de bolsa, bonos, y divisas.

Sean

- $n$  índices de bonos de diferentes países
- $m$  índices de bolsa de distintos países
- $l$  divisas

se implementan las siguientes estrategias

- $(n-1)+(n-2)+\dots+1$  pares de apuestas entre los diversos índices de bonos
- $(m-1)+(m-2)+\dots+1$  pares de apuestas entre los diversos índices bursátiles
- $\min(n,m)$  pares de apuestas entre los índices bursátiles y de bonos de un mismo país.
- $(l-1)+(l-2)+\dots+1$  pares de apuestas entre divisas

de manera que

- la posición neta en cada una de las estrategias sea cero,
- el alpha objetivo anual sea Euribor 12 meses + X% anual
- y el “traking error” ex-ante sean menor o igual a X% anual, es decir el Ratio de Información (IR) sea mayor o igual que 1.

Formalmente el problema quedaría definido de la siguiente manera:

$$\begin{aligned}
 & \underset{F}{\text{Min}} \frac{1}{2} \mathbf{F}' \mathbf{Q} \mathbf{F} \\
 & \text{s.a. } \mathbf{F}' \bar{\mathbf{a}} = \text{Euribor 12 meses} + X\% \\
 & \quad IR \geq 1 \\
 & \quad F_k \geq 0, k = 1, 2, \dots, K \\
 & \quad K = (n-1) + (n-2) + \dots + 1 + (m-1) + (m-2) + \dots + 1 + \min(n, m) + (l-1) + (l-2) + \dots + 1
 \end{aligned} \tag{18}$$

De la resolución de [18] se derivan de cada apuesta las diversas ponderaciones para cada uno de los instrumentos considerados:

- De cada par de apuestas entre índices de bonos

$$\forall i, j \left\{ \begin{array}{l} i \neq j \\ i, j = 1, \dots, n \end{array} \right\} \Rightarrow \left\{ \begin{array}{l} \omega_{Bono\ i} = BetBono_i Bono_j \\ \omega_{Bono\ j} = -BetBono_i Bono_j \end{array} \right\} \quad [19]$$

- De cada par de apuestas entre índices de bolsas

$$\forall i, j \left\{ \begin{array}{l} i \neq j \\ i, j = 1, \dots, m \end{array} \right\} \Rightarrow \left\{ \begin{array}{l} \omega_{Bolsa\ i} = BetBolsa_i Bolsaj \\ \omega_{Bolsa\ j} = -BetBolsa_i Bolsaj \end{array} \right\} \quad [20]$$

- De cada par de apuestas entre índices de bolsa y bonos de un mismo país

$$\forall i = \min(i, j) \Rightarrow \left\{ \begin{array}{l} \omega_{Bolsa\ i} = BetBolsa_i Bono_i \\ \omega_{Bono\ i} = -BetBolsa_i Bono_i \end{array} \right\} \quad [21]$$

- De cada par de apuestas entre divisas

$$\forall i, j \left\{ \begin{array}{l} i \neq j \\ i, j = 1, \dots, l \end{array} \right\} \Rightarrow \left\{ \begin{array}{l} \omega_{Divisa\ i} = BetDivisa_i Divisaj \\ \omega_{Divisa\ j} = -BetDivisa_i Divisaj \end{array} \right\} \quad [22]$$

De la definición del problema anterior, se propone incluir estrategias de pares de apuestas entre divisas, a través de futuros. El argumento fundamental, tal como veremos con posterioridad, son altos ratios de información ex-ante, y ex-post, que se obtienen, obviamente muy superiores a las estrategias basadas en pares de apuestas entre bonos, bolsa, y liquidez, siendo bastante mayores que 1. Pero, por qué las divisas ofrecen ratios de información superiores a uno. La respuesta hay que encontrarla en las enormes ineficiencias existentes en el mercado de divisas. Arnott y Pham (1992), encuentran las siguientes evidencias:

- 1.- Los tipos de cambio forward no predicen los tipos de cambio spot: los mercados forward son predictores sesgados de los movimientos del tipo de cambio, y además dicho sesgo lo está en una forma muy predecible.
- 2.- Altos tipos de interés de los bonos del Tesoro atraen capitales, presionando al alza a la correspondiente divisa.
- 3.- Además, pendientes de curva positivizadas tienden a apreciar la correspondiente divisa.

De 2 y 3 se deriva que o bien el vínculo entre inflación y tipos es débil, o que la paridad de poder de compra tiene menos influencia que los flujos de capital en los movimientos de las divisas en el corto plazo.

- 4.- Existe correlación serial positiva en el comportamiento de algunas divisas debido a las intervenciones de los Bancos Centrales, sobre todo de la Reserva Federal (FED) y del Banco de Japón (BOJ), en mercado abierto, con el fin de disminuir la volatilidad a corto plazo de su divisa, especialmente contra aquellas monedas con quien más comercia.

Al existir una clase de inversores que no tienen en cuenta el binomio rentabilidad-riesgo en su toma de decisiones, no hay razón para que las ineficiencias comentadas tiendan a disiparse, por mucho que los mercados de divisas sean grandes y líquidos. En esta línea, algunas aproxi-

---

maciones matemáticas a las propiedades de las divisas, véanse Peters (1991, 1994), sugieren un reescalamiento con el tiempo de la desviación estándar de las mismas a tasas más rápidas que en el caso de bonos u acciones, y que además no está acotada, lo cual sugeriría que las divisas no están sujetas a ciclo económico, y que no tienen, por lo tanto, un valor fundamental ligado a la actividad económica. Profundizando un poco más, Peters (1991, 1994) encuentra que los coeficientes de Hurst son altamente persistentes, y que además, en la búsqueda de ciclos, a través del estadístico  $V$ , no se encuentra aparentemente ciclos de largo plazo. Lo que ello sugiere es, por un lado, la existencia en el mercado de participantes que no tienen como objetivo maximizar el rendimiento, y, por otro, que los inversores de largo plazo deberían tener mucho cuidado, ya que el riesgo se incrementa con el tiempo, y, por lo tanto, una estrategia de “buy and hold” no debe asumirse como provechosa en el largo plazo.

A continuación vamos a detallar, a través de un ejemplo, como utilizar las divisas en el diseño de posiciones “long-short”. Para ello implementaremos estrategias L-S con tres divisas: el Euro (EUR), el dólar estadounidense (USD), y el yen japonés (JPY), utilizando árboles de regresión y clasificación, concretamente el algoritmo no lineal CART, con el fin de identificar zonas homogéneas o fotos que nos permitan predecir a final de cada mes los rendimientos en exceso forward a 3 meses de una moneda frente a otra, así como las alphas y la matriz de varianzas y covarianzas de las alphas entre las distintas pares de apuestas. Todas las variables predictivas que utilizaremos son variables numéricas de ordenación, relevantes para la previsión de rendimientos en exceso entre las divisas, siguiendo la literatura financiera y los comentarios que hemos visto con anterioridad, y que podrían agruparse en las siguientes categorías:


- (i) Tipos de interés relativos a corto y largo plazo entre las dos divisas.
- (ii) Pendiente relativa de la curva de tipos de interés entre las dos divisas.
- (iii) Tipos de cambio efectivos reales relativos entre las dos divisas.
- (iv) Variables de riesgo.
- (v) Variables que recogen preferencias por estilos de inversión.
- (vi) “Momentum” a 3, 6, 9, y 12 meses de cada una de las variables anteriores.

Las variables que se recogen en el grupo (v) asumen la existencia de un ciclo de “estilos” en el comportamiento de los mercados financieros.

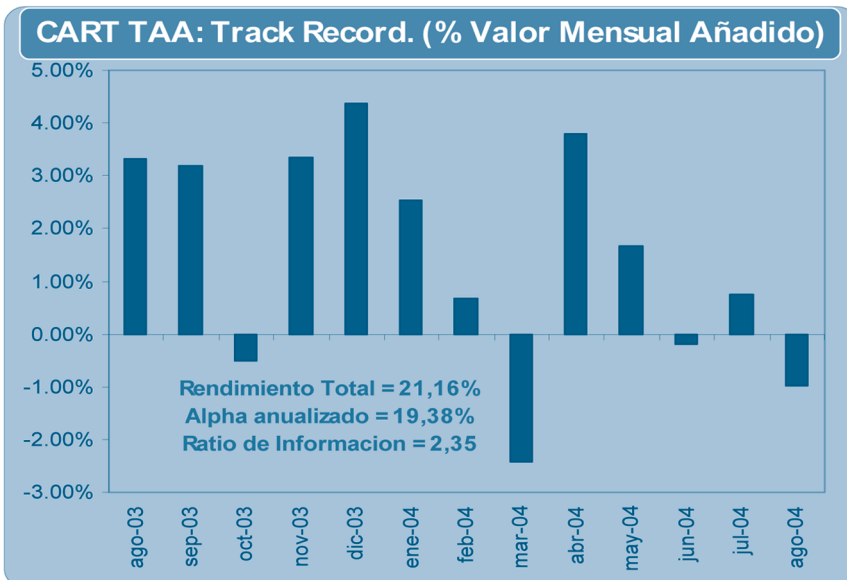
El problema consiste en obtener los factores de agresividad y el tamaño total para cada apuesta a través de la minimización del tracking error total, con un objetivo de alpha anual sobre el tipo de interés del EUR a 12 meses del 20%. Con una muestra de aprendizaje de datos mensuales que empieza en enero de 1973, y una muestra dinámica de contraste de las previsiones del 2,5%, se obtiene desde agosto de 2003, momento en el que empezamos a implementarlo, las apuestas y el track record que aparecen en los gráficos 7 y 8, respectivamente.

Se observa, como hemos comentado al principio, y en base a las razones que hemos argumentado, que el ratio de información es muy alto, muy superior a la unidad, ¡en torno a 2!, de ahí la utilidad, y necesidad, de incluir las divisas en toda estrategia L-S “global macro”.

**Gráfico 7.**  
Apuestas en divisas (USD, EUR, y JPY) derivadas de la minimización del “tracking error” y un alpha objetivo anual sobre Euribor 12 meses del 20%.



**Gráfico 8.**  
Valor añadido mensual, alpha anual y ratio de información obtenido, a partir de las apuestas en divisas (USD, EUR, y JPY) del gráfico anterior.



---

## CONCLUSIONES

Se propone, teniendo en cuenta las características estadísticas de las series financieras, una metodología que permita predecir adecuadamente los rendimientos relativos entre activos financieros, e implementar estrategias de colocación táctica de activos (TAA), dentro de un esquema básico de gestión de carteras (bolsa, bonos, y liquidez), y estrategias “long-short” (L-S) en mercados de acciones, bonos y divisas.

El proceso tradicional de colocación táctica de activos (TAA), que incluye índices de referencia o benchmark rígidos, según el perfil del cliente, en numerosos casos se ha traducido en posiciones de cartera que no siempre han sido óptimas. Una estrategia global debería eliminar restricciones innecesarias, permitiendo el uso de posiciones largas y cortas en bolsa, bonos, y divisas. En este sentido, detallaremos el diseño de estrategias “long-short” (L-S), especialmente desde una visión “global macro”, e introduciremos el papel de las divisas como generadoras de rentabilidad absoluta.

La técnica propuesta para el diseño de estrategias de TAA y L-S, que se engloba dentro de los modelos de reconocimiento de pautas, se denomina árboles de regresión y clasificación. El resultado final es un árbol binario secuencial que asigna probabilidades a los posibles resultados categóricos de la variable dependiente, en nuestro caso si los rendimientos relativos en exceso entre dos activos son positivos o negativos, en función de variables predictoras, utilizando el algoritmo CART. Todas las variables predictoras propuestas son numéricas, de ordenación, y se expresan en niveles y en “momentum” (variaciones a 3, 6, 9, y 12 meses). La justificación de cada una de ellas se encuentra en la literatura de Economía Financiera.

CART identifica de manera secuencial la variable predictiva y el correspondiente nivel que permite particionar las observaciones de la variable dependiente en dos subgrupos en cada nodo. Utilizando métodos de reducción del tamaño del árbol, y de finalización del proceso de división de los datos, identificaremos las variables más relevantes para la estimación de los rendimientos en exceso.

Una vez que se han calculado, a través de las zonas homogéneas derivadas del algoritmo CART, las previsiones de los rendimientos relativos en exceso, utilizaremos dicha información para derivar los factores de agresividad y el tamaño que daremos a cada apuesta. En primer lugar, de la información obtenida a través de los árboles de clasificación, obtendremos las expectativas de las alphas y de la matriz de varianzas y covarianzas de las mismas. Posteriormente, se plantea el problema de optimización relevante para la construcción de carteras, y que definiremos como la maximización del ratio de información, combinando apuestas o señales, utilizando los factores de agresividad como los equivalentes a las “ponderaciones o pesos tradicionales” en los procedimientos de optimización de carteras media-varianza. Se trata de determinar el vector óptimo de factores de agresividad  $\mathbf{F}$ , que permita establecer los rangos de trading óptimos para cada activo de acuerdo con el rango de cada señal. Si graficamos el alpha total objetivo contra el mínimo tracking error se obtiene la *Frontera Eficiente Alpha-Tracking Error* (A-TE), sobre la cual se pueden hacer una serie de consideraciones: por un lado, cualesquiera de las carteras tácticas óptimas a lo largo de la frontera eficiente A-TE están positivamente correlacionadas, y por otro lado, la frontera eficiente A-TE es una línea recta en el espacio A-TE.

Finalmente, en base a los resultados obtenidos, convendría plantear dos reflexiones. En España es muy frecuente establecer perfiles de riesgo del inversor que llevan asociados, bajo criterios “ad-hoc”, índices de referencia o benchmarks para los diferentes activos, con niveles mínimos y máximos de inversión en cada uno de ellos. La inclusión de restricciones de rangos mínimos y máximos, lleva a soluciones no óptimas, en el sentido de que en numerosas ocasiones el alpha objetivo establecido no se puede alcanzar con las previsiones obtenidas de rendimientos en exceso, alphas, y matriz de varianzas y covarianzas forward estimadas. Como consecuencia, se propone definir como índice de referencia una cartera neutral de mercado, e implementar una gestión táctica 0%-100% entre los diferentes activos (bolsa, bonos y liquidez), y si el perfil de riesgo del cliente no coincide con el de la cartera mercado, combinar el resultado derivado de la gestión táctica 0%-100% con instrumentos de liquidez.

La segunda reflexión gira en torno al papel de las divisas en la gestión. Se propone la necesidad de incluir las estrategias de pares de apuestas entre divisas en toda estrategia L-S “global macro”. El argumento fundamental, como demostramos, son altos ratios de información ex-ante, y ex-post, que se obtienen, obviamente muy superiores a las estrategias basadas en pares de apuestas entre bonos, bolsa, y liquidez, siendo bastante mayores que 1, ¡próximos a 2!

## BIBLIOGRAFIA:

- Arnott, R. and Fabozzi, F. (1992): “The Many Dimensions of The Asset Allocation Decisions” in Arnott, R. and Fabozzi, F.J. (eds.), *Active Asset Allocation*, Probus Press, 3-8.
- Arnott, R. and Pham, T. (1992): “Tactical Currency Allocation”, in *Investment Management Reflections, N°1. First Quadrant Corporation*.
- Black, F., and Litterman, R. (1992): “Global Portfolio Optimization”, *Financial Analysts Journal* September/October, 28-43.
- Breiman, L., et al. (1998): *Classification And Regression Trees*. Chapman & Hall / CRC Press.
- Eric, H., et al. (2000): “The Decision Tree Approach to Stock Selection”, *Journal of Portfolio Management*, Fall, 42-51.
- Gehrke, J., and Loh, W.-Y. (1999): *Data Mining with Decision and Regression Trees*. KDD1999 Tutorial.
- Grinold, R. (1989): “The Fundamental Law of Active Management”, *Journal of Portfolio Management* **Spring**, 30-37.
- Grinold, R. (1994): “Alpha is Volatility Times IC Times Score”, *Journal of Portfolio Management* **Summer**, 9-16.
- Grinold, R. and Kahn, R. (1995): *Active Portfolio Management*. Irwin, Chicago, Illinois.
- Mandelbrot, B.B. (1997): *Fractal and Scaling in Finance*. Springer-Verlag.
- Mandelbrot, B.B., et al. (1997): “A Multifractal Model of Asset Returns”. *Mimeo*.

- 
- Mandelbrot, B.B., et al. (1997): “Multifractality of Deutschemark / US Dollar Exchange Rates”. *Mimeo*.
  - Laborda, J., and Munera, A. (2001): “Tactical Asset Allocation with Classification and Regression Trees”. *Proceedings Eight International Conference Forecasting Financial Markets: Advances for Exchange Rates, Interest Rates and Asset Management*.
  - Laborda, J., and Munera, A. (2002): “Traditional against Alternative Equity Investment: Optimum Strategy based on Historical Evidence and Simulations”. *Proceedings Nine International Conference Forecasting Financial Markets: Advances for Exchange Rates, Interest Rates and Asset Management*.
  - Laborda, J. (2003): “Tactical Yield Curve Movements, and Fixed Income Long-Short Strategies with Classification and Regression Trees.”. *Proceedings Ten International Conference Forecasting Financial Markets: Advances for Exchange Rates, Interest Rates and Asset Management*.
  - Laborda, J. (2004): “Tactical Asset Allocation and Long-Short Strategies with Classification and Regression Trees.”. *Proceedings 3<sup>rd</sup> Annual Merrill Lynch Conference Challenges in Asset Allocation*.
  - Lee W. (2000): *Advanced Theory and Methodology of Tactical Asset Allocation*. John Wiley & Sons, New York, NY.
  - Loh, W.-Y., and Shih, Y.-S. (1997): “Split Selection Methods for Classification Trees”. *Statistica Sinica*, 7, 815-840.
  - O&A Research Group (1995): “Fractals and Intrinsic Time-A Challenge To Econometricians”. *O&A Working Paper Series*.
  - O&A Research Group (1995): “Unveiling Non Linearities Through Time Scale Transformations”. *O&A Working Paper Series*.
  - Perold, A., and Sharpe, W. (1988): “Dynamic Strategies for Asset Allocation”, *Financial Analysts Journal* January/February, 16-27.
  - Peters, E. (1991): *Chaos and Order in the Capital Markets*. John & Wiley Sons.
  - Peters, E. (1994): *Fractal Market Analysis*. John & Wiley Sons.
  - Philips, T. E., Rogers, G.T., and Capaldi, R.E. (1996): “Tactical Asset Allocation: 1977-1994”, *Journal of Portfolio Management*, Fall, 57-64.
  - Putman, B. (2000): *Integrating Risk Management into Asset Allocation*. Global Investor.
  - Refenes, A.N., et al. (1995): “Neural Networks in Investment Management” in Gootinake, S. and Treleaven, P. (eds.), *Intelligent Systems for Finance and Business*, John Wiley & Sons, 177-208.
  - Refenes, A.N., and Zapranis, A.D. (1999): “Specification Tests for Neural Networks” *Journal of Forecasting*, 18, 177-208.