

Como Mejorar un Índice de Acciones Usando la Dispersión de
Retornos Como Factor de *Timing*

Martin Sebastián Cornero

Legajo: 12G437

Tesis para optar al grado de Master en Economía



Departamento de Economía

Universidad Torcuato Di Tella

Julio, 2020

Resumen

La gestión activa de portafolios ha enfrentado dificultades en los últimos tiempos para obtener rendimientos superiores a su benchmark, a la vez que fondos mutuos (como los ETFs) han ganado popularidad debido a un historial de retornos y riesgo similares a cambio de comisiones más bajas. En este trabajo se desarrolló un marco donde los portafolio managers adoptan una estrategia pasiva, para luego realizar ‘apuestas activas’ en determinados momentos donde la dispersión de los retornos de acciones es alta. Se demuestra que aquellos managers con mejor capacidad para predecir retornos logran rendimientos superiores durante estos períodos. Sin embargo, el resultado está sujeto a que el portafolio manager logre predecir retornos con un mínimo nivel de precisión (medido por el coeficiente de información).

Índice

I. Introducción	4
II. Metodología	8
A. Descripción de la estrategia pasiva	8
B. Descripción de la estrategia activa	11
C. Medidas de dispersión	12
D. Modelo de Black-Litterman	13
E. Predicciones semi-perfectas	16
III. Resultados	18
A. Rendimiento del Índice y los portafolios MVO	18
B. MVO con predicciones semi-perfectas	21
C. Análisis de la dispersión de los retornos	22
C.1. Relación entre la dispersión y el retorno de los portafolios	24
D. Estrategia Black-Litterman usando la dispersión	27
IV. Conclusión	33
V. Apéndice	34
A. Acciones seleccionadas para el índice proxy	34
B. Rendimiento del potafolio MVO sin restricciones	35
C. Ponderaciones históricas de los portafolios MVO restringidos	36
D. Autocorrelación de las medidas de dispersión	37
E. Transición de estados para la dispersión de corte transversal	38
F. Estrategia Black-Litterman con 2 estados	39

I. Introducción

La gestión activa de portafolios, que predominó por mucho tiempo en la industria financiera, ha enfrentado diversos retos en los últimos años. Las estrategias de gestión activa buscan superar un determinado índice objetivo, o benchmark, mediante cambios en las ponderaciones de los componentes (subir la participación de algunos activos y disminuir la de otros). Este objetivo se basa en la premisa que los gestores de portafolios, los portafolio managers, poseen la habilidad de predecir retornos y obtener mejores rendimientos. Sin embargo, muchos estudios sugieren que esto no sucede en la mayoría de los casos.

Gruber (1996) y Malkiel (1995), muestran que los fondos de gestión activa suelen tener rendimientos por debajo de los índices que tienen como benchmark. Nguyen and Miles (2012) obtuvieron resultados similares. Incluso para aquellos casos donde los portafolio managers logran obtener mejores rendimientos, las comisiones y costos de transacción reducen considerablemente los rendimientos al punto de terminar por debajo del benchmark. Artículos más recientes agregan que los avances en tecnología, trading algorítmico e inteligencia artificial, junto con una mayor cantidad de analistas en la industria, ha incrementado la competencia en el mercado y, por ende, la capacidad de obtener mayores rendimientos. Estos argumentos sustentan el cambio observado de estrategias activas a estrategias pasivas.¹ Por ejemplo, post crisis financiera de 2008 hubo un surgimiento de los fondos pasivos *exchange-traded funds* (ETF por sus siglas en inglés) debido principalmente a las menores tasas de comisiones y rendimientos sólidos durante esos años.²

Si bien la inversión activa se ha visto en dificultades para generar retornos superiores en el largo plazo, esto no implica que no existan momentos en los que ésta agregue valor. Algunas de las razones por las cuales un inversionista se inclina a una gestión activa son: (a) un portafolio manager

¹Ellis, C. D. (19 de enero del 2017). The end of active investing? *Financial Times*

²Tuckwell, David (28 de junio del 2020). A new trend is shaking up the ETF industry: active management *Financial Times*

tiene mayor flexibilidad para invertir en ciertos sectores o activos difíciles de acceder a través de estrategias pasivas, (b) tener a un experto en temas relevantes con la capacidad de rebalancear el portafolio cuando observe cambios en el mercado, e (c) incorporar expectativas de variables difíciles de cuantificar, tales como riesgos políticos. En base a un artículo reciente, en el año 2020 hubo un incremento en la oferta y demanda de ETFs activos debido principalmente a dos factores: tasas tan bajas de comisión ponían en riesgo a la industria de gestión de inversiones, y la incertidumbre durante la pandemia del Covid-19 llevó a los inversionistas a diversificar más sus portafolios.³ Aunque las estrategias pasivas continúan teniendo mayor demanda, existe incertidumbre acerca de qué tipo de estrategia tendrá mayor éxito en el futuro. Todos estos elementos conllevan a las siguientes preguntas: qué condiciones del mercado determinan el éxito de la estrategia activa sobre la pasiva, cómo obtener mayor ventaja de ambos enfoques (pasivo y activo), qué universo de activos puede funcionar para implementar una estrategia híbrida. El presente trabajo busca obtener respuestas a algunas de estas preguntas.

Los principales métodos para combinar estrategias activas y pasivas son: *stock selection* y/o *asset allocation* (Cremers and Petajisto (2009)). El primero es un enfoque que va de abajo hacia arriba, en donde el portafolio manager trata de identificar qué activos van a generar retornos superiores e inferiores en el futuro para luego tomar posiciones. Por otro lado, *asset allocation* es un enfoque de arriba hacia abajo en donde el manager considera al portafolio como un todo y se enfoca en minimizar el riesgo mientras que maximiza sus retornos.

Carhart (1997) muestra que los retornos de los fondos de inversión no son persistentes a través del tiempo. Aquellos fondos con rendimientos superiores en un año no suelen mantenerlo en los años siguientes. Von Reibnitz (2017) demostró que existe una relación positiva entre el rendimiento del portafolio y el nivel de dispersión de los retornos en el mercado. Dicho análisis demuestra que

³Referirse a la nota al pie número 2

en períodos donde los retornos entre activos son similares es más difícil identificar aquellos que obtendrán mayores retornos. Esto dificulta la posibilidad de obtener mayores rendimientos que el promedio de la industria. Por otro lado, cuando la dispersión de los retornos incrementa, la selección de activos puede producir mejores rendimientos. Por lo tanto, sugiere intentar seguir una estrategia pasiva cuando las condiciones de mercado son similares al primer escenario, y se desvían en los momentos donde los retornos entre activos son dispares. Además, el estudio demuestra que la dispersión es persistente, por lo que invertir en períodos de dispersión alta no produce rebalances del portafolio constantes (*asset turnover*). Este argumento también es respaldado por Gorman, Sapra, and Weigand (2010), quien explica que la dispersión de corte transversal resulta más apropiada como medida de riesgo del portafolio que la volatilidad histórica. Estos argumentos sugieren que la dispersión de corte transversal no sólo es útil como medida de riesgo, sino como un indicador del momento para cambiar de estrategia (*timing*).

Como se mencionó anteriormente, un alto nivel de dispersión en los retornos puede expandir el conjunto de oportunidades de inversión. Por lo tanto, el presente estudio busca probar que en períodos donde la dispersión de corte transversal es alta, moverse de una estrategia pasiva hacia una activa puede mejorar el rendimiento del portafolio. Para demostrar la hipótesis, se desarrolló una metodología que busca mejorar los retornos de una gestión pasiva a través de ‘apuestas activas’ durante períodos en los que la dispersión de los retornos es alta. Durante estos períodos, los portafolio managers con mayor habilidad para predecir retornos podrán mejorar los rendimientos de la gestión pasiva.

Para implementar la estrategia primero se define un benchmark y, posteriormente, se utiliza el modelo de Black-Litterman de optimización inversa para generar los retornos esperados implícitos por la composición del benchmark. Cuando la dispersión de corte transversal es alta, se cambia a una enfoque activo donde se ajustan los retornos implícitos por Black-Litterman para generar una

composición activa del portafolio.

El primer paso es decidir qué benchmark pasivo utilizar. El presente estudio se enfoca en el mercado bursátil de Estados Unidos, particularmente el índice Dow Jones Industrial Average (DJIA) dado que contiene las acciones con mayor capitalización de la bolsa de Estados Unidos y es un índice de referencia para muchos inversores. Para propósitos del presente estudio, se creó un índice aproximado del DJIA para utilizarlo como benchmark pasivo, compuesto por 30 acciones que han pertenecido al DJIA. Por otro lado, la estrategia activa será representada por un modelo de optimización de media-varianza. Finalmente, la metodología se puede resumir de la siguiente manera: (i) se empieza desde la composición del benchmark, (ii) se calcula la dispersión de corte transversal del grupo de 30 acciones seleccionadas, (iii) si la dispersión es baja, se mantienen la composición del benchmark, (iv) si la dispersión es alta, entonces la composición cambia a la estrategia activa (optimización de media-varianza).

El resto del trabajo se organiza de la siguiente forma. La sección II explica la metodología que se utilizó para demostrar la hipótesis. Se comienza por describir la estrategia pasiva y la estrategia activa, después se explica la medida de dispersión a utilizar en el análisis y, finalmente, se describe el modelo de Black-Litterman que se implementó para combinar la estrategia pasiva con la activa. La sección III presenta los resultados del análisis, mientras que la sección IV presenta las conclusiones.

II. Metodología

A. Descripción de la estrategia pasiva

El presente trabajo busca demostrar que es posible utilizar la dispersión de corte transversal de los retornos como un indicador del tipo de estrategia a seguir (activa o pasiva) en un determinado período. Para alcanzar dicho objetivo, se consideró al índice DJIA como punto de partida para la estrategia pasiva, dado que se compone por las acciones más representativas de la bolsa de Estados Unidos. Las ponderaciones del DJIA están definidas por el precio de cada acción. En otras palabras, el índice se construye como un portafolio donde se compra 1 acción de cada compañía que lo compone. El índice está compuesto por 30 acciones de las compañías más grandes del país. Por lo tanto, la mayoría de los sectores se encuentran representados por este índice, con excepción de la industria de transporte que posee su propio índice (el Dow Jones Transportation Average).

Los criterios de selección de los componentes son:

1. La reputación de la compañía debe ser excelente. Es decir, incluye únicamente compañías que hayan demostrado un crecimiento sostenido a través del tiempo y que sean de interés al mayor número posible de inversionistas.
2. La compañía debe estar basada en Estados Unidos.
3. La mayor parte de los ingresos de las empresas que pertenecen al índice debe venir de Estados Unidos
4. Otra consideración es mantener una adecuada representación de los sectores de la economía

No existe un periodo determinado para el rebalanceo del índice, sino que los cambios en su composición se dan como respuesta al desarrollo de los mercados o cambios corporativos en las empresas. El nivel del índice esta determinado por la suma de los precios de cada acción que compone el índice, y luego dividido por un coeficiente para contrarrestar los efectos de los rebalanceos,

dividendos o *splits* de acciones.⁴

A pesar de ser unos de los índices de acciones más antiguos y conocidos en la industria, el DJIA ha sido sujeto de críticas por parte de algunos especialistas. En primer lugar, algunos argumentan que un índice compuesto por solo 30 acciones no puede ser una buena representación del mercado, y se inclinan por índices más diversificados como el índice S&P 500. La segunda crítica se refiere a su ponderación en base a precios, y no capitalización, lo que no refleja el verdadero tamaño de los componentes en el índice.⁵ Por el otro lado, aquellos en favor del DJIA sostienen que sigue siendo un índice representativo ya que incluye las compañías con mayor capitalización y más influyentes de Estados Unidos. Además, sumado al índice Dow para el sector de transporte logran tener participación en las principales industrias del país.⁶

Durante el periodo bajo análisis (1991 a 2019), el DJIA ha tenido varios cambios en sus componentes. No sólo por la decisión de retirar ciertas compañías, sino porque algunos de sus componentes se fusionaron o vendieron a otras compañías.⁷ Esto dificulta obtener las series de retornos históricos para cada componente durante todo el período de análisis. Dado que el presente estudio se basa en data histórica, se seleccionó un grupo de 30 compañías (detalladas en el apéndice) que posean data histórica para el periodo entre 1987 y 2019, y, mayormente, pertenecieran al índice durante al menos la mitad del periodo bajo análisis. Utilizando la misma ponderación por precios del índice DJIA, se creó un índice proxy del DJIA (referido como el Índice en la sección III) a partir de las 30 compañías seleccionadas.

⁴Fuente: <www.spglobal.com/spdji/en/indices/equity/dow-jones-industrial-average/#overview>

⁵Ganti, Akhilesh (20 de julio del 2020). Dow Jones Industrial Average (DJIA), *Investopedia*

⁶Kosakowski, Paul (14 de noviembre del 2019). Why The Dow Matters, *Investopedia*

⁷Para ver la composición histórica del DJIA dirijase a <us.spindices.com/indexology/djia-and-sp-500/the-changing-djia>

Figura 1. Retorno acumulado histórico



La figura 1 muestra el comportamiento histórico del índice proxy y el DJIA, en donde se aprecia que el proxy es una buena aproximación del DJIA. El índice proxy muestra un peor rendimiento durante la crisis financiera del 2001, pero logra mejores rendimientos durante la crisis financiera del 2008. Esto puede deberse a que la composición del índice proxy tiene mayor ponderación en el sector de tecnología y menor ponderación en el sector financiero que el DJIA.

La data de precios históricos para el índice DJIA y las acciones seleccionadas ha sido obtenida de Yahoo Finance.⁸

⁸<finance.yahoo.com>

B. Descripción de la estrategia activa

Una vez seleccionado el benchmark pasivo, el siguiente paso es definir la estrategia activa a implementar durante los periodos de alta dispersión. Para el presente trabajo se utilizó la metodología propuesta por Markowitz (1952), donde presenta una optimización de media-varianza (MVO por sus siglas en inglés) para estimar las ponderaciones óptimas de un portafolio de activos. Esta metodología busca obtener la composición que minimice la volatilidad del retorno del portafolio y, a su vez, alcance un determinado retorno objetivo. Implícitamente, la optimización busca maximizar el *Sharpe Ratio*, definido como el exceso de retorno de un activo sobre el activo libre de riesgo dividido por la volatilidad del activo.

El problema de optimización es el siguiente:

$$\begin{aligned} \text{Min}_w \quad & w^T \Sigma w - \lambda \mu^T w \\ \text{sujeto a} \quad & w^T \mathbf{1} = 1 \end{aligned}$$

Donde w es un vector $n \times 1$ de ponderaciones, Σ es la matriz $n \times n$ de covarianzas, λ es el coeficiente de aversión al riesgo, μ es un vector $n \times 1$ de retornos esperados y $\mathbf{1}$ es un vector $n \times 1$ de unos.

La optimización anterior es un simple problema cuadrático que se puede resolver mediante el multiplicador de Lagrange. Como referencia, se define el portafolio resultante de esta optimización como portafolio MVO Long-short.

Sin embargo, en la práctica se suelen incluir restricciones adicionales dependiendo de la clase de portafolio (portafolio personal, fondo de pensión, entre otros). Un ejemplo común es la restricción sobre las posiciones de venta (posición *short*) para evitar el apalancamiento financiero (portafolio MVO Long). De ser posible el apalancamiento, este suele estar delimitado a cierto nivel para evitar que el portafolio manager asuma demasiado riesgo en la inversión (portafolio Long-short).

Un problema que presenta la optimización media-varianza es la sensibilidad a los retornos y matriz de covarianzas utilizados. Un pequeño cambio en los inputs puede generar resultados muy diversos. Por esta razón, para limitar la sensibilidad de los resultados se consideran dos portafolios con ciertas restricciones adicionales para implementar la estrategia activa. Para el primer caso, se utiliza una optimización media-varianza long restringida, sin posibilidad de posiciones *short* y con ponderaciones entre 1.0 % y 50.0 %. Para el segundo caso, se utiliza una optimización media-varianza long-short, con ponderaciones entre -50.0 % y 50.0 %. Límites a las posiciones *short* o altamente concentradas en pocas compañías son restricciones a las que muchos portafolios managers suelen estar sujetos. Por esta razón, para el presente trabajo se consideraron estas restricciones adicionales.

Como referencia, en las siguientes secciones del trabajo se refiere al portafolio MVO Long y MVO Long-short como la versiones con las restricciones adicionales mencionadas en el párrafo anterior.

C. Medidas de dispersión

Como se mencionó anteriormente, el presente estudio tiene como objetivo determinar el papel que juega la dispersión de los retornos en el rendimiento del portafolio. Por lo tanto, primero se debe definir la medida de dispersión a utilizar para probar esta hipótesis. Para propósitos del análisis, se utiliza el desvío estándar de corte transversal de los retornos para cada punto en el tiempo. Sea $R_{i,t}$ el retorno mensual del activo i en un tiempo t , y \bar{R}_t el retorno promedio del total de k instrumentos en el portafolio. Siguiendo la definición de Von Reibnitz (2017), la dispersión de corte transversal es:

$$Disp_t = \sqrt{\frac{1}{k-1} \sum_{i=1}^k (R_{i,t} - \bar{R}_t)^2} \quad (1)$$

Cabe destacar que al momento de tomar la decisión de inversión el portafolio manager no dispone

de información sobre la dispersión futura, por lo que debe basar su decisión en predicciones. Existen varias soluciones para este problema. La primera sería estimar una predicción de los retornos futuros y calcular la dispersión sobre estas predicciones. Sin embargo, bajo este enfoque, la precisión de las predicciones juega un doble rol: indica el momento de cambiar de la estrategia pasiva a la activa, así como la ponderación que se le otorga a cada activo. El segundo enfoque utiliza valores recientes de la dispersión de corte transversal. Si la autocorrelación de la dispersión histórica es alta, entonces el valor actual puede ser una buena aproximación del valor en el siguiente período. Von Reibnitz (2017) encuentra una alta autocorrelación (0.68) en la medida de dispersión de los retornos para los componentes del índice S&P 500, lo que sugiere que el portafolio manager no necesita predecir la dispersión futura ya que puede usar el nivel actual. La tercera opción es identificar algún aproximado de la dispersión futura que no esté ligado a las predicciones de los retornos. Por ejemplo, una medida de dispersión para un universo de acciones podría ser la diferencia entre un nivel de retorno alto y uno bajo (e.g., percentil 90 % and 10 %) basados en los rendimientos pasados que Kenneth French utilizó para calcular sus portafolios de *momentum*.

D. Modelo de Black-Litterman

La predicción de los retornos es un parámetro clave en el modelo de optimización de media-varianza de Markowitz (1952), y cambios pequeños en su valor puede generar grandes cambios en los resultados. Por dicha razón, la estimación de retornos es una de las tareas más relevantes de un analista financiero. La forma más sencilla es usar los retornos históricos como referencia, pero existen dos principales desventajas de este enfoque. En primer lugar, los errores estándar de las medias estimadas señalan que el nivel de confianza es bajo, por lo que las estimaciones no resultan muy confiables. En segundo lugar, asumiendo que se construyen intervalos de confianza apropiados, la probabilidad de que la historia se repita otra vez suele ser baja. Por dichas razones, el resultado

de una optimización de media-varianza usando estimados históricos es muy poco estable.

El modelo de Black-Litterman empieza tomando la composición del benchmark, y luego el analista estima el grado de desvío de esta composición inicial en el futuro. Los dos parámetros que se toman en cuenta para determinar el grado de desvío son (i) la confianza del analista en sus predicciones y (ii) la incertidumbre en la composición inicial del benchmark.

En su trabajo original (Black and Litterman (1991) y Black and Litterman (1992)), los autores utilizan las ponderaciones basadas en la capitalización de mercado como benchmark, consistente con la teoría del portafolio de equilibrio del modelo *capital asset pricing model* (CAPM por sus siglas en inglés). Sin embargo, en el presente estudio se utiliza un portafolio ponderado por el precio de cada acción, como lo es el índice DJIA.

De He and Litterman (2002) se asume que los retornos de una economía con n activos tienen una distribución normal:

$$r \sim N(\mu, \Sigma) \quad (2)$$

donde r es un vector $n \times 1$ de retornos de activos, μ es un vector $n \times 1$ de retornos medios, and Σ es una matriz $n \times n$ de covarianzas. En este escenario μ no es constante, pero se distribuye normal con media Π y varianza $\tau\Sigma$. Un escalar arbitrario τ nos permite ir de una medida de varianza de retornos a una medida de varianza de sus medias. Por lo general es menor a uno, y se define como el inverso del número de observaciones de retornos históricos.

Asumiendo un parámetro de aversión al riesgo λ , el punto óptimo de media-varianza es:

$$w_b = \frac{1}{\lambda} \Sigma^{-1} \Pi \quad (3)$$

En donde w_b es un vector $n \times 1$ de ponderaciones en el benchmark. Es posible invertir esta fórmula

para encontrar así la media implícita de los retornos esperados Π dado w_b :

$$\Pi = \lambda \Sigma w_b \quad (4)$$

El siguiente paso en el modelo de Black-Litterman es incorporar las expectativas del portafolio manager. En particular, el modelo asume que las k expectativas se expresan como:

$$P\mu \sim N(Q, \Omega) \quad (5)$$

Donde P es una matriz $k \times n$ de expectativas, Q es un vector $k \times 1$ de retornos provenientes de las expectativas de la matriz P , y Ω es una matriz $k \times k$ de covarianzas de las expectativas. Un caso particular se da cuando el portafolio manager tiene una expectativa de retorno medio para cada activo y su matriz de covarianzas esperada será proporcional a la actual matriz de covarianzas de los activos. En otras palabras, $P = I_n$ y $\Omega = k\Sigma$, donde I_n es una matriz identidad $n \times n$ y k es un escalar.

Citando nuevamente a He and Litterman (2002), los retornos esperados serán:

$$\mu_{BL} \sim N(\bar{\mu}, \bar{M}) \quad (6)$$

con:

$$\bar{\mu} = [(\tau\Sigma)^{-1} + P'\Omega^{-1}P]^{-1} [(\tau\Sigma)^{-1}\Pi + P'\Omega^{-1}Q] \quad (7)$$

y

$$\bar{M} = [(\tau\Sigma)^{-1} + P'\Omega^{-1}P]^{-1} \quad (8)$$

Dado lo anterior, la distribución de los retornos que se utiliza en la optimización de media-varianza

serán:

$$r \sim N(\bar{\mu}, \bar{\Sigma}) \quad (9)$$

en donde $\bar{\Sigma} = \Sigma + \bar{M}$. Aplicamos la ecuación (3), reemplazando Π con $\bar{\mu}$ para obtener las ponderaciones finales. En este caso, con $P = I_n$ y $\Omega = k\Sigma$, las ecuaciones (7) y (8) se transforman en:

$$\bar{\mu} = \frac{k}{\tau + k} \cdot \Pi + \frac{\tau}{\tau + k} \cdot Q \quad (10)$$

y

$$\bar{M} = \left(\frac{1}{\tau} + \frac{1}{k} \right)^{-1} \cdot \Sigma \quad (11)$$

o, alternativamente:

$$\bar{\mu} = \Pi + \frac{\tau}{\tau + k} \cdot (\Pi - Q) \quad \bar{M} = \frac{\tau}{\tau + k} \cdot k \cdot \Sigma$$

Entonces, para un valor fijo de $\tau > 0$, se tiene $k \rightarrow 0$, i.e., una confianza alta en las expectativas del analista, $\bar{\mu} \rightarrow Q$ y $\bar{M} \rightarrow 0_n$. Esto es equivalente a usar la optimización de media-varianza con las expectativas del analista como el vector de retornos esperados. Por otro lado, tenemos que si $k \rightarrow \infty$, i.e., baja confianza, $\bar{\mu} \rightarrow P$ y $\bar{M} \rightarrow \tau\Sigma$. Cabe destacar, que esta distribución no necesariamente lleva a las ponderaciones originales del benchmark w_b , ya que la nueva matriz de covarianzas es $\Sigma(1 + \tau)$ para reflejar la incertidumbre en el valor esperado del retorno medio de cada activo.

E. Predicciones semi-perfectas

En la sección anterior se describió el modelo Black-Litterman que permite a los portafolio managers incorporar sus expectativas como una desviación de los retornos esperados implícitos por

las ponderaciones del benchmark. En la sección II.A, se describió el modelo a utilizar como punto de partida. Dado que el rebalanceo del benchmark solo depende del precio actual de la acción, este no requiere un pronóstico de los retornos futuros.

La predicción de los movimientos del mercado es una parte fundamental del trabajo de un analista financiero, por lo que existen diversas metodologías para predecir retornos futuros. Dado que el presente trabajo no se enfoca en metodologías de predicción de retornos, pero dichas predicciones forman un papel fundamental para el análisis, se adaptó la metodología de Grinold and Kahn (2000) para diversos activos y así crear predicciones artificiales basadas en las habilidades del portafolio manager. Dicha habilidad se captura con el coeficiente de información (IC por sus siglas en inglés) que se define como la correlación de las predicciones con los retornos reales del período siguiente. De esta manera, existe neutralidad respecto a la metodología de predicción y se toma en cuenta únicamente la precisión de dichas predicciones.

Entonces, sea r_t un vector aleatorio de retornos $k \times 1$ de los k activos, IC el coeficiente de información objetivo, Σ la matriz de covarianzas, $k \times k$, con una descomposición de Cholesky LL^T , y z_t un vector $k \times 1$ de variables aleatorias independientes distribuidas normalmente. Definimos el vector de predicciones α_t como:

$$\alpha_t = IC \left[IC \cdot r_t + \sqrt{1 - IC^2} \cdot z_t \cdot L^T \right] \quad (12)$$

Es fácil verificar que estos pronósticos tienen una correlación igual al IC con los retornos actuales r_t . Teniendo lo siguiente:

$$Var(\alpha_t) = IC^4 \cdot \Sigma + IC^2(1 - IC^2) \cdot LL^T = IC^2 \cdot \Sigma$$

$$Cov(\alpha_t, r_t) = IC^2 \cdot \Sigma$$

Lo que significa que para cada activo i , tenemos $Corr(\alpha_{t,i}, r_{t,i}) = IC$. Esta metodología no solo permite llevar a cabo la estrategia sin depender de ningún modelo particular de predicción, sino que también permite testear la sensibilidad del modelo a las habilidades de predicción del portafolio manager. Una desventaja es que se está asumiendo que el analista cuenta con modelos de predicción que le otorgan un IC constante a través del tiempo, y para todos los activos.

III. Resultados

A. Rendimiento del Índice y los portafolios MVO

Se comenzó realizando una comparación entre el rendimiento del benchmark (el Índice) y los portafolios MVO Long y MVO Long-short, ambos restringidos, a lo largo del período de análisis. Para este trabajo se utilizaron los retornos medios y matriz de covarianzas con una ventana móvil de 60 meses. Se excluyó del análisis el portafolio MVO Long sin restricción, debido su composición altamente concentrada entre pocas acciones, y el portafolio MVO Long-short sin restricciones, debido a su composición altamente apalancada. En el apéndice se muestran los resultados para estos dos portafolios.

El siguiente cuadro I muestra los retornos medios y volatilidad mensuales anualizados para cada estrategia, así como su *Sharpe Ratio*.⁹

Cuadro I. Rendimiento del Índice contra los portafolios MVO

Portafolio	Retorno (%)	Volatilidad (%)	<i>Sharpe Ratio</i>
Índice	7.86	14.09	0.38
MVO (long)	10.32	14.38	0.55
MVO (long-short)	5.42	42.34	0.07

Analizando el rendimiento de los portafolios desde junio de 1991 a diciembre de 2019, se observa

⁹Para el *Sharpe Ratio* se utilizó la tasa de las T-Bills a tres meses obtenidas de la FRED como activo libre de riesgo

que el portafolio MVO Long obtuvo el mayor *Sharpe Ratio*, seguido del Índice, y por último el portafolio MVO Long-short. Del cuadro anterior se observa que el portafolio MVO Long obtiene mejores retornos que el Índice con un riesgo similar, mientras que el MVO Long-short logra retornos menores al MVO Long pero con una volatilidad tres veces mayor.

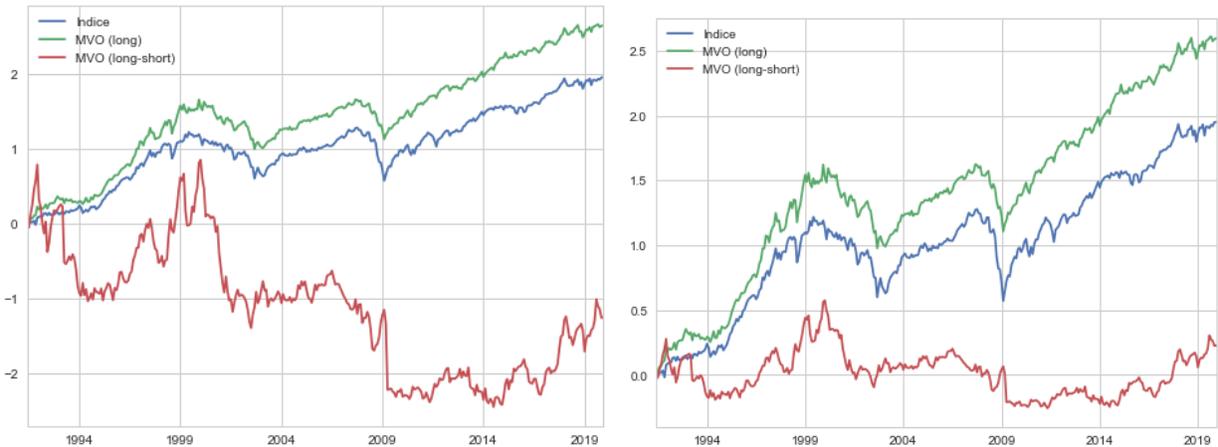
Si bien el portafolio MVO Long-short debería obtener el mayor *Sharpe Ratio*, dado que es posee menos restricciones que el MVO Long, no es el caso para el periodo de análisis. Dado que la optimización de media-varianza es muy sensible a los inputs, si los retornos y matriz de covarianzas estimados difieren de los realizados el rendimiento del portafolio no sería bueno. En este caso, los retornos medios históricos y matriz de covarianzas histórica no proporcionan una buena proyección de los retornos y volatilidad futuros, lo que se ve reflejado en el rendimiento del portafolio. Además, la restricción a posiciones *short* pareciera ser beneficiosa en este caso, dado que restringe la posibilidad de tomar mayores riesgos basados en proyecciones pobres.

Es también importante aclarar que no se han considerado costos de transacción. Dado que los portafolios MVO son rebalanceados mensualmente, la existencia de costos de transacción tendrían un impacto negativo en el rendimiento de los portafolios. A pesar de que el portafolio MVO Long es el de mejor performance, esto podría no ser cierto si se tomaran los retornos netos de costos.

La figura 2 muestra los retornos acumulados históricos para los tres portafolios. El gráfico de la izquierda está estimado con los retornos reales del cada portafolio, mientras que el de la derecha está estimado con los retornos ajustados de tal forma que los tres portafolios tengan la misma volatilidad histórica (en este caso igual a la volatilidad del Índice).

En los gráficos anteriores se observa que el rendimiento del portafolio MVO Long fue sostenidamente superior a la del Índice, y acentuándose la diferencia después de la crisis financiera del 2008. Por otro lado, el rendimiento del portafolio MVO Long-short es más errático durante la mayor parte del periodo de análisis. En interesante observar que el portafolio MVO Long-short se beneficia del

Figura 2. Retorno acumulado histórico



apalancamiento durante la crisis financiera del 2001, donde obtiene retornos superiores a los otros dos portafolios, debido a los retornos negativos observados para la mayoría de las compañías. Sin embargo, los retornos negativos acentúan el apalancamiento del portafolio, lo que genera un rendimiento negativo durante las posteriores recuperaciones del mercado. El apalancamiento también parece potenciar las pérdidas durante la crisis financiera del 2008.

Figura 3. *Sharpe Ratio* móvil de 60 meses



La figura 3 muestra el *Sharpe Ratio* histórico de cada portafolio usando una ventana móvil de 60 meses. Aquí se observa que el Índice y portafolio MVO Long obtienen ratios similares a lo largo de todo el período, excepto los últimos años donde el MVO Long es superior. En línea con los resultados anteriores, los ratios para el portafolio MVO Long-short son menores para la mayoría

de los años.

Para apreciar mejor la diversificación, rebalanceo y apalancamiento de los distintos portafolios, la figura 11 del apéndice muestra la ponderación promedio para un grupo de compañías seleccionadas.

B. MVO con predicciones semi-perfectas

En esta sección se muestra el rendimiento de los portafolios con predicción semi-perfecta basados en la metodología descrita en la sección II.E. Estos portafolios fueron construidos mediante una optimización de media-varianza utilizando las predicciones de los retornos futuros, pero con la matriz de covarianzas histórica móvil de 60 meses (la misma utilizada para estimar los resultados de la sección III.A). Como se mencionó previamente, para evitar portafolios concentrados o con alto apalancamiento alto se utilizaron las optimizaciones de media-varianza long y long-short restringidas.

En el siguiente cuadro se presenta el resumen del rendimiento de los portafolios con predicción semi-perfecta para distintos coeficientes de información implícitos en la predicción de los retornos.

Cuadro II. Rendimiento de los portafolios con predicción semi-perfecta

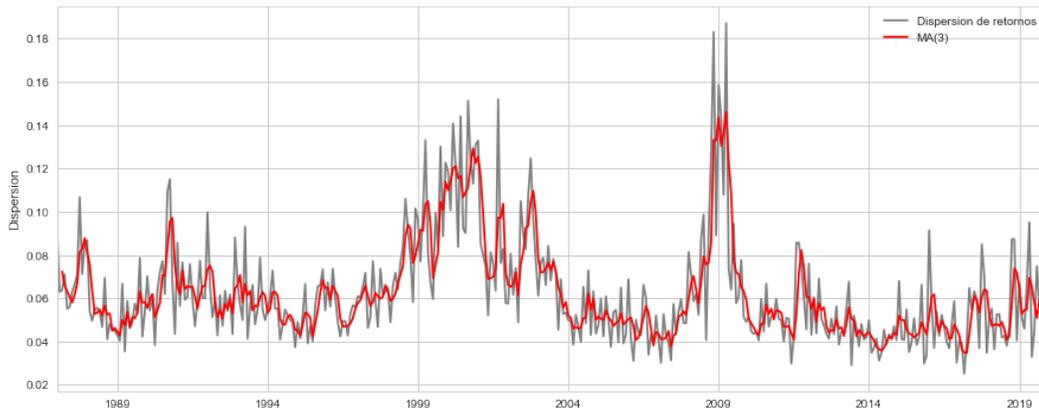
IC	Long			Long-short		
	Retorno (%)	Volatilidad (%)	<i>Sharpe Ratio</i>	Retorno (%)	Volatilidad (%)	<i>Sharpe Ratio</i>
0.05	10.96	11.36	0.75	18.97	12.06	1.36
0.1	14.40	12.52	0.95	42.76	19.20	2.09
0.25	30.76	15.83	1.79	152.69	35.24	4.26
0.5	57.79	20.11	2.76	363.23	58.86	6.14
0.75	83.18	21.19	3.82	572.08	80.26	7.11

Del cuadro II se puede observar una relación fuertemente positiva entre el rendimiento del portafolio y el coeficiente de información. Como era esperable, un coeficiente más alto implica mejores predicciones de los retornos, y, por lo tanto, la optimización media-varianza se acerca al objetivo de maximizar el *Sharpe Ratio*. Al obtener mejores predicciones también hace mejor uso del apalancamiento, y así la estrategia long-short supera a la estrategia long. A medida que el coeficiente baja, las predicciones de los retornos incluyen mayor ruido y, por lo tanto, el apalancamiento reduce el rendimiento.

C. Análisis de la dispersión de los retornos

Como se describió en la sección II.C, la medida de dispersión seleccionada para la estrategia es la dispersión de corte transversal, estimada como el desvío estándar del retorno mensual de las 30 compañías que componen el índice proxy del DJIA desde enero de 1987 a diciembre de 2019. La figura 4 muestra la serie histórica de dispersión de los retornos junto con su media móvil de 3 meses.

Figura 4. Dispersión de los retornos histórica



El siguiente cuadro muestra algunos estadísticos para ambas series, incluyendo el coeficiente de autocorrelación de orden 1. El coeficiente de autocorrelación de 0.57 muestra una persistencia similar a la obtenida por Von Reibnitz (2017) para la dispersión de los retornos mensuales de los

componentes del índice S&P500 (coeficiente de 0.68 para el periodo entre 1972 y 2013). Es posible que al utilizar una menor cantidad de compañías y tener menor diversificación por sector la autocorrelación observada sea levemente menor que para los componentes del índice S&P500. En la sección V.D del apéndice se muestra los resultados de la regresión AR(1) para ambas series, incluyendo el gráfico de autocorrelación y autocorrelación parcial para la dispersión de corte transversal.

Cuadro III. Estadísticos para la dispersión de los retornos y su media móvil

	Media (%)	Mediana (%)	Desvío estandar (%)	$\rho(t-1, t)$
Dispersión del retorno	6.23	5.58	2.46	0.5667
Media móvil (MA(3))	6.22	5.66	2.01	0.9368

Para utilizar la medida de dispersión como factor de *timing*, la dispersión estimada en un período se considera la predicción de la dispersión en el período siguiente. Por lo tanto, para el éxito de la estrategia es fundamental que exista una persistencia alta en la dispersión de un período al otro. Es por esta razón que se optó por utilizar la media móvil como medida de dispersión. Como muestra la tabla III, suavizar la serie genera una mayor autocorrelación en la dispersión.

Cuadro IV. Matriz de transición de 2 estados

	Dispersión de corte transversal	
	Estado 1	Estado 2
Estado 1	0.679	0.321
Estado 2	0.325	0.675

	Media móvil (MA(3))	
	Estado 1	Estado 2
Estado 1	0.862	0.138
Estado 2	0.142	0.858

Cuadro V. Matriz de transición de 3 estados

	Dispersión de corte transversal		
	Estado 1	Estado 2	Estado 3
Estado 1	0.466	0.344	0.191
Estado 2	0.382	0.374	0.244
Estado 3	0.160	0.275	0.565

	Media móvil (MA(3))		
	Estado 1	Estado 2	Estado 3
Estado 1	0.815	0.185	0.000
Estado 2	0.189	0.667	0.144
Estado 3	0.000	0.153	0.847

Para la estrategia no se utiliza la serie de dispersión directamente, sino una medida para identificar los períodos de alta y baja dispersión. Para ello, se dividió cada estimación mensual en estados o regímenes basados en su correspondiente percentil histórico.

Primero se dividió la serie en dos estados, dispersión baja (estado 1) y dispersión alta (estado 2), basado en si la dispersión mensual se encontraba sobre o debajo de la mediana histórica. Para testear la persistencia de cada estado se procedió a estimar la matriz de transición de la serie de tiempo. El cuadro IV muestra la matriz de transición para la serie de dispersión con dos estados, donde se observa que ambos estados son persistentes y en línea con los resultados obtenidos anteriormente.

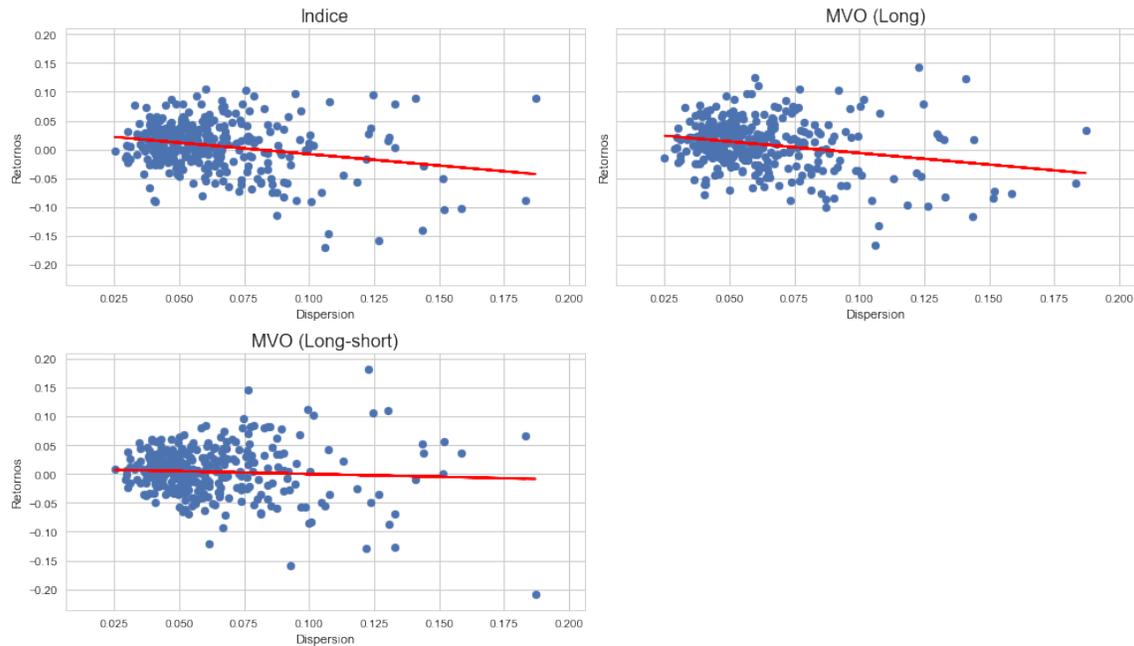
Luego se dividió la dispersión en tres estados: estado 1 donde la dispersión es menor al percentil 1/3 (dispersión baja), estado 2 donde la dispersión es mayor al percentil 1/3 y menor al percentil 2/3 (dispersión media), y estado 3 donde la dispersión es mayor al percentil 2/3 (dispersión alta). El cuadro V muestra la matriz de transición para la serie de dispersión con tres estados. Se puede observar que los estados de baja y alta dispersión presentan alta persistencia, pero no tanto el estado de dispersión media. En la figura V.E del apéndice se muestran las transiciones de estado para la dispersión con dos y tres estados.

La media móvil de tres meses fue seleccionada como la medida de dispersión de la estrategia dado que posee una alta persistencia, y además no representa una serie demasiado suavizada como para reducir su capacidad de predicción. También se optó por usar el modelo de tres estados, dado que presenta la mayor estabilidad para el estado de dispersión alta. Estos resultados están en línea con lo obtenido por Von Reibnitz (2017), donde el quintil con dispersión más alta era el estado de dispersión más estable.

C.1. Relación entre la dispersión y el retorno de los portafolios

Las figuras 5 y 6, junto con los cuadros VI y VII, muestran la relación entre la serie de dispersión de corte transversal y el retorno de los tres portafolios utilizados en la sección III.A y los portafolios con predicción semi-perfecta de la sección II.E.

Figura 5. Retornos contra dispersión: Índice y portafolios MVO



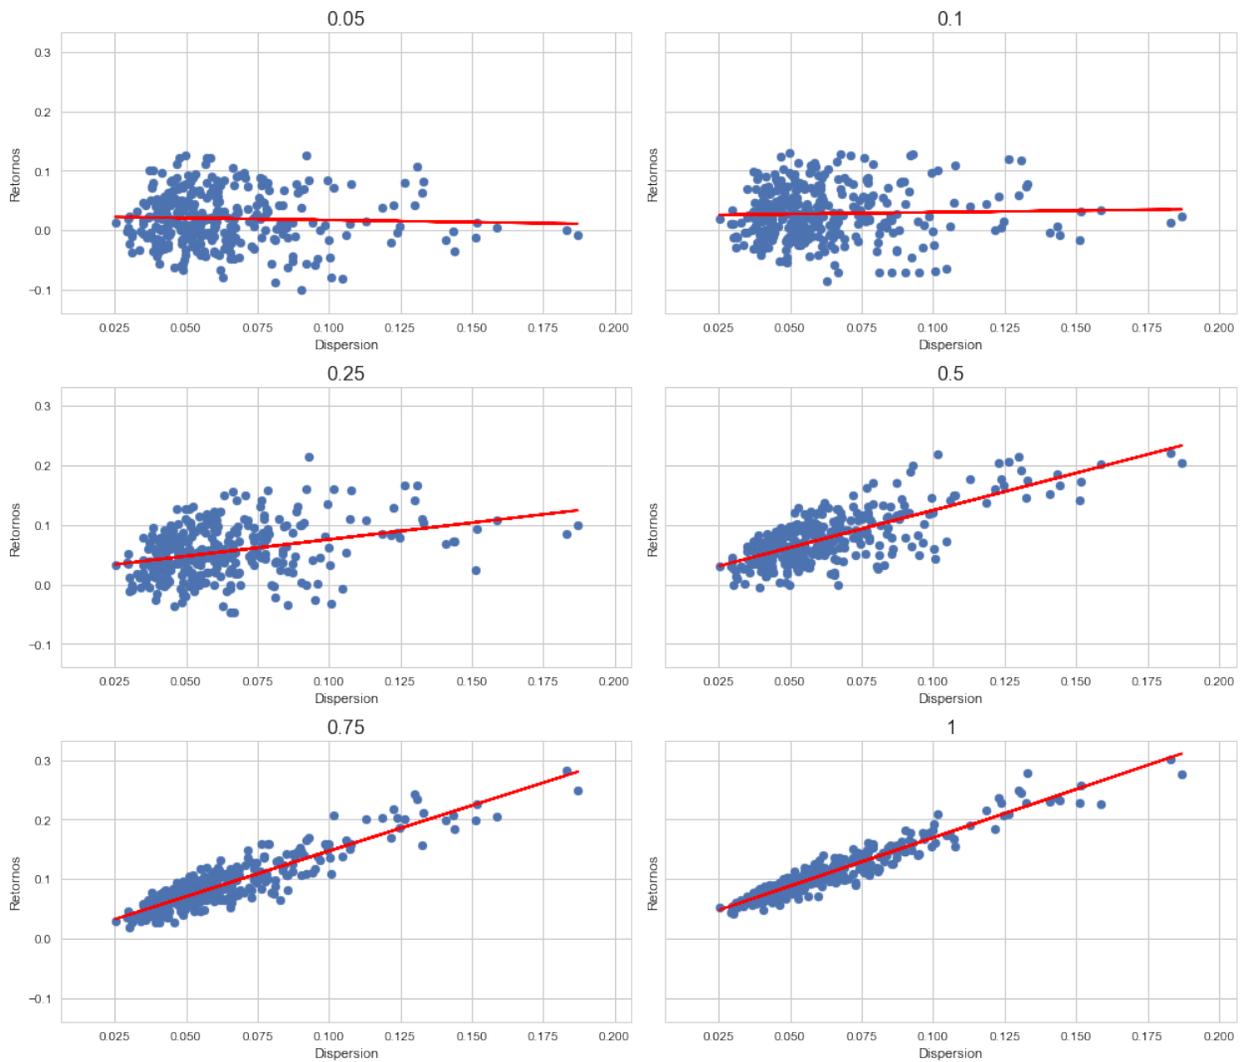
Cuadro VI. Regresión lineal de los retornos contra dispersión: Índice y portafolios MVO

Portafolio	Coefficiente ($Disp_t$)	t -stat	Coefficiente ($Disp_{t-1}$)	t -stat
Índice	-0.371	-2.720	-0.089	-0.834
MVO (long)	-0.383	-3.072	-0.159	-1.483
MVO (long-short)	-0.210	-0.573	-0.226	-0.875

La figura 5 muestra la regresión lineal entre la dispersión y los retornos del Índice y los portafolios MVO, que parece ser levemente negativa para los tres casos. En el cuadro VI se muestran los coeficientes de la regresión junto con sus estadísticos t (t -stat). Del cuadro podemos observar que el coeficiente de la regresión es estadísticamente significativo para el Índice y el portafolio MVO Long. Esto podría ser el resultado de las crisis financieras de 2001 y 2008, ya que presentan alta dispersión y retornos fuertemente negativos para las acciones. Sin embargo, cuando consideramos la regresión con la dispersión rezagada 1 periodo, los coeficientes son mas cercanos a cero y no son estadísticamente significativos. Esto podría indicar que los retornos de los portafolios no estarían afectados por la dispersión del período anterior.

La figura 6 muestra la regresión lineal entre la dispersión y los portafolios con predicciones semi-perfecta, basados en una optimización de media-varianza long-short restringida. En este caso, se observa una relación fuertemente positiva para los portafolios con IC alto (mayores a 0.25). Esto es esperable, dado que un mayor IC representa mejores predicciones y, por lo tanto, se traduce en mejores retornos en los períodos de alta dispersión. A medida que se reduce el IC, las predicciones son más ruidosas y la relación se hace mas débil hasta el punto de ser prácticamente cero.

Figura 6. Retornos contra dispersión: Portafolios con predicción semi-perfecta



Cuadro VII. Regresión lineal de los retornos contra dispersión: Portafolios con predicción semi-perfecta

IC	Coficiente ($Disp_t$)	t -stat	Coficiente ($Disp_{t-1}$)	t -stat
0.01	-0.074	-1.758	-0.037	-0.793
0.05	-0.060	-0.878	-0.031	-0.396
0.10	0.066	0.591	0.025	0.204
0.25	1.309	6.376	0.722	3.183
0.50	4.904	20.015	2.611	6.393
0.75	8.189	32.135	4.529	7.642
0.99	9.678	39.660	5.759	9.020
1.00	9.664	39.852	5.746	8.997

Esta relación positiva implica que es posible obtener mayores retornos en los periodos de alta dispersión. Esta conclusión resulta intuitiva, ya que aquellos portafolio managers que obtengan mejores predicciones podrán sacar máyores beneficios en los períodos de dispersión alta. El cuadro VII muestra los resultados de la regresión, donde se observa que los coeficientes son significativos en los portafolios con IC mayor a 0.1. Cuando se utiliza la dispersión con 1 rezago la relación no resulta tan fuerte, aunque sigue siendo positiva y significativa para portafolios con IC mayor a 0.1. Este resultado resulta fundamental, debido a que le impone a los portafolio managers un objetivo mínimo en su habilidad para predecir retornos. Para poder obtener mejores retornos en los períodos de dispersión alta los portafolio managers deben poder predecir retornos con un IC cercano a 0.25 o mayor.

D. Estrategia Black-Litterman usando la dispersión

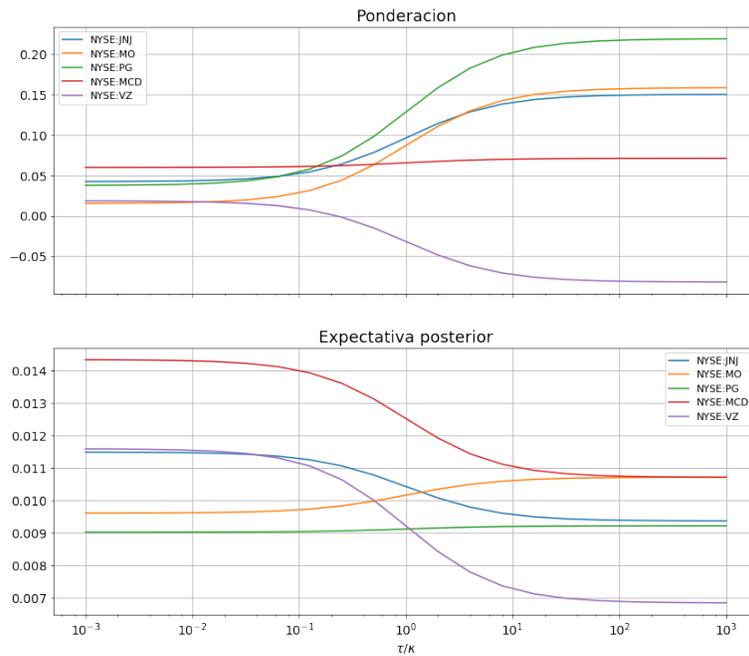
En esta sección se aplica el modelo de Black-Litterman, descrito anteriormente, el cual permite moverse de la composición de un benchmark pasivo a otra composición basada en las predicciones del portafolio manager.

Como se demostró en la seccion II.D, la relación entre los parámetros del modelo k y τ determinan el grado de desviación de los retornos esperados implícitos por la composición del benchmark

y las expectativas del portafolio manager.

Conforme τ aumenta en relación a k , la incertidumbre en los retornos medios futuros implícita en el benchmark se vuelve relativamente mayor que la incertidumbre que tiene el portafolio manager en sus expectativas. En caso de que el analista tenga una predicción individual para cada τ mayor, esto implica expectativas posteriores similares a la de portafolio manager y viceversa. Para entender mejor cómo la relación entre τ and k impacta las expectativas posteriores y, en consecuencia, la composición del portafolio, la figura 7 muestra los retornos esperados y las resultantes ponderaciones para diferentes niveles de τ/k , de 10^{-3} a 10^3 . Este ejercicio es similar al realizado por Haesen, Hallerbach, Markwat, and Molenaar (2017) para un portafolio construido mediante paridad de riesgo.

Figura 7. Black-Litterman - sensibilidad τ/k



La metodología que se sigue en el presente trabajo evita que el portafolio manager deba escoger el nivel de incertidumbre en sus estimaciones k . En cambio, se propone una selección de k basada en la medida de dispersión. En la sección III.C se define la dispersión de corte transversal, y en la

sección III.C se estudió su persistencia y se dividió la series en dos estados (alta y baja).

Debido a que el objetivo es aplicar una estrategia activa en períodos de alta dispersión, se le otorgan diferentes valores k a cada estado o al ratio τ/k , dado que se asume que τ se mantiene constante. Se utilizan valores pasados de dispersión para evitar sesgos a futuro.

Mejorar los rendimientos del benchmark puede deberse únicamente a buenas predicciones, independientemente del momento en el que esas predicciones fueron utilizadas. Por lo tanto, sería inconsistente comparar el rendimiento del benchmark con los obtenidos por los portafolios con predicción semi-perfecta, especialmente para aquellos que tienen un IC muy alto.

Para probar que la dispersión de corte transversal ayuda a identificar los momentos en los que una gestión activa agrega valor, se comparó el retorno del modelo Black-Litterman basado en la dispersión con el de un modelo Black-Litterman aleatorio. Mientras que el modelo Black-Litterman basado en la dispersión de corte transversal los estados de τ/k se seleccionan de acuerdo a la medida de dispersión, en el modelo Black-Litterman aleatorio esos mismos estados se permutan de manera aleatoria. De esta forma, se asegura que se utilicen las predicciones de retornos futuros para un mismo número de períodos en ambas estrategias. Sin embargo, si la hipótesis presentada es correcta, el modelo Black-Litterman basado en la dispersión debería generar mejores retornos que la aleatoria dado que las predicciones usadas en la primera deben ayudar a mejorar el rendimiento.

Los cuadros VIII y IX muestran un comparativo del rendimiento de la estrategia basada en la dispersión y la estrategia aleatoria. Para implementar la estrategia primero se dividió la serie de dispersión en tres estados, pero solo se consideró un estado de dispersión baja y uno de dispersión alta como medida de *timing*. En otras palabras, se considera estado de dispersión alta si la dispersión es mayor al percentil 2/3, y dispersión baja si es menor al percentil 2/3. Esto genera solo dos valores extremos para el ratio τ/k , como se muestra en la figura 7. Esta estrategia implica que el portafolio manager utiliza la composición del benchmark (en este caso el Índice) en los estados de dispersión

baja, mientras que en los períodos de dispersión alta la composición proviene de una optimización de media-varianza utilizando sus predicciones de los retornos.

A continuación se muestra el rendimiento de la estrategia para distintos valores del coeficiente de información, como proxy de la habilidad de predicción del portafolio manager. La tabla VIII muestra los resultados utilizando una optimización media-varianza long restringida, mientras que el cuadro IX muestra los resultados para la versión long-short.

Cuadro VIII. Tres estados - Long

	Retorno (%)		Volatilidad (%)		<i>Sharpe Ratio</i>	
	Dispersión	Aleatorio	Dispersión	Aleatorio	Dispersión	Aleatorio
0.10	10.38	10.01	13.07	13.70	0.61	0.55
0.25	18.37	16.55	15.65	15.70	1.02	0.90
0.50	31.86	27.41	20.58	20.04	1.43	1.24
0.75	43.15	35.60	23.37	21.64	1.75	1.53

Cuadro IX. Tres estados - Long-short

	Retorno (%)		Volatilidad (%)		<i>Sharpe Ratio</i>	
	Dispersión	Aleatorio	Dispersión	Aleatorio	Dispersión	Aleatorio
0.10	23.22	22.08	15.57	17.07	1.33	1.15
0.25	70.96	61.57	33.70	32.34	2.04	1.83
0.50	168.32	135.42	75.65	64.25	2.20	2.07
0.75	264.87	208.01	117.49	96.66	2.24	2.13

El cuadro X muestra la diferencia entre los retornos medios de la estrategia con dispersión y la estrategia aleatoria para los distintos coeficientes de información. También se incluyen los estadísticos t basados en hipótesis de media cero.

Cuadro X. Diferencia de retornos entre la estrategia con dispersión y estrategia aleatoria

IC	Long		Long-short	
	Diferencia media (%)	t -stat	Diferencia media (%)	t -stat
0.10	0.37	0.40	1.13	0.40
0.25	1.83	1.19	9.40	1.38
0.50	4.46	1.67	32.90	2.15
0.75	7.55	2.14	56.85	2.40

Se observa que la estrategia long-short basada en la dispersión logra un mejor rendimiento que la estrategia con *timing* aleatorio, y la diferencia parece hacerse mas fuerte a medida que la habilidad de predicción sube. Por otro lado, la diferencia de retornos parece ser estadísticamente significativa para coeficientes de 0.5 o mayores. Para la estrategia long se observan resultados similares, aunque la diferencia pareciera ser más débil y solo significativa para coeficientes de información muy altos (mayores a 0.5).

La sección V.F en el apéndice muestra los resultados para el caso de dispersión en dos estados basados en la mediana histórica. Estos resultados parecen estar en línea a los obtenidos con 3 estados. Esto sugiere que la estrategia puede ser exitosa sin la necesidad de dispersión en un percentil alto como, por ejemplo, el quintil superior considerado por Von Reibnitz (2017).

Las figuras 8 y 9 muestran un comparativo entre los retornos acumulados para la estrategia basada en dispersión, la estrategia aleatoria, el Índice y el portafolio con predicción semi-perfecta. Los colores de fondo indican el estado de dispersión del período, siendo verde dispersión alta y azul dispersión baja.

Figura 8. Retorno acumulado de la estrategia Black-Litterman - Long

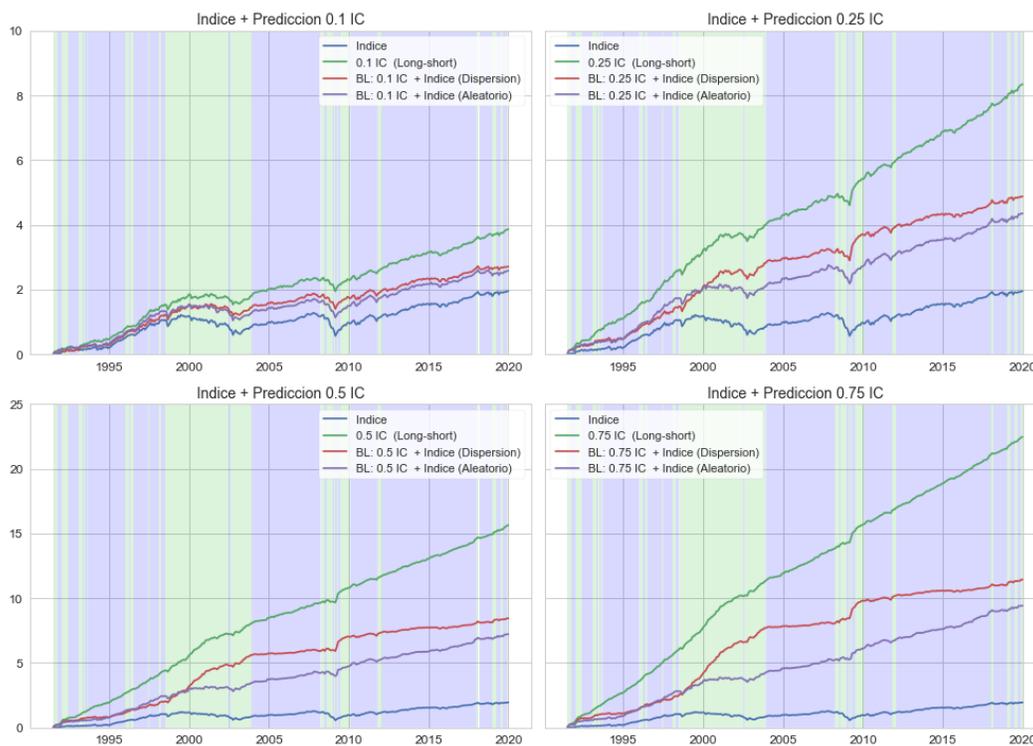
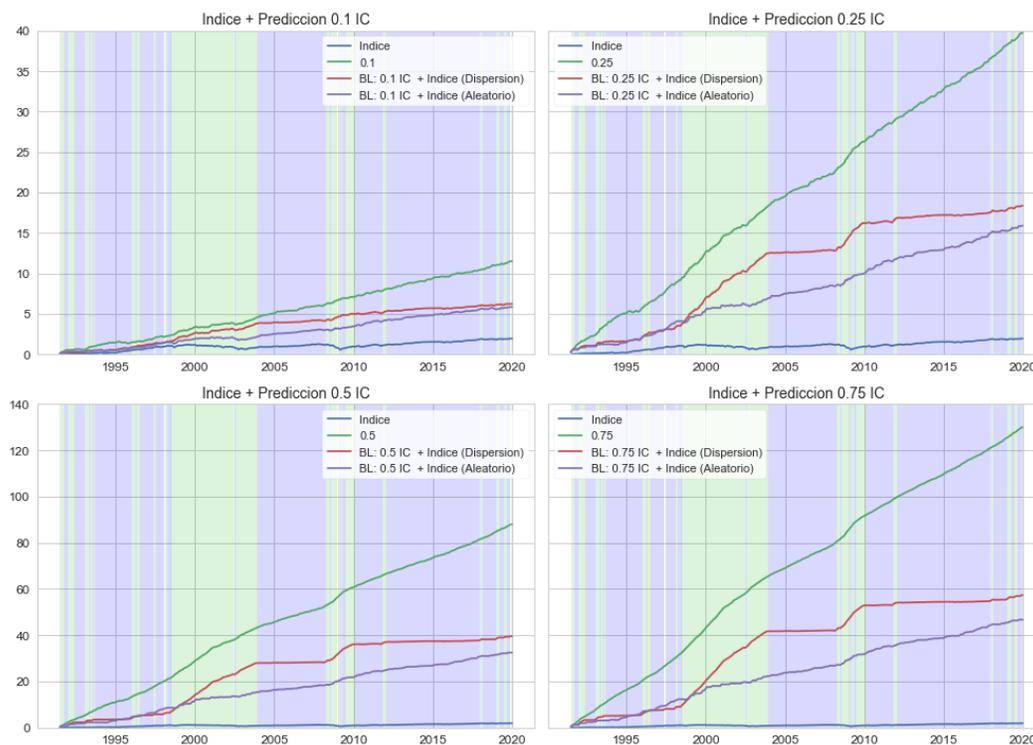


Figura 9. Retorno acumulado de la estrategia Black-Litterman - Long-short



IV. Conclusión

El presente estudio propone una metodología que busca mejorar los retornos de una estrategia pasiva por medio de incorporar apuestas activas en momentos en los que la dispersión de corte transversal sea alta. La idea de fondo es que cuando la dispersión de corte transversal es alta, una estrategia activa puede mejorar el rendimiento de una estrategia pasiva.

En la sección III.C se muestra, a través de una simple regresión, que el rendimiento de un benchmark pasivo no es impactado por el nivel de la dispersión de corte transversal rezagada un período.

Se construyó un portafolio activo usando diversos conjuntos de predicciones aleatorias de retornos que tengan un coeficiente de información constante a través de toda la muestra. Se demostró que el rendimiento tiene una relación positiva, y estadísticamente significativa, con la dispersión de corte transversal actual y rezagada, especialmente para niveles altos de IC. Posteriormente, se combinó una estrategia pasiva con una activa usando el modelo de Black-Litterman, en donde se utiliza el nivel de dispersión de corte transversal para determinar la incertidumbre relativa entre las expectativas pasivas y activas de cada activo.

Luego se comparó el rendimiento de la estrategia Black-Litterman basada en la dispersión y de Black-Litterman aleatoria. Por construcción, ambos portafolios usan las predicciones semi-perfectas en la misma proporción a lo largo de la muestra para que sus rendimientos sean comparables.

El análisis muestra que cuando las predicciones son suficientemente buenas, medidas por el IC, el modelo de Black-Litterman basado en la medida de dispersión genera mejores rendimientos que el modelo Black-Litterman aleatorio. Este resultado confirma la idea de que la dispersión puede utilizarse como factor de *timing* para la estrategia activa. Sin embargo, otra conclusión importante es que la estrategia requiere que el portafolio manager posea una buena capacidad para predecir retornos para que los resultados sean significativos.

V. Apéndice

A. Acciones seleccionadas para el índice proxy

Cuadro XI. Componentes del índice proxy

Ticker	Nombre	Retorno (%)	Volatilidad (%)	Sharpe Ratio
NYSE:MMM	3M Company	9.73	19.84	0.37
NYSE:AXP	American Express Company	11.93	28.69	0.33
NYSE:BA	The Boeing Company	11.10	27.67	0.31
NYSE:CAT	Caterpillar Inc.	13.34	30.46	0.36
NYSE:CVX	Chevron Corporation	10.12	19.28	0.40
NYSE:KO	The Coca-Cola Company	9.42	19.64	0.35
NYSE:DD	DuPont de Nemours, Inc.	6.79	31.72	0.14
NYSE:XOM	Exxon Mobil Corporation	8.48	16.45	0.36
NYSE:HD	The Home Depot, Inc.	14.78	24.98	0.49
NYSE:IBM	IBM	7.67	26.72	0.19
NasdaqGS:INTC	Intel Corporation	13.98	35.84	0.32
NYSE:JNJ	Johnson & Johnson	11.24	18.50	0.47
NYSE:JPM	JPMorgan Chase & Co.	13.38	30.75	0.35
NYSE:MCD	McDonald's Corporation	12.85	20.15	0.51
NYSE:MRK	Merck & Co., Inc.	8.64	24.50	0.25
NasdaqGS:MSFT	Microsoft Corporation	17.77	29.82	0.51
NYSE:PFE	Pfizer Inc.	10.15	21.86	0.35
NYSE:PG	The Procter & Gamble Company	11.05	19.40	0.44
NYSE:RTX	Raytheon Technologies Corporation*	13.46	22.87	0.48
NYSE:VZ	Verizon Communications Inc.	8.20	21.46	0.27
NYSE:WMT	Walmart Inc.	9.88	21.60	0.34
NYSE:DIS	The Walt Disney Company	10.57	24.78	0.33
NYSE:GE	General Electric Company	4.79	26.45	0.09
NYSE:T	AT&T Inc.	8.31	21.86	0.27
NYSE:BAC	Bank of America Corporation	6.96	37.43	0.12
NYSE:HPQ	Hewlett-Packard Company	9.08	34.33	0.19
NYSE:MO	Altria Group, Inc.	12.85	25.34	0.41
NYSE:HON	Honeywell International Inc.	13.34	28.28	0.38
NasdaqGS:GT	Goodyear Tire and Rubber Company	1.97	43.00	-0.01
NYSE:FL	Foot Locker, Inc.	2.55	42.34	0.00

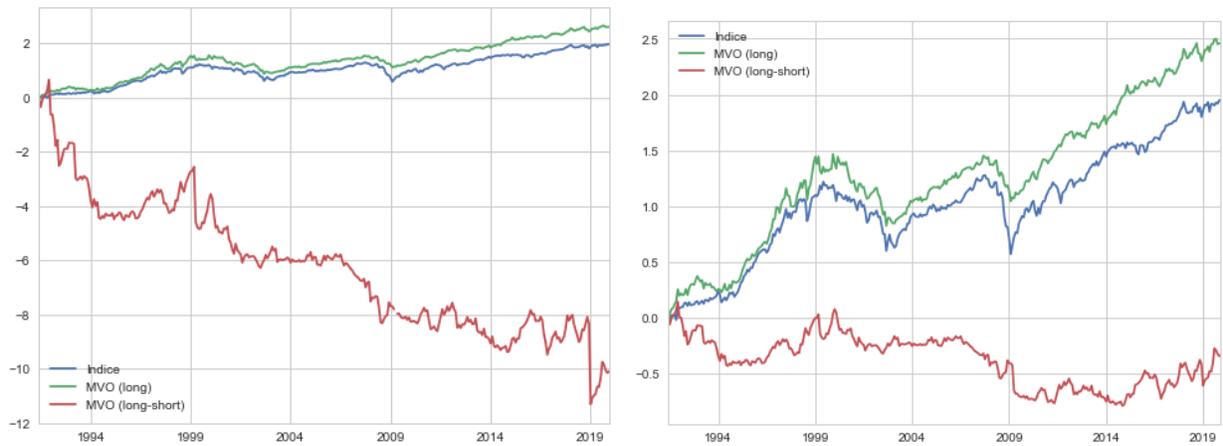
*Previamente denominada United Technologies Corporation

B. Rendimiento del potafolio MVO sin restricciones

Cuadro XII. Rendimiento del Índice contra los portafolios MVO sin restricciones

Portafolio	Retorno (%)	Volatilidad (%)	Sharpe Ratio
Índice	7.86	14.09	0.38
MVO (long)	10.22	14.96	0.52
MVO (long-short)	-0.78	76.82	-0.04

Figura 10. Retorno acumulado histórico

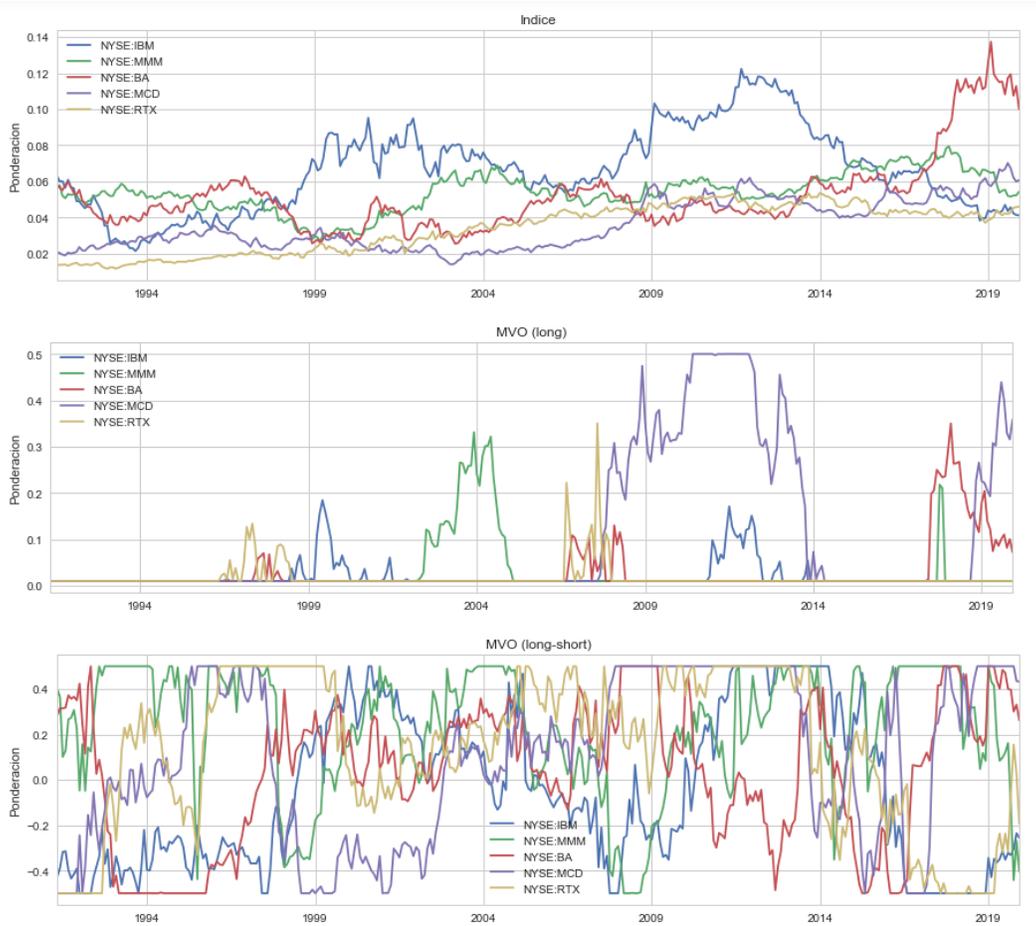


C. Ponderaciones históricas de los portafolios MVO restringidos

Cuadro XIII. Ponderaciones medias para acciones seleccionadas

Ticker	Índice (%)	MVO (long) (%)	MVO (long-short) (%)
NYSE:IBM	6.63	1.89	-5.13
NYSE:MMM	5.39	2.65	22.65
NYSE:BA	5.16	2.87	3.51
NYSE:MCD	3.58	9.79	10.01
NYSE:RTX	3.39	1.69	13.03
NYSE:MO	3.19	10.80	24.96
NYSE:JPM	2.94	1.47	12.94
NasdaqGS:GT	2.64	1.50	-18.14

Figura 11. Ponderación histórica



D. Autocorrelación de las medidas de dispersión

Figura 12. Regresión de autocorrelación AR(1) para la dispersión de corte transversal

OLS Regression Results						
Dep. Variable:	y	R-squared:	0.321			
Model:	OLS	Adj. R-squared:	0.320			
Method:	Least Squares	F-statistic:	81.96			
Date:	Sat, 25 Jul 2020	Prob (F-statistic):	6.56e-18			
Time:	20:20:21	Log-Likelihood:	979.92			
No. Observations:	395	AIC:	-1956.			
Df Residuals:	393	BIC:	-1948.			
Df Model:	1					
Covariance Type:	HC0					
	coef	std err	z	P> z	[0.025	0.975]
const	0.0269	0.004	7.620	0.000	0.020	0.034
x1	0.5667	0.063	9.053	0.000	0.444	0.689
Omnibus:	113.935	Durbin-Watson:	2.352			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	343.722			
Skew:	1.327	Prob(JB):	2.30e-75			
Kurtosis:	6.721	Cond. No.	40.8			

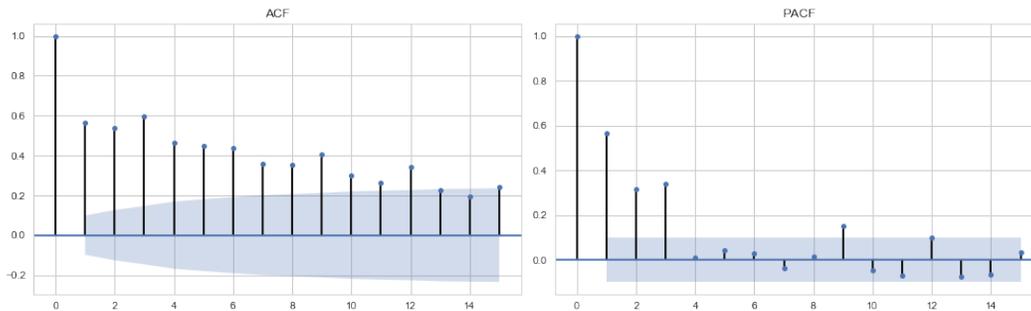
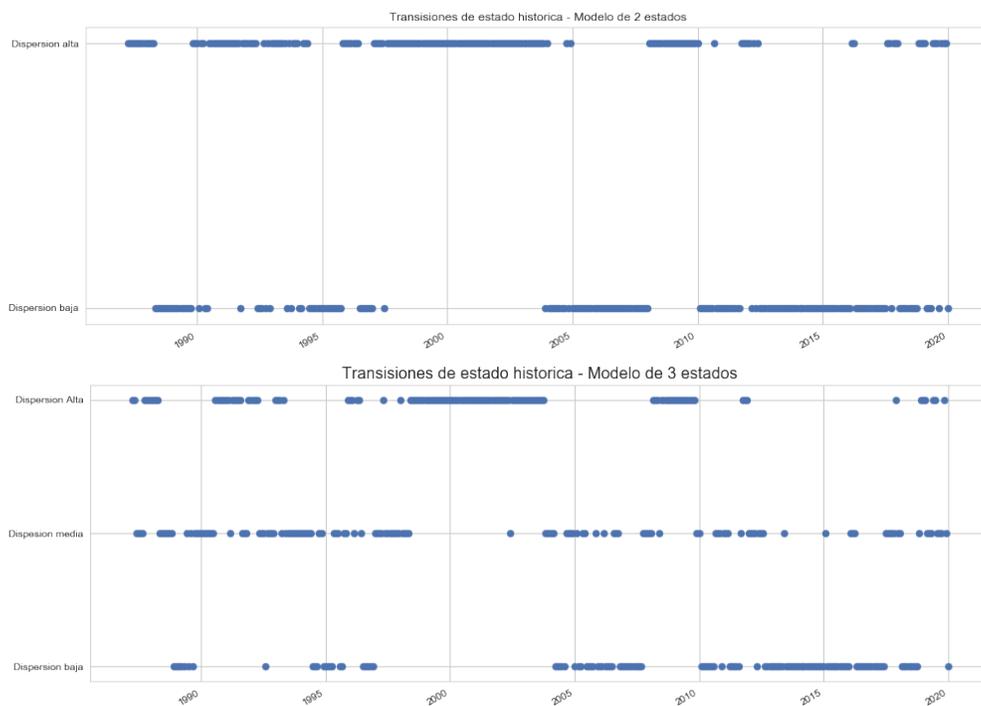


Figura 13. Regresión de autocorrelación AR(1) para la media móvil MA(3)

OLS Regression Results						
Dep. Variable:	y	R-squared:	0.877			
Model:	OLS	Adj. R-squared:	0.877			
Method:	Least Squares	F-statistic:	1391.			
Date:	Sat, 25 Jul 2020	Prob (F-statistic):	1.55e-130			
Time:	20:20:23	Log-Likelihood:	1370.4			
No. Observations:	391	AIC:	-2737.			
Df Residuals:	389	BIC:	-2729.			
Df Model:	1					
Covariance Type:	HC0					
	coef	std err	z	P> z	[0.025	0.975]
const	0.0039	0.001	2.805	0.005	0.001	0.007
x1	0.9368	0.025	37.299	0.000	0.888	0.986
Omnibus:	83.911	Durbin-Watson:	1.625			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	641.896			
Skew:	0.660	Prob(JB):	4.11e-140			
Kurtosis:	9.137	Cond. No.	48.5			

E. Transición de estados para la dispersión de corte transversal

Figura 14. Transición de estados

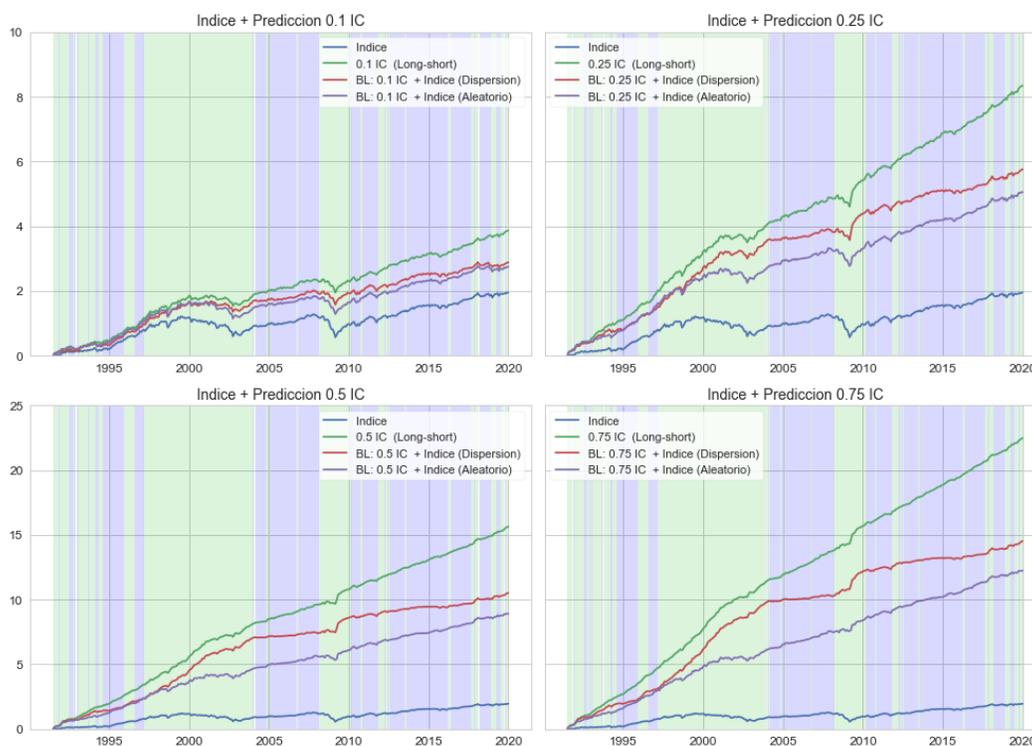


F. Estrategia Black-Litterman con 2 estados

Cuadro XIV. Dos estados - Long

	Retorno (%)		Volatilidad (%)		Sharpe Ratio	
	Dispersión	Aleatorio	Dispersión	Aleatorio	Dispersión	Aleatorio
0.10	27.56	25.77	16.88	17.80	1.49	1.31
0.25	93.01	80.27	36.73	34.11	2.47	2.28
0.50	223.37	181.41	77.94	66.78	2.84	2.68
0.75	352.84	285.42	118.66	99.89	2.96	2.83

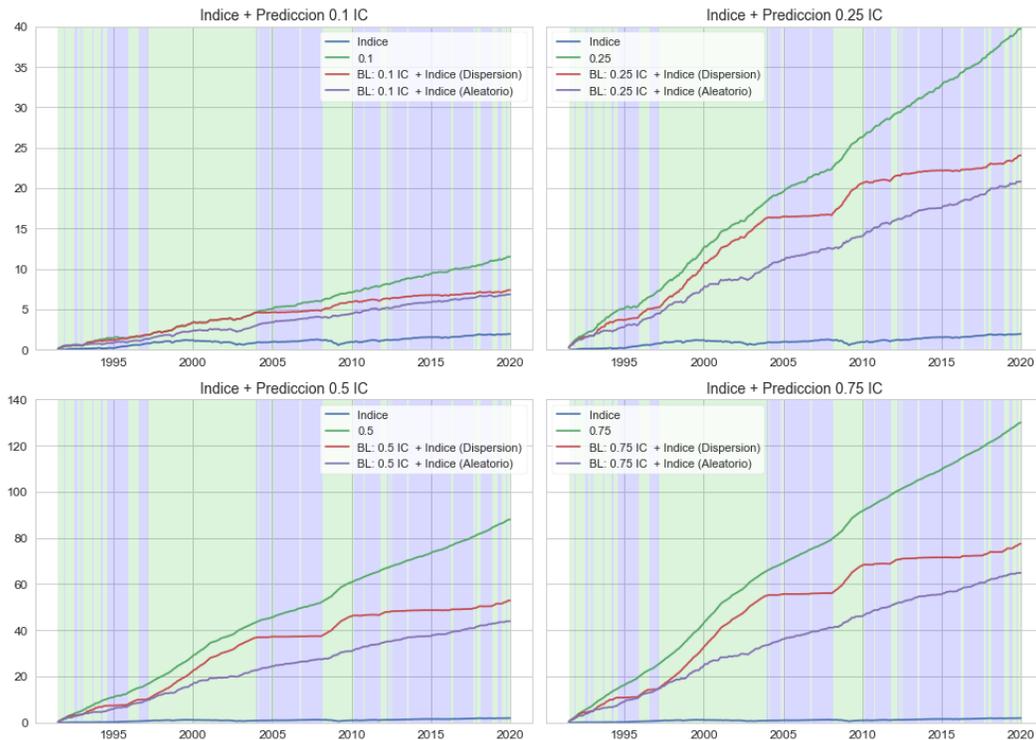
Figura 15. Retorno acumulado de la estrategia Black-Litterman - Long



Cuadro XV. Dos estados - Long-short

	Retorno (%)		Volatilidad (%)		<i>Sharpe Ratio</i>	
	Dispersión	Aleatorio	Dispersión	Aleatorio	Dispersión	Aleatorio
0.10	10.98	10.58	12.91	13.54	0.66	0.60
0.25	21.52	19.02	15.75	15.65	1.21	1.06
0.50	39.34	33.54	20.91	20.37	1.77	1.53
0.75	54.34	45.90	23.60	22.44	2.21	1.94

Figura 16. Retorno acumulado de la estrategia Black-Litterman - Long-short



Referencias

- Andrea Amato, Marcela Cervini, Amneet Singh, and Martin Cornero, 2018, Active bets in high dispersion (unpublished master's thesis), *University of California, Berkeley* .
- Black, Fischer, and Robert Litterman, 1991, Asset allocation: combining investor views with market equilibrium, *The Journal of Fixed Income* 1, 7–18.
- Black, Fischer, and Robert Litterman, 1992, Global Portfolio Optimization, *Financial Analysts Journal* 48, 28–43.
- Carhart, Mark M., 1997, On Persistence in Mutual Fund Performance, *The Journal of Finance* 52, 57.
- Cremers, KJ Martijn, and Antti Petajisto, 2009, How active is your fund manager? a new measure that predicts performance, *The Review of Financial Studies* 22, 3329–3365.
- Gorman, Larry R., Steven G. Saprà, and Robert A. Weigand, 2010, The role of cross-sectional dispersion in active portfolio management, *Investment Management and Financial Innovations* 7, 54–64.
- Grinold, Richard C, and Ronald N Kahn, 2000, Active portfolio management .
- Gruber, Martin J, 1996, Another puzzle: The growth in actively managed mutual funds, *The Journal of Finance* 51, 783–810.
- Haesen, Daniel, Winfried G. Hallerbach, Thijs Markwat, and Roderick Molenaar, 2017, Enhancing Risk Parity by Including Views, *Journal of Investing* 26, 53–68.
- He, Guangliang, and Robert Litterman, 2002, The Intuition Behind Black-Litterman Model Portfolios, *SSRN Electronic Journal* .

Malkiel, Burton G, 1995, Returns from investing in equity mutual funds 1971 to 1991, *The Journal of Finance* 50, 549–572.

Markowitz, H. M., 1952, Portfolio selection, *The Journal of Finance* 7, 77–91.

Nguyen, Lam H, and James Miles, 2012, Return in investing in equity mutual funds from 1990 to 2009, *The Penn State McNair Journal* 55.

Von Reibnitz, Anna, 2017, When Opportunity Knocks: Cross-Sectional Return Dispersion and Active Fund Performance, *Critical Finance Review* 303–356.