

Trabajo Final de Graduación

Maestría en Finanzas UTDT

Año Académico 2021

Alumno: Benjamín Ogando

Tutor: Lionel Modi

Estrategias de construcción de portfolios: óptimas vs. naive

Índice

1.	Introducción	3
2.	Universo de activos	4
2.1	Clases de activos	4
2.2	Vehículos de inversión colectiva	4
2.3	Set de activos a utilizar	7
3.	Análisis descriptivo	11
4.	Tasa libre de riesgo	14
5.	Estrategias de construcción de portfolios	15
5.1	Mean-Variance	16
5.2	Fama-French 5 factores	20
5.3	Risk Parity	23
5.4	Hierarchical Risk Parity	25
6.	Portfolio Benchmark “1/N”	29
7.	Metodología para la evaluación de performance	31
7.1	Muestreo	31
7.2	Medida de performance	36
8.	Resultados	39
9.	Conclusiones	49

1. Introducción

Los mercados de capitales en economías modernas cumplen el rol fundamental de asignar recursos entre los distintos sectores productivos, transfiriendo e intermediando ahorros de un sector para financiar a otro, sus inversiones en bienes y servicios que le permitan crecer y desarrollar sus actividades. En simultáneo, los mercados aspiran a ser, idealmente, un fiel reflejo de los riesgos implícitos y perspectivas futuras de las firmas y estados que adquieren ese financiamiento, con el objetivo de que inversores tomen decisiones de inversión de la manera más informada posible.

La búsqueda de un portfolio óptimo es el proceso de determinar la mejor combinación de activos disponibles en los mercados para invertir con el objetivo de maximizar el retorno esperado en relación con el riesgo asumido, buscando una exposición a estos riesgos lo más balanceada posible. A través de distintas estrategias y enfoques, inversores enfrentan dicha tarea a diario con la idea de obtener retornos superiores a los de un *benchmark* y/o la competencia.

A lo largo de los años, diferentes autores han propuesto distintas teorías y modelos para alcanzar el portfolio óptimo, cada uno bajo sus propias restricciones y definiciones de “óptimo”. Desde lo más clásico, allá por 1952, con Harry Markowitz, padre de la teoría moderna de portfolios y la primera aproximación de inversores diversificando capital en distintos activos riesgosos en función de su media y varianza esperada. Hacia los años 60s, partiendo y continuando lo propuesto por la teoría de construcción de portfolios de Markowitz, otro grupo de investigadores con William Sharpe y John Lintner a la cabeza, desarrollaron una teoría primordial para explicar la formación de precios de mercado de los activos denominada *Capital Asset Pricing Model* o, simplemente, CAPM. A partir de allí, las contribuciones de autores sobre propuestas para construcción de carteras fueron múltiples, destacándose Eugene Fama y Kenneth French y su modelo multi-factores como una extensión de CAPM, hasta lo más contemporáneo y reciente de Marcos López de Prado involucrando algoritmos de mayor complejidad técnica y un enfoque en la equitativa exposición a riesgos idiosincráticos de los distintos activos y sectores económicos.

Usando datos de un universo de 13 activos de distintas clases y sectores para una ventana de tiempo yendo desde enero del 2010 hasta diciembre del 2021, se buscará testear si estas estrategias de construcción de portfolios ofrecieron retornos *out-of-sample* ajustados por riesgo superiores a las de un *naive* portfolio, es decir, un portfolio equitativamente ponderado, a utilizar como *benchmark*.

En una primera instancia describiremos el universo de activos seleccionados para llevar adelante este trabajo, describiendo las distintas clases de activos junto a sus principales características. Luego explicaremos el marco teórico de cada una de las cuatro estrategias de construcción de portfolios bajo estudio junto a la del portfolio *benchmark*. Paso siguiente introduciremos la metodología de *backtesting* y métricas seleccionadas para la evaluación de performance ajustada por riesgo con las cuales contrastaremos las estrategias y nos permitirán tomar conclusiones respecto a lo que se busca testear.

2. Universo de activos

En este trabajo utilizaremos *Exchange-Traded Funds* o ETF, por lo que, en primer lugar, procederemos a explicar brevemente las características de este tipo de instrumento.

2.1 Clases de activos

A la hora de armar una cartera de inversión, los inversores tienen a su disposición un amplio abanico de alternativas de inversión. Podemos clasificar a estas en dos grandes grupos: instrumentos de renta variable y de renta fija.

En el mundo de la renta variable encontramos a las acciones, que representan una porción del capital social de una empresa y otorgan al comprador el derecho a percibir dividendos, entre otros. Se les asigna la etiqueta de renta variable dado que el inversor no conoce el flujo de fondos futuros que recibirá por su inversión. Las acciones cotizan diariamente en función de las fuerzas de la oferta y demanda, que, a su vez, son función de la información disponible en el mercado y las expectativas que formen los inversores sobre la evolución futura de los resultados de la empresa. El retorno de una inversión en acciones dependerá de las ganancias o pérdidas de capital producidas por la fluctuación de la cotización en el mercado y de los dividendos en efectivo que la empresa otorgue.

Por otro lado, los instrumentos de renta fija, el inversor ya conoce de antemano las condiciones en las que el emisor devolverá el capital y los intereses, estipuladas en las condiciones de emisión. Es decir, el inversor conoce el flujo de fondos futuro que percibirá por su inversión. Los principales y más habituales instrumentos de renta fija son los títulos públicos, emitidos por estados nacionales, provinciales o municipales y las obligaciones negociables, emitidas por empresas. El precio de estos títulos de deuda refleja las expectativas de los inversores respecto a la capacidad de los emisores para cumplir con las condiciones de emisión.

2.2 Vehículos de inversión colectiva

Un vehículo de inversión colectiva consiste en un portfolio administrado por profesionales con el objetivo de llevar adelante un mandato o estrategia de inversión previamente determinado. Los fondos mutuos o fondos comunes de inversión son de los más tradicionales de esta familia. Distintos inversores, tanto individuales como institucionales, pueden suscribir dinero al fondo el cual luego será invertido por la sociedad administradora del mismo de acuerdo a las políticas de inversión. El valor cuota o precio del fondo es conocido al cabo de cada rueda bursátil y fluctúa en función de los precios de los activos que constituyen su cartera. Estos vehículos ofrecen a los inversores atractivas ventajas impositivas y operativas a cambio de una comisión preestablecida. Existen distintos tipos de fondos mutuos para atender necesidades financieras de inversores con distintos perfiles de riesgo. Desde fondos con fines transaccionales o de *Cash Management* como los de “Mercado de dinero” o *Money Market* de liquidez inmediata, hasta fondos exclusivos de renta fija, renta variable o renta mixta (combinación de renta fija y variable).

Los *Exchange-Traded funds* o ETF son otro vehículo de inversión colectiva similar a un fondo mutuo, pero con la particularidad de que cotizan en el mercado al igual que una acción tradicional y con significativa liquidez (en su mayoría). Los ETFs le permiten a cualquier tipo de inversor, sea individual o institucional, obtener exposición a casi cualquier tipo y clase de activos, desde sectores económicos como la energía o tecnología hasta bonos de mercados emergentes, *commodities* y, más recientemente, criptomonedas. Así también podemos encontrar ETFs con el mandato de cumplir una estrategia o temática de inversión determinada como, por ejemplo, invertir únicamente en acciones de baja


capitalización bursátil (Vanguard Small-Cap ETF), en acciones de empresas desarrolladoras de robótica e inteligencia artificial (Global X Robotics & Artificial Intelligence ETF), entre tantas otras.

Hill, Nadig y Hougan (2015) enumeran cuatro ventajas para entender el fuerte crecimiento de los ETF respecto a otros vehículos de inversión más tradicionales:

- **Acceso:** los ETF representan la democratización del acceso a mercados, clases de activos y estrategias que antes estaban disponibles únicamente para grandes y sofisticados inversores calificados como fondos de pensión, *Hedge Funds*, etc. Bajan la barrera de entrada a mercados emergentes y de frontera que previamente eran de complejo acceso para todo tipo de inversor, incluso institucionales. Además, le permiten al inversor construir posicionamiento táctico en distintos enfoques de inversión basados en clases y subclases de activos, estilos, sectores, entre otros.
- **Transparencia:** Inversores tienen conocimiento directo de los activos constituyentes de la cartera del ETF y de su valor de mercado.
- **Liquidez y Price Discovery:** El *Price Discovery* o descubrimiento de precio es el proceso de determinar el valor de mercado de un activo en función de la interacción de oferta y demanda. Previo a la aparición de los ETF, el Price Discovery era acotado para acciones de empresas de baja capitalización como así también de acciones y bonos de mercados emergentes y de frontera, acentuándose aun mas durante periodos de stress financiero.
- **Eficiencia fiscal:** las estructuras de los ETF están diseñadas para minimizar los eventos gravados impositivamente, en comparación a los tradicionales fondos mutuos de inversión.

La participación y popularidad de los ETFs es de las que más ha crecido en la industria en los últimos años. El flujo destinado a esta industria fue creciendo significativamente respecto a la de los fondos mutuos, especialmente en los años recientes.

Imagen 1



Dado que hoy por hoy la mayoría de los ETFs consisten en replicar un índice, es de gran importancia buscar definir qué es un índice en el mundo de los mercados financieros. Tal como describe Lo (2016), la definición standard de un índice es el promedio ponderado por capitalización bursátil de una lista de activos individuales. Originalmente y hace muchos años, los índices se utilizaban pura y exclusivamente como una herramienta numérica para conocer el estado general del mercado. Charles H. Dow publicó el primer índice en 1884, el *Dow Jones Transportation Average*, precursor del Dow Jones Industrial Average, uno de los tres índices más famosos de la actualidad junto al *Standard & Poors 500* y al *NASDAQ Composite*. Inicialmente, Dow calculaba el índice como un mero promedio simple de los precios de determinadas acciones del mercado, para luego pasar a la metodología más utilizada hoy en la construcción de índices: el promedio ponderado por capitalización bursátil. Esto implicaba que cada acción tendría en el índice una importancia relativa a su capitalización bursátil en el mercado. Además, este método saca el efecto de acciones corporativas como *splits*, fusiones, dividendos, entre otros, que pueden alterar el precio de la acción sin o con muy acotado efecto financiero, distorsionando el índice.

Con el paso del tiempo y transportándonos hasta la actualidad, los índices siguen desempeñando aquella original función como también otros roles nuevos. Hoy por hoy, además de comprimir y resumir información de mercado de muchos activos en particular, también funcionan como referencias para la evaluación y atribución de performance. Con la evolución de la teoría moderna de portfolio (a desarrollar más adelante) y como introducimos en la sección anterior, los índices pasaron también a usarse para construir vehículos de inversión colectiva de carácter pasivo. Los relativamente recientes avances tecnológicos en materia de computación, telecomunicaciones que escalaron la capacidad y velocidad de procesamiento de datos y operaciones bursátiles allanaron el camino para la proliferación de nuevos instrumentos financieros atados a los índices.


Para entender el surgimiento y popularidad de los ETFs hay que remontarse a 1976: John Bogle fundador de Vanguard Group y pionero del *Index Investing*. El *Index Investing*, pilar y base de los ETF, es un enfoque de inversión pasivo con el objetivo de replicar la performance de un índice de mercado dejando de lado la discrecionalidad del inversor. John Bogle introdujo el primer fondo de inversión mutuo con el mandato de seguir la performance del índice accionario Standard and Poors 500. Este fue llamado “First Index Investment Trust” y comenzó con activos bajo administración por 11 millones de dólares. La premisa detrás de esta estrategia es que los inversores, en promedio, no pueden batir la performance del índice de mercado y la mejor alternativa es replicar la cartera de este. En parte debido a que, con el objetivo de batir el índice de mercado, inversores activamente incurren en reiteradas operaciones generando gastos de operatoria que terminan erosionando las ganancias, si las hay. En 1993 State Street Global Investors introdujo el S&P 500 Trust ETF (Símbolo “SPY”), el primer ETF en el mercado en lanzarse con éxito. Los principales motivos por los cuales el *index investing* giro hacia vehículos como los ETF fueron las altas comisiones, iliquidez, altos mínimos de inversión requeridos y complejo acceso por parte de las gestoras de los fondos mutuos, sin dejar de mencionar la flexibilización por parte de los reguladores. Hoy por hoy, el S&P 500 Trust ETF o SPY, tiene 338.26 miles de millones de dólares bajo administración, según YCharts¹. Es importante remarcar que los modelos o estrategias de inversión a estudiar en este trabajo tienen un enfoque de gestión activa, diferente al descrito según *passive investing*. En esta modalidad, el inversor busca tomar decisiones de inversión discrecionalmente en base a un criterio o tesis de inversión determinado con el fin de batir al benchmark. Siendo su cartera no necesariamente similar a la del portfolio benchmark. El tema de si *passive investing* es superior al active investing, o viceversa, es uno de los debates más frecuentes en la industria, como también de ensayos académicos.

Una dinámica que se viene percibiendo en los últimos dos años es el número de lanzamiento de ETFs de gestión activa superando a los de gestión pasiva. Gestores que antiguamente hubieran elegido

¹ <https://ycharts.com/>

lanzar sus fondos de inversión bajo la estructura de un fondo mutuo o incluso de un *Hedge Fund* ahora escogen la de ETFs.

Imagen 2



La composición de la cartera de estos ETFs corre completamente a costa de la discrecionalidad y criterios de inversión del gestor. El caso que mayor relevancia ha cobrado en la industria es el de la gestora Ark Investment Management bajo el mando de su CEO, Cathie Wood.

2.3 Set de activos a utilizar

El set de activos a utilizar para el trabajo consiste de 13 ETFs obtenidos de la API² de Yahoo!Finance, la cual a la fecha es de libre acceso. Los mismos son los detallados en la tabla 1. Se llevó adelante la selección con el objetivo de armar un grupo de activos diversificados incluyendo ETFs de distintas clases y temáticas de inversión y, que, además, se disponga de por lo menos diez años de datos de cada ETF. Describiremos brevemente los mismos a continuación. De esta manera llegamos a un set de datos que va desde enero del 2010 a diciembre de 2021 contando con 3015 observaciones diarias.

² Interfaz de programación de aplicaciones

Tabla 1

#	Simbolo	Nombre	Clase
1	VTV	Vanguard Value	Renta Variable
2	VUG	Vanguard Growth	Renta Variable
3	SCHA	Schwab U.S. Small-Cap	Renta Variable
4	VYM	Vanguard High Dividend Yield ETF	Renta Variable
5	VEA	Vanguard FTSE Developed Markets	Renta Variable
6	EEM	iShares MSCI Emerging Markets	Renta Variable
7	SUSA	iShares MSCI USA ESG Select	Renta Variable
8	VNQ	Vanguard Real Estate	Renta Variable / REITs
9	TLT	iShares 10-20 Year Treasury Bond	Renta Fija
10	BWX	SPDR Barclays International Treasury Bond	Renta Fija
11	EMB	iShares J.P. Morgan USD Emerging Markets Bond	Renta Fija
12	GLD	SPDR Gold Shares	Commodities
13	DBC	Invesco DB Commodity	Commodities

1. VTV – Vanguard Value ETF

El ETF tiene el objetivo de seguir la performance replicando la cartera del índice *CRSP US Large Cap Value*. Este índice incorpora empresas clasificadas como de “valor” a su cartera en función de criterios de fundamentos como el ratio precio-valor libros, precio-ganancias futuras, precio ganancias históricas, dividendos-precio y ventas-precio. A la fecha tiene en cartera un total de 349 empresas, siendo estas principalmente de los sectores de servicios financieros (21%), salud (18.7%), industriales (13.8%) y consumo básico (10.8%), entre otros.

2. VTG – Vanguard Growth ETF

El vehículo tiene el objetivo de replicar y seguir la performance del índice *CRSP U.S. Large Cap Growth*, el cual este compuesto de empresas clasificadas como de “crecimiento” en función de un modelo multifactores que incorpora métricas de fundamentos como el crecimiento futuro de corto y largo plazo de las ganancias por acción de la compañía, como así también del crecimiento histórico del ratio ventas por acción, inversión corrientes sobre activos y retorno sobre activos. A la fecha cuenta con 265 empresas en cartera siendo estas un 50.3% del sector tecnológico, 23.9% de consumo discrecional, 10.3% industriales, principalmente.

3. SCHA – Schwab U.S. Small-Cap ETF

El objetivo del ETF es dar exposición a las empresas de baja capitalización bursátil del mercado norte americano, replicando el índice *Dow Jones U.S. Small-Cap Total Stock Market*. A la fecha de elaboración de ese trabajo, el ETF tiene en cartera 1792 acciones de distintos sectores siendo estas principalmente un 16.7% del sector industrial, 16.2% de servicios financieros, 15.2% de tecnología, 14.8% de salud, entre otros sectores.

4. VYM – Vanguard High Dividend Yield ETF

El ETF replica el índice FTSE High Dividend Yield, índice compuesto por acciones de empresas clasificadas por tener una tasa de dividendos superior a la media del mercado. Esta compuesto por 410 empresas principalmente de los sectores de servicios financieros, consumo básico y salud.

5. SUSA – iShares MSCI USA ESG Select ETF

El ETF replica al índice *MSCI USA ESG*. Este índice está compuesto por empresas del mercado norteamericano clasificadas por su de impacto positivo en materia de medio ambiente, social y gobernanza. A la fecha tiene posiciones en 183 empresas siendo un 31.4% tecnológicas, 11.8% del sector de servicios financieros y 10% del industrial, principalmente.

6. VEA – Vanguard FTSE Developed Markets

El ETF replica al índice *FTSE Developed All Cap ex US*. Este índice se compone por empresas de países de mercados desarrollados ex estados unidos. Estas empresas pueden ser de baja, mediana y alta capitalización bursátil. A la fecha su cartera estaba compuesta por 4120 empresas, 52.8% de empresas de Europa, 36.6% de Asia-Pacífico y el remanente en Norteamérica ex Estados Unidos (Canadá) y medio oriente.

7. EEM – iShares MSCI Emerging Markets ETF

El ETF replica el índice MSCI Emerging Markets, el cual está compuesto por empresas de alta y media capitalización bursátil de 25 países clasificados como mercados emergentes (China en un 30.2%, Taiwan 16.2%, India 13.2% y Brasil 5.2%, entre otros). Se incluyo este ETF con el objetivo de diversificación al mercado de renta variable norteamericano.

8. VNQ – Vanguard Real Estate ETF

El ETF replica al índice MSCI REIT, el cual está compuesto por acciones de REITs (*Real Estate Investment Trusts*) del mercado norteamericano. Los REITs consisten en sociedades formadas con el fin exclusivo de invertir en el sector inmobiliario.

9. TLT – iShares 10-20 Year Treasury Bond ETF

El ETF tiene el objetivo de dar exposición a bonos emitidos por el tesoro norteamericano de madurez entre diez y veinte años. A diferencia de los anteriores, este es un ETF de renta fija.

10. BWX – SPDR Barclays International Treasury Bond ETF

El ETF busca replicar la performance del índice *Bloomberg Global Treasury ex-US Capped*, el cual se constituye de bonos denominados en moneda local de los tesoros de países ex Estados Unidos con la calificación crediticia de “Investment Grade”, de madurez superior a un año.

11. EMB – iShares J.P. Morgan USD Emerging Markets Bond ETF

El ETF replica al índice *J.P. Morgan USD Emerging Markets Bond*, el cual se constituye de bonos de estados soberanos denominados en dólares estadounidenses de países de mercados emergentes, siendo sus principales posiciones en México, Indonesia, Arabia Saudita, Qatar,

China, Brasil, Chile, entre otros. Los vencimientos residuales de los bonos en cartera son a diez o mas años, en su mayoría.

12. GLD – SPDR Gold Shares ETF

El ETF tiene el objetivo de dar un acceso simple y eficiente al mercado del oro.

13. DBC – Invesco DB Commodity ETF

El ETF da exposición a catorce commodities del sector energético y del agro, metales preciosos, metales industriales.

3. Análisis descriptivo

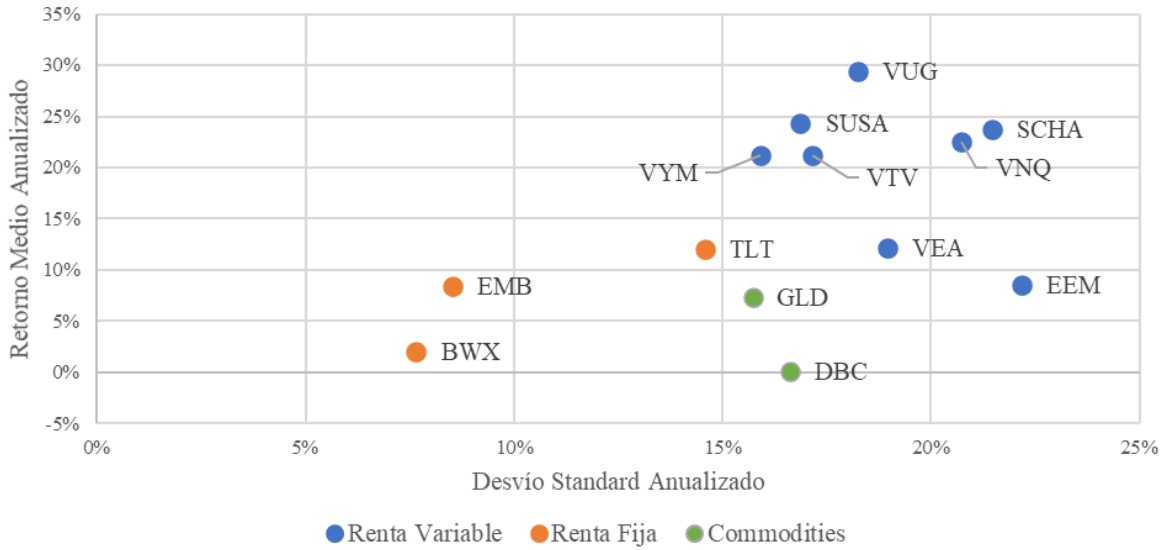
El objetivo de esta sección es conocer las características estadísticas del set de series de tiempo a utilizar. En la tabla 2 podemos ver algunos principales estadísticos de los datos a utilizar: mínimo y máximo retorno diario, media y desvío standard anualizados, coeficiente de asimetría y curtosis. Todas las métricas se calcularon a partir de los retornos diarios observados entre el 4 de enero de 2010 al 30 de diciembre de 2021, totalizando 3020 observaciones.

Tabla 2

ETF	Mínimo	Máximo	Media anualizada	Desvío Standard anualizado	Simetría	Curtosis	P-valor Test raíz unitaria (Augmented Dickey-Fuller)
VTV	-11.1%	9.8%	21.3%	17.1%	-0.54	14.90	0.000
VUG	-12.6%	8.9%	29.4%	18.2%	-0.60	11.97	0.000
SCHA	-13.9%	9.9%	23.7%	21.5%	-0.76	11.36	0.000
VYM	-10.1%	9.0%	21.2%	15.9%	-0.49	16.04	0.000
VEA	-11.2%	8.9%	12.2%	19.0%	-0.83	10.73	0.000
EEM	-12.5%	7.5%	8.6%	22.2%	-0.49	6.11	0.000
SUSA	-10.3%	10.5%	24.4%	16.9%	-0.35	13.34	0.000
VNQ	-17.7%	9.1%	22.6%	20.7%	-0.98	19.14	0.000
TLT	-6.7%	7.5%	12.1%	14.6%	0.07	5.10	0.000
BWX	-5.3%	3.4%	2.0%	7.6%	-0.61	8.97	0.000
EMB	-9.2%	4.0%	8.4%	8.5%	-3.40	57.95	0.000
GLD	-8.8%	4.9%	7.3%	15.7%	-0.48	5.02	0.000
DBC	-7.8%	4.4%	0.1%	16.6%	-0.54	3.33	0.000

A simple vista, los retornos de los ETFs de renta variable tienen rangos mínimo - máximo más amplios que los de renta fija, así como también una dispersión más alta. Mirando la media y desvío standard anualizados, es interesante contrastarlas entre ETFs de distintas clases, esto lo podemos ver en el gráfico X. Los ETFs de renta variable mostraron, en términos medios, retornos superiores a los de renta fija y commodities, pero a costa de un mayor desvío standard, medida que refleja el riesgo asumido para alcanzar estos retornos. Esta relación riesgo-retorno que observamos en el gráfico será de gran importancia más adelante en el trabajo a la hora de describir las estrategias de construcción de portfolios que estudiaremos.

Imagen 3




Siguiendo adelante, con el fin de analizar si las series de los retornos aproximan una distribución normal miramos que el coeficiente de asimetría, donde valores negativos indica presencia de “colas pesadas” hacia la izquierda, mientras que valores positivos, hacia la derecha. La curtosis nos indica cuan concentrados se encuentran los retornos respecto a la media. En este caso se observan valores superiores a 3 para todos los casos, indicando la característica de curtosis leptocúrtica o distribuciones de colas pesadas

Como una primera aproximación para entender la relación lineal que tiene cada uno de los activos con el resto, la imagen 4 muestra en un gráfico de calor la matriz de correlaciones (Pearson) de los activos bajo estudio. Visualmente se ve, como se podía esperar, que activos correspondientes tanto como a la misma clase o sector, muestran correlaciones positivas y altas, especialmente en los correspondientes a renta variable. Es importante remarcar que, tratándose de correlaciones, debemos tener en consideración que estas no suelen ser persistentes en el tiempo y están sujetas al período y frecuencia temporal que se toma para examinarlas. En el reporte científico *Quantifying the Behavior of Stock Correlations Under Market Stress*³, los autores analizan 72 años de retornos diarios de los componentes del índice accionario *Dow Jones Industrial Average* concluyendo que la correlación promedio entre estos aumenta linealmente con el stress de mercado y, consecuentemente, los beneficios de la diversificación que deberían proteger un portfolio en momentos de pánico se ven erosionados en momentos donde más se lo precisa.

³ Tobias Preis, Dror Y. Kenett, H. Eugene Stanley, Dirk Helbing & Eshel Ben-Jacob.


Imagen 4



Como se observa en la imagen 4, ETFs de la clase renta variable como SCHA (*Small-Caps*), SUSA (ESG), VTV (*Value*), VUG (*Growth*), VYM (*High Dividend Yield*), VEA (*Developed Markets*) y, en menor medida, EEM (Mercados emergentes) correlación entre sí con niveles positivos y muy altos de entre 0.75 y 1. Es decir que, en general, estos activos tienden a moverse en la misma dirección. Por otro lado, vemos otro conjunto de activos, correspondientes a la clase renta fija y commodities que muestran valores de correlación más cercanos a 0 e incluso negativos. El ETF TLT (*U.S. Treasuries* con *maturities* de 10 a 20 años) tiene una correlación negativa, aunque no tan alta yendo de -0.25 a casi -0.5 salvo para con dos activos que son EMB (Bonos en dólares de mercados emergentes) y GLD (oro). Esto quiere decir que las variaciones diarias de TLT tienden a ser en la dirección opuesta. Para el inversor puede resultar atractivo tener a disposición una fuente de retornos no correlacionada con el resto de los activos para facilitar su objetivo de construir una cartera diversificada. Por último, el resto de los ETFs de renta fija, EMB y BWX (Bonos soberanos de países ex Estados Unidos denominados en moneda local) y de commodities GLD y DBC si bien tienen baja correlación con los ETFs de renta variable, esta no llega a ser negativa como la que exhibe TLT.

Si bien la correlación nos describe la manera en la que dos activos cavarían entre sí, o sea, si tienden a moverse en la misma dirección (correlación positiva) o en dirección contraria (correlación negativa), no nos dice en que magnitud. Por ejemplo, VUG y SUSA tienen una correlación de 0.95 según la matriz de correlaciones de la imagen 4, pero si miramos la siguiente imagen vemos que, si bien ambos se mueven en la misma dirección, VUG demostró alcanzar retornos acumulados significativamente mayores. Para analizar esto, la siguiente imagen expone las series de retornos acumulados de los activos a tomar para este trabajo. Para su cálculo se tomó el precio de cierre ajustado por dividendos. Como mencionado previamente, se vuelve a apreciar la diferencia de retornos entre los ETFs de renta variable respecto de a los de renta fija y commodities, especialmente destacándose el ETF de acciones de crecimiento (Símbolo VUG).

Imagen 5




4. Tasa libre de riesgo

Como menciona Damodaran (2008), una inversión libre de riesgo, en teoría, es aquella cuyo retorno actual es equivalente al retorno esperado, es decir, no hay varianza respecto al retorno esperado. Para que una inversión sea considerada libre de riesgo debe cumplir con dos condiciones básicas: No hay riesgo de default ni riesgo de reinversión. El riesgo de default es el riesgo de que el emisor no cumpla las condiciones de emisión. Esto es que, por ejemplo, el tomador de la deuda no pague las amortizaciones o rentas estipuladas o no cumpla con las fechas de pago estipuladas. Se considera que la única institución con prácticamente nulo riesgo de default (por lo menos en cuanto a inversiones denominadas en dólares) es el tesoro norteamericano. Esta es dado que, en última instancia, este podría acudir a emitir más de su propia moneda para atender sus obligaciones con acreedores. Es importante remarcar que en la práctica ningún activo está libre de riesgo de default, sin embargo, los bonos del tesoro norteamericano son la mejor aproximación a ello por lo mencionado. Además, en una definición mas estricta de “libre de riesgo”, podríamos argumentar de la presencia de otros tipos de riesgo como el de inflación: si bien los un *treasury* pueden estar casi exento de riesgo de default, sus retornos en términos reales, es decir, ajustados por inflación no lo están. Los bonos del tesoro norteamericano son bonos de tasa fija, la cual se determina al momento de emisión, por lo tanto, su flujo de caja para toda su vida residual no está protegida de eventuales subas en la tasa de inflación, erosionando el valor real de estos.

En este trabajo, como tasa libre de riesgo utilizaremos la tasa del bono del tesoro norteamericano con madurez de diez años, madurez semejante a la que uno podría esperar respecto a los flujos de caja de una inversión en activos renta variable. Por practicidad, a los retornos diarios de los activos que seleccionamos les restaremos esta tasa libre de riesgo, compuesta también con frecuencia diaria, con el fin de obtener el set de retornos en exceso a la tasa libre de riesgo con los que llevaremos adelante el trabajo.

Los datos de la misma se pueden acceder de manera libre a través de la API de *Federal Reserve Economic Data* (FRED).

Imagen 6



5. Estrategias de construcción de portfolios

En la actualidad, modelos o estrategias de construcción de portfolios hay múltiples, cada una con un enfoque o criterio de optimización distinto. Sin embargo, todas se dieron a partir del trabajo expuesto por Harry Markowitz en 1952, autor que cimiento las bases de la denominada teoría moderna del portfolio. Markowitz propuso un proceso cuantitativo y también un lenguaje con el cual comenzar a discutir la construcción de portfolios. Como resume Roche (2016), podemos destacar tres aportes claves. En primer lugar, la importancia de entender la covarianza, esto es el grado de variación conjunta de dos variables aleatorias en torno a su media. En segundo lugar, las ventajas de la diversificación entendido como la combinación de un conjunto de activos con, idealmente, baja correlación con el objetivo de alcanzar retornos superiores al mismo tiempo que reduciendo la varianza total del portfolio. Además, también aportó la primera la noción de riesgo cuantificable, expresado como el desvío standard de los retornos, y así poder tener una herramienta para comenzar a medir y entender el riesgo en un portfolio. Por último, la presentación de la idea de la frontera eficiente, como un sistema para la selección de portfolios y control del riesgo. Todos conceptos a profundizar más adelante en el trabajo.

La diversificación parte de la idea de descomponer el riesgo de un activo individual en riesgo de mercado, también descrito en la literatura como el riesgo sistemático, y el riesgo asociado al activo en particular o riesgo idiosincrático. El riesgo sistemático es el tipo de riesgo que el inversor no puede controlar ni minimizar, y afecta a todo el mercado en su conjunto. Por otro lado, el riesgo idiosincrático se asume ser no correlacionado al riesgo sistemático y el inversor puede lograr minimizar o al menos disminuir a través de la diversificación. Esta dinámica es modelada por la teoría *Capital Asset Pricing Model* (CAPM), a ser explicada en las siguientes secciones. Das & Uppal (2003) define al riesgo sistemático como la probabilidad de que el mercado de capitales falle a sus funciones esenciales de proveer crédito, hacer mercados y custodiar títulos de valores. Los eventos de riesgo sistemático, comúnmente, se gestan de manera gradual en el tiempo, pero se materializan y gatillan de manera abrupta y expresándose vía dos efectos inmediatos: la reducción de los beneficios de la diversificación y la penalización a inversores por sostener posiciones apalancadas, esto es posiciones por un valor nocional superior a la del capital del inversor, amplificando potenciales ganancias o pérdidas. Los eventos de riesgo sistemático se diferencian de correcciones habituales de mercado en que presionan sobre el fondeo y libre movilidad de capitales, cuestiones de contabilidad y legales, así llevando a la liquidación forzosa de posiciones dejando poco o nulo espacio para inversores a la libre elección.

El ejemplo más popular de riesgo sistemático es la crisis del mercado hipotecario *sub-prime* o de baja calificación en los años 2007-2008, cuyas condiciones se deterioraron significativamente producto del crecimiento de incumplimiento de pagos por parte de los deudores de estos créditos. Ello desembocó en la quiebra del banco de inversión Lehman Brothers hacia fines del año 2008, institución que mantuvo una excesiva y apalancada exposición a este tipo de créditos. La caída de Lehman Brothers fue la más relevante dado su historia y tamaño al momento del evento, pero los efectos pegaron en toda la industria financiera como también en las economías a escala global, desembocando en la denominada “gran recesión”, la mayor crisis desde el año 1929.

El termino de diversificación hace referencia al proceso de asignar capital a un número y variedad suficiente de activos individuales con el objetivo de que el inversor quede expuesto únicamente al riesgo de mercado. En la práctica, inversores buscar distribuir capital en bonos y acciones de distintos sectores económicos (Energía, servicios financieros, tecnología, salud, materiales básicos, entre otros), temáticas de inversión (Empresas *Growth*, *Value*, *ESG*, *High Dividend Yield*, etc.), geografías y clases de activos con el objetivo de aumentar la diversificación y disminuir la exposición al riesgo idiosincráticos asociados a cada uno de los activos en particular.

En las siguientes secciones expondremos las cuatro estrategias de construcción de portfolios a estudiar. Al final de la sección de cada estrategia se mostrará la cartera optima según cada modelo construida a partir de los retornos diarios para la ventana temporal del set de datos completo, es decir, desde el 01/01/2008 al 31/12/2022. Es importante tener en cuenta que al trabajar con ETFs, estos ya representan una cartera compuesta por múltiples activos. Por ejemplo, al 31/12/2022 la cartera del ETF VUG (Vanguard Growth) estaba constituida por 267 acciones o el ETF SCHA (Schwab U.S. Small-Cap) tenía acciones de 1796 empresas distintas con una exposición máxima del 0.41% total de la cartera. Claro que son todas empresas asociadas al mismo sector, clase de activos o temática de inversión respectiva al mandato de inversión u objetivos del ETF. Al tener un elevado número de activos en cartera, el riesgo idiosincrático es acotado. Esta mención viene a raíz de que quizás una estrategia propone asignar una porción significativa de la cartera a un solo ETF (digamos 20% o más, por ejemplo) y, a priori, se tendería a concluir que la exposición al riesgo idiosincrático es significativa, pero ello no es así dado las características de las carteras de los ETFs mencionadas previamente.

Las estrategias de construcción de portfolios a estudiar son cuatro, cada una buscando resolver el problema de la elección optima de la ponderación de cada activo en la cartera desde una perspectiva distinta o complementando teorías ya propuestas por otros autores en el pasado. Estas son:

- Portfolio media-varianza (MV por *Mean-variance*) – Harry Markowitz
- Fama-French 5 factores (FF) - Eugene F. Fama
- Paridad de riesgo (RP por *Risk Parity*)
- Paridad de riesgo por jerarquías (HRP por *Hierarchical Risk Parity*) – Marcos López de Prado.

5.1 Mean-Variance

La consideración de los retornos de una inversión de manera conjunta a sus riesgos, es decir, no solo los potenciales retornos de manera aislada a la hora de elegir asignar capital a una inversión, es algo que puede resultar intuitivo y propio de cualquier agente racional. Sin ir más lejos, la tradicional expresión “No poner los huevos en la misma cesta” hace una simple pero efectiva referencia al concepto de diversificación. Probablemente es un concepto que los inversores ya tenían concebido previo a las publicaciones de la teoría moderna de portfolio. Sin embargo, Harry Markowitz desarrollo y propuso un marco teórico y formal para trabajar sobre esta idea de construir portfolios y seleccionar activos bajo incertidumbre.

En un mundo donde la regla es que un inversor se comporta buscando el portfolio de mayor retorno posible y, en simultáneo, es averso al riesgo, definido como la varianza de los retornos, Markowitz modeló este comportamiento de manera geométrica.

Partiendo de las fórmulas de retorno y varianza esperadas de un portfolio p :

$$\begin{aligned} \text{retorno esperado} &\Rightarrow \mu_p = w^T \mu \\ \text{varianza esperada} &\Rightarrow \sigma_p^2 = w^T \Sigma w \end{aligned}$$

Donde w es el vector de ponderaciones de los n activos en la cartera

$$w = (w_1 \ w_2 \ w_3 \ \dots \ w_n)$$

Σ es la matriz de covarianzas

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \cdots & \sigma_{1,n} & \vdots & \vdots & \sigma_{n,1} & \cdots & \sigma_n^2 \end{pmatrix}$$

Siendo volatilidad el desvío standard de los retornos del portfolio, el modelo propuesto por Harry Markowitz se resume a minimizar la volatilidad esperada de un portfolio:

$$w^T \Sigma w$$

Sujeto a:


$$0 \leq w_i \leq 1$$

$$\sum_{i=1}^n w_i = 1 \quad (\text{no se toman posiciones short ni con apalancamiento})$$

En términos de media y varianza, no todas las combinaciones de ponderaciones son eficientes. Hay distintas combinaciones para un mismo nivel de riesgo, pero cada una con un retorno esperado distinto. Para cada nivel de riesgo, el inversor elige exclusivamente el portfolio de mayor retorno esperado, ignorando las demás combinaciones. Como resultado de estas preferencias se obtiene una curva denominada “Frontera de Portfolios Eficientes”, donde se encuentran los portfolios de mayor retorno esperado para cada nivel de volatilidad esperada.

Por ejemplo, para ilustrar la idea previa podemos observar la imagen 5 que, para un universo de cinco activos riesgosos y, por simplicidad, tomando la tasa libre de riesgo $r_f = 0$, iterando sobre distintos posibles portfolios se obtiene:

Imagen 7



En el eje horizontal de la imagen 5 encontramos la volatilidad esperada o riesgo, medida como el desvío standard de los retornos diarios, y en el eje vertical al retorno esperado del portfolio, calculado como la media simple de los retornos pasados. Bajo esta teoría, el inversor escoge portfolios únicamente

ubicados sobre la frontera eficiente de portfolios, siendo los todos restantes considerados no eficientes en términos de retorno-riesgo esperado.

(i) Sharpe y Treynor – *Capital Asset Pricing Model (CAPM)*

Como avance y complementación de lo propuesto por Harry Markowitz, Jack Treynor y William F. Sharpe introdujeron nuevos conceptos para la valuación de activos y estimación óptima del portfolio de mercado. Para interpretar mejor la relación retorno-volatilidad se introduce “Sharpe ratio”, definido como $SR = \frac{\mu_p - r_f}{\sigma_p}$, el cual relaciona el retorno esperado del portfolio en exceso a la tasa libre de riesgo y la volatilidad esperada.

La idea central de CAPM es proponer un marco teórico para entender, modelar y medir la relación entre retorno y riesgo esperado de un activo. El modelo en cuestión toma cuatro supuestos: (1) Todos los inversores son aversos al riesgo y eligen su portfolio de inversión con la función de maximizar la relación retorno y volatilidad esperada; (2) No hay costos impositivos ni de transacción, tanto en comisiones para la compra-venta de activos como también del *Bid-Offer Spread*, esto es la diferencia entre el máximo precio que un comprador esta dispuesto a pagar para comprar un activo y el precio mas bajo al que un vendedor esta dispuesto a obtener por el mismo; (3) Todos los inversores comparten la mismas expectativas respecto a la distribución de probabilidad de los retornos de los activos; (4) Los inversores pueden tanto tomar prestado como colocar fondos a la tasa libre de riesgo. Este modelo se describe formalmente por la siguiente

$$E(r_i) = r_f + \beta_i (E(r_m) - r_f) + \alpha$$

Donde,

r_f es la tasa libre de riesgo

$E(r_m)$ es el retorno esperado del portfolio de mercado

β_i es la sensibilidad de los retornos del activo i a las variaciones de los retornos del mercado. Puede estimarse como $\frac{\sigma_{im}}{\sigma_m^2}$, el cociente de la covarianza de los retornos del activo i y el mercado y la varianza de los retornos de mercado.

α es el residuo o el retorno en exceso idiosincrático del activo

En este trabajo, trabajaremos con retornos netos de la tasa libre de riesgo por lo que, en el eventual cálculo del Sharpe ratio, este se reducirá al cociente entre retorno y volatilidad esperada. Como mencionamos, bajo CAPM, el riesgo idiosincrático de un activo i no está correlacionado con el de los otros activos, y este puede ser reducido a través de la diversificación. El inversor es compensado por tomar riesgo sistemático medido por β pero no por tomar riesgo específico asociado a α . Dado que el inversor tiene acceso a un activo considerado libre de riesgo, usualmente un bono del tesoro norteamericano, la elección del portfolio óptimo se reduce a la tangente a la frontera de portfolios eficientes con ordenada al origen en la tasa libre de riesgo, el cual, por definición, es el portfolio de máximo *Sharpe ratio*. Esta tangente se la denomina *Capital Market Line* y está definida por el sistema de ecuaciones:

$$t(x) = a + bx$$

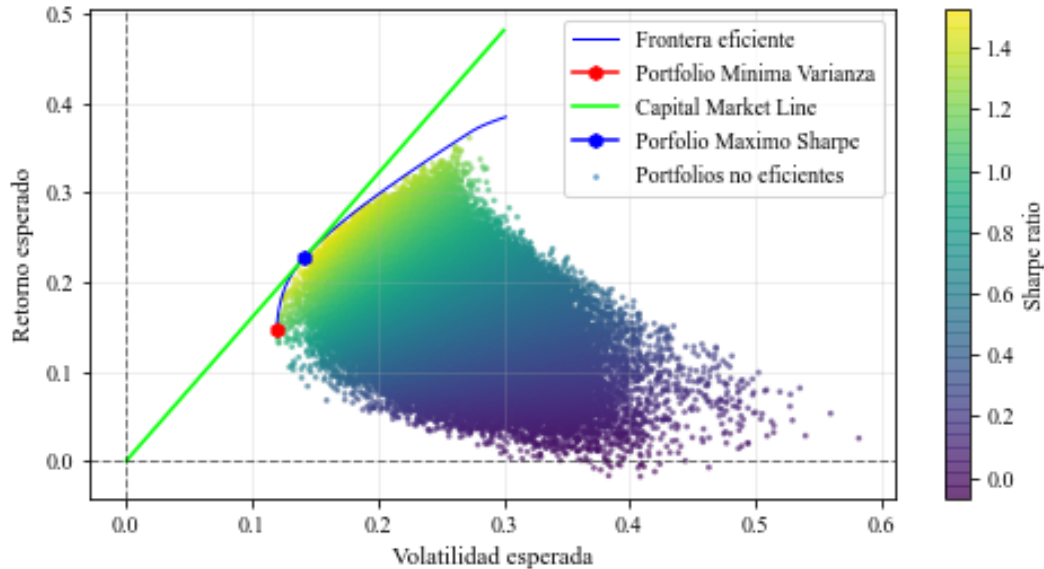
$$t(0) = r_f \Leftrightarrow a = r_f$$

$$t(x) = f(x) \Leftrightarrow a + bx = f(x)$$

$$t(x) = f(x) \Leftrightarrow b = f(x)$$

Siguiendo el ejemplo anterior e incorporando la *Capital Market Line* y *Sharpe ratio*:

Imagen 8



En la imagen 8 agregamos el concepto de *Sharpe ratio* y *Capital Market Line*, siendo los puntos de colores fríos los portafolios de menor *Sharpe* mientras que los de colores más cálidos aquellos con mayor *Sharpe ratio*. La *capital market line* resulta ser aquella recta con origen en la tasa libre de riesgo (en este ejemplo estamos trabajando con retornos netos de la tasa libre de riesgo, por lo que el origen es cero) tangente al portafolio de máximo *Sharpe ratio*. Es interesante notar en este gráfico la relación del nivel de la tasa libre de riesgo con el nivel de riesgo al que expone el portafolio de máximo *Sharpe*: ante un aumento de la tasa libre de riesgo, esta es la de los bonos del tesoro norteamericano, y resto constante, la pendiente de la *capital market line* disminuiría desplazando al portafolio de máximo *Sharpe* mas arriba en la frontera eficiente, es decir, llevando a los inversores a posicionarse en un portafolio más riesgoso a que el previo a la suba de la tasa.

El modelo no está libre de falencias, Best & Grauer (1991) demuestran su alta sensibilidad ante cambios en el vector de retornos esperados, principal *input* del modelo. Los autores divulgan como una pequeña variación en el retorno medio de un solo activo del vector produce un cambio significativo en el vector de ponderaciones óptimas, resultando en portafolios concentrados en pocos activos y altamente inestables. Por otro lado, DeMiguel, Garlappi y Uppal (2007) lleva adelante el proceso de evaluar la inestabilidad en la implementación empírica del portafolio propuesto por este modelo, sosteniendo que la teoría al utilizar el vector de retornos y matriz de covarianzas *in-sample*, es decir de muestras pasadas o históricas, los cuales tienden a distar de aquellos *out-of-sample*, incurre en carteras con ponderaciones extremas y altamente fluctuantes en el tiempo que performan mal o lejos de lo esperado. Este problema se

lo denomina error de estimación y hace alusión a la diferencia entre el valor estimado y el verdadero valor de un parámetro dado.

A modo de ejemplo, fijando los parámetros del modelo de vector de retornos esperados y matriz de covarianza esperada equivalente a la media simple de los retornos y matriz de covarianza calculados a partir de los retornos de todo el período del set de datos (desde 02-01-2010 al 31-12-2021), estimamos y obtenemos el portfolio óptimo *Mean-variance* de Harry Markowitz de la imagen 9 donde podemos observar lo mencionado.

Tabla 3

ETF	Nombre	Clase	Ponderación (%)
VTV	Vanguard Value	Renta Variable	0
VUG	Vanguard Growth	Renta Variable	17.5
SCHA	Schwab U.S. Small-Cap	Renta Variable	27.7
VYM	Vanguard High Dividend Yield ETF	Renta Variable	0
VEA	Vanguard FTSE Developed Markets	Renta Variable	0
EEM	iShares MSCI Emerging Markets	Renta Variable	0
SUSA	iShares MSCI USA ESG Select	Renta Variable	0
VNQ	Vanguard Real Estate	Renta Variable / REITs	0
TLT	iShares 10-20 Year Treasury Bond	Renta Fija	48.8
BWX	SPDR Barclays International Treasury Bond	Renta Fija	0
EMB	iShares J.P. Morgan USD Emerging Markets Bond	Renta Fija	0
GLD	SPDR Gold Shares	Commodities	5.9
DBC	Invesco DB Commodity	Commodities	0

Como resultado se obtiene un portfolio altamente concentrado en 4 de los 13 activos incluidos, con un restante de 9 activos recibiendo asignación nula. Portfolios altamente concentrados están expuestos a shocks idiosincráticos en aquellos activos donde se asigna tanto capital. Podemos notar que el activo que recibe mayor asignación de capital es TLT, ETF de bonos del tesoro norteamericano de madurez 10 a 20 años. Además, podemos ver que la estrategia asigna capital a las tres clases de activos: 45.2% a ETFs de renta variable (Vanguard Growth un 17.5% más Schwab U.S. Small-Cap otro 27.7%), un 48.8% a un ETF de renta fija y, en menor medida, un 5.9% al SPDR Gold Shares perteneciente a la clase de *commodities*. Por ello podemos observar que, a simple vista, este portfolio *Mean-Variance* esta balanceado en términos de sectores.

5.2 Fama-French 5 factores

Capital Asset Pricing Model, W. Sharpe (1964) y J. Lintner (1965), o CAPM, plantea que el retorno esperado de un activo, $E(r_i)$, es equivalente a la tasa libre de riesgo r_f , mas una prima de riesgo de mercado $E(r_m) - r_f$, ponderada por el beta del activo i , $\beta_{i,m}$, el cual puede ser interpretado como la sensibilidad de los retornos del activo i a las variaciones de los retornos del mercado:

$$CAPM \Rightarrow E(r_i) = r_f + \beta_{i,m} [E(r_m) - r_f]$$

Donde $\beta_{i,m}$ es el coeficiente estimado por mínimos cuadrados ordinarios.

Como extensión a lo anterior, el modelo Fama-French 3 Factores (Fama, French 1993) propone complementar CAPM incorporando dos factores adicionales:

- SMB: el retorno de un portfolo diversificado de empresas de baja capitalización de mercado, o *Small Caps*, en exceso al retorno de un portfolo diversificado de empresas de alta capitalización de mercado, o *Large Caps*.
- HML: el retorno de portfolo diversificado de empresas de bajo ratio Valor Libro-capitalización de mercado en exceso al retorno de un portfolo diversificado con ratios altos de Valor Libro-capitalización de mercado

Por lo que Fama-French 3 Factores se define:

$$FF3 \Rightarrow E(r_i) = r_f + \beta_1 [E(r_m) - r_f] + \beta_2 SMB + \beta_3 HML + e_i$$

Interpretando s_i como la relación de los retornos del activo (o portfolo) i al factor *Size* o capitalización de mercado y h_i como la relación de los retornos del activo i a el factor *Value* o ratio Valor Libro-capitalización de mercado.

Evidencia expuesta por Novy-Marx (2012), Titman, Wei, and Xie (2004) y demás autores demuestran que Fama-French 3 Factores es un modelo incompleto dado que estos factores no logran capturar las variaciones explicadas por otros factores como rentabilidad de las empresas e inversiones de estas. Este último factor busca diferenciar empresas agresivas de conservadoras, en función de su nivel de inversiones.

- RMW: el retorno de un portfolo diversificado de empresas alta rentabilidad por sobre el retorno de un portfolo diversificado de empresas de baja o débil rentabilidad.
- CMA: el retorno de un portfolo diversificado de empresas conservadoras por sobre el retorno de un portfolo diversificado de empresas agresivas.

Fama-French 5 Factores (Fama, French 2014) toman en consideración lo anterior e incorporan estos dos factores al modelo anterior:

$$FF5 \Rightarrow E(r_i) = r_f + \beta_1 [E(r_m) - r_f] + \beta_2 SMB + \beta_3 HML + \beta_4 RMW + \beta_5 CMA + e_i$$

En este trabajo, tomaremos los retornos de cada factor como dados, provistos por la base de datos de Kenneth R. French y Tuck School of Business at Dartmouth⁴. En la imagen 10, podemos ver cada uno de los cinco factores indexados a cero en el inicio de la serie observada.

⁴ https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library.html

Imagen 10



Dado nuestro objetivo de construir carteras balanceadas en riesgo que maximizan el *Sharpe* ratio ex-post, utilizaremos este modelo de Fama-French para obtener el portfolio con exposición más equilibrada posible a cada uno de estos cinco factores. Esto se obtiene de la siguiente manera: La exposición de un portfolio dado a los factores se mide a través de los coeficientes estimados de una regresión lineal donde la variable dependiente son los retornos del portfolio y las variables independientes son los retornos del factor. Para medir el desvío de la exposición a un factor, utilizaremos una función de pérdida o *Loss Function* similar a “Error Cuadrático Medio” o *MSE* por sus siglas en inglés. Esta estará definida como la sumatoria de los desvíos al cuadrado de los coeficientes estimados respecto de un valor objetivo. Dado que la idea es que cada factor contribuya equitativamente al riesgo del portfolio, el valor objetivo mencionado será igual al cociente entre 1 y la cantidad de factores, en este caso 5.

$$Loss Function = \sum_{i=1}^n \left(\beta_i - \frac{1}{N} \right)^2$$

Donde

β_i es el coeficiente estimado del factor i

N es la cantidad de factores, 5 en este caso.

Una vez definida la *loss function*, esta se introduce como función objetivo a minimizar en un optimizador y, consecuentemente, el optimizador nos retorna como portfolio óptimo aquel que ofrezca la exposición más equitativa a cada uno de los 5 factores, es decir, aquel que minimiza la *loss function*.

Siguiendo el ejercicio del final de la sección anterior y tomando el set de datos completo de los 30 activos (desde 02-01-2008 al 31-12-2020) y estimando el portfolio óptimo según el algoritmo de Fama-French 5 Factores obtenemos el portfolio de la imagen 11.

Tabla 4

ETF	Nombre	Clase	Ponderación (%)
VTV	Vanguard Value	Renta Variable	0
VUG	Vanguard Growth	Renta Variable	0
SCHA	Schwab U.S. Small-Cap	Renta Variable	3.1
VYM	Vanguard High Dividend Yield ETF	Renta Variable	0
VEA	Vanguard FTSE Developed Markets	Renta Variable	0
EEM	iShares MSCI Emerging Markets	Renta Variable	0
SUSA	iShares MSCI USA ESG Select	Renta Variable	0
VNQ	Vanguard Real Estate	Renta Variable / REITs	34.4
TLT	iShares 10-20 Year Treasury Bond	Renta Fija	28.8
BWX	SPDR Barclays International Treasury Bond	Renta Fija	14.1
EMB	iShares J.P. Morgan USD Emerging Markets Bond	Renta Fija	19.6
GLD	SPDR Gold Shares	Commodities	0
DBC	Invesco DB Commodity	Commodities	0

Al igual que el portfolio de *Mean-variance*, obtenemos un portfolio concentrado donde también un ETF de *treasuries* es el que recibe mayor ponderación en el portfolio pero que, a diferencia del de Media-varianza, asigna capital a ETFs de renta variable como IJR y XLU. Estos son ETFs de empresas de baja capitalización de mercado y empresas del sector de *utilities*, respectivamente. También lo hace, pero en menor medida, en un ETF de commodities y otro de *real state*. La exposición a los 5 factores de este portfolio óptimo está dada como en la tabla 5.

Tabla 5

Factor	Abreviatura	Exposición
Prima de riesgo de mercado	Mkt-RF	29.8%
<i>Small Caps vs. Large Caps</i>	SMB	14.1%
<i>Low Value vs. Growth</i>	HML	6.3%
<i>Robust vs. Weak</i>	RMW	18.6%
<i>Conservative vs. Aggressive</i>	CMA	9.4%

En este trabajo, por motivos de simplicidad y extensión, utilizamos una regresión lineal multivariada para estimar la exposición a los factores. Esta no es la única alternativa apta para tal tarea, en la práctica se podría probar con otros tipos de regresiones como por ejemplo Lasso o Ridge, entre otras.

5.3 Risk Parity

Risk Parity es un concepto concebido por Edward E. Qian y hace referencia a la idea encontrar la combinación de ponderaciones que dé como resultado que cada activo contribuya equitativamente en términos de volatilidad o riesgo esperado al portfolio. Algebraicamente esto se resuelve definiendo la ponderación w_i de cada activo proporcionalmente a su volatilidad σ_i y luego normalizando para que la suma de las ponderaciones sume uno y cumplan con las condiciones de no posiciones *short* ni apalancamiento.

$$w_i = \frac{\frac{1}{\sigma_i}}{\sum_{i=1}^n \frac{1}{\sigma_i}}$$

Sujeto a:

$$0 \leq w_i \leq 1$$

$$\sum_{i=1}^n w_i = 1$$

La literatura también llama a esta estrategia como “*Naive Risk Parity*” o “*Inverse Variance Portfolio*” dado que ignora la información que puede haber en la matriz de correlaciones. Podemos también notar que Risk Parity no toma como input ningún vector de retornos esperados.

Se puede comprobar que, cuando las volatilidades de todos los activos son equivalentes entre sí, el portfolio Risk Parity es equivalente al portfolio benchmark 1/N. La tabla 4 muestra la asignación de la estrategia Risk Parity, tomando nuevamente como en las secciones anteriores los retornos de todo el set de datos disponible.

Tabla 6

ETF	Nombre	Clase	Ponderación (%)
VTV	Vanguard Value	Renta Variable	4.6
VUG	Vanguard Growth	Renta Variable	4.9
SCHA	Schwab U.S. Small-Cap	Renta Variable	4.6
VYM	Vanguard High Dividend Yield ETF	Renta Variable	5.4
VEA	Vanguard FTSE Developed Markets	Renta Variable	3.9
EEM	iShares MSCI Emerging Markets	Renta Variable	2.3
SUSA	iShares MSCI USA ESG Select	Renta Variable	5.4
VNQ	Vanguard Real Estate	Renta Variable / REITs	1.9
TLT	iShares 10-20 Year Treasury Bond	Renta Fija	9.3
BWX	SPDR Barclays International Treasury Bond	Renta Fija	28.2
EMB	iShares J.P. Morgan USD Emerging Markets Bond	Renta Fija	17.1
GLD	SPDR Gold Shares	Commodities	6.5
DBC	Invesco DB Commodity	Commodities	5.7

Observamos que se obtiene un portfolio que, en contraste a los dos modelos previos, todos los activos reciben algún nivel de asignación de capital, con algo de mayor concentración en los activos de renta fija. En este caso, los activos TLT, BWX y EMB son los que mayor ponderación en la cartera reciben. Esto se debe a la marcada baja volatilidad que ofrecieron estos activos en comparación al resto, lo cual lo podemos observar a simple vista en la tabla 2. Por otro lado, en este ejemplo esta estrategia de construcción de portfolios asigna 5.7% de ponderación en la cartera a DBC, el cual como visto en la tabla 3 es un activo ligado a los commodities que, históricamente, demostró tener un retorno negativo en exceso a la tasa libre de riesgo. A diferencia de las dos estrategias anteriores que asignaban nula ponderación a un activo de estas características. Es acá donde se puede notar la diferencia entre *Risk Parity* y los anteriores modelos como *Mean-variance* y Fama-French 5 Factores: *Risk Parity* ignora por completo la información disponible acerca de los retornos y, como se ve en este ejemplo, asigna capital a un activo con retorno medio negativo, en exceso a la tasa libre de riesgo. En las próximas secciones donde analizaremos y compararemos la performance de los distintos modelos, se podrá ver en mayor profundidad el impacto en la performance de lo mencionado.

Como visto, *Risk Parity* tiene un enfoque totalmente distinto a las dos primeras estrategias introducidas. Esta estrategia no involucra la estimación de un vector de retornos esperados por lo que no cae en los problemas mencionados que trae esa estimación, denominado error de estimación. De esta manera, *Risk Parity* propone que lo óptimo es la equitativa contribución del riesgo de cada activo individual al riesgo total del portfolio, así asignando mas capital a aquellos activos cuyos retornos diarios presentaron menor desviación de su media, históricamente hablando.

5.4 Hierarchical Risk Parity

Esta estrategia o modelo, si bien parte del concepto de paridad de riesgo (como su nombre lo indica), visto previamente, tiene un enfoque distinto a introducir a continuación. Este no garantiza mejores o peores resultados, pero resulta interesante incorporar al trabajo una estrategia que presente estas alternativas. Su autor, Marcos López de Prado, ha contribuido a modernizar y proponer la adopción de nuevas herramientas de la rama denominada *Machine Learning*, subcampo de las ciencias de la computación y, más específicamente, de la inteligencia artificial. Como define Gerón (2004): (*Machine Learning*) Es la ciencia (y arte) de programar computadoras para que puedan aprender de los datos. Lopez de Prado refiere a los métodos de *Machine Learning* en el campo de las finanzas como herramientas para conocer los patrones de múltiples dimensiones inherentes en las estructuras de los datos con el fin de entender qué *features* o variables explicativas tienen relevancia alguna para ayudar a elaborar teorías y explicaciones, con robustez estadística, sobre dinámicas presentes en el día a día de los mercados. Dicho este, procedemos a explicar en que consiste *Hierarchical Risk Parity*.

La matriz de covarianza, uno de los principales inputs de los modelos clásicos como Markowitz, carece de la noción de jerarquía. Es decir, todos los activos son potenciales sustitutos entre sí, sin importar sus características. López de Prado (2016) plantea que los activos pueden ser agrupados en función de su clase, sector económico, geografía, capitalización de mercado, liquidez, etc. y luego estos en cada grupo compiten entre sí por asignación de capital en el portfolio, por lo que no todos los activos son potenciales sustitutos de todos.

El algoritmo trabaja en tres etapas: agrupación en árboles, cuasi-diagonalización y bisección recursiva.

(i) Agrupación en árboles

El objetivo de esta primera etapa es clasificar los activos a observar en distintos grupos. Para ello, el autor utiliza el algoritmo “Hierarchical Tree Clustering”.

Partiendo de la matriz de retornos indexados por tiempo, de dimensión $T \times N$ donde T es el índice temporal y N el número de activos, calcula la correlación de los retornos de cada activo con el resto, resultando en la matriz de correlaciones ρ . Luego, a partir de la matriz de correlaciones, se obtienen dos matrices de distancia euclidiana D y \bar{D} .

$$D(i, j) = \sqrt{\frac{1}{2} (1 - \rho_{i,j})}$$

$$\bar{D}(i, j) = \sqrt{\sum_{k=1}^n (D(k, i) - D(k, j))^2}$$

Donde

$\rho_{i,j}$ es el coeficiente de correlación de Pearson entre el activo i y el activo j

D es la distancia euclidiana entre dos activos mientras que \bar{D} se interpreta como la similitud de dos activos respecto al resto.

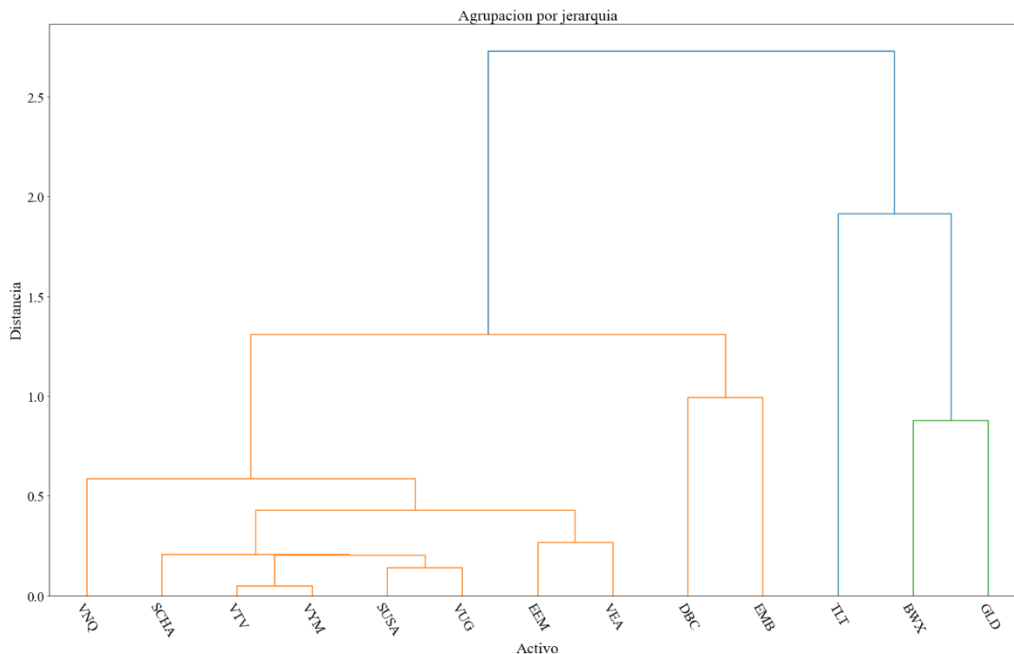
Paso siguiente, construye los grupos o *clusters*, denotados como $U[1]$.

$$U[1] = \operatorname{argmin}_{i,j} \bar{D}(i, j)$$

Se actualiza la matriz D , calculando la distancia entre el nuevo *cluster* con los otros activos. Además, también se actualiza \bar{D} , incorporando $D_{i, U[1]}$ en lugar de $D_{i,j}$, también eliminando las filas y columnas de $j \in U[1]$.

Al aplicar los pasos anteriores de manera recursiva, se obtiene la matriz D con $N - 1$ clusters. Podemos visualizar el resultado de este algoritmo de agrupación a través del siguiente dendograma.

Imagen SEQ Imagen * ARABIC 14



En primer lugar, podemos notar que el algoritmo agrupo dos grandes clusters: por un lado TLT, BWX y GLD, y por el otro lado todos los ETFs de renta variable, más el de commodities y renta fija de mercados emergentes. Es interesante de remarcar que haya ubicado al ETF del oro (GLD) junto al ETF de *treasuries* y bonos en moneda local de países *investment grade*, dado que el oro suele ser asemejado como un vehículo de reserva de valor en contextos de stress. Si bien el algoritmo no poseía información al respecto de esto, lo pudo deducir a partir de los retornos diarios del ETF y la matriz de correlaciones.

Yendo al otro *cluster*, se observan agrupaciones interesantes de destacar. Por un lado, agrupa al par DBC-EMB, el ETF de commodities y al de bonos de mercados emergentes. Resulta interesante dado que los fundamentos que explican la performance de bonos de mercados emergentes suelen estar muy ligados al perfil exportador de materias primas de estos países, es decir, suelen oscilar con los ciclos de commodities que se experimentan en los mercados. Luego el par EEM-VEA, agrupados en otro sub grupo, si bien son ETFs de renta variable, estos son de empresas de países fuera de estados unidos por lo que es justificado que se encuentren clasificados un sub grupo ajeno al del resto de los ETFs de renta variable. Luego encontramos al resto de los ETFs de renta variable en otro subgrupo, todos pertenecientes a empresas del mercado norteamericano, aunque de distintas temáticas o factores como ESG, acciones de crecimiento, de valor, de baja capitalización bursátil y de alta tasa de dividendos. Por último, separado encontramos al ETF de REITs, es decir, de empresas encargadas de invertir en el sector de bienes raíces, lo que también hace sentido encontrarla en otro subgrupo separado dado que son todas empresas de un sector totalmente distinto de la economía al resto, y ello se manifiesta en la matriz de correlaciones.


(ii) Cuasi-diagonalización

Este paso buscar reorganizar las filas y columnas de la matriz de correlaciones para que los valores más altos se encuentren cerca de la diagonal principal y que activos similares sean ubicados cerca uno de otros mientras que activos disimilares los más alejado posible. Como resultado se obtiene, a partir

de la matriz de correlaciones original, una matriz con valores equivalentes a la original pero reorganizada para mostrar los *clusters* inherentes.

Gráficamente se puede representar en las siguientes dos figuras.

Imagen 15



(iii) Bisección recursiva

El último paso del algoritmo consiste, en función de la matriz de correlaciones transformada en los anteriores pasos, determinar las ponderaciones de cada activo para conformar el portfolio final. La función para determinar estas ponderaciones es similar a la vista en la sección anterior de *Risk Parity*, donde a cada activo se le asigna una ponderación en proporción inversa a su varianza.

Primero, se determina la ponderación w_i de que cada activo i equivalente a 1. Se toma el gran cluster obtenido en el paso (i) seguido de ramificaciones de *clusters* más reducidos y con activos a menor distancia intragrupo. Luego, de arriba abajo, a cada *cluster* se lo particiona en dos sub-*clusters* V_1 y V_2 utilizando la matriz obtenida en (ii). Para cada sub-*cluster* se calcula su varianza.

$$\bar{V} = w^T V w$$

Donde

$$w = \frac{\text{diag}[V]^{-1}}{\text{traza}(\text{diag}[V]^{-1})}$$

Se computan factores divisores α para cada sub-*cluster*

$$\alpha_1 = 1 - \frac{V_1}{V_1 + V_2}$$

$$\alpha_2 = 1 - \alpha_1$$

Por último, se actualiza la ponderación de cada activo en cada sub-*cluster* a través de los factores anteriores.

$$w_1 = w_1 \alpha_1$$

$$w_2 = w_2 \alpha_2$$

Los anteriores pasos de esta sección se llevan adelante recursivamente hasta que todos los activos reciben una ponderación. Dada la forma de arriba a abajo en que se ejecuta el algoritmo, se cumple la idea principal de que solo activos de un mismo *cluster*, es decir, activos de similares características compitan entre ellos por participación en el portfolio.

Como al final de las secciones anteriores, llevamos adelante a modo de ejemplo la estimación del portfolio óptimo según este modelo tomando como input los retornos del set de datos completo. Dicho portfolio lo podemos ver en la imagen 16 y volvemos a notar a como en *Risk Parity*, la mayor concentración en ETFs de renta fija (TLT, BWX y EMB). Al igual que *Risk Parity*, no hay activos con ponderación nula.

Tabla 7

ETF	Nombre	Clase	Ponderación (%)
VTV	Vanguard Value	Renta Variable	2.8
VUG	Vanguard Growth	Renta Variable	4.4
SCHA	Schwab U.S. Small-Cap	Renta Variable	6.1
VYM	Vanguard High Dividend Yield ETF	Renta Variable	1.7
VEA	Vanguard FTSE Developed Markets	Renta Variable	1.9
EEM	iShares MSCI Emerging Markets	Renta Variable	1.1
SUSA	iShares MSCI USA ESG Select	Renta Variable	1.7
VNQ	Vanguard Real Estate	Renta Variable / REITs	2.6
TLT	iShares 10-20 Year Treasury Bond	Renta Fija	17.9
BWX	SPDR Barclays International Treasury Bond	Renta Fija	28.7
EMB	iShares J.P. Morgan USD Emerging Markets Bond	Renta Fija	18.2
GLD	SPDR Gold Shares	Commodities	6.6
DBC	Invesco DB Commodity	Commodities	6.1

6. Portfolio Benchmark “1/N”

El porfolio de referencia o *benchmark* para contrastar la performance de las distintas estrategias será un “*Naive Portfolio*” o “1/N”, donde cada activo tendrá la misma ponderación en la cartera. El cálculo de la ponderación a asignar a cada activo está dado por:

$$w_i = \frac{1}{N}$$

Donde,

w_i es la ponderación en la cartera del activo i

N es la cantidad de activos

Como se ve, no implica ninguna optimización ni estimación como así también ignora por completo la relación que puede existir de los activos entre sí, es decir, no contempla la matriz de varianzas y covarianzas.

Como describe Jurzenko (2015), si bien el portfolio “1/N” parece una metodología de asignación de activos dentro de todo simple, esta presenta algunas características importantes de remarcar. En primer lugar, 1/N evita portfolios concentrados y, en consecuencia, poco expuesto a shocks idiosincráticos de un activo en particular. Además, con el objetivo de mantener las posiciones equitativamente distribuidas, el algoritmo de 1/N implica un rebalanceo periódico teniendo que desprenderse de activos que sobre-performaron e incrementaron su participación en la cartera y simultáneamente incorporando activos que sub performaron, por lo que en el fondo es una estrategia que se beneficia de las reversiones. Por otro lado, dependiendo la frecuencia en la que se especifique el rebalanceo, el *turnover* de la cartera o la frecuencia con la que ingresamos y quitamos activos de esta se puede volver alto. Un alto *turnover* significa incurrir más gastos de transacción que restan a la potencial performance de la cartera. De todas maneras, en este trabajo asumiremos costos de transacción equivalentes a cero. Otra característica, es que en el caso de que el universo de activos donde trabajemos incluya algunos con escasa liquidez, el portfolio 1/N va a tomar posición en ellos exponiéndose a potenciales riesgos de iliquidez en la entrada y salida de las posiciones.


En la tabla 4 vemos el portfolio 1/N. Este se reduce a asignar mismas proporciones de capital a cada uno de los activos disponibles. El riesgo idiosincrático, a priori, es menor a que en los modelos tradicionales de construcción de portfolios como *Mean-variance*, dado que no expone al inversor a grandes asignaciones de capital a un activo individual.

Tabla 8

ETF	Nombre	Clase	Ponderación (%)
VTV	Vanguard Value	Renta Variable	7.7
VUG	Vanguard Growth	Renta Variable	7.7
SCHA	Schwab U.S. Small-Cap	Renta Variable	7.7
VYM	Vanguard High Dividend Yield ETF	Renta Variable	7.7
VEA	Vanguard FTSE Developed Markets	Renta Variable	7.7
EEM	iShares MSCI Emerging Markets	Renta Variable	7.7
SUSA	iShares MSCI USA ESG Select	Renta Variable	7.7
VNQ	Vanguard Real Estate	Renta Variable / REITs	7.7
TLT	iShares 10-20 Year Treasury Bond	Renta Fija	7.7
BWX	SPDR Barclays International Treasury Bond	Renta Fija	7.7
EMB	iShares J.P. Morgan USD Emerging Markets Bond	Renta Fija	7.7
GLD	SPDR Gold Shares	Commodities	7.7
DBC	Invesco DB Commodity	Commodities	7.7

En la siguiente imagen podemos ver los retornos acumulados para todo el set de datos y contrastando contra el portfolio “de mercado”, el ETF del índice Standard & Poors 500. En el periodo desde el inicio de la ventana observada hasta casi los comienzos del 2014, el portfolio “1/N” acumulo mejor performance que el Standard & Poors 500, no así para el periodo restante que le sigue donde la diferencia se revierte notablemente. No dejamos de mencionar que tal comparación no termina ser del todo justa dado que los universos de activos en donde cada portfolio puede invertir no son iguales, pero no deja de ser interesante llevar adelante el paralelismo. Otro punto a destacar no menor son las correcciones o caídas que experimentan ambos portfolios, a simple vista estos tienden a ser menores en el “1/N”, por ejemplo, durante el periodo del año 2018 y mas aun en la gran corrección de marzo del año 2020.

Imagen 17



7. Metodología para la evaluación de performance

En esta sección describiremos el proceso para evaluar la performance de cada una de las estrategias de construcción de portafolios bajo estudio, para así luego comparar y contrastar resultados entre ellas.

7.1 Muestreo

Dado que el objetivo del trabajo es observar si existe evidencia estadística de si las estrategias descritas en el apartado anterior ofrecieron performance ajustada por riesgo superior a la del portafolio *benchmark*, paso siguiente es definir este proceso.

La idea general de llevar adelante una simulación histórica de una estrategia de trading o asignación de activos se la denomina *backtesting*. Consiste en aplicar una estrategia o algoritmo de inversión sobre las series de precios históricos de un set de activos para analizar ex-post como esta se comportó.

Metodologías de *backtesting* hay muchas, aunque, por defecto, la noción básica de este proceso se la tiende asociar simplemente con una simulación histórica habiendo múltiples variables y matices de este tema. De hecho, el *backtesting* es una rama dentro de las finanzas cuantitativas sujeto a una profunda investigación y desarrollo, dado que este es el proceso encargado de darle validez o no a potenciales estrategias de inversión. Es por ello que procederemos a introducir las distintas variantes disponibles para tanto investigadores como inversores, para luego detallar la que será usada en este trabajo. Si bien hay múltiples alternativas, cada una con sus propias características, todas están altamente expuestas a errores y sesgos durante su implementación. Como describe Yin Luo (2014), existen principalmente siete errores o sesgos usualmente cometidos durante el proceso de *backtesting*:

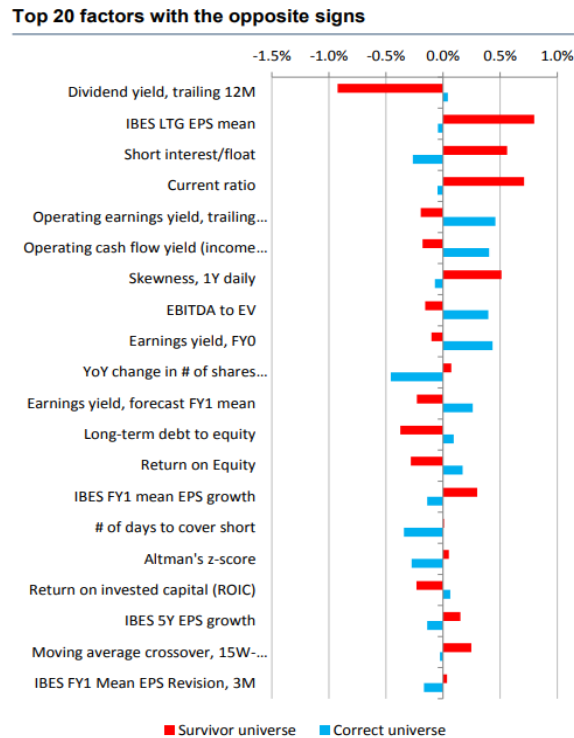
1. **Sesgo de supervivencia:** este tipo de sesgo es uno de los principales y en el que incurren la gran mayoría de los *backtesting*. Este es una forma de sesgo de selección y, en el campo de las finanzas y mercados, hace referencia a usar como universo de inversión el actualmente disponible, es decir, ignorando empresas que fueron sacadas del mercado producto de haber quebrado o adquiridas por otra firma, o también títulos de deuda que cayeron en default. En la práctica, inversores e investigadores suelen llevar adelante el proceso de *backtesting* con un universo de activos que esta disponible hoy, dejando de lado aquellas que dejaron de existir, lo que eventualmente hubiera afectado la performance de la estrategia de inversión. Este es uno de los sesgos más frecuentemente incurridos. El sesgo de supervivencia lleva a tener una impresión más optimista de lo que se hubiera obtenido si se hubiese utilizado un universo de activos corregido por ello, es decir, teniendo en consideración aquellas acciones de empresas que desaparecieron y cuyo valor tendió a cero.

Un claro ejemplo es si estuviésemos analizando una estrategia de construcción de un portafolio para invertir en el sector de bancos de inversión y en nuestro universo de activos incluimos a JPMorgan Chase, Goldman Sachs, Morgan Stanley, Citigroup, entre tantos otros, pero excluimos a Lehman Brothers, Bear Stearns y Merrill Lynch. En la crisis del 2008, Lehman Brothers se declaró en banca rota mientras que Bear Stearns y Merrill Lynch fueron absorbidos por JPMorgan Chase y Bank of America, respectivamente, a valores históricamente bajos o de liquidación. Claramente, si hiciéramos un *backtesting* de la estrategia de inversión, sea cual sea, lo más probable es que el resultado de esta sería significativamente distinto si en el universo de activos disponibles para invertir se hubiese excluido los tres bancos gravemente afectados durante el 2008 a que si los hubiésemos incluido.

En la imagen 18, podemos observar lo mencionado: métricas o factores utilizados por modelos y estrategias de construcción de carteras para clasificar y decidir si introducir o no empresas en un portfolio demuestran performance totalmente distinta, hasta incluso de signo y magnitud opuesta, cuando se corrige y ajusta el universo de activos por el sesgo de supervivencia.

Imagen 18

Fuente: *Seven Sins of Quantitative Investing, Deutsche Bank Quantitative Strategy (2014)*



El trabajo de investigación muestra que, observando el índice Russell 3000, el cual sigue y da exposición a la totalidad del mercado de acciones norteamericanas, solo aproximadamente 500 de las 3000 empresas que estaban en el índice a la fecha del 31 de diciembre del 1986 “sobrevivieron” o continuaban existiendo a la fecha de la elaboración del trabajo, septiembre del 2014.

2. **Sesgo de anticipación o look-ahead bias:** hace referencia al habitual uso de información o datos que no estaban públicamente disponibles al momento de realizar la simulación de la toma de una decisión de inversión. Este sesgo está más asociado con información de los fundamentos de las empresas como por ejemplo el reporte de sus resultados financieros: no todas las empresas reportan sus resultados el mismo día, y ello se suele perder o confundir en un set de datos. La más común solución para ello es hacer un *lag* o atrasar este set de datos, asumiendo que no se conocían los resultados financieros hasta una fecha x , de ninguna de las empresas del universo elegido. Por convención, este *lag* se suele establecer en 3 meses calendario. Otros ejemplos de sesgo de anticipación son los *splits* y *reverse-splits*, acciones corporativas con el fin de captar mayor liquidez, entre otros y la corrección o *restatements* de datos ya reportados por parte de la fuente, algo que también suele ocurrir para variables económicas como producto, índices de precios, resultados fiscales, etc.

3. **Narración o *Storytelling***: consiste en crear una “historia” o narrativa con el objetivo de justificar y argumentar un resultado que en realidad tiene las características de aleatoriedad o casualidad, careciendo de relevancia estadística. Esto se suele dar dado que, al trabajar con series de tiempo, se debe tomar una decisión de elegir ventanas de tiempo para observar algunas métricas como media, desvío standard, coeficiente de correlación, entre tantos otros. Elegir una ventana, por ejemplo, de 20 días o 250 días puede dar resultados totalmente distintas que deberían ser analizadas con detenimiento a la hora de tomar conclusiones a partir de ellas. Lo mismo en cuanto a qué tan atrás en el tiempo debemos irnos para realizar el *backtesting*. Idealmente lo más atrás posible y tengamos disponible las series de datos que vamos a utilizar para nuestros modelos o estrategias de inversión. Además, distintos ciclos de mercado pueden dar una idea distinta respecto a un factor o comportamiento de un activo respecto a otro, es por eso la importancia de contar con la presencia de distintos ciclos económicos y de mercado en el set de datos con el que trabajar. Por ejemplo, si observamos el factor *value* del sector tecnológico entre los años 1997 al 2000, el factor tuvo una atribución a la *performance* relativamente malo, empresas mas ligadas a la clasificación *growth*, es decir, con altas tasas de crecimiento y altos múltiplos de valuación performaron notablemente mejor que aquellas más de carácter de *value*. Para el año 2000, dado el conocido desenlace de la burbuja *dot com*, la tendencia previa se revirtió bruscamente. Conclusiones o referencias respecto a cada uno de los factores pueden ser completamente opuestas o encontradas dependiendo de la ventana de tiempo y momento de la historia que se toma para su análisis, por ello la importancia de tener presente la posible presencia de este sesgo o error.
4. ***Data mining* y *data snooping***: refiere a la exhaustiva búsqueda y optimización de parámetros, patrones y reglas de inversión que den como resultado la mejor performance *in-sample* del modelo o estrategia, pero luego cuando se pasa a medir y evaluar la misma *out-of-sample*, la performance decae significativamente. Para los autores, es uno de los errores o sesgos más difíciles de corregir y evitar en su totalidad.
5. **Costos de transacción**: comúnmente los procesos de *backtesting* suelen no tener en consideración e incluso pasar por alto la mención de los costos de transacción que erosionan la performance de cualquier estrategia de inversión y a los que están expuestos todos los inversores, en mayor o menor medida en función de su *turnover*, es decir, con qué frecuencia se compran y vendan activos de una cartera. Estrategias con mayor *turnover* están más expuestas a estos costos de transacción. Estos refieren a comisiones que deben pagar lo inversores a intermediarios para comprar o vender activos, como así también al *Bid-Offer spread* (mencionado en secciones previas) el cual se incrementa considerablemente en activos de baja liquidez como así también para todo el mercado en general durante periodos de stress y crisis de mercado. Además, simular históricamente los costos de transacción para cada momento requeriría tener acceso e interactuar con libro de operaciones (*trading book*) de los distintos mercados, tarea casi imposible dada su complejidad técnica como así también el alto costo de acceso a esa información.
6. ***Outliers***: refieren a presencia de valores atípicos en el set de datos, generalmente causados por errores en los datos o eventos específicos con baja probabilidad de volver a ocurrir en un futuro y que pueden llevar a tomar conclusiones sesgadas si estos se presentan durante el *backtesting* de una estrategia.
7. ***Shorting***: para tomar una posición de venta en corto o *short* es necesario encontrar una contraparte u otro inversor que te alquile el activo a vender en corto en el mercado y, posteriormente, recomprarlo idealmente a precio más bajo así beneficiándose de una caída en su precio de mercado. Es decir, el activo debe estar disponible para ello y no todos los activos están siempre disponibles para venderlos en corto. Usualmente en los procesos de *backtesting*,

estrategias que no tienen la restricción de posiciones *short*, asumen que todos los activos se encuentran siempre disponibles para vender en corto y por el tiempo que la estrategia lo demande. Este supuesto no suele ser así en la realidad. La disponibilidad para alquilar los activos y los costos de ello son desconocidos para el inversor, más aún en periodos de mayor incertidumbre de mercado como durante las correcciones y crisis.

Como vemos, el proceso de *backtesting* es altamente sensible a estar sesgado por múltiples razones previamente mencionadas. De todas maneras, no todos los potenciales sesgos y errores afectan a todos los *backtesting*, pero es de gran importancia estar informado, tener en consideración la existencia de estos y cuándo podemos estar ante la presencia de ellos para evitar conclusiones sesgadas. Por ejemplo, un modelo o estrategia de inversión que lo única fuente de datos que utiliza para tomar decisiones de inversión son las series históricas de los precios de los activos del universo seleccionado, no va a estar lidiando con el sesgo de anticipación dado que los precios de los activos provienen todos de la misma fuente y cotizan diariamente en los mismos mercados. Sus nuevos valores son conocidos todos al mismo tiempo una vez que finaliza la sesión de operatoria bursátil diaria. Lo mismo sucede con el supuesto de *shorting* o venta en corto, este no tiene incidencia si estamos trabajando con una estrategia que, de antemano, tiene la restricción de no tomar posiciones en corto.

En cuanto a variantes de *backtesting*, podemos encontrar las siguientes tres principales:

1. **Vanilla:** se trata de la alternativa más simple. consiste en dividir el set de datos en dos: un set se llamado *in-sample* o set de entrenamiento, que se usara para estimar el modelo y sus parámetros (vector de retornos esperados, volatilidad y matriz de covarianzas por ejemplo para el caso de *Mean-variance*), y un segundo set denominado *out-of-sample* o set de testeo a utilizar para evaluar la performance de la estrategia.
2. **Walk-forward:** esta es una extensión de la previa y consiste en una ejecución en cadena de múltiples *Vanilla backtestings*, donde, los sets *in-sample* y *out-of-sample* se van desplazando sucesivamente a lo largo del periodo observado y en orden cronológico. Este es uno de los métodos más utilizados en la práctica por su clara interpretación histórica y es la metodología que se empleara para este trabajo y explicaremos en mayor profundidad luego.
3. **K-Fold cross validation:** el concepto de la validación cruzada de K iteraciones es buscar testear la estrategia o modelo bajo estudio en k escenarios alternativos, de los cuales solo uno corresponde al histórico. Esta metodología es de común uso en tareas de *Machine Learning*. La metodología consiste en particionar el conjunto de datos en k subconjuntos y luego para $i = 1, 2, \dots, k$, iterar entrenando o estimando el modelo en los $k-i$ subconjuntos para luego testear su performance en el subconjunto apartado i . Si bien esta alternativa permite estudiar la estrategia bajo múltiples escenarios, no solo el histórico, tiende a recibir criticas dado que asume que los datos cuentan con la característica estadística de ser aleatorias, idénticas e independientemente distribuidos.

Como mencionado, en este trabajo la metodología específica de *backtesting* será la denominada *walk-forward* o semejante a *rolling-window* empleada en DeMiguel, Garlappi, Nogales y Uppal (2009). El proceso consiste, en primer lugar, denotar la longitud t de la ventana temporal donde estimar el portfolio, cumpliendo con $\tau < T$, siendo T la longitud total de las series con las que trabajamos. Segundo, calculamos cada portfolio usando los datos de la ventana t . En tercer lugar, repetimos lo anterior para el siguiente período t y dejando de lado el período anterior. Este proceso se lleva adelante recursivamente hasta el final del set de datos. Hacia el final, vamos a tener $T - \tau$ vectores de ponderaciones w_t para cada estrategia, es decir, w_t^i para $t = \tau, \dots, T - 1$ y para cada estrategia i . Paso cuarto, consiste en medir la

performance *out-of-sample* del portfolio i dado por w_t^i en el siguiente período: $r_{t+1}^i = w_t^{i^T} r_{t+1}$, donde r_{t+1}^i es el retorno del portfolio i y r_{t+1} los retornos de los activos en el siguiente período.

Gráficamente este proceso se puede ver en la siguiente imagen:

Imagen 19

Backtesting via Walk-Forward

	t_0	t_1	t_2	...	t_{n-1}	t_n
iteracion 1	Estimar portfolio optimo	Evaluar performance				
iteracion 2		Estimar portfolio optimo	Evaluar performance			
iteracion 3			Estimar portfolio optimo	Evaluar performance		
...				Estimar portfolio optimo	Evaluar performance	
iteracion n					Estimar portfolio optimo	Evaluar performance

Como se observa gráficamente, en t_0 se estima el portfolio óptimo según el modelo que se este analizando y tal como descrito en la sección 5. Una vez estimados esos *weights* o ponderaciones objetivo, el inversor compra esa cartera a precios de cierre del día. Esto último es por simplicidad del trabajo, dado que no se cuentan con series históricas del *bid* y *offer* para cada activo a los que el inversor podría comprar y vender activos a precios más representativos que el precio de cierre ajustado. Ello implica tomar el supuesto de que los inversores no tienen costos de transacción de los activos en el mercado. Una vez posicionado en el portfolio óptimo el inversor permanecerá comprado durante todo el periodo y, finalizado este tiempo, volverá a repetir tal proceso de estimar el portfolio óptimo en el que invertirá por el siguiente periodo t_1 y así sucesivamente hasta el periodo t_{n-1} . Como se ve, en el periodo t_n no se estima ningún portfolio ya que es donde finaliza el proceso. En paralelo, una vez llegado y finalizado el periodo t_i , ya dispondrá de los resultados de su inversión durante el respectivo periodo y podrá tomar las métricas de evaluación de performance a describir en la sección a continuación. Al igual que con el proceso de estimación del portfolio, el procedimiento de evaluación de performance se lleva adelante sucesivamente hasta el último periodo.

En la figura de arriba, el período τ de estimación es equivalente al período de evaluación de performance. Es importante destacar que esto no tiene que ser necesariamente así, es decir, los periodos para la estimación y horizontes de rebalanceo no tienen que coincidir. En este trabajo tendremos en cuenta esto para analizar los resultados en distintas combinaciones de estos dos parámetros. Siguiendo, por ejemplo, dado que el set de datos de este trabajo es de frecuencia diaria, fijando $\tau = 20$, usaremos los retornos de las últimas 20 sesiones de mercado para determinar el portfolio óptimo, en el cual invertiremos por las siguientes 20 ruedas. Al término de estas 20 ruedas, evaluaremos la performance del portfolio y volveremos a estimar el nuevo portfolio óptimo para el siguiente período, y así iterando hasta el final del set de datos. Cabe mencionar que no necesariamente tiene que ser iguales, es decir, podemos realizar el ejercicio con un período de estimación de 240 ruedas y un período de evaluación de 20 ruedas, o la combinación que queramos analizar.

Como describe López de Prado (2018), esta metodología tiene dos ventajas por sobre otros métodos: (1) una clara interpretación histórica dado su carácter cronológico y (2) evaluación de performance *out-of-sample*, es decir, el set de datos donde se evalúa la performance de la estrategia no fue utilizado ni está superpuesto con el set de datos utilizados para hacer la decisión de inversión, lo cual es consistente con la dinámica que enfrenta un inversor en la realidad. Por el contrario, una desventaja es que analizamos un único camino o *path*: el histórico. Esto puede exponernos a quedar sesgados por las características de esta única secuencia observada. Alternamente, para no quedarse únicamente con lo observado en el *path* histórico, se puede utilizar este para derivar una distribución de probabilidad de los retornos de cada activo y, a partir de eso, simular series de retornos sintéticos con los que poder generar nuevos sets de datos e incluso más extensos que los originales, con los que llevar a adelante más procesos de *backtesting* con series que conservan las características estadísticas originales, pero con distintos desenlaces a los vistos históricamente. En este trabajo no realizaremos esto último y nos acotaremos únicamente al set de datos históricos.

7.2 Medida de performance

El ratio recompensa-riesgo o *Sharpe ratio*, introducido en Sharpe (1966) y mencionado en secciones previas, es una de las métricas más utilizadas a la hora de evaluar la performance de una o varias estrategias. Su uso también se extiende al análisis de *performance attribution*, donde se busca descomponer los factores que explican los retornos de una estrategia o portfolio, al testeo de eficiencia de mercado, así como también al *risk management*, Sharpe (1994). Es una medida que relaciona los retornos de un activo o un portfolio de activos en exceso a la tasa libre de riesgo (recompensa por tomar riesgo) y el desvío standard o volatilidad de los retornos del activo (riesgo asumido).

$$\text{Sharpe Ratio} = \frac{\mu_p - r_f}{\sigma_p}$$

Donde

μ_p es el retorno esperado del portfolio

r_f es la tasa libre de riesgo

σ_p es el devio standard de los retornos del portfolio

En la practica μ_p y σ_p no los conocemos por lo que se los estima a través de los retornos históricos y, como toda estimación en base a observaciones históricas, está sujeta a la ventana y frecuencia temporal que se elige para la estimación. Por ejemplo, ¿Tomamos los últimos 250 retornos

diarios (aproximadamente un año de datos)? ¿Los últimos 260 retornos semanales (aproximadamente 5 años)? Además, y, quizás lo más relevante a tener en consideración es que, como toda estimación, esta está expuesta a errores durante dicho proceso. La precisión del *Sharpe* ratio como medida de performance ajustada por riesgo va a inherir las características estadísticas de los retornos bajo observación, las cuales al mismo tiempo van a variar de portfolio en portfolio. La performance de estrategias más volátiles no se puede medir con el mismo nivel de confianza que otras más estables.

Uno de los supuestos implícitos más sensibles al trabajar con series de retornos de portfolios o activos financieros es el de que estos están normal, independiente e idénticamente distribuidos. Como en Lo (2002), asumiendo retornos normalmente distribuidos, con asimetría y curtosis equivalentes a 0 y 3, respectivamente, el *Sharpe* ratio estimado sigue una distribución normal con media cero y varianza dada por:

$$\hat{\sigma}^2 = \frac{1}{n-1} \left(1 + \frac{1}{2} \hat{SR}^2 \right)$$

Donde,

$\hat{\sigma}^2$ es la varianza del Sharpe ratio estimado
 \hat{SR} es el Sharpe ratio estimado
 n es la cantidad de observaciones

De todas maneras, Mertens (2002) demuestra que el supuesto de normalidad en la distribución de los retornos puede ser dejado de lado y, aun así, el *Sharpe* ratio estimado seguiría una distribución normal con media cero y varianza dada por:


$$\hat{\sigma}^2 = \frac{1}{n} \left(1 + \frac{1}{2} \hat{SR}^2 - \gamma_3 \hat{SR} + \frac{\gamma_3 - 3}{4} \hat{SR}^2 \right)$$

Donde,

γ_3 es la asimetría
 γ_4 es la curtosis

El autor Marcos López de Prado, “Aunque la asimetría y curtosis no afecten la estimación puntual del *Sharpe* ratio, sí afectan en gran medida a sus intervalos de confianza y, en consecuencia, su significatividad estadística”. En la siguiente imagen podemos observar gráficamente lo mencionado: el desvío standard del *Sharpe* ratio aumenta en función de la curtosis y asimetría (*skewness*).

Imagen 20 – Fuente: Bailey, H., López de Prado, M. (2012)



Con el objetivo de mitigar lo mencionado, Bailey y López de Prado (2012) proponen el concepto de Sharpe Ratio Probabilístico (PSR por *Probabilistic Sharpe Ratio*). PSR toma como datos de entrada los retornos de un portfolio observado y los de un *benchmark* a utilizar como referencia. A partir de ellos, estima la probabilidad de que el Sharpe Ratio del portfolio sea superior al del benchmark.

$$PSR(SR^*) = Z \left[\frac{(\hat{SR} - SR^*) \sqrt{n-1}}{\sqrt{1 - \hat{\gamma}_3 \hat{SR} + \frac{\hat{\gamma}_4 - 1}{4} \hat{SR}^2}} \right]$$

Donde

Z es la función de probabilidad acumulada (*cdf*) para una distribución normal standard

\hat{SR} es el Sharpe ratio estimado del portfolio

SR^* es el Sharpe ratio del benchmark

n es la cantidad de observaciones

$\hat{\gamma}_3$ es el grado de asimetría de la distribución de los retornos

$\hat{\gamma}_4$ es la curtosis de la distribución de los retornos

Como vemos de la notación anterior, la formula del Sharpe ratio probabilístico retorna un valor de la función de probabilidad acumulada (o *cdf* por *Cumulative Distribution Function*), con el cual en la práctica buscaremos marcas de este valor de al menos 95% para sostener con suficiente evidencia estadística que el Sharpe ratio de una estrategia es superior a un determinado valor a comparar.


Alternamente, también se puede fijar SR^* (el Sharpe ratio del benchmark) en cero para analizar la probabilidad de que la estrategia tenga alguna ventaja o aptitud en absoluto. En este trabajo, realizaremos ambas evaluaciones: por un lado, estimaremos el Sharpe ratio probabilístico de cada una de las cuatro estrategias bajo estudio respecto al portfolio benchmark “1/N”, como así también respecto a un SR^* igual a cero.

8. Resultados

Dado el set de datos y las estrategias de construcción de portfolios previamente descritas, se procedió a analizar los resultados empíricos de estas. En primer lugar, llevaremos adelante el proceso de cálculo y análisis de performance de las estrategias para una ventana de estimación de portfolios y horizontes de inversiones fijos y equivalentes a 20, proxy a un mes de operatoria. En términos prácticos, quiere decir que el inversor al cabo de 20 ruedas observara los retornos de los 13 activos bajo estudio y estimara cada uno de los cuatro portfolios óptimos en los cuales invertir por los siguientes 20 días de operatoria. Repetirá este proceso hasta el término del set de datos disponibles, el cual consta de 3015 observaciones para cada activo (equivalente a todas las ruedas de trading entre el 5 de enero del 2010 y el 30 de diciembre del 2021). Una vez realizado el proceso de backtesting y contando con las series de los retornos, tanto de la estrategia bajo análisis como del portfolio *benchmark*, se podrá calcular el *Sharpe* ratio probabilístico


En las siguientes imágenes podemos ver los retornos diarios acumulados en exceso a la tasa libre de riesgo, volatilidad y Sharpe ratio (móvil para una ventana de 180 días) de cada uno de los cuatro portfolios bajo los parámetros de estimación y horizonte de inversión mencionados.

Imagen 21




En términos de performance absoluta en exceso a la tasa libre de riesgo, podemos observar que Fama French 5 Factores junto al portfolio *benchmark* predomina por sobre el resto. Se puede destacar la débil performance acumulada de la cartera de la estrategia *Hierarchical Risk Parity* como también de *Mean-Variance*. *Risk Parity* lo podemos encontrar entre los dos extremos. De todas maneras, más allá de la mejor o peor performance acumulada relativa entre una estrategia y otra, podemos notar una elevada correlación entre todas las estrategias en general: todos los modelos experimentan caídas en los mismos periodos (2011, fines de 2014 hasta comienzos de 2016, 2018 y comienzos de 2020). Lo mismo aplica para los ciclos alcistas.

Imagen 22



En la imagen 20 observamos la volatilidad anualizada para una ventana móvil de 180 días y destacamos los picos y periodos de mayor volatilidad que experimentan el portfolio *benchmark* y *Mean-variance* en relación al resto de las estrategias. Es interesante ver que *Risk Parity* y *Hierarchical Risk Parity* ofrecieron, a lo largo de todo el periodo analizado, una notable menor volatilidad respecto del resto.

Imagen 23



Dado que trabajamos con retornos en exceso a la tasa libre de riesgo, el Sharpe ratio móvil para una ventana de tiempo de 180 días, que se observa en la imagen 21 resulta del cociente entre los retornos acumulados para una ventana móvil de 180 días y la volatilidad anualizada para el mismo periodo (imagen 20). Se observa es la alta y positiva correlación entre los *Sharpes* de todas las estrategias. El portfolio benchmark que invierte una cantidad equivalente en cada uno de los activos parece, a simple vista, ser un fuerte competidor de los portfolios óptimos de cada una de las estrategias propuestas. Para tener una primera aproximación, en términos estadísticos, de ver que probabilidad, en base a las observaciones históricas, de que el *Sharpe* ratio de cada una de las estrategias sea superior al del portfolio *benchmark* resumimos los *Sharpe* ratios probabilísticos de cada estrategia versus el portfolio *benchmark* 1/N en la tabla 9:


Tabla 9

Portfolio	Sharpe Ratio Probabilístico
Mean-Variance	17.4%
Fama-French 5 Factores	44.7%
Risk Parity	27.0%
Hierarchical Risk Parity	39.5%

Ninguno de los portfolios, para el caso de período de estimación y horizonte de inversión de 20 días, tiene un *Sharpe* ratio superior al del *benchmark*. Se observa que, si bien *Hierarchical Risk Parity* demostró una performance absoluta acumulada considerablemente menor a la de Fama-French 5 Factores, el *Sharpe* Ratio Probabilístico de uno y otros respecto al benchmark no son tan distantes (39.5% vs. 44.7%). Esto se debe principalmente a que Fama-French 5 Factores se expuso a una mayor volatilidad o riesgo para lograr esa mayor performance, en comparación a *Hierarchical Risk Parity*.


Análogamente, podemos preguntarnos qué resulta del mismo ejercicio, pero tomando ventanas de tiempo más amplias para tanto la estimación del portfolio como para estar invertidos en este. En las siguientes imágenes llevamos adelante el mismo ejercicio, pero fijando los parámetros de periodo para la estimación del portfolio óptimo y del tiempo que el inversor estará invertido en él, con un valor de 240 días para ambos.

Imagen 24



En contraste al ejercicio anterior donde utilizamos 20 días para los dos parámetros, observamos periodos como 2011 al 2015 donde el portfolio Fama-French predomina en términos de performance absoluta por sobre el resto. De la misma manera que periodos como 2016 al 2020 donde *Mean-Variance* demuestra lo propio, más aún considerando que en el ejercicio anterior esta estrategia fue la que peor performance demostró. La elevada correlación entre las estrategias que se destacó en el anterior ejercicio no es tan clara en este, observando varios periodos de divergencias entre ellas.


Imagen 25



En términos de volatilidad realizada, las observaciones del ejercicio anterior se sostienen también en este. La sostenida baja volatilidad relativa de las estrategias enfocadas en la equitativa distribución del

riesgo como *Risk Parity* y *Hierarchical Risk Parity* se vuelve a destacar en esta ocasión. Como así también la elevada volatilidad de *Mean-Variance*. A posteriori resulta que era de algo de esperarse, dado que, como vimos en la sección 5 el portfolio de ejemplo de *Mean-variance* era uno altamente concentrado en algunos pocos de los 13 activos disponibles mientras que *Risk Parity* y *Hierarchical Risk* asignaron una pequeña capital a todos los activos, sobre ponderando los ETFs de renta fija que se caracterizaban por su menor volatilidad (y retorno esperado).

Imagen 26




Para esta variante de parámetros, si bien los Sharpe ratio probabilísticos aumentaron en todos los casos, siguen siendo muy bajos para sostener que ofrecieron un *Sharpe* ratio superior al del portfolio benchmark. Recordemos que exigimos una probabilidad o Sharpe ratio probabilístico de al menos 95% para sostener la afirmación contraria.

Tabla 10

Portfolio	Sharpe Ratio Probabilístico
Mean-Variance	40.1%
Fama-French 5 Factores	54.0%
Risk Parity	51.4%
Hierarchical Risk Parity	54.6%

A partir de los dos previos e introductorios ejercicios observamos que los resultados y, en consecuencia, las potenciales conclusiones a las que podemos llegar son altamente sensibles a los valores que fijemos para los dos parámetros de ventana temporal para la estimación del portfolio óptimo y de horizonte de inversión o tiempo durante el que el inversor permanecerá comprado en esa cartera optima estimada. Por ello, con el fin de poder observar los resultados para distintas combinaciones de estos dos parámetros, decidimos expresar estos en una matriz donde el eje vertical represente el periodo para la

estimación del portfolio y el eje horizontal el horizonte de inversión o el periodo por el cual el inversor permanecerá invertido en esa cartera optima. Cada espacio o casilla de la matriz indica el *Sharpe* ratio probabilístico resultante de cada una de las posibles combinaciones de período de estimación (eje vertical) y horizonte de inversión (eje horizontal), yendo desde 20 días (aproximadamente un mes de operatoria bursátil) hasta 240 (aproximadamente un año de datos).



Para ayudar a la interpretación de los resultados, por ejemplo, en el gráfico de arriba (*Mean-variance*) en la esquina inferior derecha, leemos el resultado que tomando los últimos 240 ruedas para la estimación del portfolio óptimo e invirtiendo en las siguientes 240 ruedas, la probabilidad de que el *Sharpe* ratio de la estrategia *Mean-variance* sea superior al del portfolio *benchmark* 1/N es de 64%.

Fama-French 5 Factores

		Horizonte de inversion											
		20	40	60	80	100	120	140	160	180	200	220	240
Periodo para la optimizacion del portfolio	20	76%	34%	61%	41%	39%	33%	75%	39%	57%	69%	77%	50%
	40	31%	29%	49%	42%	56%	78%	59%	23%	51%	48%	47%	49%
	60	31%	51%	19%	48%	41%	51%	57%	62%	20%	52%	51%	50%
	80	28%	28%	29%	49%	43%	36%	58%	77%	14%	33%	46%	58%
	100	33%	30%	41%	36%	38%	21%	80%	78%	37%	39%	48%	32%
	120	17%	25%	27%	37%	46%	31%	42%	62%	30%	26%	45%	33%
	140	20%	27%	31%	27%	38%	20%	48%	65%	20%	38%	32%	24%
	160	23%	37%	37%	45%	48%	47%	45%	64%	38%	49%	36%	46%
	180	21%	27%	22%	24%	34%	51%	36%	65%	39%	60%	59%	52%
	200	19%	19%	39%	21%	34%	58%	21%	49%	30%	65%	46%	56%
	220	21%	21%	22%	28%	28%	60%	54%	58%	21%	70%	31%	56%
	240	19%	18%	19%	20%	23%	50%	50%	51%	14%	62%	37%	36%

Risk Parity

		Horizonte de inversion											
		20	40	60	80	100	120	140	160	180	200	220	240
Periodo para la optimizacion del portfolio	20	48%	51%	58%	62%	44%	61%	48%	54%	62%	66%	40%	58%
	40	52%	47%	44%	53%	54%	50%	41%	55%	57%	56%	42%	51%
	60	51%	53%	55%	42%	54%	60%	45%	58%	54%	57%	43%	49%
	80	52%	52%	48%	44%	50%	54%	55%	53%	58%	46%	40%	50%
	100	50%	48%	44%	57%	52%	51%	48%	59%	51%	49%	36%	50%
	120	50%	52%	54%	54%	50%	45%	53%	54%	46%	45%	48%	46%
	140	50%	49%	50%	44%	52%	48%	52%	51%	43%	50%	42%	43%
	160	49%	49%	44%	46%	51%	45%	46%	48%	44%	49%	47%	45%
	180	49%	46%	46%	53%	42%	50%	45%	48%	46%	46%	55%	49%
	200	45%	45%	47%	46%	45%	50%	45%	47%	49%	49%	51%	50%
	220	48%	46%	45%	45%	46%	54%	54%	52%	52%	54%	56%	57%
	240	47%	46%	47%	46%	49%	49%	55%	51%	50%	50%	54%	53%

Hierarchical Risk Parity

		Horizonte de inversion											
		20	40	60	80	100	120	140	160	180	200	220	240
Periodo para la optimizacion del portfolio	20	30%	33%	48%	50%	45%	61%	46%	47%	63%	61%	32%	55%
	40	57%	54%	41%	51%	50%	50%	42%	53%	57%	49%	40%	50%
	60	59%	58%	53%	37%	52%	65%	52%	51%	50%	55%	48%	42%
	80	59%	54%	50%	37%	50%	61%	59%	50%	62%	38%	33%	55%
	100	50%	41%	41%	50%	56%	58%	56%	60%	55%	42%	33%	49%
	120	47%	53%	47%	55%	46%	35%	55%	51%	36%	41%	50%	39%
	140	42%	45%	44%	33%	43%	35%	52%	40%	33%	41%	35%	34%
	160	43%	45%	36%	30%	39%	35%	40%	33%	37%	38%	46%	31%
	180	45%	38%	34%	42%	34%	42%	37%	34%	43%	35%	57%	35%
	200	40%	41%	45%	40%	39%	49%	38%	41%	43%	44%	44%	42%
	220	43%	43%	41%	41%	42%	47%	51%	44%	43%	46%	45%	52%
	240	47%	47%	40%	44%	49%	40%	45%	43%	41%	42%	48%	47%

En general observamos que, para este universo de activos seleccionados y esta grilla de distintas combinaciones de los parámetros período de optimización y período de inversión, los portfolios bajo estudio tienen muy bajas chances de lograr un Sharpe ratio superior a los del portfolio *benchmark* “1/N”. Solo Mean-Variance y Fama-French 5 factores muestran, para casos aislados de combinaciones de ambos parámetros, chances cercanas o superiores al 80% de tener una performance ajustada por riesgo superiores al *benchmark*. Para el caso de *Risk Parity* y *Hierarchical Risk Parity*, ambos son los que más bajas probabilidades se observan, este ejercicio trae a luz el costo que incurren en ignorar la información disponible en el vector de retornos esperados, por más simple que sea el método que se utilice para estimar estos retornos esperados, como lo hace, por ejemplo, *Mean-variance* a través de un promedio simple de los retornos históricos. Como se anticipó en la sección de descripción del portfolio *benchmark*, si bien es una estrategia simple que no requiere ningún algoritmo de optimización ni criterio de selección, esta garantiza una exposición a uniforme a todo el universo de activos evitando un portfolio concentrado. Se beneficia de reversiones en las tendencias de los precios de los activos dado que, cuando llega el momento de rebalanceo de su cartera, se reducirá la posición en activos que mejor performaron así tomando ganancias y aumentando exposición a aquellos cuyo precio disminuyó y, en consecuencia, también su ponderación en la cartera. De esta manera el portfolio *benchmark* vuelve a tener una misma asignación de la cartera a cada uno de los activos disponibles.

Por último y como mencionado previamente, llevamos adelante el mismo ejercicio, pero en lugar de contrastar contra el portfolio *benchmark* lo hacemos contra un *Sharpe* ratio equivalente a cero con el fin de observar si las estrategias tienen alguna aptitud en absoluto. Esto lo podemos observar en las siguientes matrices:

Mean-Variance

Horizonte de inversion

		20	40	60	80	100	120	140	160	180	200	220	240
Periodo para la optimizacion del portfolio	20	85%	90%	99%	91%	73%	100%	90%	98%	100%	97%	97%	97%
	40	97%	98%	95%	96%	92%	95%	77%	99%	98%	97%	85%	90%
	60	94%	90%	94%	81%	90%	98%	95%	97%	98%	97%	90%	96%
	80	87%	90%	75%	93%	97%	89%	99%	99%	99%	97%	84%	96%
	100	80%	77%	88%	99%	95%	93%	98%	100%	100%	99%	67%	99%
	120	83%	91%	91%	90%	87%	78%	100%	96%	96%	94%	86%	95%
	140	94%	94%	97%	83%	96%	92%	100%	87%	88%	89%	82%	97%
	160	83%	93%	90%	90%	94%	92%	89%	93%	80%	87%	95%	98%
	180	83%	80%	85%	97%	94%	97%	92%	97%	90%	95%	90%	98%
	200	82%	94%	85%	97%	94%	98%	91%	90%	92%	95%	70%	97%
	220	75%	71%	88%	79%	88%	92%	98%	94%	96%	82%	79%	81%
	240	85%	95%	98%	94%	92%	93%	96%	93%	97%	87%	96%	92%

Fama-French 5 Factores

Horizonte de inversion

		20	40	60	80	100	120	140	160	180	200	220	240
Periodo para la optimizacion del portfolio	20	99%	90%	98%	90%	91%	90%	98%	89%	96%	94%	98%	92%
	40	91%	90%	96%	93%	95%	100%	97%	82%	94%	89%	92%	92%
	60	92%	97%	80%	96%	93%	95%	97%	98%	81%	94%	95%	95%
	80	90%	90%	89%	97%	94%	91%	96%	100%	75%	86%	94%	97%
	100	91%	88%	94%	87%	93%	76%	99%	98%	93%	90%	93%	85%
	120	80%	86%	83%	89%	93%	86%	93%	95%	75%	83%	92%	87%
	140	87%	90%	91%	90%	91%	85%	97%	98%	77%	92%	92%	88%
	160	89%	95%	94%	96%	96%	97%	92%	98%	90%	96%	94%	97%
	180	86%	88%	83%	82%	91%	95%	90%	98%	91%	98%	98%	98%
	200	85%	85%	94%	82%	93%	97%	82%	95%	89%	99%	85%	98%
	220	84%	81%	84%	86%	85%	96%	94%	97%	75%	94%	76%	88%
	240	79%	78%	72%	80%	73%	93%	93%	96%	66%	92%	82%	77%

Risk Parity

Horizonte de inversion

	20	40	60	80	100	120	140	160	180	200	220	240
20	96%	96%	97%	96%	93%	98%	92%	94%	97%	93%	87%	95%
40	97%	96%	95%	96%	95%	97%	91%	96%	96%	92%	90%	93%
60	97%	97%	97%	94%	96%	97%	94%	98%	96%	95%	93%	95%
80	97%	97%	96%	95%	96%	96%	95%	97%	97%	91%	92%	95%
100	96%	95%	95%	95%	97%	93%	94%	95%	96%	93%	87%	93%
120	96%	96%	95%	95%	94%	92%	96%	93%	86%	93%	93%	93%
140	97%	97%	97%	95%	96%	96%	98%	96%	92%	95%	95%	95%
160	97%	97%	96%	96%	96%	96%	93%	95%	92%	95%	97%	96%
180	97%	95%	94%	95%	94%	95%	93%	94%	94%	95%	97%	97%
200	96%	96%	95%	94%	96%	96%	94%	94%	95%	97%	88%	96%
220	96%	94%	95%	94%	93%	94%	94%	96%	94%	87%	91%	88%
240	94%	94%	92%	94%	91%	92%	94%	95%	93%	86%	91%	88%

Hierarchical Risk Parity

Horizonte de inversion

	20	40	60	80	100	120	140	160	180	200	220	240
20	90%	89%	95%	93%	93%	98%	91%	92%	97%	91%	83%	94%
40	98%	97%	94%	95%	94%	96%	91%	96%	95%	90%	89%	93%
60	98%	98%	96%	93%	96%	98%	96%	96%	96%	95%	94%	93%
80	98%	97%	96%	93%	96%	97%	96%	97%	98%	88%	89%	96%
100	96%	92%	94%	93%	97%	95%	96%	95%	97%	91%	86%	93%
120	95%	97%	93%	95%	93%	88%	96%	92%	80%	91%	94%	90%
140	96%	96%	95%	92%	93%	93%	98%	92%	87%	92%	93%	92%
160	96%	96%	94%	92%	93%	94%	90%	90%	89%	92%	96%	92%
180	96%	93%	90%	91%	91%	92%	90%	88%	93%	92%	98%	94%
200	95%	95%	95%	93%	95%	95%	92%	93%	94%	96%	84%	95%
220	94%	93%	94%	93%	92%	92%	93%	93%	90%	82%	85%	85%
240	94%	94%	89%	93%	91%	89%	91%	93%	89%	81%	88%	84%

En esta variante, los cuatro modelos ahora muestran significativamente más altas probabilidades que en el ejercicio previo (vs. *Benchmark* “1/N”). Las cuatro estrategias bajo estudio demuestran tener

probabilidades de entre 90% y 100% para varias combinaciones de ambos parámetros. No se observa una tendencia que prevalezca, es decir, ninguna estrategia muestra tener notablemente mayores o menores probabilidades para combinaciones más altas o bajas de los parámetros a elegir. Sino que, las probabilidades se muestran distribuidas uniformemente a lo largo y ancho de la matriz de resultados. Quizás resulta interesante de destacar que, a simple vista, se puede observar un nivel de probabilidades algo menores para las estrategias *Mean-variance* y Fama-French 5 factores en comparación a *Risk Parity* y *Naive Risk Parity*. Para las primeras se puede divisar algunas casillas particulares con probabilidades iguales o menores al 70% de tener un Sharpe ratio menor a cero, mientras que esto no se observa en los resultados de *Risk Parity* y *Naive Risk Parity*. De todas maneras, los resultados a nivel general son los mismos.

Es relevante volver a recordar que estamos trabajando con retornos en exceso a la tasa libre de riesgo, esta es, la tasa de un bono del tesoro norteamericano con vencimiento a diez años. Por lo que, en términos prácticos, podemos sostener que, a partir de esta variante del ejercicio, las cuatro estrategias ofrecen un *Sharpe* ratio superior a cero con alto nivel de probabilidad y son una mejor alternativa a no estar invertido o estar 100% líquido o en *cash*.

9. Conclusiones

A lo largo del trabajo, hemos introducido los principales diferentes tipos de activos disponibles para que un inversor construya una cartera de inversión en el mercado de capitales. Asumiendo que un inversor busca la mejor combinación y exposición posible a activos de renta fija y renta variable, con distintos retornos esperados y riesgos asociados, seleccionamos un conjunto de 13 ETFs que mejor represente este abanico de alternativas de inversión disponibles en los mercados de capitales para eventualmente ser incorporados a sus carteras. Lo anterior también sujeto a que cada ETF cuente con, por lo menos, 10 años de historia y así poder llevar adelante los ejercicios para una ventana de tiempo considerable. Procedimos a explicar brevemente la historia de las principales teorías de construcción de portfolios y *pricing* de activos con el objetivo de darle un marco conceptual e hilo a las estrategias seleccionadas. Desde lo más clásico propuesto por Harry Markowitz y la teoría moderna del portfolio, pasando por Sharpe y Litner, Fama y French y su modelo de cinco factores hasta estrategias de un enfoque distinto y de divulgación más reciente como *Risk Parity* y *Hierarchical Risk Parity*. Es importante resaltar que existen múltiples otras alternativas y teorías distintas a las propuestas en este trabajo, buscando también lograr un portfolio optimizado con la mayor performance ajustada por riesgo posible. Consideramos que las cuatro elegidas son de gran relevancia, sirviendo como puntapié para extensiones y mejoras de estas, y, aparte, las cuatro tienen un enfoque variado por lo que resulta interesante para luego contrastar resultados. Posteriormente, se introdujeron las técnicas de muestreo o *backtesting*, metodologías para evaluar performance de una estrategia de inversión junto a los sesgos posiblemente presentes y de gran importancia de tener en cuenta al analizar resultados. La métrica elegida para la evaluación de performance fue el *Sharpe* ratio probabilístico propuesto en Bailey y López de Prado (2012). Dado el universo de activos, estrategias, metodologías para la simulación histórica de estas y métricas de performance elegidas, buscamos los resultados de estas para distintas combinaciones de los dos parámetros que también debe elegir el inversor: (1) ventana de tiempo histórica a tomar para observar los datos y a partir de ellos estimar el portfolio óptimo y (2) la ventana de tiempo por la que permanecerá invertido en él. Los resultados de ello los mostramos en una matriz donde cada eje representa cada uno de esos dos parámetros, con la idea de evitar tomar conclusiones condicionadas a únicamente dos valores específicos de ellos.

En primer lugar, es relevante volver a remarcar que los resultados y conclusiones están sujetos al universo de los 13 activos y tasa libre de riesgo seleccionados en esta oportunidad. Si bien se buscó elegir un set de activos que abarque de la mejor manera posible tanto todos los *asset classes* como también sectores económicos y temáticas de inversión disponibles para un inversor, las conclusiones respecto a estas estrategias son también función a los activos con los que se trabajó y sus respectivas características observadas.

En cuanto a los resultados de los ejercicios empíricos realizados, vistos en la sección previa, las cuatro estrategias de optimización de portfolio bajo estudio demuestran tener, para el universo de 13 activos seleccionados, muy bajas chances de lograr un *Sharpe* ratio, es decir, performance ajustada por riesgo superior al del portfolio *benchmark* “1/N”. Como se anticipó y luego se comprobó con mayor profundidad, la simplicidad del portfolio *benchmark* “1/N” prevaleció por sobre las cuatro estrategias estudiadas. La equitativa asignación de capital a cada uno de los 13 activos que garantiza el portfolio “1/N” predomina por sobre las carteras relativamente concentradas y que resultan de las estrategias de optimización de portfolios. Los métodos basados en un algoritmo de optimización demuestran ser notablemente inestables producto de los errores de estimación de los parámetros que requieren (retornos y volatilidad esperada, matriz de covarianzas, etc.) para su cálculo. Estos pueden sesgar dando relativamente buenos resultados cuando se los testea *in-sample*, pero cuando se pasa a evaluarlos *out-of-sample*, es decir, con datos no conocidos o vistos a la hora de estimar el portfolio óptimo, los efectos del error de estimación salen a luz y la performance en relación al riesgo de estas estrategias cae sustancialmente.

Posteriormente, a raíz de la baja performance relativa al *benchmark*, se buscó testear si las estrategias ofrecen alguna aptitud o *skill* en absoluto, es decir, un *Sharpe* ratio superior a 0. Para ello llevamos adelante el mismo ejercicio de evaluar, nuevamente, para distintas combinaciones de período para la estimación del portfolio y horizonte de inversión, el *Sharpe* ratio probabilístico respecto a 0, es decir, cuáles son las chances de que la performance ajustada por riesgo o volatilidad incurrida de una estrategia sea positiva. En este caso conseguimos ver probabilidades significativamente mayores e incluso cercanas a 1 para casi todas las posibles combinaciones de los parámetros de días para la estimación de los portfolios y periodos de inversión.

Si bien a priori estos resultados pueden ser llamativos, están en línea con las conclusiones de DeMiguel, Garlappi y Uppal (2007). Los autores demuestran que para que estrategias de optimización muestren ventajas por sobre el portfolio 1/N, la longitud crítica para la estimación del portfolio son 3000 meses para un universo de 25 activos y de 6000 meses para uno de 50 activos. Esto es causado, principalmente, por los mencionados errores de estimación a los que están expuestos el vector de retornos esperados y matriz de varianzas y covarianzas que toman como input estos algoritmos. Hay que destacar que no existen muchos, si es que los hay, activos que dispongan de datos históricos por 3000 o 6000 meses. Los autores llegan a estas conclusiones vía métodos de generación de datos sintéticos, es decir, datos que no existen ni nunca sucedieron, pero son simulados a partir de las distribuciones de probabilidad derivadas a partir de los datos históricos más algún shock aleatorio. Los autores también destacan que esta longitud crítica para la mínima ventana temporal de estimación del portfolio se incrementa a la par de que lo hace nuestro universo de activos. Es decir, a mayor número de activos potencialmente incluibles en la cartera, más longitud de datos vamos a precisar para llegar a observar que los portfolios óptimos sobre-performen al portfolio 1/N. Esto último es intuitivo: a mayor número de activos, 1/N garantiza una mayor diversificación, aunque sea *naive*, versus los portfolios concentrados de las estrategias de optimización y, al mismo tiempo, a mayor cantidad de activos mayor cantidad de estimaciones a realizar ergo mayor exposición a errores de estimación de los modelos de optimización de portfolios.

En la práctica, donde usualmente se dispone de 60 a 120 meses de datos, el portfolio 1/N es el que menor expuesto está a errores de estimación respecto de las estrategias de optimización, por el simple hecho de que no requiere ningún tipo de estimación del vector de retornos esperados y matriz de covarianzas, más que asignarle misma ponderación en la cartera a cada uno de los activos del universo de inversión. En consecuencia, ofrece los resultados en línea con lo antes visto. Incluso esfuerzos de otros autores investigando nuevas estrategias para minimizar los errores de estimación reportan leves mejoras en la performance respecto al portfolio 1/N.

Para concluir, la estrategia *naive* o 1/N es más probable que ofrezca performance ajustada por riesgo superior a la de las estrategias *Mean-variance*, *Fama-French*, *Risk Parity* y *Hierarchical Risk Parity*, cuando el universo de activos es amplio y cuando no se cuenta con suficientes datos históricos de este universo de activos.

Referencias

- Bailey, D. and López de Prado, M. “The Deflated Sharpe Ratio: Correcting for Selection Bias, Backtest Overfitting and Non-Normality.” *Journal of Portfolio Management*, Vol. 40, No. 5 (2014), pp. 94-107.
- Best, M., Grauer, R. (1991). “On the Sensitivity of Mean-variance-Efficient Portfolios to Changes in Asset Means: Some Analytical and Computational Results”. *Review of Financial Studies* 4(2): 315-42.
- Damodaran, A. (2008). “What is the risk-free rate? A Search for the Basic Building Block”. Stern School of Business, New York University.
- Das, S.R., Uppal, R. (2003). “Systemic Risk and International Portfolio Choice”. AFA 2003 Washington, DC Meetings.
- De Miguel, V., Garlappi, L. and Uppal, R. (2009). “Optimal versus naive diversification: How inefficient is the 1/N portfolio strategy?” *Review of Financial Studies*, Vol. 22, pp. 1915– 1953.
- Fama, E. F., and French, K. R. (1993). Common Risk Factors in the Returns on Stock and Bonds. *Journal of Financial Economics* 33:3–56.
- Lo, A. (2002) “The Statistics of Sharpe Ratios”. *Financial Analysts Journal* (July), pp. 36-52.
- López de Prado, M. (2016). “Building diversified portfolios that outperform out-of-sample”. *Journal of Portfolio Management*, 1-31.
- Lopez De Prado, M. (2018). *Advances in Financial Machine Learning*. Wiley.
- Markowitz, H. (1952). “Portfolio selection.” *Journal of Finance*, Vol. 7pp. 77–91
- Mertens, E. (2002) “Variance of the IID estimator in Lo (2002)”. Working paper, University of Basel.
- Sharpe, W. (1966) “Mutual Fund Performance”, *Journal of Business*, Vol. 39, No. 1, pp. 119–138.
- Sharpe, W. (1994) “The Sharpe ratio”, *Journal of Portfolio Management*, Vol. 21, No. 1, Fall, pp. 49-58.
- Luo, Y. (2014). Seven Sins of Quantitative Investing, *DB Quant Handbook*, Part II.
- Systematic Risk and Systematic Value. Managing (systemic) risk. Recuperado de <https://www.sr-sv.com/>.