



Facultad de Ciencias Económicas y Empresariales

Factor Investing y Sostenibilidad: El Factor ESG en Bonos Corporativos Investment Grade

Autor: Rodrigo González Gómez

Director: María Coronado Vaca



Factor Investing y Sostenibilidad: El Factor ESG en Bonos Corporativos Investment Grade

RESUMEN

El presente trabajo se centra en la aplicación del factor investing en los mercados de renta fija, específicamente en los bonos corporativos de grado de inversión, también conocidos como investment grade. Además, se pone un particular énfasis en el estudio de un nuevo posible factor que juegue un papel en la explicación del riesgo y retorno de los activos, el factor ESG.

A lo largo del análisis, revisitamos los principales conceptos del factor investing, destacando la teoría de carteras de Markowitz, el modelo de fijación de precios de activos de capital (CAPM) y los modelos multifactoriales desarrollados por Fama y French en sus estudios. Estas teorías, desarrolladas inicialmente para los mercados de renta variable, sentaron las bases para comprender la relación entre el riesgo y retorno esperado de las inversiones.

Durante la revisión de la literatura respectiva a la materia, se ha identificado que el estudio del factor investing en renta fija se encuentra en una fase embrionaria si lo comparamos con su homólogo en renta variable. De la misma manera, los criterios ESG están tomando una especial relevancia en la toma de decisiones de inversión. Y si bien es cierto que se les está prestando una atención cada vez mayor, los resultados acerca de la relevancia de estos criterios a la hora de explicar el riesgo y retorno de los activos no son concluyentes. Es por ello que este trabajo pretende aportar un nuevo punto de vista a un campo relativamente inexplorado hasta el momento: la relevancia del factor ESG en los bonos corporativos de grado de inversión.

Para ello, se ha realizado un análisis, empleando técnicas de machine learning entre las que destacamos los random forest, que discurre entre enero de 2013 y abril de 2023 de los componentes del Índice Bloomberg US Corporate Total Return Value Unhedged USD y que nos permitirá comprobar la relevancia que ha podido llegar a tener este factor en el retorno de los correspondientes activos.

PALABRAS CLAVE

Factor investing, ESG, renta fija corporativa, bonos corporativos de grado de inversión, machine learning, random forest, predicción

ABSTRACT

This paper focuses on the application of factor investing in fixed income markets, specifically in investment grade corporate bonds. In addition, particular emphasis is placed on the study of a new possible factor that plays a role in explaining the risk and return of assets, the ESG factor.

Throughout the analysis, we review the main concepts of factor investing, highlighting Markowitz's portfolio theory, the capital asset pricing model (CAPM) and the multifactor models developed by Fama and French in their studies. These theories, initially developed for equity markets, laid the foundation for understanding the relationship between risk and expected return on investments.

During the review of the literature on the subject, it has been identified that the study of factor investing in fixed income is at an embryonic stage compared to its counterpart in equities. In the same way, ESG criteria are taking on special relevance in investment decision making. And while it is true that they are receiving increasing attention, the results on the relevance of these criteria in explaining the risk and return of assets are not conclusive. This is why this paper aims to bring a new point of view to a relatively unexplored field so far: the relevance of the ESG factor in investment grade corporate bonds.

To this end, an analysis has been carried out, using machine learning techniques among which we highlight random forests, which runs between January 2013 and April 2023 of the components of the Bloomberg US Corporate Total Return Value Unhedged USD Index, and which will allow us to verify the relevance that this factor has been able to have on the return of the corresponding assets.

KEY WORDS

Factor investing, ESG, corporate fixed income, investment grade bonds, machine learning, random forest, prediction

ÍNDICE

1. INTRODUCCIÓN.....	5
1.1 Objetivo.....	5
1.2 Justificación del tema de estudio.....	5
1.3 Metodología.....	6
1.4 Estructura.....	6
2. FACTOR INVESTING.....	7
2.1 Conceptos fundamentales del factor investing.....	7
2.2 Factor Investing en Renta Fija.....	16
2.3 ESG Factor Investing.....	20
3. MACHINE LEARNING EN EL ÁMBITO DEL FACTOR INVESTING.....	26
3.1 Paradigmas del machine learning.....	26
3.2 El aprendizaje supervisado en el machine learning y su metodología.....	28
3.3 Algoritmos de aprendizaje supervisado con especial atención a los random forest.....	35
4. ANÁLISIS EMPÍRICO.....	38
4.1 Aspectos fundamentales del estudio.....	38
4.2 Datos.....	41
4.3 Resultados.....	44
5. CONCLUSIONES, LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN.....	48
6. ANEXO.....	51
7. BIBLIOGRAFÍA.....	70

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Beneficios de la diversificación de activos en una cartera de inversión.....	8
Ilustración 2: Rendimiento en las dos últimas décadas de la inversión en factores.....	15
Ilustración 3: Rebalanceo cíclico de la inversión en factores.....	15
Ilustración 4: Evolución ESG AuM.....	21
Ilustración 5: Rendimiento de un modelo de ML en contextos de underfitting y overfitting.....	31
Ilustración 6: Representación de los fenómenos de sesgo y varianza.....	31
Ilustración 7: Método Hold-Out de validación cruzada.....	32
Ilustración 8: Validación cruzada k-Fold donde $k=5$	33
Ilustración 9: Funcionamiento de un árbol de decisión.....	35
Ilustración 10: Porcentaje de bonos con información ESG disponible de su emisor.....	41
Ilustración 11: RMSE en el conjunto de entrenamiento y prueba con diferentes particiones.....	43
Ilustración 12: Rendimiento predictivo de los modelos empleados en el estudio.....	45
Ilustración 13: Tipos de interés de las principales economías mundiales en la última década.....	46
Ilustración 14: Rendimiento del modelo de tres factores en el primer periodo analizado (2013-2015).....	47

1. INTRODUCCIÓN

1.1 Objetivo

El principal objetivo de este trabajo es estudiar la relevancia del factor ESG en el ámbito del factor investing en renta fija corporativa, más concretamente en los bonos corporativos de grado de inversión.

Para ello, se analizará el origen del factor investing, revisitando sus fundamentos históricos y teóricos además de los factores más relevantes identificados en la literatura académica. Todo ello nos permitirá, más adelante, y mediante técnicas de machine learning, analizar grandes conjuntos de datos de uno de los principales índices de renta fija corporativa para evaluar la capacidad predictiva de una serie de modelos que tendrán precisamente como atributos algunos de los factores a los que se irá haciendo referencia a lo largo del trabajo.

Es por ello que, el objetivo final de este análisis empírico será determinar si, efectivamente, en el ámbito de la renta fija corporativa, podemos constatar la existencia de un factor ESG significativo que influya en el retorno y riesgo de los bonos. Esto implicará evaluar si las calificaciones ESG de las empresas emisoras de bonos tienen un impacto medible y consistente en los rendimientos de estos instrumentos de deuda. Si se confirma la existencia de este factor ESG, se podrá demostrar que los criterios de sostenibilidad no solo tienen valor ético, sino también financiero, ofreciendo a los inversores una forma de optimizar sus carteras considerando tanto el rendimiento como el impacto social y ambiental de sus inversiones.

1.2 Justificación del tema de estudio

La elección del presente trabajo se fundamenta esencialmente en dos motivos.

En primer lugar, se debe hacer referencia a la falta de literatura académica en el preciso ámbito de estudio del factor ESG en renta fija corporativa, en general, y en renta fija corporativa de grado de inversión, en particular. Esta deficiencia de la literatura académica se ve más acentuada aún si tenemos en consideración la utilización de técnicas de machine learning a la hora de realizar el análisis. Por lo tanto, para la realización de este estudio se ha buscado un campo dentro del factor investing que apenas hubiese sido tratado con el objetivo de aportar nuevas perspectivas sobre el mismo.

Por su parte, el segundo motivo que justifica la elección esta concreta materia es la, cada vez mayor, relevancia que están adquiriendo los criterios ESG en el ámbito financiero. Como se explicará a lo largo del trabajo, la cantidad de inversores que tienen en consideración estos criterios es cada vez mayor al existir recientes estudios que sugieren que las inversiones que consideran factores ESG pueden ofrecer rendimientos comparables o incluso superiores a las inversiones tradicionales, además de presentar un perfil de riesgo potencialmente más bajo. Con todo, la combinación de ambos motivos hacen adquirir a este estudio una particular utilidad.

1.3 Metodología

En cuanto a la metodología del trabajo se refiere, se han estudiado diversos trabajos concernientes al ámbito del factor investing tanto en renta variable como renta fija para poder plasmar los principales conceptos de los mismos y servir como fundamento para el restante análisis. En esta línea, se ha realizado un proceso similar a la hora de explorar el novedoso factor ESG y su relevancia en las finanzas actuales.

Posteriormente, se ha recopilado información relevante acerca de ciertas técnicas y procesos de machine learning en el ámbito del factor investing buscando, en todo momento, un enfoque eminentemente práctico que facilitase la comprensión del análisis empírico que se realiza al final del trabajo

Por último, se ha realizado un análisis, empleando dichas técnicas de machine learning, de los componentes de uno de los principales índices de renta fija corporativa de grado de inversión con el objetivo de encontrar la relevancia del factor ESG en este contexto.

1.4 Estructura

El presente estudio se estructura en cinco bloques fundamentales. En primer lugar, se encuentra la introducción que estamos realizando del mismo, resaltando el contexto del estudio y su relevancia. En segundo lugar, nos enfocamos en una revisión de literatura sobre el factor investing en sus diversas modalidades: renta variable, renta fija y posibles nuevos factores. Continúa el trabajo con el análisis de diferentes algoritmos, técnicas y procesos de machine learning relevantes que se emplearán en el posterior análisis. Posteriormente, se lleva a cabo el estudio empírico de la relevancia del factor ESG en renta fija corporativa. Y, por último, se presentan una serie de conclusiones valorando el trabajo en su conjunto.

2. FACTOR INVESTING

2.1 Conceptos fundamentales del factor investing

El factor investing es un estilo de inversión que se centra en el estudio de los posibles distintos elementos que impulsan los retornos de los activos. En este sentido, un factor puede ser entendido como “cualquier característica relativa a un grupo de valores que sea importante para explicar su rentabilidad y riesgo” (Bender et al., 2013). Pero antes de adentrarnos de lleno en este concepto debemos de tener en mente ciertas consideraciones.

En primer lugar, una cuestión fundamental en el mundo de las finanzas ha sido el comprender cómo el riesgo de una inversión debe afectar a su retorno esperado (Perold, 2004).

Para ello, el modelo más estudiado y nuclear que comenzó a aportar luz en la materia es el Capital Asset Pricing Model (CAPM, en adelante) desarrollado por (Sharpe, 1964), (Lintner, 1965), (Treynor, 1961) y (Mossin, 1966) en los años sesenta del siglo pasado. Sin embargo, este trabajo se apoya en importante medida en el trabajo elaborado por Harry Markowitz, conocido como Teoría de Carteras, una década antes (Markowitz, 1952). En este modelo, de manera resumida, se busca, asumiendo el comportamiento racional del inversor, encontrar la cartera óptima de cada inversor en términos de rentabilidad y riesgo (Mendizábal Zubeldia et al., 2002).

Según la propuesta de Markowitz, una cartera de inversión eficiente es aquella que para un determinado nivel de riesgo, utilizando como indicador de la misma la varianza, maximice la rentabilidad, dependiente esta de su esperanza matemática, o viceversa. Esta idea que, en la actualidad, nos puede parecer evidente fue disruptiva en su época debido a que hasta la fecha, los gestores de carteras, se centraban principalmente en la optimización de la rentabilidad de sus inversiones sin tener en consideración el riesgo que derivaban de aquellas.

Claro está que cada inversor puede tener un grado de aversión al riesgo distinto, por lo tanto, empleando este modelo iremos obteniendo una serie de rentabilidades esperadas para cada nivel de riesgo. Esto, gráficamente, derivará en la conocida como frontera eficiente que no será más que las carteras que, para un determinado riesgo, maximizan la rentabilidad esperada.

Además, Markowitz realiza una importante apreciación relativa a la diversificación de una cartera de activos. Su trabajo es la primera formalización matemática de la idea de diversificación en las inversiones y postula, como se ha mencionado, que el inversor debería maximizar el retorno esperado de la cartera (μ_p) a la vez que se minimiza la varianza del retorno de dicha cartera (σ_p^2). La cuestión relevante es que no se ha de considerar el riesgo de un activo de manera aislada sino la contribución que dicho activo supone respecto de la varianza de la totalidad de la cartera. Por lo tanto, la decisión de seleccionar un activo u otro como parte de una cartera de inversión no se debe tomar exclusivamente sobre el retorno esperado y varianza de un activo comparado con otros sino teniendo en consideración el conjunto de activos que van a integrar la cartera y, consecuentemente, teniendo que evaluar las correlaciones entre dichos activos. De esta interpretación obtenemos la siguiente ecuación para calcular la varianza del retorno y, por lo tanto, del riesgo de una cartera (Rubinstein, 2002):

$$\sigma_p^2 = \sum_j x_j^2 \sigma_j^2 + \sum_j \sum_{k \neq j} x_j x_k \rho_{jk} \sigma_j \sigma_k \quad (1)$$

Donde x_j es peso del activo j en la cartera de tal manera que $\sum_j x_j = 1$ y ρ_{jk} es la correlación entre los activos j y k .

La teoría de Markowitz sugiere que un inversor debería tratar de construir una cartera de tal manera que sus activos tuviesen una baja o incluso negativa correlación entre ellos de tal suerte que si un activo tiene un mal desempeño, otro activo de la cartera pueda compensar dicha pérdida, reduciendo así el riesgo (Mangram, 2013).

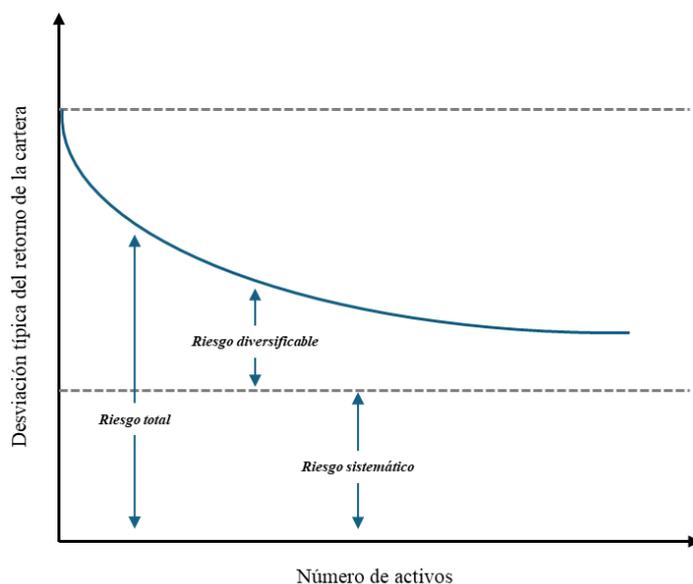


Ilustración 1: Beneficios de la diversificación de activos en una cartera de inversión

Fuente: Elaboración propia, 2024

Pues bien, partiendo de los fundamentos aportados por Markowitz y otros autores como Tobin con su artículo “Estimation of Relationships for Limited Dependent Variables” (Tobin, 1958), el CAPM aportó un importante paso en la evolución de las finanzas modernas al desglosar el riesgo de un activo en dos elementos: el riesgo diversificable y el riesgo sistemático. En este sentido, podemos afirmar que se entiende por riesgo diversificable aquel que viene dado por las características específicas del activo sin influencia de las variaciones del mercado y que, como su nombre indica, es diversificable en tanto en cuanto se incorporen más activos en la cartera de inversión. Por otro lado, el riesgo sistemático sería aquel que se ve afectado por la volatilidad del propio mercado y que, consecuentemente, no podrá ser diversificado (Sharpe, 1964).

El CAPM es un modelo financiero que calcula el retorno esperado de un activo teniendo en consideración el retorno esperado del mercado y de un activo libre de riesgo además de la correlación del activo respecto del mercado. Esta correlación la denotaremos como beta (β_i) y nos aportará información de la sensibilidad de los retornos esperados y, consecuentemente, del riesgo del activo frente a los retornos esperados y riesgo del propio mercado (Fama & French, 2004). Por lo tanto, si un activo tiene más riesgo que el mercado su beta será superior a uno, incrementando así el riesgo de la cartera y, consecuentemente, se exigirá un mayor retorno a la cartera; podría clasificarse como un activo agresivo. La misma idea aplica en sentido opuesto, si la beta de un activo es inferior a uno nuestra cartera tendrá una menor exposición al riesgo y, de la misma manera, se aceptará una disminución en la rentabilidad esperada como consecuencia del menor riesgo, pudiéndolo considerar como un activo defensivo. Por su parte, si la beta fuese cero estaríamos ante un activo cuya covarianza con el mercado sería también de cero, como sería el caso del activo libre de riesgo. Y, en último lugar, un activo con beta negativa sería indicativo de una correlación con el mercado inversa. Ejemplos de este último supuesto podrían ser las opciones de venta o los ETFs inversos¹.

¹ Un Inverse Exchange Traded Fund, también conocido como ETF inverso, es un fondo cotizado en bolsa que busca replicar el rendimiento inverso de un índice o activo subyacente. Esto significa que el ETF gana valor cuando el índice o activo pierde valor y viceversa. Se utiliza comúnmente para estrategias de cobertura o para especular sobre la caída de un mercado.

En definitiva, bajo el CAPM, son tres los elementos fundamentales a tener en cuenta para valorar un activo. Estos serían la tasa libre de riesgo, el retorno esperado del mercado y la exposición del activo al riesgo sistemático, la anteriormente mencionada (β_i).

La formulación matemática de la beta sería la siguiente:

$$\beta_i = \frac{\sigma_{iM}}{\sigma_M^2} \quad (2)$$

Donde σ_{iM} es la covarianza del activo con el mercado y σ_M^2 la varianza del propio mercado.

Por otro lado, derivada de la explicación proporcionada anteriormente y combinando todos sus elementos, el retorno de un activo debería ser el siguiente:

$$E(r_i) = r_f + \beta_i(E(r_M - r_f)) \quad (3)$$

Donde $E(r_i)$ sería el rendimiento esperado en el activo i , r_f la rentabilidad del activo libre de riesgo, $(E(r_M - r_f))$ la prima de rendimiento esperada del mercado por encima de la tasa libre de riesgo y β_i la medida del riesgo sistemático o, en otras palabras, la sensibilidad de una acción ante variaciones del mercado.

En este análisis que estamos llevando a cabo sobre factor investing, el CAPM, tiene una gran relevancia debido a que, para explicar el rendimiento de un activo, utiliza una variable como es el exceso de rentabilidad del mercado respecto al activo libre de riesgo, pudiendo así considerar este como el primer factor que explica la rentabilidad y riesgo de los activos. Más concretamente, el CAPM implica que el retorno esperado en un activo es una función lineal positiva de su beta de mercado (Fama & French, 1992).

En otras palabras, el factor de mercado trata de capturar el exceso de rendimiento del mercado en general basado en la evidencia de que, a pesar de las fluctuaciones a corto plazo, el mercado de valores tiende a ofrecer rendimientos positivos a largo plazo.

Como se desarrollará a continuación, el rendimiento del mercado explica hasta cierto punto el propio retorno de los activos que lo componen, pero no es ni mucho menos un elemento completamente explicativo de los retornos de los activos. Es por ello que durante las siguientes décadas se han tratado de estudiar diferentes factores que expliquen el retorno de los activos.

En el año 1992, los profesores de la Universidad de Chicago, Eugene Fama y Kenneth French, elaboran un artículo titulado “The Cross-Section of Expected Stock Returns” (Fama & French, 1992) en el que recopilan una serie de contradicciones empíricas del CAPM como sería la evidencia de que aquellas empresas con una capitalización bursátil baja tienden a tener unos retornos medios superiores a los que deberían de resultar teniendo en consideración exclusivamente sus betas, y viceversa (Banz, 1981). Otra anomalía que se encontró en las décadas posteriores a la publicación del CAPM fue el hecho de que los retornos medios de las acciones se encontraban positivamente relacionadas con el ratio determinado por el valor contable de las acciones ordinarias dividido por el valor de mercado de las mismas (Stattman, 1980) (Rosenberg et al., 1985) (Chan et al., 1991), el conocido como factor de valor. Además, en este artículo, los autores afirman que durante el periodo comprendido entre 1941 y 1990, la relación entre la beta de las acciones y el retorno medio obtenido por ellas es débil, suponiendo así una contradicción a la más básica conclusión aportada por el CAPM: el retorno medio de una acción debe estar relacionado positivamente con su beta..

Tras confirmar que, efectivamente, el tamaño y el valor de las empresas tenían un efecto a la hora de justificar el retorno de una acción y teniendo aún en consideración el factor de mercado propuesto por el CAPM nos encontramos ante un modelo multidimensional con el que poder explicar la rentabilidad esperada y, consecuentemente, el riesgo de una acción (Fama & French, 1993). Este modelo vendría dado por los siguientes elementos:

$$r_i - r_f = \alpha_i + \beta_1(r_M - r_f) + \beta_2(SMB) + \beta_3(HML) + \varepsilon_i \quad (4)$$

En este sentido, la formula se debería de interpretar de la siguiente manera: $r_i - r_f$ sería la prima de riesgo del activo, esto es el exceso de retorno del activo sobre el activo libre de riesgo; $\beta_1, \beta_2, \beta_3$ serían los coeficientes de cada factor; $r_M - r_f$ sería el exceso de retorno del mercado sobre el activo libre de riesgo; SMB sería el factor “Small Minus Big” que trataría de capturar el exceso de retorno generado por empresas de menor capitalización bursátil sobre las de mayor capitalización; HML sería el factor “High Minus Low” que capturaría el exceso de retorno generado por activos que tienen cotizaciones bajas respecto de su valor fundamental.

Como es observable, las dos principales aportaciones que realizan (Fama & French, 1993) con su modelo de tres factores, son las de los factores de tamaño y valor. Enfocándolo desde el punto de vista de la rentabilidad del activo, el factor tamaño nos da la idea de

que, históricamente, aquellas empresas con una capitalización bursátil baja tienden a obtener una mayor rentabilidad que aquellas con una capitalización alta. De la misma manera, si observamos el riesgo de dichas empresas con capitalización baja sería mayor. Motivos como la menor diversificación de productos o mercados, menor acceso a fuentes de financiación o su mayor vulnerabilidad a las fluctuaciones económicas hacen que se exija una mayor rentabilidad a activos que incrementen la exposición al riesgo de nuestra cartera. Por otro lado, el factor valor tiene como fundamento el hecho de que aquellas acciones que se encuentran infravaloradas por el mercado ofrecen un mayor potencial de revalorización a medida que el mercado corrige dicha valoración.

La búsqueda de factores que explicasen el retorno y riesgo de los activos no paró con este trabajo de (Fama & French, 1993). De esta manera, son numerosos los trabajos, en las siguientes décadas, que trataron de encontrar nuevos factores. En este sentido, debemos de detenernos a analizar el trabajo realizado por Jegadeesh y Titman en 1993 titulado “Returns to Buying Winners and Selling Loser: Implications for Stock Market Efficiency”.

En este artículo, se trata de analizar una sospecha recurrente por parte de economistas, periodistas y psicólogos consistente en el hecho de que el ser humano tiende a sobre-reacción a la información (Jegadeesh & Titman, 1993). Pues bien, a la hora de tomar una decisión financiera, el inversor, tiene en consideración una gran cuantía de variables y datos por lo que no resultaría extraño encontrar un comportamiento anómalo en la valoración de los activos como consecuencia de esta sobre-reacción a la información pasada. Es por ello que Jegadeesh y Titman llevaron a cabo un análisis de los retornos obtenidos por acciones cotizadas del NYSE entre los años 1965 a 1989 y observaron que aquellas estrategias de inversión basadas en la compra de acciones ganadoras, es decir, que han mostrado un buen rendimiento en el pasado, y la venta de acciones perdedoras generaban retornos significativos positivos en periodos de tenencia de tres a doce meses. Esta misma idea fue corroborada por Carhart unos años después en el mundo de los fondos de inversión, obteniendo unos resultados similares (Carhart, 1997).

Por lo tanto, observamos cómo al trabajo formulado por Fama y French de 1993 podemos añadir un nuevo factor que trate de capturar la tendencia que lleven los propios activos durante un periodo temporal previo. A este nuevo factor se le ha denominado comúnmente como “momentum” y nos hará que podamos explicar, aunque sea parcialmente, los retornos de los activos en función de la siguiente ecuación matemática:

$$r_i - r_f = \alpha_i + \beta_1(r_M - r_f) + \beta_2(SMB) + \beta_3(HML) + \beta_4(WML) + \varepsilon_i \quad (5)$$

Donde el nuevo factor lo recogeríamos bajo la nomenclatura de *WML* y tendría como significado “Winners Minus Losers”.

A continuación, debemos hacer referencia al artículo de, nuevamente, Fama y French, del año 2015 en el que proponen un modelo multifactorial compuesto por cinco factores: los tres propuestos en su artículo inicial de 1993 (mercado, tamaño y valor) y añadiendo dos nuevos factores como serían la calidad y la inversión (Fama & French, 2015).

El primero de estos dos nuevos factores, calidad, trata de capturar la diferencia en los rendimientos entre las empresas con altas rentabilidades operativas frente aquellas que cuentan con bajas rentabilidades operativas. Con esta idea, tratan de justificar, a través de la teoría de descuento de dividendos, que aquellas empresas que cuentan con una rentabilidad operativa más alta tendrán más posibilidades de generar flujos de efectivo en el futuro y, por lo tanto, se esperará un mayor retorno de ellas (Fama & French, 2015). El problema, a nivel práctico, que encuentra este factor es la dificultad de definir lo que entendemos por empresas de calidad ciñéndonos exclusivamente a indicadores cuantitativos ya que podemos tomar como referencia diferentes medidas: competitividad, eficiencia, crecimiento estable, sostenibilidad de los beneficios, ROE... Pero, al fin y al cabo, lo que se pretende capturar con este nuevo factor sería el exceso de retorno generado por aquellas compañías que manejan correctamente su capital y evitan el sobreapalancamiento y la sobrecapitalización (Bender et al., 2013).

Por su parte, el factor inversión captura la diferencia en los rendimientos entre empresas con tasas de inversión bajas y, por lo tanto, conservadoras, de aquellas con tasas de inversión más agresivas. Con inversión los autores se refieren tanto a crecimiento en los activos como al crecimiento de los fondos propios de la empresa ya que derivaron similares resultados con el análisis de ambas. Se entiende que aquellas compañías con una inversión estable se asimilan a las conocidas como empresas “value” mientras que aquellas con una fuerte inversión se asemejan a las empresas “growth” (Fama & French, 2015).

Con todo, la formulación matemática de este modelo sería la siguiente:

$$r_i - r_f = \alpha_i + \beta_1(r_M - r_f) + \beta_2(SMB) + \beta_3(HML) + \beta_4(RMW) + \beta_5(CMA) + \varepsilon_i \quad (6)$$

Donde *RMW* sería la diferencia en rendimiento de aquellas carteras de acciones diversificadas con rentabilidades robustas y débiles (“Robust Minus Weak”) y *CMA*, por su parte, la diferencia en rendimiento de acciones de aquellas empresas con inversiones conservadoras y agresivas (“Conservative Minus Aggressive”).

Por último, debemos tratar un último factor muy relevante a nivel práctico como es el de baja volatilidad o “low volatility”. Este trata de capturar el exceso de retorno generado por aquellas acciones con una volatilidad, beta o riesgo idiosincrático inferior a la media (Bender et al., 2013). Si bien este factor puede parecer contrario a uno de los principios más básicos de las finanzas: a mayor volatilidad, mayores retornos (Blitz & van Vliet, 2007) defendido también por el CAPM, se ha demostrado que aquellos activos con una volatilidad inferior tienden a superar el rendimiento del mercado. Es extensa la bibliografía en la que se constata dicho efecto (Baker & Haugen, 1991) (Jagannathan & Ma, 2003) (Nielsen & Subramanian, 2008) que es especialmente útil en periodos negativos de los mercados.

Finalmente, a modo de explicación de este factor se suele emplear el conocido como “efecto lotería”. Este nos indica que, en ocasiones, tendemos a tomar apuestas asumiendo una posible pequeña pérdida, pero con una gran posibilidad de retorno, de tal manera que la media ponderada del resultado sea negativa. Esto en el mundo de la inversión se asemejaría a una tendencia por comprar acciones a bajo precio pero con gran volatilidad con ese objetivo de obtener un gran retorno, debido a un comportamiento irracional por parte del inversor (Bender et al., 2013). Esta explicación acaba derivando en que, en ocasiones, los inversores paguen más de lo debido por acciones volátiles y menos por acciones estables, generando una ineficiencia que pretende capturar el factor de baja volatilidad.

Con todo, ha quedado constatado como el factor investing es un estilo de inversión que, empleado correctamente, puede ser de gran utilidad para los inversores en el objetivo de tratar de maximizar sus retornos. Este beneficio puede ser claramente observado si tenemos en consideración que esta técnica de inversión puede, y debe, ser utilizada para rebalancear las carteras de los inversores en función del momento macroeconómico en el que nos encontremos. Así, y, a modo ejemplificativo, podemos afirmar que, en momentos económicos adversos puede ser óptimo sobreponderar el factor de baja volatilidad y que,

en situaciones macroeconómicas más positivas, una posibilidad a analizar debe ser el sobreponderar factores como el de momentum o tamaño.

Hypothetical Annual Returns (%) of Factor Strategies versus the Broader Market

	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
Value	61.6	25.0	15.2	20.6	14.2	-28.9	113.3	28.0	5.6	19.6	40.8	14.5	3.1	26.3	21.8	-1.2	30.9	20.5	31.5	-3.2
Dividend Yield	56.4	21.9	11.8	17.6	10.1	-42.1	72.3	27.9	2.9	19.2	40.4	13.4	1.8	23.8	21.4	-5.7	29.9	15.9	29.3	-7.3
Momentum	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Quality	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Low Volatility	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Size	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Broader Market	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Value	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Dividend Yield	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Momentum	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Quality	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Low Volatility	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Size	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9
Broader Market	43.4	10.9	10.9	16.0	2.7	-43.3	53.8	24.3	1.2	19.0	38.9	12.8	-3.8	21.3	18.7	-8.1	29.2	12.6	27.2	-11.9

Ilustración 2: Rendimiento en las dos últimas décadas de la inversión en factores

Fuente: Fidelity Investments, 2023

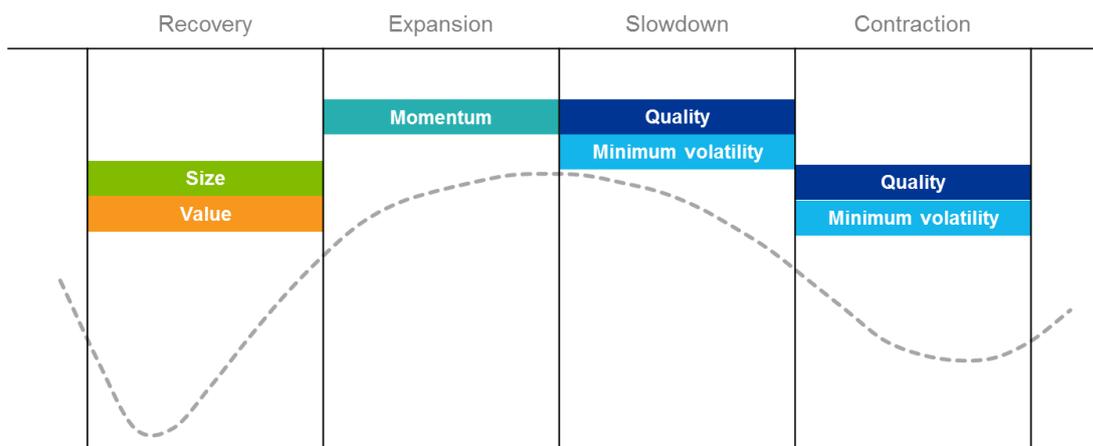


Ilustración 3: Rebalanceo cíclico de la inversión en factores

Fuente: Blackrock, 2024

Hasta ahora, se han recogido las aportaciones más trascendentes de las últimas décadas relativas a los conocidos como factores de estilo. Por otro lado, nos encontramos los llamados factores macroeconómicos que también han visto demostrada su influencia en la determinación del riesgo y retorno de categorías de activos, en su significado amplio. Ejemplos de estos factores macroeconómicos serían el crecimiento económico, las tasas de interés, la inflación, la liquidez o el riesgo crediticio (Bender et al., 2013). Debido al

carácter sumario de esta explicación no podremos entrar en más detalle sobre estos, pero es conveniente tener en mente su existencia.

Como podemos observar, se han descubierto cientos de factores que, al parecer, son capaces de explicar en cierta medida el riesgo y retorno de los activos.

En este sentido, en los últimos años ha habido una especial proliferación de publicaciones relativas al descubrimiento de nuevos factores. Es lo que Harvey y Liu denominan como “factor zoo” y si, verdaderamente, pudiesen todos estos explicar el riesgo y retorno de los activos estaríamos ante una gran noticia. La cuestión y advertencia que se realiza es que, en la práctica, la utilización de estos nuevos factores, en muchas ocasiones, está produciendo resultados fuera de los esperados (Harvey & Liu, 2019). Esto se debe, en parte, a la minería de datos con la que, en ocasiones, se realizan los estudios y que provoca la falta de replicabilidad de los resultados del mismo. Con este comentario simplemente se pretende hacer una anotación sobre la situación actual del factor investing y de la necesidad de ser rigurosos a la hora de elaborar y publicar nuevos descubrimientos.

Pese a que el factor investing lleve presente y haya sido estudiado durante décadas, es tras la crisis financiera de 2008, cuando surgieron dos tendencias que potenciaron esta técnica de inversión para diferentes tipos de activos. En primer lugar, los inversores comenzaron a evaluar e implementar la diversificación de sus carteras en términos de riesgo sistemático debido al fracaso de la gestión activa de proporcionar una adecuada gestión de riesgos. Y, en segundo lugar, los inversores buscaron una alternativa de inversión más económica a la gestión activa, pero que aún les permitiese capturar parte del *alpha* generado (Soe & Xie, 2016).

2.2 Factor Investing en Renta Fija

La inmensa mayoría de la literatura académica relativa a la inversión en factores ha sido estudiada para los mercados de renta variable debido a diversos motivos. Esto hace que exista un especial interés de investigación para la materia en los mercados de renta fija y el estudio relativo a si los factores generadores de un exceso de retorno para las acciones actúan de manera similar en los bonos.

Uno de los motivos por los que el factor investing en renta fija está en una etapa de desarrollo mucho más prematura que en renta variable es su mayor facilidad para cometer errores. En primer lugar, la literatura académica de la inversión en factores para mercados

de renta variable podríamos decir que comienza alrededor de hace setenta años con el CAPM. Esto hizo que durante las siguientes décadas se haya podido establecer un marco conceptual común sobre el que trabajar, cuestión que no ha ocurrido aún con los mercados de renta fija. Pero la mayor complicación viene, seguramente, derivada de la dificultad de aplicar e implementar de manera efectiva factores en renta fija. La falta de completitud y coherencia en la información supone un importante hándicap frente a la renta variable, generando así diferentes estrategias para tratar de explicar los factores que impulsan los retornos en los mercados de renta fija (Blackrock Systematic Investing, 2023).

(Heckel et al., 2021) en su artículo “Out-performing corporate bonds indices with factor investing” exponen una serie de elementos que influyen en el poco éxito que ha tenido la inversión en factores en renta fija frente a en renta variable por las diferencias entre ambos activos. Entre otros mencionan los siguientes hechos: (1) Cada compañía puede emitir bonos con distintos vencimientos y especificaciones y, por lo tanto, con distinto riesgo; (2) El riesgo de cada bono cambia a medida que pasa el tiempo porque el plazo hasta el vencimiento disminuye; (3) Los bonos corporativos ofrecen una liquidez relativamente escasa y muchos son difíciles de negociar ya que una importante parte de los inversores los compran y los mantienen hasta su vencimiento; (4) A diferencia de las acciones que pueden ver su valor incrementado a lo largo del tiempo, los rendimientos obtenidos por la inversión en bonos corporativos no se verán tan afectados por el aumento de la capitalización bursátil de la empresa en cuestión.

Sin embargo, pese al inicialmente desalentador panorama, encontramos ciertos ETFs de bonos corporativos que incorporan factores de estilo y cuyos rendimientos, tanto en términos absolutos como ajustados a riesgo, han sido superiores a los proporcionados por índices del mercado (Blackrock Systematic Investing, 2023).

Existe una diferencia fundamental entre los perfiles de riesgo y retorno que nos podemos encontrar en los mercados de renta fija y renta variable. En este último, los inversores pretenden beneficiarse de los futuros flujos de caja que generará la empresa mientras que en el caso de los bonos corporativos, el inversor simplemente busca el pago en tiempo de aquellos intereses que le correspondan además de la devolución del principal.

Además, observamos otra diferencia en el hecho de que el riesgo de una acción es principalmente idiosincrático, es decir, específico del propio activo. Por su parte, el riesgo en los activos de renta fija viene en buena medida determinado por el riesgo sistemático.

Esto se debe al hecho de que en los activos de renta fija, el riesgo de tipo de interés y el riesgo crediticio acumulan cerca de un 90% de las diferencias en los retornos de estos activos, haciendo muy interesante el estudio de la inversión en factores en renta fija y buscando en las carteras una exposición a factores de riesgo sistemáticos que generen un exceso de rentabilidad (Soe & Xie, 2016).

Como hemos mencionado, el punto de partida en cuanto a literatura se refiere es peor en renta fija que en renta variable, pero esto no implica que en la primera no se hayan producido interesantes aportaciones. En este sentido, hasta el trabajo realizado por Houweling y van Zundert en 2017, se habían identificado principalmente dos factores que afectasen a los rendimientos de los bonos corporativos: bajo riesgo (Frazzini & Pedersen, 2014) y momentum (Jostova et al., 2013). Además, se había comenzado a investigar el factor valor (Correia et al., 2012) y no existía información relativa al factor tamaño (Houweling & van Zundert, 2017). Nótese que aunque los nombres de los factores sean similares a los propuestos en renta variable, las definiciones de los mismos se encuentran adaptadas al mercado de renta fija. En este sentido, las definiciones propuestas por Houweling y van Zundert sobre los factores anteriormente mencionados son las siguientes.

El factor tamaño se define mediante el valor total de mercado de los bonos en circulación de una empresa con respecto al valor total del índice de referencia que emplean en su estudio (Barclays U.S. Corporate Investment Grade Index y the Barclays U.S. Corporate High Yield Index). Se busca determinar si las empresas con una menor capitalización de mercado de deuda pueden presentar características de rendimiento distintivas en comparación con aquellas empresas de mayor tamaño, lo cual puede parecer lógico si tenemos en consideración el hecho de que, en general, existen diferencias de liquidez y riesgo entre empresas grandes y pequeñas.

Por su parte, el factor de bajo riesgo ha sido definido principalmente alrededor de dos opciones. O bien empleando el corto vencimiento del bono, exponiéndose, por tanto, a un menor riesgo de cambios en la tasa de interés (Derwall et al., 2009) o, por otro lado, utilizando la calificación crediticia del bono, es decir, midiendo la posibilidad de incumplimiento del pago (Frazzini & Pedersen, 2014), siendo posible la elaboración de carteras que combinen ambos criterios. La motivación de este factor sería la misma que se aportó anteriormente para explicar el factor de baja volatilidad en la inversión en factores para renta variable: el llamado “efecto lotería”. Un similar fundamento

encuentran (Frazzini & Pedersen, 2014) que llegaron a la conclusión de que las betas bajas producen mayores retornos debido a que, tanto para acciones como para bonos corporativos, una beta alta suele ser más atractiva para el inversor que busca rendimientos altos, generando así un exceso de demanda que lleva a un incremento de precio y que, consecuentemente, produce una reducción de los rendimientos futuros esperados.

El factor valor puede ser entendido como la reversión a la media de las valoraciones: aquellas acciones baratas tienden a tener mejores rendimientos mientras que las sobrevaloradas suelen tener peores rentabilidades. Por lo tanto, se trata de explotar la infravaloración del mercado con respecto un activo. Como se comentó anteriormente, en renta variable se suelen emplear medidas como P/B o P/E. Por su parte, en renta fija, la dificultad se encuentra en determinar una métrica que capture adecuadamente la sobre o infra valoración del bono corporativo en cuestión. El artículo publicado por (Correia et al., 2012) evalúa la relación entre el precio de mercado de un bono y una medida de su valor intrínseco basada en ciertos indicadores de riesgo como el apalancamiento, la rentabilidad, el vencimiento, la calificación crediticia o el *credit spread*.

En el trabajo elaborado por (Houweling & van Zundert, 2017), se emplea una metodología específica para implementar este factor en la construcción de carteras. En este sentido, se realiza una regresión en la cual los spreads de crédito de los bonos se ajustan en función de variables explicativas como calificaciones crediticias, madurez y la variación del spread de crédito en un período de tres meses.

$$S_i = \alpha + \sum_{r=1}^{21} \beta_r I_{ir} + \gamma M_i + \delta \Delta S_i + \varepsilon_i \quad (7)$$

Donde S_i es el spread de crédito del bono i ; I_{ir} es una variable dicotómica que tomará como valor 1 si el bono tiene una valoración superior a un límite preestablecido y 0 en caso contrario; M_i sería el vencimiento del bono i ; ΔS_i sería la variación del spread de crédito en un periodo de tres meses.

De esta regresión se obtiene un spread estimado que, posteriormente, se compara con el spread efectivamente observado, obteniendo la diferencia entre ambos. Los bonos entonces se clasifican según esta diferencia, y aquellos con las mayores discrepancias positivas (es decir, bonos cuyo spread de crédito observado es sustancialmente más alto que el estimado por el modelo) se consideran de valor, ya que ofrecen una compensación de riesgo aparentemente mayor de lo justificado por sus fundamentos.

Por último, nos encontramos con el factor momentum que pretende capturar las ganancias asociadas con la persistencia de tendencias en los rendimientos de los bonos a lo largo del tiempo, capitalizando así las dinámicas de comportamiento del mercado y las inercias en los patrones de precios. En este sentido, el mercado de bonos corporativos es, incluso, menos eficiente con la información que el de acciones debido a que se presta mucha más atención a las acciones que a los bonos de una compañía. Esto hace que ese comportamiento irracional por parte del inversor que se puede dar respecto a las noticias que recibe se vea amplificado en el mercado de bonos corporativos y que dicha irracionalidad se mantenga durante un periodo de tiempo superior, generando así la posibilidad de utilizar estrategias de inversión que exploten esta ineficiencia (Gebhardt et al., 2005). Más allá de esto, el factor no presenta especiales particularidades con respecto a lo explicado para el factor investing en el mercado de renta variable por lo que nos remitimos a dicho comentario realizado anteriormente.

Con todo, observamos cómo el factor investing también puede ser aplicado en renta fija y más concretamente en bonos corporativos. Ciertamente es que los factores son, en algunos casos, distintos o se interpretan de manera diferente a la forma tradicional propuesta por el factor investing de renta variable, pero independientemente de esta circunstancia, lo relevante es la demostración de la existencia de ineficiencias en el mercado de renta fija que pueden ser explotadas a través de la exposición a ciertos factores.

2.3 ESG Factor Investing

En la actualidad, y, especialmente, en Europa, los inversores no solo miran por la rentabilidad que les puedan dar sus inversiones sino que también tienen en cuenta si la estrategia de negocio que tiene la compañía en cuestión se encuentra alineada con los factores ESG. Este acrónimo que responde, en inglés, a las palabras Environmental, Social y Governance hace referencia a los elementos que convierten a una compañía en sostenible, sin descuidar en ningún caso los aspectos financieros (Deloitte, 2021). En general, en nuestra sociedad, existe cada vez una mayor concienciación por estas cuestiones que afectan al cómo una empresa lleva a cabo sus operaciones y se ve reflejado en que, por ejemplo, el 85% de los miembros del CFA Institute tengan en cuenta consideraciones sobre sostenibilidad en sus inversiones (CFA Institute, 2023). Es más, las propias empresas entienden de este requisito que se les exige y ven esta nueva casuística como una forma de crear valor a largo plazo. Todas estas consideraciones implican, en último término, un crecimiento en la inversión que tiene presentes a los factores ESG.

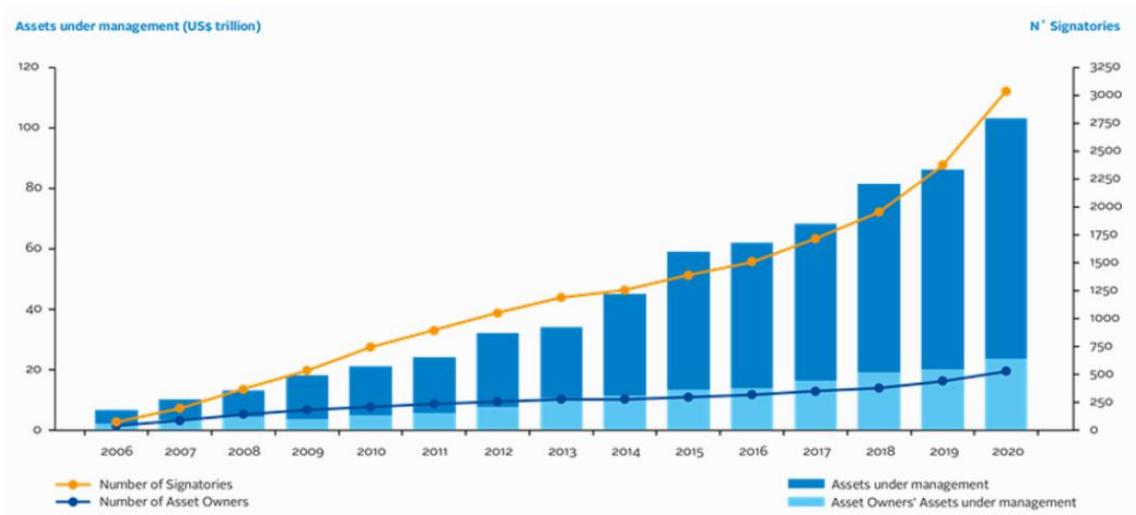


Ilustración 4: Evolución ESG AuM

Fuente: Forbes, 2020

La inversión ESG ha demostrado ser más que una tendencia pasajera. Estudios recientes sugieren que las inversiones que consideran factores ESG pueden ofrecer rendimientos comparables o incluso superiores a las inversiones tradicionales, además de presentar un perfil de riesgo potencialmente más bajo (Fan & Michalski, 2020). Esto se debe a que las prácticas sostenibles pueden proteger a las empresas contra riesgos operativos, regulatorios y legales. Por lo tanto, las empresas que se enfocan en sostenibilidad tienden a experimentar menos volatilidad en sus acciones, mayor estabilidad y, en algunos casos, mejores rendimientos ajustados al riesgo (Friede et al., 2015). En esta línea encontramos estudios que han demostrado cómo en el mercado de renta variable australiano, el no realizar un filtrado previo con criterios ESG implica obtener un rendimiento inferior ajustado a riesgo (Fan & Michalski, 2020). Aunque, por otro lado, también es cierta la existencia de ciertos trabajos que critican de “greenwashing” los estudios realizados por los fondos de inversión tratando de mostrarse más “verdes” de lo que verdaderamente son. En estos estudios se obtienen resultados que prueban que la prima ofrecida por la inversión en activos sostenibles es, de hecho, negativa y estadísticamente significativa (Alessi et al., 2021).

En este sentido, debemos mencionar el informe “Who Cares Wins”, resultado de una iniciativa liderada por las Naciones Unidas en colaboración con más de 20 instituciones financieras de todo el mundo. Este documento fue pionero en establecer una conexión clara entre la integración de factores ambientales, sociales y de gobernanza (ESG) en la toma de decisiones de inversión y la generación de valor a largo plazo tanto para las

empresas como para la sociedad en general. Pese a que la ONU ya había comenzado a acuñar el término ESG en eventos como el World Economic Forum de 1999 (Pollman, 2022), fueron estas recomendaciones las que sirvieron como catalizador para la adopción generalizada de los criterios ESG por parte de los inversores y las empresas (Compact UN Global, 2004). Y ahondando en la relevancia del ESG en el mundo empresarial, se han elaborado estudios en los que se demuestra cómo estos factores afectan a la valoración y rendimiento de las compañías a través tanto del riesgo sistemático como idiosincrático (Giese et al., 2019).

Si atendemos al detalle de cada uno de los tres criterios observamos las siguientes características.

En primer lugar, tendríamos el criterio “environmental”. El factor ambiental se refiere a la consideración de cómo las actividades empresariales impactan en el medio ambiente. Esta dimensión evalúa las prácticas de sostenibilidad de una empresa, su capacidad para gestionar y mitigar los riesgos ambientales asociados a sus operaciones y su contribución a la lucha contra el cambio climático. Algunos ejemplos de actividades que se encuadran dentro de este primer pilar serían la gestión de emisiones de gases de efecto invernadero, la eficiencia energética, la conservación del agua, la gestión de residuos, la biodiversidad y la prevención de la contaminación. Vinculando estas actividades con el ámbito empresarial, una compañía que destaque en este factor típicamente adopta prácticas que minimizan su huella ecológica, lo que puede traducirse en una reducción de costes a largo plazo mejorando así su rendimiento operativo, un incremento de la reputación de la marca y generación de ventajas competitivas (Clark et al., 2015). Además, se ha comprobado cómo aquellas empresas con malas políticas medioambientales tienden a tener una correlación negativa con el rendimiento (Konar & Cohen, 2001) y que, nuevamente, aquellas compañías con controversias medioambientales suelen tener que pagar un diferencial crediticio significativamente más alto en sus préstamos (Goss & Roberts, 2011).

En segundo lugar, se encuentra el factor “social”. Este se centra en el impacto que una empresa tiene en las personas, tanto interna como externamente mediante la evaluación de cómo la empresa gestiona sus relaciones con los empleados, proveedores, clientes y las comunidades en las que opera. Los indicadores de este factor incluyen, entre otros, la protección de los derechos humanos, las prácticas laborales (como las condiciones de trabajo, salud y seguridad), el compromiso comunitario y el respeto por la diversidad y la

inclusión (Clark et al., 2015). La atención en este criterio ha sido incrementada en los últimos años debido a la atención puesta por la sociedad en los sistemas sanitarios, educativos, las desigualdades y la seguridad en el lugar de trabajo (Amundi Asset Management Smart Beta, 2020). Especialmente interesante resulta el análisis realizado en el artículo de (Kim & Li, 2021), “Understanding the Impact of ESG Practices in Corporate Finance” en el que llegan a la conclusión de que el factor social tiene un especial impacto en la calificación crediticia de la empresa, lo que sugiere que las prácticas socialmente responsables pueden mejorar la percepción de los inversores y el valor de mercado de una compañía.

Por último, se sitúa el elemento denominado “governance”. Este factor evalúa cómo está estructurada la dirección de una empresa, incluyendo la eficacia de la junta directiva, los derechos de los accionistas, las prácticas de liderazgo y la independencia de la junta (Clark et al., 2015). A modo de ejemplo de la importancia de un adecuado gobierno corporativo, podemos acudir a la literatura académica que ha demostrado como aquellas empresas que conceden menos derechos a los accionistas muestran un ROA inferior a sus competidores (Core et al., 2006) o cómo las empresas con un mal gobierno corporativo son tendentes a pagar a sus ejecutivos más que sus competidores, resultando esto en un peor rendimiento de la compañía (Core et al., 1999).

Centrándonos ahora en la integración de criterios ESG en la dinámica del factor investing, debemos comenzar resaltando que durante la última década, una gran cantidad de inversores institucionales han comenzado a tener en cuenta estas consideraciones en la elaboración de sus carteras. La cuestión, por tanto, que nos debemos plantear es el efecto que tiene en el rendimiento y riesgo de las carteras el construirlas en función de una serie de consideraciones ambientales, sociales y de gobernanza que deben tener las empresas que la conforman.

En este sentido, el trabajo realizado por (Melas et al., 2016) analiza la relación entre las características ESG con los factores de riesgo tradicionales, tratados anteriormente, en el mercado de renta variable. Con su estudio, observaron que las puntuaciones ESG de las empresas tenían correlaciones positivas con los factores tamaño, calidad y baja volatilidad y que la incorporación de criterios ESG en estrategias de inversión pasivas generalmente mejoraba el rendimiento ajustado a riesgo de la cartera, inclinando la selección de activos hacia aquellos de mayor calidad y menor volatilidad. Además, al integrar los criterios ESG en estrategias de factor investing, especialmente en el factor de baja volatilidad,

vieron una mejora del 30% en la exposición a estos con una reducción de apenas un 7% en la exposición al factor objetivo. Por lo tanto, aquellas estrategias defensivas basadas en la inversión en factores, principalmente los de baja volatilidad y calidad, pueden aumentar sus calificaciones ESG sin apenas afectar su objetivo de inversión principal. Por otro lado, se demuestra como aquellas estrategias más dinámicas, como el momentum, tamaño o valor, también pueden mejorar su valoración ESG, pero estas sí que sacrifican un mayor porcentaje de exposición al factor objetivo.

Tras este trabajo que analiza el efecto que tienen los criterios ESG sobre los factores tradicionales, han sido diversos los estudios que estudian la posibilidad de considerar el ESG como un factor más explicativo del riesgo y retorno de los activos. En este sentido, se ha determinado que, realizando regresiones empleando solo un factor, el factor ESG sería, desde el año 2010, el que más capacidad explicativa tiene por detrás del factor de mercado propuesto por el CAPM. Es decir, el factor ESG obtiene una R^2 superior a todos los factores propuestos por Fama y French, a excepción del factor de mercado. Ahora bien, si se considera el factor ESG dentro de un modelo multifactorial se observa que la R^2 del modelo de cinco factores es muy próxima a la obtenida por un modelo de seis factores en el que se incluyese el factor ESG, pudiendo afirmar que, en este caso, el impacto explicativo de este nuevo factor es escaso. A lo anterior hay que realizar un comentario relativo al hecho de que el factor ESG no es significativo analizado en el mercado de renta variable norteamericano, pero sí es significativo en la eurozona (Amundi Asset Management Smart Beta, 2020).

Por otro lado, se ha desarrollado por parte del Ministerio de Educación e Investigación alemán un proyecto llamado “Carbon Risk Management” (CARIMA). Este tiene el objetivo de cuantificar, a través de las cotizaciones de las diferentes acciones, los riesgos y oportunidades existentes en las valoraciones de los activos financieros que vengan derivados por el cambio climático y la transición hacia una economía verde (Görge et al., 2020). Para llevar a cabo esta tarea de cuantificación, plantean la utilización de un factor que refleja los riesgos de la transición ecológica, al que llaman BMG (Brown Minus Green) e incorporan en el siguiente modelo:

$$r_i - r_f = \alpha_i + \beta_1(r_M - r_f) + \beta_2(SMB) + \beta_3(HML) + \beta_4(WML) + \beta_5(BMG) + \varepsilon_i \quad (8)$$

Como observamos, emplean el modelo de cuatro factores que incorpora el factor momentum (Jegadeesh & Titman, 1993) (Carhart, 1997) y se le añade un quinto factor

llamado BMG que representa la diferencia entre los retornos obtenidos por firmas con una Brown-Green-Score, cifra que calculan teniendo en cuenta 55 variables que pueden afectar a la transición ecológica de las compañías, por encima de la media y aquellas por debajo de esta.

Esta nueva beta que se propone estima el impacto que tiene sobre la cotización de un activo los posibles cambios en expectativas que pueden ocurrir si la economía actual cambia más rápido, o lento, de lo esperado hacia una economía verde. Por lo tanto, es aplicable para determinar la sensibilidad en valor a cambios en el proceso de transición de la economía y cuenta con utilidad tanto para acciones como para bonos corporativos.

Por último, en cuanto a la interpretación de la β_{BMG} , debemos de entender que si tiene un valor superior a cero, el valor del activo se verá reducido comparado con el mercado si el proceso de transición hacia una economía verde se acelera de manera inesperada. De manera opuesta, si la β_{BMG} es inferior a cero, el valor ese mismo activo, comparado con el mercado, se verá incrementado si el proceso de transición hacia una economía verde se ve decelerado de manera inesperada.

En esta misma línea se encuentra el trabajo realizado por (Gimeno & González, 2022) que plantea un enfoque similar al de (Görge et al., 2020) aunque con ciertas peculiaridades. En este sentido, el modelo CARIMA, cuenta con una importante limitación que es la gran cantidad de información necesaria para generar las Brown-Green-Score. Esto hace que, en un ámbito como el de la sostenibilidad, en el que existe poca información disponible debido a la no obligatoriedad de publicación de estos datos por parte de las empresas, sea de gran dificultad conseguir una calificación para cada una de las empresas objeto de estudio. Esto hizo que, en el artículo de 2020, se tuviesen que descartar más de 1000 empresas de la muestra inicial de 2600 por falta de la información necesaria. Por su parte, en este nuevo trabajo del Banco de España, para aquellas empresas que no revelan sus emisiones, se emplea la sensibilidad de las cotizaciones de sus acciones a este factor medioambiental, mediante la beta correspondiente, como una aproximación indirecta a su exposición al cambio climático. La lógica detrás de esto es que, aunque una empresa no divulgue directamente su huella de carbono, su precio de acción puede verse influenciado por cómo el mercado percibe su exposición al riesgo climático a través de su relación con el factor medioambiental.

Con todo, hemos observado cómo el factor investing es una estrategia de inversión muy extendida en el mundo tanto académico como profesional aunque es cierto que en renta fija se encuentra menos estudiado que en renta variable. Además, nos encontramos con una gran cantidad de trabajos, especialmente en la última década, que consideran el ESG como un posible nuevo factor a tener en consideración y que cada vez está tomando más importancia a medida que avanza la situación económica y social mundial. Por ello, centraremos nuestro estudio en aquellos campos que se encuentran menos desarrollados: el factor investing en renta fija, en concreto en bonos corporativos, y la posibilidad de considerar como significativo un nuevo factor ESG en este tipo de activos. Para lograrlo, realizaremos una combinación de ciertas estrategias ya explicadas en las anteriores páginas junto con técnicas de Machine Learning que comentaremos a continuación.

3. MACHINE LEARNING EN EL ÁMBITO DEL FACTOR INVESTING

3.1 Paradigmas del machine learning

El aprendizaje puede ser considerado como el proceso de adquirir y modificar el conocimiento o comportamiento como resultado de la experiencia. Sin embargo, en contraposición al aprendizaje en base a la experiencia de los humanos, las máquinas emplean datos para la adquisición de conocimientos. De manera muy simplificada, el Machine Learning (ML) es una subcategoría dentro de la Inteligencia Artificial en virtud de la cual los ordenadores son capaces de pensar y aprender por sí mismos (Alzubi et al., 2018).

Son numerosas las definiciones formales aportadas en la literatura académica relativas al concepto de ML, es por ello que, para tener una comprensión del mismo, destacaremos la primera utilización de este concepto por (Samuel, 1959), quien definió el ML como aquel campo de estudio que proporciona capacidad de aprendizaje a los ordenadores sin estar explícitamente programados para ello.

El objetivo final del ML es descubrir patrones en los datos que, a simple vista no son aparentes y permitirnos realizar predicciones a futuro en función de estos. Para ello, se emplean algoritmos que son entrenados con una parte del conjunto total de los datos disponibles, a los que denominaremos conjunto de entrenamiento, para luego comparar esos resultados frente a aquellos datos que se quedaron fuera del conjunto de entrenamiento, es decir, lo que se conoce como conjunto de prueba, empleando una serie de métricas de rendimiento. Nótese que este proceso puede ser repetido tantas veces como

sea necesario para ir logrando mejorar el rendimiento del modelo mediante la realización de cambios en los algoritmos, o parámetros utilizados por ellos. Una vez que se haya conseguido optimizar el modelo, será el momento de emplearlo con datos que se encuentren fuera de la muestra inicial en base a la cual se realizaron las fases de entrenamiento y validación.

El ML puede ser utilizado en prácticamente cualquier ámbito empresarial, en industrias tan dispares como las logísticas, sanitarias o financieras, entre otras. En definitiva, puede utilizarse en cualquier situación en la que exista una gran cantidad de datos disponibles. Sin embargo, pese a esta aparente infinidad de aplicaciones, resulta posible clasificar el ML entorno a tres grandes paradigmas.

En primer lugar, nos encontramos con el aprendizaje supervisado. En este, se emplean una serie de datos etiquetados para entrenar a los algoritmos de clasificación o predicción. De esta manera, los algoritmos son capaces de predecir el valor correspondiente a cualquier dato que no haya sido empleado en el proceso de entrenamiento del algoritmo. Es decir, el aprendizaje supervisado es empleado para describir tareas de predicción, siendo el objetivo predecir o clasificar un resultado específico de interés (Jiang et al., 2020).

Además del aprendizaje supervisado, otra categoría de gran relevancia en el ML es el conocido como aprendizaje no supervisado. Este se centra en encontrar patrones y estructuras ocultas en datos no etiquetados, suponiendo esto la principal diferencia frente al aprendizaje supervisado. Esto permite a los algoritmos identificar agrupaciones, el conocido como clustering, o reducir la dimensionalidad de los datos, entre otras funciones (Garg & Kalai, 2018).

Por último, debemos también destacar el reinforcement learning, también conocido como aprendizaje por refuerzo. Este se centra en cómo los agentes deben tomar acciones en un entorno para maximizar una recompensa acumulada a lo largo del tiempo. Este proceso implica que el agente interactúa con su entorno, ejecutando acciones y recibiendo retroalimentación en forma de recompensas, lo cual guía su aprendizaje para lograr optimizar sus decisiones futuras (Malibari et al., 2023).

3.2 El aprendizaje supervisado en el machine learning y su metodología

Tras haber realizado una breve explicación de los principales paradigmas del Machine Learning, profundizaremos en el concepto del aprendizaje supervisado y los distintos algoritmos que pueden emplearse dentro de esta categoría. Esta especial atención se debe a la necesidad de proporcionar un mayor contexto que permita entender el procedimiento que se empleará más adelante en la construcción del modelo.

Pero antes de entrar a analizar algunos de los algoritmos de aprendizaje supervisado, entre los que prestaremos especial atención a los árboles de decisión y random forest al ser estos los que emplearemos en el posterior análisis, debemos hacer una especial mención a la metodología que se ha de emplear a la hora de llevar a cabo un análisis que incorpore técnicas de ML.

En primer lugar, debemos hacer referencia a la manipulación que se ha de realizar con respecto del conjunto de datos. Como se ha mencionado anteriormente, del total del dataset se suele realizar una partición de la cual obtendremos el conjunto de entrenamiento, que servirá para ajustar el modelo haciendo que este aprenda de los datos, y el conjunto de prueba, sobre el que realizaremos predicciones para comparar los valores predichos de los reales, obteniendo así una serie de medidores del rendimiento y capacidad de generalización del modelo. En caso de no realizar esta partición, no tendremos manera de interpretar si nuestro modelo es generalizable ya que no tendremos datos con los que realizar el proceso de validación de los resultados. Por lo tanto, realizar esta partición es un paso fundamental en cualquier proceso de ML.

No existe un ratio de división fijo que haya que emplear sobre el conjunto de datos, pero, generalmente, el conjunto de entrenamiento suele estar compuesto del 60-80% del total de datos iniciales y al conjunto de prueba le corresponderá el 40-20% restante. Además, la división entre ambos conjuntos debe de ser aleatoria, de manera que evitemos caer en sesgos. Nótese que también sería posible realizar una tercera partición, denominada conjunto de validación, que podría emplearse para estimar el error de generalización del conjunto de entrenamiento de manera independiente al error del conjunto de prueba, siendo esta técnica útil para aquellos algoritmos que empleen hiperparámetros que deban ser ajustados.

Sobre el conjunto de entrenamiento, que, recordemos, tiene como objetivo el conseguir que el valor de salida del modelo se aproxime lo máximo al valor real, podemos realizar

una serie de cálculos para determinar la capacidad predictiva del mismo. Este análisis se realiza a través de las conocidas como funciones de coste, las cuales se buscará minimizar ya que esto indicará una mejor capacidad predictiva de nuestro modelo. Son numerosos los indicadores que se pueden emplear para medir esta capacidad predictiva, pero la idea subyacente en todos ellos es idéntica. Las principales métricas que podremos usar son las siguientes:

1. Mean Error (ME)

$$\frac{1}{n} \sum \text{Observed}_Y - \text{Predicted}_Y \quad (9)$$

2. Mean Squared Error (MSE)

$$\frac{1}{n} \sum (\text{Observed}_Y - \text{Predicted}_Y)^2 \quad (10)$$

3. Mean Porcentual Absolute Error (MAPE)

$$100 * \frac{1}{n} \sum \frac{|\text{Observed}_Y - \text{Predicted}_Y|}{\text{Observed}_Y} \quad (11)$$

4. Absolute Mean Error (MAE)

$$\frac{1}{n} \sum |\text{Observed}_Y - \text{Predicted}_Y| \quad (12)$$

De las antes mencionadas, son especialmente empleadas el MSE y MAE. Entre ellas, la principal diferencia radica, como se puede observar en las fórmulas, en el hecho de que el MSE recoge el error al cuadrado mientras que el MAE emplea valores absolutos. Esto tiene importantes implicaciones a la hora de valorar los posibles outliers que encontremos en los datos ya que el MSE será especialmente sensible a este tipo de valores y tenderá a descartar modelos en los que la presencia de outliers sea alta (Hodson, 2022).

A la hora de medir cómo se comportará nuestro modelo con datos futuros, es decir, con datos que no se encuentran en la muestra utilizada para elaborar el modelo, es fundamental atender a los conceptos de varianza y sesgo.

El primero de estos componentes, la varianza, mide la variabilidad de las predicciones del modelo cuando se entrena con diferentes muestras de datos. Nos informa de la sensibilidad de nuestro modelo a la muestra de entrenamiento. En modelos con una varianza elevada, el modelo se ajustará muy bien a los datos de entrenamiento (*overfitting*), pero su rendimiento se verá mermado cuando se empleen datos que no se

encuentran en la muestra inicial (Singh, 2018). Sin embargo, la varianza no suele ser un problema irresoluble sino que mediante un incremento del número de observaciones que empleamos en la construcción de nuestro modelo, podremos reducir esta deficiencia.

Por su parte, el sesgo, mide el error sistemático en las predicciones del modelo debido a supuestos simplificadores o a una representación insuficiente de la relación entre las variables. Un sesgo elevado indica que el modelo tiene una capacidad limitada para capturar las complejidades de los datos, lo que resulta en predicciones consistentemente desviadas del valor real. En definitiva, un modelo con alto sesgo tenderá a tener el conocido como *underfitting*, proporcionando resultados pobres tanto en los datos de entrenamiento como en los datos no vistos, debido a su incapacidad para aprender adecuadamente la estructura subyacente de los mismos (Singh, 2018). De la misma manera que con la varianza, podremos reducir el sesgo tomando ciertas medidas como pueden ser el aumentar la complejidad del modelo o añadir más variables al mismo.

Además de los conceptos de varianza y sesgo, debemos también explicar de manera más detenida en qué consiste el *underfitting* y *overfitting*, es decir, debemos tratar la complejidad que ha de tener un modelo de ML.

Pues bien, son varios los algoritmos en los que podemos decidir los parámetros que queremos incorporar. Entre ellos, podemos destacar el número de vecinos en el K-NN o la profundidad de un árbol de decisión. Y si bien podríamos pensar que a mayor complejidad mejores resultados nos ofrecerá el modelo, esto no es del todo correcto, como se puede observar en la Ilustración 5.

A medida que se incrementa la complejidad de un modelo, podemos observar que el error de entrenamiento va disminuyendo paulatinamente. Esto es un resultado lógico porque implicará que nuestro modelo será capaz de ajustarse muy bien a los datos de entrenamiento, sin prácticamente tener error alguno. Sin embargo, existe un segundo componente a tener en cuenta, esto es el error de generalización que se representa gráficamente de forma convexa y, por lo tanto, a medida que aumenta la complejidad del modelo, aumenta también el error de generalización.

Por lo tanto, si nuestro modelo tiene poca complejidad incurrirá en *underfitting*, al no ser capaz de tener la flexibilidad suficiente para representar correctamente las relaciones entre los datos. Por otro lado, si el modelo es excesivamente complejo, nos encontraremos ante una situación de *overfitting*. El modelo se habrá ajustado excesivamente a los datos

de entrenamiento, capturando ruido y patrones irrelevantes, resultado así en un mal rendimiento cuando se le presenten nuevos datos. Para evitarlo, se pueden emplear técnicas de validación cruzada, regularización o, simplemente, reducción de la complejidad del modelo.

Con todo, el objetivo final es contar con un modelo que minimice el error de generalización. Para ello, existen diferentes métricas de gran relevancia que podemos emplear como pueden ser el R^2 ajustado, el Akaike Information Criterion (AIC) y el Schwartz Bayesian Information Criterion (BIC).

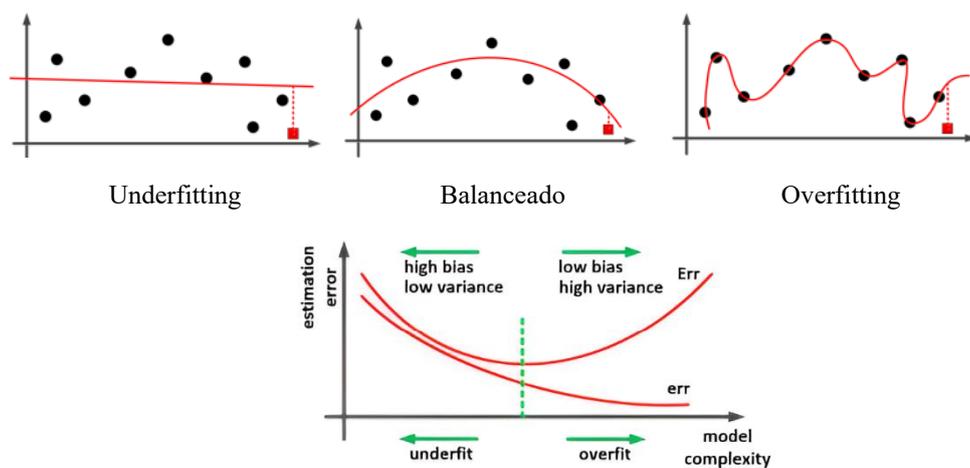


Ilustración 5: Rendimiento de un modelo de ML en contextos de underfitting y overfitting

Fuente: Elaboración propia a partir de (Ghojogh & Crowley, 2023)

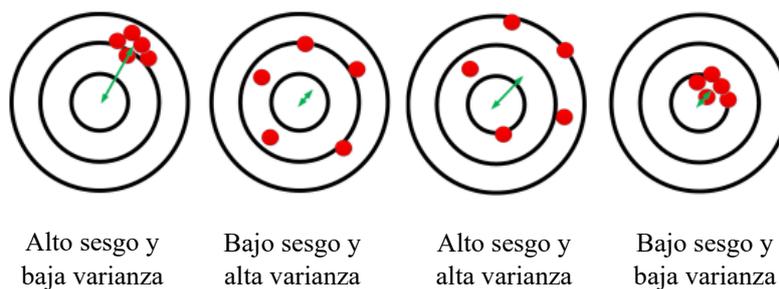


Ilustración 6: Representación de los fenómenos de sesgo y varianza

Fuente: Elaboración propia a partir de (Ghojogh & Crowley, 2023)

Como se ha mencionado anteriormente, dos de los métodos que se pueden emplear para reducir el *overfitting* de un modelo son las técnicas de validación cruzada y la

regularización. Debido a la relevancia de estas técnicas, nos detendremos en la explicación de ambas.

En lo relativo a las técnicas de validación cruzada, destacaremos el método Hold-Out y el k-Fold. La primera de ellas es la forma más básica de validación cruzada de los datos. Consiste en separar el dataset en tres partes: conjunto de entrenamiento, conjunto de validación y conjunto de prueba. Sobre el conjunto de entrenamiento se podrán entrenar diferentes tipos de algoritmos como regresiones, redes neuronales o árboles decisión y el rendimiento de estos se medirá con respecto a los datos que se encuentran en el conjunto de validación. Por último, una vez tengamos el modelo con mejor rendimiento y los hiperparámetros adecuados, podrá ser empleado con el conjunto de prueba (Raschka, 2018).

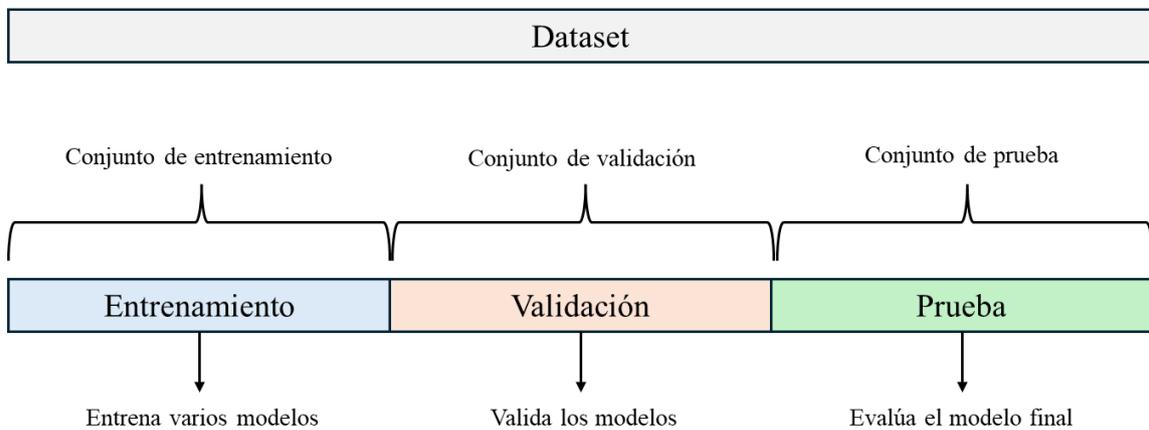


Ilustración 7: Método Hold-Out de validación cruzada

Fuente: Elaboración propia, 2024

Por otro lado, la validación cruzada k-Fold es seguramente la técnica más utilizada para la evaluación y selección de modelos en ML. En este método, la idea subyacente es la posibilidad de que cada elemento de nuestro dataset pueda tener la opción de formar parte tanto del conjunto de entrenamiento como de validación. Para ello, se divide el conjunto total de los datos en k partes y se realizan k iteraciones. En cada una de estas, una de las k partes se emplea como conjunto de validación, mientras que las $k-1$ restantes sirven como conjunto de entrenamiento. Este proceso se repite, como se ha mencionado anteriormente, en k ocasiones y en cada una de ellas se estará entrenando un modelo con distintos datos y, por lo tanto, el rendimiento final será la media aritmética de cada una de las iteraciones.

La principal ventaja que nos proporciona este método es la posibilidad de emplear más datos en el conjunto de entrenamiento ya que, a diferencia del método Hold-Out, no tenemos que apartar una parte del dataset para emplearla como conjunto de validación sino que todos los datos sirven en algún momento para ambas etapas de entrenamiento y validación (Raschka, 2018).

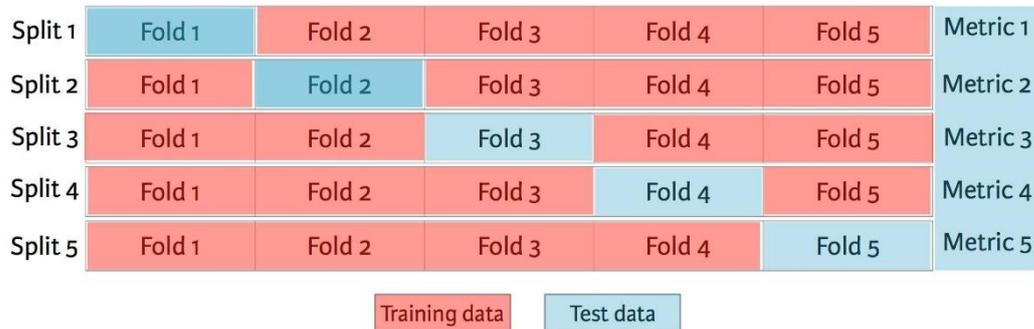


Ilustración 8: Validación cruzada k-Fold donde k=5

Fuente: (Allibhai, 2018)

En segundo lugar, otra manera mediante a través de la cual podemos reducir la complejidad del modelo y, por lo tanto, reducir el *overfitting* y mejorar la capacidad de generalización, es la utilización de técnicas de regularización. Estas se pueden aplicar a diferentes tipos de algoritmo aunque bien es cierto que en función de estos, las técnicas a emplear serán distintas. La regularización, en definitiva, es un método que introduce un término de penalización en la función de pérdida para evitar el sobreajuste (Universidad Pontificia de Comillas, 2021).

Cabe mencionar que este tipo de técnicas han sido empleadas en diversos trabajos de factor investing para mejorar la robustez de las regresiones. Un ejemplo de ello es el trabajo realizado por (Rapach & Zhou, 2019) en el que consiguen, mediante el empleo de regresiones penalizadas, mejorar la predicción del retorno de acciones.

Así, en regresiones lineales son muy comunes las conocidas como regresión Lasso (L_1) y regresión Ridge (L_2). Ambas regularizaciones tiene como objetivo reducir el *overfitting* y manejar la multicolinealidad en modelos de regresión lineal. En las fórmulas de ambas regresiones (L_1 en la ecuación 13 y L_2 en la ecuación 14) podemos observar como la diferencia entre ambas radica principalmente en que la regresión Lasso es bastante más agresiva que la Ridge. Esto a nivel práctico supone que mediante la primera de ellas pueda servir incluso para seleccionar características del modelo, descartando aquellas que sean

irrelevantes. Por su parte, mediante la regresión Ridge no llegaremos a descartar predictores del modelo, pero sí puede ser de gran utilidad para reducir la varianza del mismo mediante la restricción de los coeficientes del modelo y la tendencia a empujarlos a valores cercanos a cero (Amat, 2020).

$$\sum_{j=1}^N (y_j - \sum_{i=0}^p \beta_i x_{i,j})^2 + \lambda \sum_{i=1}^p |\beta_i| \quad (13)$$

$$\sum_{j=1}^N (y_j - \sum_{i=0}^p \beta_i x_{i,j})^2 + \lambda \sum_{i=1}^p \beta_i^2 \quad (14)$$

Por otro lado, los árboles de decisión, que serán objeto de análisis a continuación, son por naturaleza propensos a sufrir *overfitting*. Esto se debe principalmente al hecho de que en este tipo de algoritmos, comenzamos con un nodo inicial a partir del cual se van produciendo una serie de ramificaciones con los distintos resultados posibles. A su vez, cada uno de estos resultados vuelve a generar nuevos nodos que se ramifican otra vez en nuevos resultados y este proceso continúa hasta que el árbol se ajusta perfectamente al conjunto de entrenamiento. Esto supone un claro ejemplo de sobreajuste ya que, en caso de que utilicemos ese árbol para analizar una serie de datos que no se encuentren en el conjunto de entrenamiento, lo más probable es que no los categorice correctamente.

Para solventar este problema, podemos emplear técnicas de regularización al igual que con las regresiones lineales. En este caso, las medidas estarán encaminadas a reducir la profundidad de los árboles en dos posibles momentos: durante el entrenamiento del modelo o después del mismo.

En cuanto a la primera de las posibilidades se refiere, es posible la utilización de hiperparámetros que limiten la profundidad máxima, el mínimo número de datos que debe tener un nodo para generar una partición, o el mínimo número de datos de una hoja. También podría emplearse como solución el requerir un porcentaje mínimo de mejora en el ajuste del modelo tras realizar la nueva partición para determinar así si la nueva ramificación es relevante. Utilizando cualquiera de estas cuatro medidas, podremos tratar de evitar el sobreajuste del modelo. Por otro lado, se presenta la posibilidad de eliminar nodos después del entrenamiento del modelo con el método de poda de complejidad de costes (Breiman et al., 1984). Mediante este, se define un hiperparámetro alpha de tal manera que controla el *overfitting* consiguiendo un balance entre el rendimiento en el conjunto de entrenamiento y el de validación.

3.3 Algoritmos de aprendizaje supervisado con especial atención a los random forest

Son numerosos los distintos tipos de algoritmos de aprendizaje supervisado que existen. Entre ellos podemos destacar las regresiones lineales, logísticas, redes neuronales, k-nearest neighbours y los árboles de decisión. Nosotros nos centraremos en estos últimos al ser los que emplearemos más adelante en nuestro modelo.

Los árboles de decisión son algoritmos supervisados de ML que pueden realizar tareas tanto de clasificación como de regresión. Estos son especialmente útiles en situaciones donde la relación entre las características y la variable objetivo se puede modelar mediante decisiones condicionales (Hastie et al., 2009) y son especialmente eficientes al trabajar con datos tabulares. Como se había mencionado *supra* al hacer referencia al *overfitting* de estos algoritmos, el funcionamiento de un árbol de decisión es muy sencillo: se parte de un único nodo correspondiente a la totalidad de las observaciones que se va ramificando progresivamente en nodos más pequeños en los cuales las características de las observaciones son más similares, generando, por ende, clústers homogéneos.

Partiendo de una variable exógena Y y de una serie de características X, el árbol realiza particiones de la muestra con el objetivo de hacer grupos en los que Y sea lo más homogéneo posible. En el caso de que la variable Y fuese una variable numérica estaríamos ante un árbol de regresión, de lo contrario, es decir, si fuese categórica, estaremos ante un árbol de clasificación.

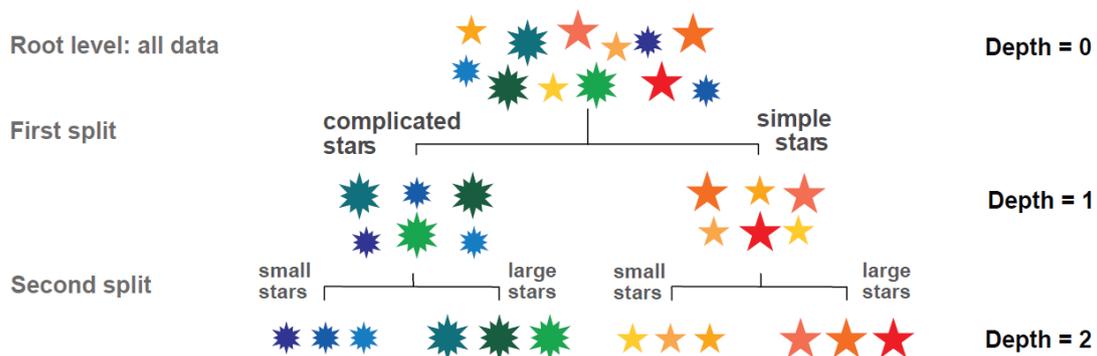


Ilustración 9: Funcionamiento de un árbol de decisión

Fuente: (Coqueret & Guida, 2023)

En la ilustración cómo se van realizando las particiones en función de la complejidad de las figuras y de su tamaño para terminar creando grupos lo más homogéneos posibles. Pues bien, esta misma idea es extrapolable al factor investing: mediante árboles de

decisión podremos determinar qué tipo activos suelen tener una mayor rentabilidad ajustada a riesgo en función de una serie de parámetros de las propias compañías, es decir, en función de sus factores (Coqueret & Guida, 2023).

En este sentido, resulta necesario tener una cierta noción relativa a cómo los árboles de decisión realizan sus particiones. Dada una muestra (y_i, x_i) de tamaño I , un árbol de regresión busca los puntos de división que minimicen la variación total de y_i dentro de los dos subclústeres. Nótese que los clústeres resultantes no tienen por qué tener el mismo tamaño. Para realizar esta división, el algoritmo funciona en dos fases. Una primera en la que encuentra para cada característica x_i el mejor punto de separación y una segunda fase en la que selecciona, para realizar la partición, a la característica que logra el mayor grado de homogeneidad en el clúster resultante.

Este proceso se repite iterativamente hasta un punto en el que no se puedan realizar más divisiones, a no ser que se haya establecido algún hiperparámetro que especifique un crecimiento determinado del árbol. Como se explicó anteriormente, esto puede generar problemas de *overfitting*, pero debemos tener en cuenta que, además de las técnicas de regularización explicadas para subsanar este problema, a la hora de interpretar los resultados del algoritmo, son las primeras particiones las más relevantes ya que contienen la mayor cantidad de información y son indicativas de los principales patrones en el conjunto de datos.

Por su parte, en los árboles de clasificación, la realización de las particiones es algo más compleja al estar trabajando con variables categóricas y no numéricas. Es por ello que el resultado final que debe brindar el algoritmo no será un número sino un vector con tantos elementos como categorías haya en la variable exógena, en el que cada uno de los elementos representará la probabilidad existente de que se dé cada una de las categorías. Por ejemplo, si hubiese tres categorías en la variable exógena, digamos: comprar, mantener y vender, y el resultado que obtuviésemos en un clúster fuese $(0.8, 0.1, 0.1)$ significaría que en ese clúster nos encontraríamos con un 80% de activos que comprar, un 10% que mantener y un 10% que vender (Coqueret & Guida, 2023).

El algoritmo, en definitiva, lo que tratará de buscar es la máxima homogeneidad y pureza en cada clúster. Para medir esta pureza existen diferentes métricas como el índice de Gini (ecuación 15) o la entropía (ecuación 16). En ambas medidas, se calcula la entropía o el valor del índice de Gini antes y después de la partición, siendo la diferencia entre ambos

valores la ganancia de información. Recordemos que este valor de ganancia de información puede también ser empleado como hiperparámetro tendente a evitar el *overfitting* en este tipo de algoritmos.

$$G(A) = 1 - \sum_{k=1}^m p_k^2 \quad (15)$$

$$H(A) = - \sum_{k=1}^m p_k \log_2(p_k) \quad (16)$$

Otra solución para reducir el riesgo de sobreajuste de nuestro modelo y así obtener un resultado más robusto es la utilización de los conocidos como random forests. Estos son un algoritmo de aprendizaje supervisado que se basa en la construcción de múltiples árboles de decisión durante el entrenamiento y cuya salida es la moda de las clases (clasificación) o la media de las predicciones (regresión) de los árboles individuales. Como se ha mencionado, este método reduce el riesgo de sobreajuste al promediar los resultados de diversos árboles, cada uno entrenado con un subconjunto aleatorio de datos y características. (Universidad Pontificia de Comillas, 2021) (Breiman, 2001).

Es un razonamiento lógico. En algoritmos con una varianza tan elevada como los árboles de decisión, es coherente entrenar varios de ellos para así poder tener un resultado combinado que elimine, al menos en parte, esa dependencia a la muestra con la que se entrene al algoritmo. En este sentido, los random forest son un tipo particular de algoritmo de aprendizaje por combinación de modelos mediante BAGGING (Boostrapped Aggregated Algorithm).

Su funcionamiento parte, lógicamente de los requisitos necesarios para la elaboración de un árbol de decisión, pero requiere de una serie de particularidades. En primer lugar, se obtienen varias muestras aleatorias del conjunto inicial de datos, con reemplazamiento. Este primer paso sería en el que se lleva a cabo el proceso de BAGGING anteriormente mencionado. Después, sobre cada uno de los árboles resultantes se aplicarán una serie aleatoria de predictores mediante la cual ramificar y dejar crecer a cada árbol. De esta manera, logramos evitar que existe alguna variable que domine sobre el resto a la hora de realizar las primeras ramificaciones de la muestra. Por último, se combinarán los resultados obtenidos por cada uno de los árboles individuales de la manera especificada anteriormente: se seguirá la regla de la mayoría para determinar el resultado en un ejercicio de clasificación, mientras que se tomará la media de los resultados individuales si estamos ante un problema de regresión.

Los random forest, como se ha mencionado, son más eficientes que los simples árboles de decisión. Además, estos han sido aplicados en el ámbito del factor investing en diversas ocasiones con resultados positivos. Ejemplos de ello son los trabajos realizados por (Krauss et al., 2017) en el que el rendimiento de los random forest supera el de las redes neuronales a la hora de generar estrategias de arbitraje estadístico en el S&P 500, o por (Huck, 2019) que utiliza estos algoritmos para generar estrategias long-short con acciones estadounidenses, obteniendo mejores resultados que el índice de referencia durante un periodo de quince años.

Con todo, observamos como la utilización de este tipo de algoritmos a la hora de generar estrategias de inversión puede ser útil y un interesante objeto de estudio. Sin embargo debemos de mencionar que, si bien existen numerosos trabajos analizando este tipo de estrategias en renta variable, no existe apenas literatura en nuestro ámbito de estudio: la renta fija corporativa y la investigación de un nuevo posible factor, como sería el ESG, que explicase parte de los retornos y riesgos generados por los activos.

4. ANÁLISIS EMPÍRICO

4.1 Aspectos fundamentales del estudio

En el presente estudio, se tiene como objetivo estudiar si, en el universo de la renta fija corporativa, podemos considerar como un nuevo factor la calificación ESG de las empresas. Es decir, buscamos analizar si esta calificación es capaz de explicar parte del retorno y riesgo de los bonos que emiten. Como se ha mencionado en los apartados correspondientes, el factor investing en renta fija corporativa está relativamente poco estudiado si lo comparamos con la literatura existente sobre esta estrategia inversión en renta variable. Esta diferencia se acentúa más si cabe en el estudio que pretendemos realizar, el factor ESG en renta fija corporativa.

Para realizar este trabajo, se ha empleado la información del índice Bloomberg US Corporate Total Return Value Unhedged USD en el periodo que transcurre entre enero de 2013 y abril de 2023. Este índice está compuesto por bonos de la categoría *investment grade* emitidos en USD por empresas industriales, de servicios y financieras tanto estadounidenses como no estadounidenses (Bloomberg Fixed Income Indices, 2023). El hecho de que este índice solo considere bonos denominados *investment grade* implica que la calificación crediticia de sus componentes debe ser, como mínimo, BBB- o BAA3. Esta calificación hace referencia al riesgo de impago por parte del emisor y, en este

sentido, debemos mencionar que los bonos *investment grade* cuentan con un menor riesgo de impago que los denominados *high yield*. En definitiva, la diferencia entre ambas categorías radica en el hecho de que los bonos *investment grade* cuentan con una mejor calificación crediticia, un menor riesgo de impago y, por lo tanto, suelen ofrecer un tipo de interés inferior a los bonos *high yield* al estar expuestos a un menor riesgo (Bankinter, s.f.).

A la hora de realizar el análisis de datos, adelantamos que se han empleado principalmente random forest. La elección de este tipo de algoritmo se justifica por los trabajos anteriormente mencionados de (Krauss, et al., 2017) y (Huck, 2019), por el hecho de que también mejoran el rendimiento de un simple árbol de decisión al reducir el sobreajuste que estos pueden sufrir y porque en el presente análisis se estudió brevemente también la posibilidad de emplear regresiones lineales con regularización Ridge y los resultados predictivos fueron claramente inferiores a los obtenidos mediante el empleo de random forest. En el trabajo realizado por (Cherief, et al., 2022) relacionado con la inversión en factores en renta fija corporativa, estudian el rendimiento en el test de entrenamiento y de prueba de diferentes algoritmos. Entre los analizados, los random forest ofrecen el segundo mejor rendimiento solo por detrás de lo que los autores denominan enhanced random forest, consistente en un algoritmo que combina un random forest clásico junto con una regresión lineal con regresión Lasso. Además, (Breiman, 2001) destaca la robustez de los modelos generados mediante este método frente a los outliers y la mayor precisión que se obtiene comparado con otros algoritmos. Con todo, se pretende dejar constancia del rendimiento proporcionado por este algoritmo en diferentes estudios y justificar la elección del mismo en el presente análisis.

En este trabajo, mediante random forest, se han entrenado una serie de modelos para predecir el rendimiento al vencimiento o yield to maturity (YTM) de los bonos componentes del índice Bloomberg US Corporate Total Return que antes mencionábamos. Para realizar esta predicción, hemos estudiado tres posibles factores que explicasen el retorno y riesgo de los activos: tamaño, bajo riesgo y ESG. Como se analizó en el apartado relativo al factor investing en renta fija, el trabajo de (Houweling & van Zundert, 2017) es de especial relevancia puesto que realiza una recopilación de los distintos factores existentes en la literatura hasta ese momento además de aportar evidencias sobre la existencia de un factor de tamaño.

Pues bien, es precisamente la definición aportada por (Houweling & van Zundert, 2017) del factor tamaño la que se ha empleado en el presente trabajo. Esto sería utilizar el peso total de cada compañía sobre el índice, definido como la suma de los pesos de valor de mercado de todos los bonos emitidos por la misma en un periodo de tiempo. Es relevante para calcular este factor el tomar como valor la suma de los pesos de todos los bonos emitidos por cada compañía. En el caso de que se tratase de calcular el mismo a través del peso de cada bono individual, los resultados predictivos que se obtienen son muy pobres. En este sentido, en el presente estudio se trató, inicialmente, de seguir este enfoque y rápidamente se tuvo que desechar dicha opción. Es por ello que, finalmente, el enfoque aplicado de este factor es el definido por (Houweling & van Zundert, 2017) que trata de capturar las diferencias en rendimiento de los bonos como consecuencia de las diferencias en el tamaño de las empresas emisoras.

El segundo factor que se ha tenido en consideración en el estudio es el de bajo riesgo bajo la definición aportada por (Derwall, et al., 2009) que estudia la relación entre el tiempo al vencimiento del bono (en inglés, *time to maturity*) y su rendimiento. Bajo este enfoque, el factor de bajo riesgo estaría midiendo el riesgo de tipo de interés. Por otro lado, una segunda opción de medir este factor sería mediante el estudio del riesgo de crédito (Frazzini & Pedersen, 2014) a través de la calificación crediticia del activo. Por su parte, (Houweling & van Zundert, 2017) propone, para calcular el efecto de este factor, tener en consideración tanto el tiempo al vencimiento como la calificación crediticia. Con todo, en el presente análisis se ha empleado el tiempo al vencimiento como indicador de este factor de bajo riesgo al ofrecer unos resultados predictivos superiores a la calificación crediticia.

Por último, se ha estudiado si se podría comenzar a hablar de un posible nuevo factor ESG en renta fija corporativa. Como se analizó en el apartado correspondiente, uno de los principales problemas que encontraban los trabajos de esta última década era la falta de información relativa a los criterios ESG de las empresas. Sin embargo, en el estudio que se ha llevado a cabo, no se ha tenido un problema tan importante como en otros análisis en este sentido, por lo que parece que a medida que pasan los años, las empresas comienzan a estar más concienciadas de la importancia de publicar esta información. En este sentido, el objetivo del presente análisis ha sido estudiar si el hecho de que una empresa tenga una mejor o peor calificación ESG afecta al YTM que pueden ofrecer sus bonos.

Porcentaje de bonos con información ESG disponible

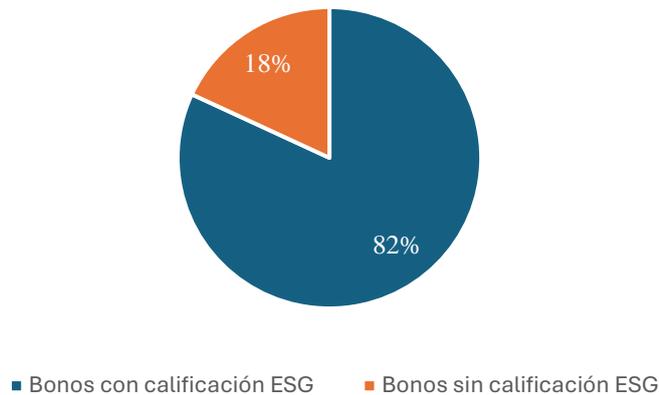


Ilustración 10: Porcentaje de bonos con información ESG disponible de su emisor

Fuente: Elaboración propia, 2024

Con todo, en este análisis se estructurará en tres fases. Una primera en la que se analizará cada uno de los factores de manera individualizada y, por lo tanto, se medirá la capacidad predictiva de los modelos más simples con respecto del YTM. En segundo lugar, se creará un modelo de los dos factores (tamaño y bajo riesgo) más estudiados en la actual literatura académica para comprobar que, efectivamente, los encontramos relevantes en nuestro análisis y podemos reafirmar la literatura existente. Y, en último lugar, se introducirá un modelo de tres factores en el que se incorporará el factor ESG y nos permitirá evaluar la importancia de esta variable comparándola con el modelo de dos factores. Además, en este modelo de tres factores no solo se emplearán random forests sino que también se estudiarán los resultados de una regresión lineal con regularización ridge para evaluar su rendimiento predictivo.

4.2 Datos

En cuanto a los datos empleados en el análisis, como se ha mencionado anteriormente, se han empleado los componentes del Índice Bloomberg US Corporate Total Return Value Unhedged USD en el periodo comprendido entre enero de 2013 y abril de 2023. A la información que obtenemos del propio índice, se ha añadido manualmente una columna con la información ESG de los diferentes bonos. Para la obtención de las calificaciones ESG de las empresas emisoras de los bonos se ha utilizado la plataforma FactSet y, más específicamente, se ha obtenido la información de la agencia de calificación ISS ESG, al ser esta la que más calificaciones ESG tenía disponible de las distintas opciones que

ofrecía la plataforma. En total obtenemos un dataset con 732.682 filas y 18 columnas, es decir, 13.188.276 elementos, correspondiendo cada fila a un bono con características propias.

Ha de resaltarse que debido a la cantidad de información a nuestra disposición, el análisis se ha realizado en cuatro periodos de 31 meses cada uno para obtener unos mejores resultados de rendimiento. Como consecuencia de las variaciones ya no solo en los mercados de renta fija, sino a nivel macroeconómico del periodo analizado, se ha tomado la decisión de realizar las mencionadas divisiones del dataset inicial para permitir a los modelos ajustar de una manera más adecuada sus predicciones. De lo contrario, se observan resultados claramente deficientes e indicativos de que los correspondientes modelos entrenados no son capaces de encontrar patrones en el conjunto de datos.

Por otro lado, cada una de las columnas representaba una característica de los bonos. Sin embargo, para el presente análisis no se emplearon todas ellas. En este sentido, de los 18 elementos de cada bono, se eliminaron 11 de ellas, quedando un total de 7 columnas en el dataset final. Estas serían las siguientes:

- ISIN: Código de identificación internacional de forma unívoca para valores e instrumentos financieros.
- Issuer: Entidad emisora de cada bono
- Yield to Maturity: Es el rendimiento al vencimiento del bono, es decir, la rentabilidad que uno obtiene al comprar un bono si lo mantiene durante toda su duración.
- Weight: Peso de los bonos emitidos por una compañía a lo largo de cada uno de los periodos analizados. Nótese que, inicialmente, esta columna contenía el peso del bono concreto sobre el índice en un periodo determinado. Esto ha sido modificado manualmente debido a la referencia realizada anteriormente a la hora de calcular el factor tamaño.
- Maturity: Tiempo restante hasta el vencimiento del bono.
- Index Rating (String): Calificación crediticia de la empresa. Esta columna ha sido empleada en el factor bajo riesgo, pero fue descartada al observar un peor rendimiento predictivo que al emplear la columna maturity.
- ESG Rating: Calificación ESG de la empresa emisora del bono. Para obtener este valor se han consultado en FactSet la información de 2.706 compañías y los

resultados obtenidos varían entre las calificaciones B+ y D-. Para aquellas compañías sin información ESG disponible, se les imputa el valor 0. Estos últimos serán posteriormente eliminados.

En cuanto a la preparación de los datos, tras realizar la importación de los mismos y eliminar las columnas que no serán empleadas, se realizan las mencionadas cuatro particiones del conjunto de datos inicial. Tras ello, se eliminan outliers, aquellas filas cuyas calificaciones ESG era 0 y se convierte la variable ESG Rating en factor. Este último paso es crucial debido a que, en principio, esta variable es categórica y el random forest no trabajaría con ella de manera adecuada. Además, en esta transformación, se especifica el orden de los distintos posibles valores que puede tomar la variable, permitiendo así al algoritmo entender la escala de las calificaciones ESG.

Una vez se ha logrado filtrar la información que no será objeto de análisis, se procede a tomar muestras de cada conjunto de datos, fijar una semilla para lograr reproducibilidad en los resultados y realizar las particiones entre conjuntos de entrenamiento y prueba. Tras realizar diferentes pruebas, fue constatado que la partición óptima era la consistente en 80% de los datos en el conjunto de entrenamiento y el 20% restante en el conjunto de prueba.

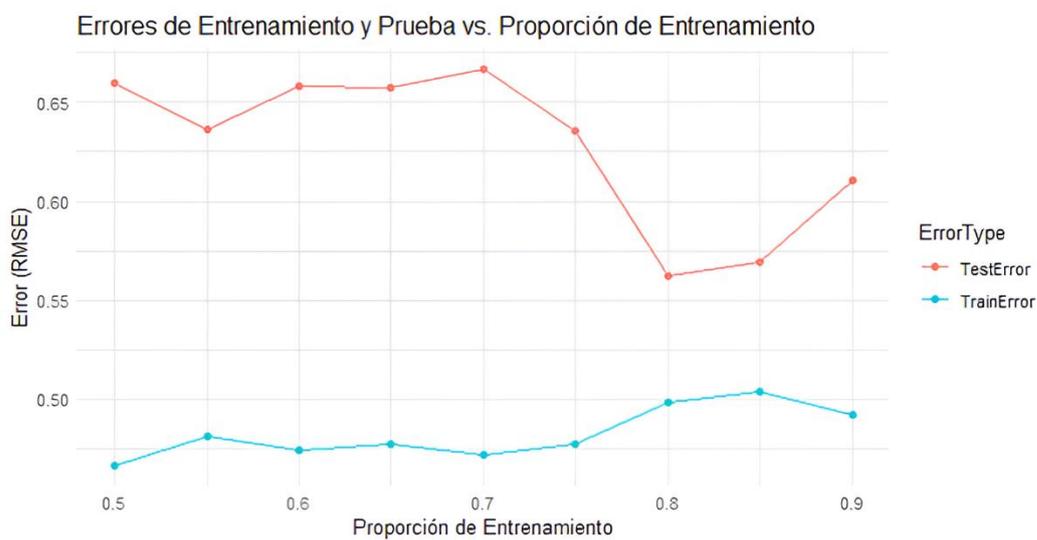


Ilustración 11: RMSE en el conjunto de entrenamiento y prueba con diferentes particiones

Fuente: Elaboración propia, 2024

4.3 Resultados

Antes de entrar en el análisis de cada modelo y su rendimiento, debemos recordar nuevamente que, como norma general, los algoritmos empleados en estos estudios serán random forests. Además, todos ellos tienen una serie de características comunes. En primer lugar, se ha de mencionar la utilización de la anteriormente explicada validación cruzada k-Fold con $k=5$ y tres repeticiones. En segundo lugar, se ha empleado el paquete de R “ranger” para entrenar los modelos. Y, en último lugar, en cuanto a hiperparámetros se refiere, se ha establecido el número de árboles a entrenar en cada modelo en 750.

En cuanto a los distintos modelos se refiere, debemos indicar que se han entrenado un total de 21 de ellos. En este sentido, se han entrenado cuatro modelos (correspondientes a cada una de las particiones realizadas del dataset inicial) de cada uno de los factores a estudiar de manera individualizada, otros cuatro modelos teniendo en cuenta los factores tamaño y bajo riesgo conjuntamente y, por último, se han entrenado cinco modelos de la estrategia formada por los tres factores anteriormente mencionados. Nótese que de estos últimos modelos, cuatro de ellos se corresponden a random forests mientras que el modelo restante se trata de la regresión lineal con regularización ridge anteriormente mencionada.

Para cada uno de los factores, se han calculado una serie de métricas de rendimiento que nos permiten evaluar la efectividad predictiva de estos modelos. La función de estas métricas fue explicada en el correspondiente apartado y serían las siguientes: RMSE, MSE, MAE y R^2 .

A continuación, se mostrarán los resultados obtenidos a lo largo del análisis y, posteriormente, se realizarán una serie de apreciaciones respecto de los mismos.

Análisis de rendimiento de modelos unifactoriales

Factor Tamaño	Enero 2013 - Julio 2015	Agosto 2015 - Febrero 2018	Marzo 2018 - Septiembre 2020	Octubre 2020 - Abril 2023
RMSE	1,24199	0,94909	0,98982	1,61876
MSE	1,54255	0,90078	0,97973	2,62039
MAE	1,02724	0,77676	0,79624	1,39225
R^2	0,27059	0,29161	0,19593	0,05532

Factor Bajo Riesgo	Enero 2013 - Julio 2015	Agosto 2015 - Febrero 2018	Marzo 2018 - Septiembre 2020	Octubre 2020 - Abril 2023
RMSE	0,64990	0,62742	0,93800	1,52811
MSE	0,42237	0,39366	0,87985	2,33511
MAE	0,46937	0,46553	0,75852	1,34011
R^2	0,80005	0,69020	0,27601	0,15757

Factor ESG	Enero 2013 - Julio 2015	Agosto 2015 - Febrero 2018	Marzo 2018 - Septiembre 2020	Octubre 2020 - Abril 2023
RMSE	1,45154	1,12157	1,09734	1,66405
MSE	2,10697	1,25792	1,20416	2,76905
MAE	1,22536	0,93266	0,86856	1,42542
R ²	0,00264	0,01022	0,00776	0,00129

Análisis de rendimiento de modelos bifactoriales (Tamaño + Bajo Riesgo)

Tamaño + Bajo Riesgo	Enero 2013 - Julio 2015	Agosto 2015 - Febrero 2018	Marzo 2018 - Septiembre 2020	Octubre 2020 - Abril 2023
RMSE	0,49507	0,46365	0,83737	1,47993
MSE	0,24507	0,21497	0,70120	2,19020
MAE	0,35543	0,33142	0,66929	1,29414
R ²	0,88397	0,83083	0,42222	0,21002

Análisis de rendimiento de modelos trifactoriales (Tamaño + Bajo Riesgo + ESG)

Tamaño + Bajo Riesgo + ESG	Enero 2013 - Julio 2015	Agosto 2015 - Febrero 2018	Marzo 2018 - Septiembre 2020	Octubre 2020 - Abril 2023
RMSE	0,47758	0,45120	0,83090	1,48659
MSE	0,22808	0,20358	0,69039	2,20995
MAE	0,34052	0,32331	0,66593	1,31678
R ²	0,89204	0,83983	0,43149	0,20538

Ilustración 12: Rendimiento predictivo de los modelos empleados en el estudio

Fuente: Elaboración propia, 2024

Como se puede observar de los resultados, el rendimiento de los modelos varía en gran medida en función de los factores empleados así como del periodo analizado. Es por ello que realizaremos, inicialmente, una serie de anotaciones sobre los factores tamaño y bajo riesgo, al ser estos los más estudiados en la literatura académica actual, para centrarnos posteriormente en el factor ESG.

En primer lugar, debemos comenzar corroborando los resultados obtenidos hasta la fecha de los diferentes estudios realizados acerca de los factores tamaño y bajo riesgo en renta fija corporativa. Efectivamente, como se puede comprobar en las cifras obtenidas en nuestro análisis, ambos factores son de especial relevancia a la hora de determinar el YTM de un bono corporativo. Tanto es así que en ciertos periodos obtenemos, con tan solo estos dos factores, obtenemos un coeficiente de determinación (R²) superior al 80% e incluso cercano al 90%. Recordemos que esta métrica indica la proporción de variabilidad en la variable dependiente explicada por las variables independientes que, en este caso, serían la suma de los pesos de valor de mercado de todos los bonos emitidos por la misma en un periodo de tiempo y el tiempo al vencimiento del bono.

Por otro lado, debemos hacer unos comentarios relativos a los resultados de la tercera y cuarta partición de los datos (marzo 2018 – abril 2023). Como se puede observar, los

errores de predicción aumentan significativamente en este espacio temporal al compararlo con los dos primeros periodos (enero 2013 – febrero 2018). Sin embargo, debemos tener en cuenta las anotaciones realizadas a lo largo del trabajo relativas a la existencia de otros factores (Harvey & Liu, 2019) ya no solo de estilo sino también macroeconómicos (Bender, et al., 2013), no empleados en el presente análisis, que se han demostrado afectan al retorno y riesgo de los activos. Es posible que en el periodo en el cual obtenemos unos peores resultados predictivos sean otros factores los predominantes en el retorno de los bonos. En particular, debemos destacar el posible efecto de las modificaciones en los tipos de interés, especialmente por la Reserva Federal de los Estados Unidos, en el periodo analizado. Como es sabido, entre 2018 y 2023, han existido bruscas modificaciones en los tipos de interés por diversos motivos como pueden ser las políticas monetarias de los bancos centrales, la pandemia del Covid-19 o factores geopolíticos como las diversas guerras que han afectado al comercio internacional en los últimos años. En este sentido, (Cherief, et al., 2022), al analizar los factores tradicionales de riesgo en renta fija corporativa, hacen referencia al hecho de que cuando los tipos de interés suben, los rendimientos de los bonos en circulación caen en comparación con los bonos de nueva emisión. Con todo, lo que se pretende anotar es que, en este periodo, se pueden estar dando patrones que un modelo de dos factores no esté siendo capaz de capturar correctamente.

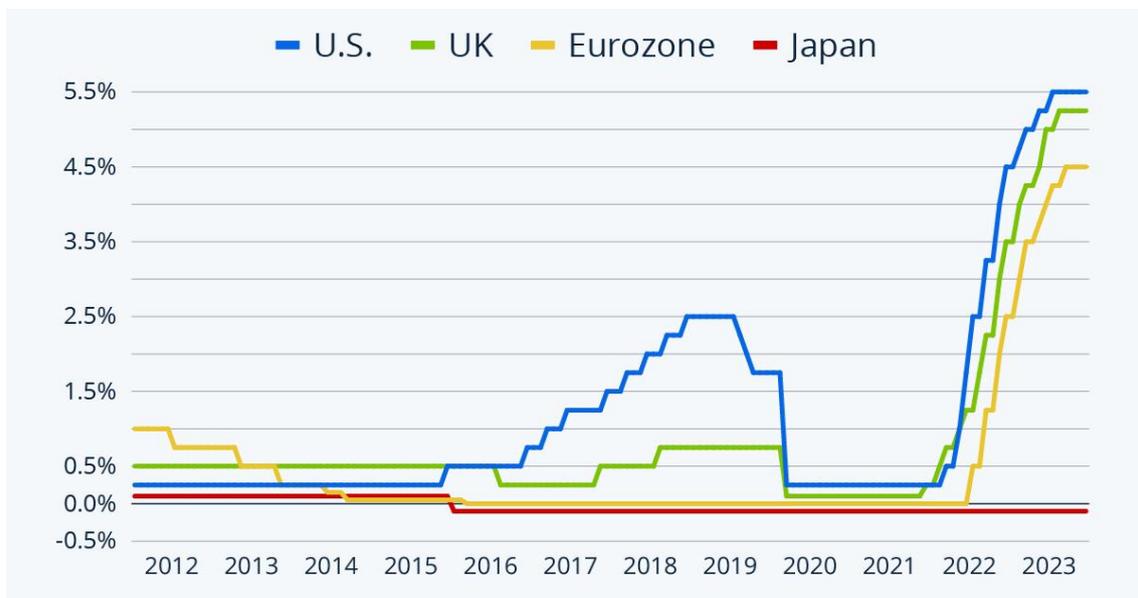


Ilustración 13: Tipos de interés de las principales economías mundiales en la última década

Fuente: Statista, 2023

En segundo lugar, debemos centrar nuestra atención en el factor ESG. Como se mencionó al comienzo del trabajo, una de las principales motivaciones del mismo era la determinación de la existencia de un posible factor ESG en renta fija corporativa. Sin embargo, como se puede observar en la ilustración 12, los resultados predictivos del factor ESG son verdaderamente pobres. Como se comentó al explicar la metodología para elaborar cada uno de los factores, el factor ESG está compuesto por las valoraciones obtenidas de ISS ESG a través de FactSet. En conjunto, estas variaban entre B+ para aquellas compañías con mejor calificación a D- en las peores.

Si comparamos la mejora en R^2 entre el modelo de dos factores y el de tres, que incluye el factor ESG, observamos como el resultado mejora en un valor cercano al 1%. Además, en el análisis de rendimiento de modelos unifactoriales observamos como, efectivamente, los valores del RMSE, MSE y MAE son mucho más elevados que para los factores tamaño y bajo riesgo, y que el R^2 de estos modelos se encuentra en valores inferiores al 1%.

Por lo tanto, como regla general, observamos cierta mejoría en el rendimiento de los modelos al introducir un factor ESG, pero esta es relativamente baja. Se debe anotar la posibilidad de que si el número de empresas con calificación ESG disponible fuese superior, los resultados mejorasen sensiblemente, pero, desde luego, no parece que este factor pueda llegar a tener la misma capacidad explicativa que los factores de tamaño y bajo riesgo anteriormente analizados. Es decir, el factor ESG, al menos en este estudio, ha demostrado tener una relevancia limitada.

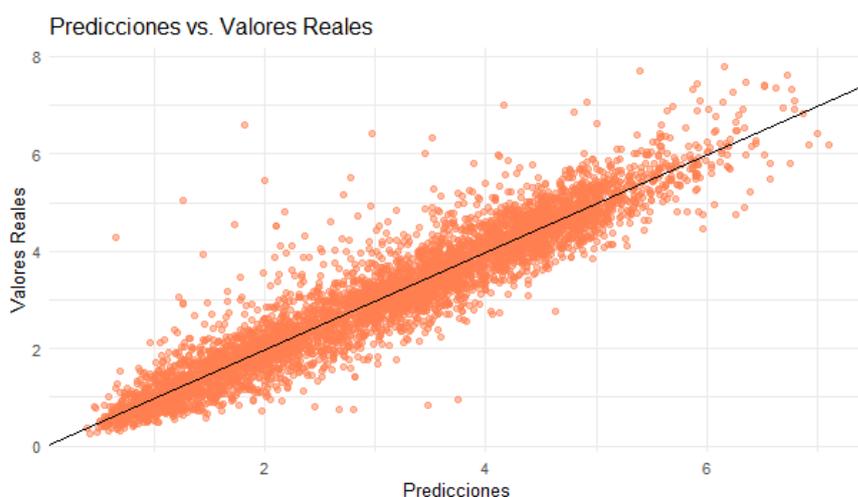


Ilustración 14: Rendimiento del modelo de tres factores en el primer periodo analizado (2013-2015)

Fuente: Elaboración propia, 2024

Con todo, además de las métricas proporcionadas en la ilustración 12, observamos a través de ciertas gráficas, como el gráfico de dispersión de la ilustración 14, que el modelo de tres factores ha tenido un rendimiento razonable y ha sido capaz de extraer, en función de los parámetros analizados, patrones significativos a la hora de predecir el YTM de los bonos corporativos de grado de inversión objeto de estudio. Es decir, con el presente estudio podemos asegurar una importante relevancia de los factores tamaño y bajo riesgo además de reconocer, al menos de manera limitada, un cierto efecto del factor ESG.

Por último, debemos mencionar que, durante el análisis, se realizaron diferentes regresiones lineales para comprobar el rendimiento de los modelos ajustando una serie de hiperparámetros para tratar de mejorar el rendimiento del mismo. Tras estos ajustes, se acabó ejecutando una regresión lineal con regularización ridge, pero los resultados fueron claramente inferiores a los obtenidos con los random forests analizados en las anteriores páginas. En esta línea, se obtuvo, de media, unos valores de R^2 inferiores en un 15% a los mostrados en la ilustración 12 con los random forests por lo que decidimos descartar este tipo de algoritmos.

5. CONCLUSIONES, LIMITACIONES Y FUTURAS LÍNEAS DE INVESTIGACIÓN

En el presente trabajo, se ha revisitado la evolución que ha sufrido el factor investing desde mediados del siglo pasado hasta la actualidad. En particular, se ha analizado como el factor investing en renta fija corporativa ha ido incorporando diferentes factores para explicar el retorno y el riesgo de los activos y, partiendo de esos fundamentos, se ha prestado especial atención a un elemento que está tomando una sustantiva relevancia en la última década como son los criterios ESG. Mediante el empleo de técnicas de machine learning, se ha estudiado la influencia de diferentes factores, particularmente el factor tamaño, bajo riesgo y ESG, en bonos corporativos de grado de inversión. Para este análisis en particular, se emplearon algoritmos como random forests y regresiones lineales con regularización ridge, lo que permitió manejar grandes volúmenes de datos y extraer patrones de los mismos.

Los resultados obtenidos han confirmado la relevancia de los factores tradicionales de tamaño y bajo riesgo en la determinación del YTM de los bonos corporativos, mostrando una capacidad predictiva significativa, especialmente en periodos económicos estables, corroborando los hallazgos previos en la literatura académica.

En cuanto al factor ESG, los resultados han mostrado una mejora limitada en la capacidad predictiva de los modelos cuando se incorpora este factor, indicando que, pese a su cada vez mayor relevancia en las decisiones de inversión, su impacto en el rendimiento y riesgo de los bonos corporativos de grado de inversión todavía es escaso. Sin embargo, como se ha mencionado a lo largo del trabajo, existen diversos artículos que confirman la existencia de este factor ESG principalmente en renta variable. Es por ello que deberá seguir analizándose el papel que pueda jugar este factor en renta fija corporativa.

Por otro lado, son diversas las limitaciones que se han encontrado a la hora de elaborar el presente trabajo, pero debemos hacer referencia, principalmente, a dos elementos que han tenido una relevancia singular a la hora de obtener los resultados expuestos anteriormente.

En primer lugar, relativo al factor ESG, la falta de calificaciones por parte de ciertas empresas ha limitado el objeto del presente análisis. En este sentido, cerca de un 30% de las empresas emisoras de bonos no contaban con una calificación ESG disponible en la base de datos consultada. Por lo tanto, teniendo en cuenta que, a medida que vayan avanzando los años, más empresas contarán con dichas calificaciones, los resultados de los estudios que se realicen podrán encontrar de manera más precisa si existe efectivamente un factor ESG en renta fija corporativa.

Por su parte, otra importante limitación que se ha encontrado a la hora de realizar este estudio ha sido la falta de cierta información que podría haber sido útil para mejorar el rendimiento de los modelos, especialmente de los dos últimos periodos. Como se ha comentado, el objeto de este estudio estaba relativamente limitado al análisis del factor ESG, pero habría sido interesante estudiar el efecto del mismo si hubiesen sido incluidos en los modelos otros factores de estilo como el momentum o valor, e incluso factores macroeconómicos como el crecimiento económico, las tasas de interés o la inflación.

Es por ello que, teniendo en consideración las mencionadas limitaciones, nuevas líneas de investigación pueden surgir principalmente en tres ámbitos. Por un lado, se podría realizar una continuación del presente estudio empleando más factores en el entrenamiento de los modelos para observar si el rendimiento predictivo mejora y si el factor ESG obtiene una mayor relevancia. Por otro lado, se podría realizar un análisis similar al presente, pero empleando una mayor cantidad de algoritmos para comprobar si existiría mejoría en los resultados y evaluar su funcionalidad en el ámbito del factor investing. Y, por último, se podría expandir el objeto de estudio a los bonos corporativos

de alto rendimiento para comprobar si los resultados obtenidos para los bonos corporativos de grado de inversión son similares o si, por su parte, son otros factores los que impulsan el riesgo y retorno de esta serie de activos.

6. ANEXO

```
setwd("C:/Users/rodri/Desktop/ICADE/5º/TFG Analytics/Data")
```

```
#Cargamos las librerías que utilizaremos en el análisis
```

```
library(readxl)
```

```
library(tidyr)
```

```
library(dplyr)
```

```
library(randomForest)
```

```
library(ggplot2)
```

```
library(caret)
```

```
library(ranger)
```

```
#Carga de datos
```

```
LUACTRUU_Index_Full_v5 <- read_excel("LUACTRUU Index Full v5.xlsx")
```

```
View(LUACTRUU_Index_Full_v5)
```

```
Datos <- LUACTRUU_Index_Full_v5
```

```
names(Datos)
```

```
#Modificaciones para obtener un Dataset con únicamente las columnas que utilizaremos
```

```
Datos_v2 <- Datos[, !names(Datos) %in% c("Description", "Ccy", "Price", "YTW", "OAD", "Par Val",  
"MV", "Time of Maturity", "BCLASS 2", "Cpn", "Payment rank")]
```

```
Ordenar <- c("ISIN", "Issuer", "Yield to Maturity", "Weight", "Maturity", "Index Rating (String)", "ESG  
Rating")
```

```
Datos_v2 <- Datos_v2[, Ordenar]
```

```
# Renombrar columnas para eliminar espacios y caracteres especiales
```

```
colnames(Datos_v2) <- make.names(colnames(Datos_v2))
```

```
#Sobre el total de los datos, realizamos cuatro particiones (31 meses cada una) para realizar el análisis
```

```
#Esto se debe a la necesidad de realizar predicciones sobre periodos temporales más cortos y que así el  
algoritmo aporte un mejor rendimiento
```

```

particion_1 <- Datos_v2[1:153477, ]
particion_2 <- Datos_v2[153478:328799, ]
particion_3 <- Datos_v2[328800:514597, ]
particion_4 <- Datos_v2[514598:732682, ]

#Eliminamos aquellos bonos de los cuales no hemos podido obtener calificación ESG de la empresa
Datos_v3_1 <- particion_1 %>% filter(`ESG.Rating` != 0 & Weight != "#NA" & Yield.to.Maturity !=0 &
Yield.to.Maturity>0)
Datos_v3_2 <- particion_2 %>% filter(`ESG.Rating` != 0 & Weight != "#NA" & Yield.to.Maturity !=0 &
Yield.to.Maturity>0)
Datos_v3_3 <- particion_3 %>% filter(`ESG.Rating` != 0 & Weight != "#NA" & Yield.to.Maturity !=0 &
Yield.to.Maturity>0)
Datos_v3_4 <- particion_4 %>% filter(`ESG.Rating` != 0 & Weight != "#NA" & Yield.to.Maturity !=0 &
Yield.to.Maturity>0)

# Convertimos la variable categórica en factor. Además, establecemos el orden de los distintos valores que
puede tomar para que el algoritmo lo pueda identificar
niveles_esg <- c("D-", "D", "D+", "C-", "C", "C+", "B-", "B", "B+")
Datos_v3_1$ESG.Rating <- factor(Datos_v3_1$ESG.Rating, levels = niveles_esg, ordered = TRUE)
Datos_v3_2$ESG.Rating <- factor(Datos_v3_2$ESG.Rating, levels = niveles_esg, ordered = TRUE)
Datos_v3_3$ESG.Rating <- factor(Datos_v3_3$ESG.Rating, levels = niveles_esg, ordered = TRUE)
Datos_v3_4$ESG.Rating <- factor(Datos_v3_4$ESG.Rating, levels = niveles_esg, ordered = TRUE)
class(Datos_v3_1$ESG.Rating)
summary(Datos_v3_1)
summary(Datos_v3_2)
summary(Datos_v3_3)
summary(Datos_v3_4)

# Identificar y eliminar outliers en las columnas relevantes para cada partición
Datos_v3_1 <- Datos_v3_1 %>% mutate(row_id = row_number())
Datos_v3_2 <- Datos_v3_2 %>% mutate(row_id = row_number())
Datos_v3_3 <- Datos_v3_3 %>% mutate(row_id = row_number())
Datos_v3_4 <- Datos_v3_4 %>% mutate(row_id = row_number())

outliers_yield_1 <- Datos_v3_1 %>% identify_outliers(Yield.to.Maturity)

```

```

Datos_v3_1 <- Datos_v3_1 %>% filter(!row_id %in% outliers_yield_1$row_id)
outliers_weight_1 <- Datos_v3_1 %>% identify_outliers(Weight)
Datos_v3_1 <- Datos_v3_1 %>% filter(!row_id %in% outliers_weight_1$row_id)
outliers_maturity_1 <- Datos_v3_1 %>% identify_outliers(Maturity)
Datos_v3_1 <- Datos_v3_1 %>% filter(!row_id %in% outliers_maturity_1$row_id)

outliers_yield_2 <- Datos_v3_2 %>% identify_outliers(Yield.to.Maturity)
Datos_v3_2 <- Datos_v3_2 %>% filter(!row_id %in% outliers_yield_2$row_id)
outliers_weight_2 <- Datos_v3_2 %>% identify_outliers(Weight)
Datos_v3_2 <- Datos_v3_2 %>% filter(!row_id %in% outliers_weight_2$row_id)
outliers_maturity_2 <- Datos_v3_2 %>% identify_outliers(Maturity)
Datos_v3_2 <- Datos_v3_2 %>% filter(!row_id %in% outliers_maturity_2$row_id)

outliers_yield_3 <- Datos_v3_3 %>% identify_outliers(Yield.to.Maturity)
Datos_v3_3 <- Datos_v3_3 %>% filter(!row_id %in% outliers_yield_3$row_id)
outliers_weight_3 <- Datos_v3_3 %>% identify_outliers(Weight)
Datos_v3_3 <- Datos_v3_3 %>% filter(!row_id %in% outliers_weight_3$row_id)
outliers_maturity_3 <- Datos_v3_3 %>% identify_outliers(Maturity)
Datos_v3_3 <- Datos_v3_3 %>% filter(!row_id %in% outliers_maturity_3$row_id)

outliers_yield_4 <- Datos_v3_4 %>% identify_outliers(Yield.to.Maturity)
Datos_v3_4 <- Datos_v3_4 %>% filter(!row_id %in% outliers_yield_4$row_id)
outliers_weight_4 <- Datos_v3_4 %>% identify_outliers(Weight)
Datos_v3_4 <- Datos_v3_4 %>% filter(!row_id %in% outliers_weight_4$row_id)
outliers_maturity_4 <- Datos_v3_4 %>% identify_outliers(Maturity)
Datos_v3_4 <- Datos_v3_4 %>% filter(!row_id %in% outliers_maturity_4$row_id)

summary(Datos_v3_1)
summary(Datos_v3_2)
summary(Datos_v3_3)
summary(Datos_v3_4)

```

Tomamos una muestra del dataset. Por motivos de capacidad computacional no podemos trabajar con la totalidad de los datos

```

#Utilizamos set.seed() para lograr replicabilidad en los resultados
set.seed(123)
Datos_v3_1_muestra <- Datos_v3_1 %>% sample_n(25000)
Datos_v3_2_muestra <- Datos_v3_2 %>% sample_n(25000)
Datos_v3_3_muestra <- Datos_v3_3 %>% sample_n(25000)
Datos_v3_4_muestra <- Datos_v3_4 %>% sample_n(25000)

# Creamos el conjunto de entrenamiento y prueba
#Tras probar distintas particiones, la división 80/20 es la que minimiza el error en el conjunto de prueba
trainIndex_1 <- createDataPartition(Datos_v3_1_muestra$Yield.to.Maturity, p = .8, list = FALSE)
DatosTrain_1 <- Datos_v3_1_muestra[trainIndex_1, ]
DatosTest_1 <- Datos_v3_1_muestra[-trainIndex_1, ]

trainIndex_2 <- createDataPartition(Datos_v3_2_muestra$Yield.to.Maturity, p = .8, list = FALSE)
DatosTrain_2 <- Datos_v3_2_muestra[trainIndex_2, ]
DatosTest_2 <- Datos_v3_2_muestra[-trainIndex_2, ]

trainIndex_3 <- createDataPartition(Datos_v3_3_muestra$Yield.to.Maturity, p = .8, list = FALSE)
DatosTrain_3 <- Datos_v3_3_muestra[trainIndex_3, ]
DatosTest_3 <- Datos_v3_3_muestra[-trainIndex_3, ]

trainIndex_4 <- createDataPartition(Datos_v3_4_muestra$Yield.to.Maturity, p = .8, list = FALSE)
DatosTrain_4 <- Datos_v3_4_muestra[trainIndex_4, ]
DatosTest_4 <- Datos_v3_4_muestra[-trainIndex_4, ]

# Cross validation para tratar de evitar un posible overfitting
control <- trainControl(method = "repeatedcv", #Método de remuestreo, en este caso cross validation
repetida
    number = 5,    #Número de folds
    repeats = 3,
    verboseIter = TRUE,
    search = "random") #Utilizamos Random Search al ser más flexible que Grid Search

# Entrenamos los modelos para el factor tamaño con el algoritmo Random Forest

```

```
modelo_rf_tamaño_1 <- train(Yield.to.Maturity ~ Weight,
  data = DatosTrain_1,
  method = "ranger",
  trControl = control,
  tuneLength = 20, #Se prueba 20 valores para cada hiperparámetro
  num.trees = 750,
  importance = "impurity") #Reducción de la impureza (Gini)
```

```
modelo_rf_tamaño_2 <- train(Yield.to.Maturity ~ Weight,
  data = DatosTrain_2,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")
```

```
modelo_rf_tamaño_3 <- train(Yield.to.Maturity ~ Weight,
  data = DatosTrain_3,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")
```

```
modelo_rf_tamaño_4 <- train(Yield.to.Maturity ~ Weight,
  data = DatosTrain_4,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")
```

```
# Métricas de rendimiento
```

```
predicciones_tamaño_1 <- predict(modelo_rf_tamaño_1, DatosTest_1)
```

```
rmse_tamaño_1 <- sqrt(mean((predicciones_tamaño_1 - DatosTest_1$Yield.to.Maturity)^2))
```

```

mse_tamaño_1 <- mean((predicciones_tamaño_1 - DatosTest_1$Yield.to.Maturity)^2)
mae_tamaño_1 <- mean(abs(DatosTest_1$Yield.to.Maturity - predicciones_tamaño_1))
r2_tamaño_1 <- cor(predicciones_tamaño_1, DatosTest_1$Yield.to.Maturity)^2

predicciones_tamaño_2 <- predict(modelo_rf_tamaño_2, DatosTest_2)
rmse_tamaño_2 <- sqrt(mean((predicciones_tamaño_2 - DatosTest_2$Yield.to.Maturity)^2))
mse_tamaño_2 <- mean((predicciones_tamaño_2 - DatosTest_2$Yield.to.Maturity)^2)
mae_tamaño_2 <- mean(abs(DatosTest_2$Yield.to.Maturity - predicciones_tamaño_2))
r2_tamaño_2 <- cor(predicciones_tamaño_2, DatosTest_2$Yield.to.Maturity)^2

predicciones_tamaño_3 <- predict(modelo_rf_tamaño_3, DatosTest_3)
rmse_tamaño_3 <- sqrt(mean((predicciones_tamaño_3 - DatosTest_3$Yield.to.Maturity)^2))
mse_tamaño_3 <- mean((predicciones_tamaño_3 - DatosTest_3$Yield.to.Maturity)^2)
mae_tamaño_3 <- mean(abs(DatosTest_3$Yield.to.Maturity - predicciones_tamaño_3))
r2_tamaño_3 <- cor(predicciones_tamaño_3, DatosTest_3$Yield.to.Maturity)^2

predicciones_tamaño_4 <- predict(modelo_rf_tamaño_4, DatosTest_4)
rmse_tamaño_4 <- sqrt(mean((predicciones_tamaño_4 - DatosTest_4$Yield.to.Maturity)^2))
mse_tamaño_4 <- mean((predicciones_tamaño_4 - DatosTest_4$Yield.to.Maturity)^2)
mae_tamaño_4 <- mean(abs(DatosTest_4$Yield.to.Maturity - predicciones_tamaño_4))
r2_tamaño_4 <- cor(predicciones_tamaño_4, DatosTest_4$Yield.to.Maturity)^2

#Imprimir resultados
cat("Modelo Random Forest enero 2013 - julio 2015 de un factor (Tamaño)")
cat("RMSE: ", rmse_tamaño_1)
cat("MSE: ", mse_tamaño_1)
cat("MAE: ", mae_tamaño_1)
cat("R2: ", r2_tamaño_1)

cat("Modelo Random Forest agosto 2015 - febrero 2018 de un factor (Tamaño)")
cat("RMSE: ", rmse_tamaño_2)
cat("MSE: ", mse_tamaño_2)
cat("MAE: ", mae_tamaño_2)
cat("R2: ", r2_tamaño_2)

```

```
cat("Modelo Random Forest marzo 2018 - septiembre 2020 de un factor (Tamaño)")
cat("RMSE: ", rmse_tamaño_3)
cat("MSE: ", mse_tamaño_3)
cat("MAE: ", mae_tamaño_3)
cat("R2: ", r2_tamaño_3)
```

```
cat("Modelo Random Forest octubre 2020 - abril 2023 de un factor (Tamaño)")
cat("RMSE: ", rmse_tamaño_4)
cat("MSE: ", mse_tamaño_4)
cat("MAE: ", mae_tamaño_4)
cat("R2: ", r2_tamaño_4)
```

```
# Entrenamos los modelos para el factor bajo riesgo con el algoritmo Random Forest
```

```
modelo_rf_br_1 <- train(Yield.to.Maturity ~ Maturity,
  data = DatosTrain_1,
  method = "ranger",
  trControl = control,
  tuneLength = 20, #Se prueba 20 valores para cada hiperparámetro
  num.trees = 750,
  importance = "impurity") #Reducción de la impureza (Gini)
```

```
modelo_rf_br_2 <- train(Yield.to.Maturity ~ Maturity,
  data = DatosTrain_2,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")
```

```
modelo_rf_br_3 <- train(Yield.to.Maturity ~ Maturity,
  data = DatosTrain_3,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
```

```

importance = "impurity")

modelo_rf_br_4 <- train(Yield.to.Maturity ~ Maturity,
  data = DatosTrain_4,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

# Métricas de rendimiento
predicciones_br_1 <- predict(modelo_rf_br_1, DatosTest_1)
rmse_br_1 <- sqrt(mean((predicciones_br_1 - DatosTest_1$Yield.to.Maturity)^2))
mse_br_1 <- mean((predicciones_br_1 - DatosTest_1$Yield.to.Maturity)^2)
mae_br_1 <- mean(abs(DatosTest_1$Yield.to.Maturity - predicciones_br_1))
r2_br_1 <- cor(predicciones_br_1, DatosTest_1$Yield.to.Maturity)^2

predicciones_br_2 <- predict(modelo_rf_br_2, DatosTest_2)
rmse_br_2 <- sqrt(mean((predicciones_br_2 - DatosTest_2$Yield.to.Maturity)^2))
mse_br_2 <- mean((predicciones_br_2 - DatosTest_2$Yield.to.Maturity)^2)
mae_br_2 <- mean(abs(DatosTest_2$Yield.to.Maturity - predicciones_br_2))
r2_br_2 <- cor(predicciones_br_2, DatosTest_2$Yield.to.Maturity)^2

predicciones_br_3 <- predict(modelo_rf_br_3, DatosTest_3)
rmse_br_3 <- sqrt(mean((predicciones_br_3 - DatosTest_3$Yield.to.Maturity)^2))
mse_br_3 <- mean((predicciones_br_3 - DatosTest_3$Yield.to.Maturity)^2)
mae_br_3 <- mean(abs(DatosTest_3$Yield.to.Maturity - predicciones_br_3))
r2_br_3 <- cor(predicciones_br_3, DatosTest_3$Yield.to.Maturity)^2

predicciones_br_4 <- predict(modelo_rf_br_4, DatosTest_4)
rmse_br_4 <- sqrt(mean((predicciones_br_4 - DatosTest_4$Yield.to.Maturity)^2))
mse_br_4 <- mean((predicciones_br_4 - DatosTest_4$Yield.to.Maturity)^2)
mae_br_4 <- mean(abs(DatosTest_4$Yield.to.Maturity - predicciones_br_4))
r2_br_4 <- cor(predicciones_br_4, DatosTest_4$Yield.to.Maturity)^2

```

```

#Imprimir resultados
cat("Modelo Random Forest enero 2013 - julio 2015 de un factor (Bajo Riesgo)")
cat("RMSE: ", rmse_br_1)
cat("MSE: ", mse_br_1)
cat("MAE: ", mae_br_1)
cat("R2: ", r2_br_1)

cat("Modelo Random Forest agosto 2015 - febrero 2018 de un factor (Bajo Riesgo)")
cat("RMSE: ", rmse_br_2)
cat("MSE: ", mse_br_2)
cat("MAE: ", mae_br_2)
cat("R2: ", r2_br_2)

cat("Modelo Random Forest marzo 2018 - septiembre 2020 de un factor (Bajo Riesgo)")
cat("RMSE: ", rmse_br_3)
cat("MSE: ", mse_br_3)
cat("MAE: ", mae_br_3)
cat("R2: ", r2_br_3)

cat("Modelo Random Forest octubre 2020 - abril 2023 de un factor (Bajo Riesgo)")
cat("RMSE: ", rmse_br_4)
cat("MSE: ", mse_br_4)
cat("MAE: ", mae_br_4)
cat("R2: ", r2_br_4)

# Entrenamos los modelos para el factor ESG con el algoritmo Random Forest
modelo_rf_ESG_1 <- train(Yield.to.Maturity ~ ESG.Rating,
  data = DatosTrain_1,
  method = "ranger",
  trControl = control,
  tuneLength = 20, #Se prueba 20 valores para cada hiperparámetro
  num.trees = 750,
  importance = "impurity") #Reducción de la impureza (Gini)

```

```

modelo_rf_ESG_2 <- train(Yield.to.Maturity ~ ESG.Rating,
  data = DatosTrain_2,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

```

```

modelo_rf_ESG_3 <- train(Yield.to.Maturity ~ ESG.Rating,
  data = DatosTrain_3,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

```

```

modelo_rf_ESG_4 <- train(Yield.to.Maturity ~ ESG.Rating,
  data = DatosTrain_4,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

```

Métricas de rendimiento

```

predicciones_ESG_1 <- predict(modelo_rf_ESG_1, DatosTest_1)
rmse_ESG_1 <- sqrt(mean((predicciones_ESG_1 - DatosTest_1$Yield.to.Maturity)^2))
mse_ESG_1 <- mean((predicciones_ESG_1 - DatosTest_1$Yield.to.Maturity)^2)
mae_ESG_1 <- mean(abs(DatosTest_1$Yield.to.Maturity - predicciones_ESG_1))
r2_ESG_1 <- cor(predicciones_ESG_1, DatosTest_1$Yield.to.Maturity)^2

predicciones_ESG_2 <- predict(modelo_rf_ESG_2, DatosTest_2)
rmse_ESG_2 <- sqrt(mean((predicciones_ESG_2 - DatosTest_2$Yield.to.Maturity)^2))
mse_ESG_2 <- mean((predicciones_ESG_2 - DatosTest_2$Yield.to.Maturity)^2)
mae_ESG_2 <- mean(abs(DatosTest_2$Yield.to.Maturity - predicciones_ESG_2))

```

```

r2_ESG_2 <- cor(predicciones_ESG_2, DatosTest_2$Yield.to.Maturity)^2

predicciones_ESG_3 <- predict(modelo_rf_ESG_3, DatosTest_3)
rmse_ESG_3 <- sqrt(mean((predicciones_ESG_3 - DatosTest_3$Yield.to.Maturity)^2))
mse_ESG_3 <- mean((predicciones_ESG_3 - DatosTest_3$Yield.to.Maturity)^2)
mae_ESG_3 <- mean(abs(DatosTest_3$Yield.to.Maturity - predicciones_ESG_3))
r2_ESG_3 <- cor(predicciones_ESG_3, DatosTest_3$Yield.to.Maturity)^2

predicciones_ESG_4 <- predict(modelo_rf_ESG_4, DatosTest_4)
rmse_ESG_4 <- sqrt(mean((predicciones_ESG_4 - DatosTest_4$Yield.to.Maturity)^2))
mse_ESG_4 <- mean((predicciones_ESG_4 - DatosTest_4$Yield.to.Maturity)^2)
mae_ESG_4 <- mean(abs(DatosTest_4$Yield.to.Maturity - predicciones_ESG_4))
r2_ESG_4 <- cor(predicciones_ESG_4, DatosTest_4$Yield.to.Maturity)^2

#Imprimir resultados
cat("Modelo Random Forest enero 2013 - julio 2015 de un factor (ESG)")
cat("RMSE: ", rmse_ESG_1)
cat("MSE: ", mse_ESG_1)
cat("MAE: ", mae_ESG_1)
cat("R2: ", r2_ESG_1)

cat("Modelo Random Forest agosto 2015 - febrero 2018 de un factor (ESG)")
cat("RMSE: ", rmse_ESG_2)
cat("MSE: ", mse_ESG_2)
cat("MAE: ", mae_ESG_2)
cat("R2: ", r2_ESG_2)

cat("Modelo Random Forest marzo 2018 - septiembre 2020 de un factor (ESG)")
cat("RMSE: ", rmse_ESG_3)
cat("MSE: ", mse_ESG_3)
cat("MAE: ", mae_ESG_3)
cat("R2: ", r2_ESG_3)

cat("Modelo Random Forest octubre 2020 - abril 2023 de un factor (ESG)")
cat("RMSE: ", rmse_ESG_4)

```

```

cat("MSE: ", mse_ESG_4)
cat("MAE: ", mae_ESG_4)
cat("R2: ", r2_ESG_4)

# Entrenamos los modelos de 2 factores con el algoritmo Random Forest
modelo_rf_2f_1 <- train(Yield.to.Maturity ~ Weight + Maturity,
  data = DatosTrain_1,
  method = "ranger",
  trControl = control,
  tuneLength = 20, #Se prueba 20 valores para cada hiperparámetro
  num.trees = 750,
  importance = "impurity") #Reducción de la impureza (Gini)

modelo_rf_2f_2 <- train(Yield.to.Maturity ~ Weight + Maturity,
  data = DatosTrain_2,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

modelo_rf_2f_3 <- train(Yield.to.Maturity ~ Weight + Maturity,
  data = DatosTrain_3,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

modelo_rf_2f_4 <- train(Yield.to.Maturity ~ Weight + Maturity,
  data = DatosTrain_4,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,

```

```
importance = "impurity")
```

```
# Métricas de rendimiento
```

```
predicciones_2f_1 <- predict(modelo_rf_2f_1, DatosTest_1)
```

```
rmse_2f_1 <- sqrt(mean((predicciones_2f_1 - DatosTest_1$Yield.to.Maturity)^2))
```

```
mse_2f_1 <- mean((predicciones_2f_1 - DatosTest_1$Yield.to.Maturity)^2)
```

```
mae_2f_1 <- mean(abs(DatosTest_1$Yield.to.Maturity - predicciones_2f_1))
```

```
r2_2f_1 <- cor(predicciones_2f_1, DatosTest_1$Yield.to.Maturity)^2
```

```
predicciones_2f_2 <- predict(modelo_rf_2f_2, DatosTest_2)
```

```
rmse_2f_2 <- sqrt(mean((predicciones_2f_2 - DatosTest_2$Yield.to.Maturity)^2))
```

```
mse_2f_2 <- mean((predicciones_2f_2 - DatosTest_2$Yield.to.Maturity)^2)
```

```
mae_2f_2 <- mean(abs(DatosTest_2$Yield.to.Maturity - predicciones_2f_2))
```

```
r2_2f_2 <- cor(predicciones_2f_2, DatosTest_2$Yield.to.Maturity)^2
```

```
predicciones_2f_3 <- predict(modelo_rf_2f_3, DatosTest_3)
```

```
rmse_2f_3 <- sqrt(mean((predicciones_2f_3 - DatosTest_3$Yield.to.Maturity)^2))
```

```
mse_2f_3 <- mean((predicciones_2f_3 - DatosTest_3$Yield.to.Maturity)^2)
```

```
mae_2f_3 <- mean(abs(DatosTest_3$Yield.to.Maturity - predicciones_2f_3))
```

```
r2_2f_3 <- cor(predicciones_2f_3, DatosTest_3$Yield.to.Maturity)^2
```

```
predicciones_2f_4 <- predict(modelo_rf_2f_4, DatosTest_4)
```

```
rmse_2f_4 <- sqrt(mean((predicciones_2f_4 - DatosTest_4$Yield.to.Maturity)^2))
```

```
mse_2f_4 <- mean((predicciones_2f_4 - DatosTest_4$Yield.to.Maturity)^2)
```

```
mae_2f_4 <- mean(abs(DatosTest_4$Yield.to.Maturity - predicciones_2f_4))
```

```
r2_2f_4 <- cor(predicciones_2f_4, DatosTest_4$Yield.to.Maturity)^2
```

```
#Imprimir resultados
```

```
cat("Modelo Random Forest enero 2013 - julio 2015 de dos factores (Tamaño + Bajo Riesgo)")
```

```
cat("RMSE: ", rmse_2f_1)
```

```
cat("MSE: ", mse_2f_1)
```

```
cat("MAE: ", mae_2f_1)
```

```
cat("R2: ", r2_2f_1)
```

```
cat("Modelo Random Forest agosto 2015 - febrero 2018 de dos factores (Tamaño + Bajo Riesgo)")
cat("RMSE: ", rmse_2f_2)
cat("MSE: ", mse_2f_2)
cat("MAE: ", mae_2f_2)
cat("R2: ", r2_2f_2)
```

```
cat("Modelo Random Forest marzo 2018 - septiembre 2020 de dos factores (Tamaño + Bajo Riesgo)")
cat("RMSE: ", rmse_2f_3)
cat("MSE: ", mse_2f_3)
cat("MAE: ", mae_2f_3)
cat("R2: ", r2_2f_3)
```

```
cat("Modelo Random Forest octubre 2020 - abril 2023 de dos factores (Tamaño + Bajo Riesgo)")
cat("RMSE: ", rmse_2f_4)
cat("MSE: ", mse_2f_4)
cat("MAE: ", mae_2f_4)
cat("R2: ", r2_2f_4)
```

```
# Entrenamos los modelos de 3 factores con el algoritmo Random Forest
modelo_rf_1 <- train(Yield.to.Maturity ~ Weight + Maturity + ESG.Rating,
  data = DatosTrain_1,
  method = "ranger",
  trControl = control,
  tuneLength = 20, #Se prueba 20 valores para cada hiperparámetro
  num.trees = 750,
  importance = "impurity") #Reducción de la impureza (Gini)

modelo_rf_2 <- train(Yield.to.Maturity ~ Weight + Maturity + ESG.Rating,
  data = DatosTrain_2,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")
```

```

modelo_rf_3 <- train(Yield.to.Maturity ~ Weight + Maturity + ESG.Rating,
  data = DatosTrain_3,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

```

```

modelo_rf_4 <- train(Yield.to.Maturity ~ Weight + Maturity + ESG.Rating,
  data = DatosTrain_4,
  method = "ranger",
  trControl = control,
  tuneLength = 20,
  num.trees = 750,
  importance = "impurity")

```

Métricas de rendimiento

```

predicciones_3f_1 <- predict(modelo_rf_1, DatosTest_1)
rmse_3f_1 <- sqrt(mean((predicciones_3f_1 - DatosTest_1$Yield.to.Maturity)^2))
mse_3f_1 <- mean((predicciones_3f_1 - DatosTest_1$Yield.to.Maturity)^2)
mae_3f_1 <- mean(abs(DatosTest_1$Yield.to.Maturity - predicciones_3f_1))
r2_3f_1 <- cor(predicciones_3f_1, DatosTest_1$Yield.to.Maturity)^2

```

```

predicciones_3f_2 <- predict(modelo_rf_2, DatosTest_2)
rmse_3f_2 <- sqrt(mean((predicciones_3f_2 - DatosTest_2$Yield.to.Maturity)^2))
mse_3f_2 <- mean((predicciones_3f_2 - DatosTest_2$Yield.to.Maturity)^2)
mae_3f_2 <- mean(abs(DatosTest_2$Yield.to.Maturity - predicciones_3f_2))
r2_3f_2 <- cor(predicciones_3f_2, DatosTest_2$Yield.to.Maturity)^2

```

```

predicciones_3f_3 <- predict(modelo_rf_3, DatosTest_3)
rmse_3f_3 <- sqrt(mean((predicciones_3f_3 - DatosTest_3$Yield.to.Maturity)^2))
mse_3f_3 <- mean((predicciones_3f_3 - DatosTest_3$Yield.to.Maturity)^2)
mae_3f_3 <- mean(abs(DatosTest_3$Yield.to.Maturity - predicciones_3f_3))
r2_3f_3 <- cor(predicciones_3f_3, DatosTest_3$Yield.to.Maturity)^2

```

```

predicciones_3f_4 <- predict(modelo_rf_4, DatosTest_4)
rmse_3f_4 <- sqrt(mean((predicciones_3f_4 - DatosTest_4$Yield.to.Maturity)^2))
mse_3f_4 <- mean((predicciones_3f_4 - DatosTest_4$Yield.to.Maturity)^2)
mae_3f_4 <- mean(abs(DatosTest_4$Yield.to.Maturity - predicciones_3f_4))
r2_3f_4 <- cor(predicciones_3f_4, DatosTest_4$Yield.to.Maturity)^2

#Imprimir resultados
cat("Modelo Random Forest enero 2013 - julio 2015 de tres factores (Tamaño + Bajo Riesgo + ESG)")
cat("RMSE: ", rmse_3f_1)
cat("MSE: ", mse_3f_1)
cat("MAE: ", mae_3f_1)
cat("R2: ", r2_3f_1)

cat("Modelo Random Forest agosto 2015 - febrero 2018 de tres factores (Tamaño + Bajo Riesgo + ESG)")
cat("RMSE: ", rmse_3f_2)
cat("MSE: ", mse_3f_2)
cat("MAE: ", mae_3f_2)
cat("R2: ", r2_3f_2)

cat("Modelo Random Forest marzo 2018 - septiembre 2020 de tres factores (Tamaño + Bajo Riesgo +
ESG)")
cat("RMSE: ", rmse_3f_3)
cat("MSE: ", mse_3f_3)
cat("MAE: ", mae_3f_3)
cat("R2: ", r2_3f_3)

cat("Modelo Random Forest octubre 2020 - abril 2023 de tres factores (Tamaño + Bajo Riesgo + ESG)")
cat("RMSE: ", rmse_3f_4)
cat("MSE: ", mse_3f_4)
cat("MAE: ", mae_3f_4)
cat("R2: ", r2_3f_4)

#Ejemplos de gráficos de rendimiento en el primer periodo
# Gráfico de Importancia de las Variables

```

```

importancia <- varImp(modelo_rf_1, scale = FALSE)
importancia_df <- as.data.frame(importancia$importance)
importancia_df$Variables <- rownames(importancia_df)

# Normalizar la importancia
importancia_df$Overall <- (importancia_df$Overall / sum(importancia_df$Overall)) * 100
importancia_df$Variables <- factor(importancia_df$Variables, levels = unique(importancia_df$Variables))

ggplot(importancia_df, aes(x = reorder(Variables, Overall), y = Overall)) +
  geom_bar(stat = "identity", fill = "coral") +
  coord_flip() +
  scale_y_continuous(limits = c(0, 100), labels = function(x) paste0(x, "%")) +
  labs(title = "Importancia de las Variables",
       x = "Variables",
       y = "Importancia (Normalizada a 100%)") +
  theme_minimal()

# Gráfico de Predicciones vs. Valores Reales
ggplot(data = NULL, aes(x = predicciones_3f_1, y = DatosTest_1$Yield.to.Maturity)) +
  geom_point(alpha = 0.5, color="coral") +
  geom_abline(slope = 1, intercept = 0, color = "black") +
  labs(title = "Predicciones vs. Valores Reales",
       x = "Predicciones",
       y = "Valores Reales") +
  theme_minimal()

# Gráfico de Residuales vs. Predicciones
residuales <- DatosTest_1$Yield.to.Maturity - predicciones_3f_1
ggplot(data = NULL, aes(x = predicciones_3f_1, y = residuales)) +
  geom_point(alpha = 0.5, color="coral") +
  geom_hline(yintercept = 0, color = "black") +
  labs(title = "Residuales vs. Predicciones",
       x = "Predicciones",
       y = "Residuales") +

```

```
theme_minimal()
```

```
# Histograma de Residuales
```

```
ggplot(data = NULL, aes(x = residuales)) +  
  geom_histogram(bins = 30, fill = "coral", alpha = 0.75) +  
  labs(title = "Histograma de Residuales",  
        x = "Residuales",  
        y = "Frecuencia") +  
  theme_minimal()
```

```
#Comparación con una regresión lineal con regularización ridge
```

```
modelo_rl <- train(Yield.to.Maturity ~ Weight + Maturity + ESG.Rating,  
                  data = DatosTrain_1,  
                  method = "ridge",  
                  trControl = control)  
  
print(modelo_rl)  
  
predicciones_rl <- predict(modelo_rl, newdata = DatosTest_1)  
  
rmse_rl <- sqrt(mean((DatosTest_1$Yield.to.Maturity - predicciones_rl)^2))  
  
mse_rl <- mean((DatosTest_1$Yield.to.Maturity - predicciones_rl)^2)  
  
mae_rl <- mean(abs(DatosTest_1$Yield.to.Maturity - predicciones_rl))  
  
r2_rl <- cor(DatosTest_1$Yield.to.Maturity, predicciones_rl)^2  
  
cat("RMSE: ", rmse_rl)  
  
cat("MSE: ", mse_rl)  
  
cat("MAE: ", mae_rl)  
  
cat("R2: ", r2_rl)
```

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Rodrigo González Gómez, estudiante de E3 Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Factor Investing y Sostenibilidad: El Factor ESG en Bonos Corporativos Investment Grade", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación [el alumno debe mantener solo aquellas en las que se ha usado ChatGPT o similares y borrar el resto. Si no se ha usado ninguna, borrar todas y escribir "no he usado ninguna"]:

1. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
2. **Interpretador de código:** Para realizar análisis de datos preliminares.
3. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
4. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 18/06/2024

Firma: Rodrigo González Gómez

7. BIBLIOGRAFÍA

Alessi, L., Ossola, E. & Panzica, R., 2021. What greenium matters in the stock market? The role of greenhouse gas emissions and environmental disclosures. *Journal of Financial Stability*, Volumen 54.

Allibhai, J., 2018. *Medium*. [En línea] Available at: <https://medium.com/@jaz1/holdout-vs-cross-validation-in-machine-learning-7637112d3f8f> [Último acceso: 4 6 2024].

Alzubi, J., Nayyar, A. & Kumar, A., 2018. Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics: Conference Series*, Volumen 1142, pp. 1-15.

Amat, J., 2020. *Ciencia de Datos*. [En línea] Available at: https://cienciadedatos.net/documentos/31_seleccion_de_predictores_subset_selection_ridge_lasso_dimension_reduction [Último acceso: 4 6 2024].

Amundi Asset Management Smart Beta, 2020. *ESG & Factor Investing: a new stage has been reached*, s.l.: s.n.

Baker, N. L. & Haugen, R. A., 1991. The efficient market inefficiency of capitalization-weighted stock portfolios. *The Journal of Portfolio Management*, 17(3), pp. 35-40.

Bankinter, s.f. *Bankinter Diccionario Económico*. [En línea] Available at: <https://www.bankinter.com/banca/diccionario-economico/grado-de-inversion#letra-A> [Último acceso: 16 6 2024].

Banz, R. W., 1981. The Relationship Between Returns and Market Value of Common Stocks. *Journal of Financial Economics*, 9(1), pp. 3-18.

Bender, J., Briand, R., Melas, D. & Subramanian, R. A., 2013. *Foundations of Factor Investing*, s.l.: s.n.

Blackrock Systematic Investing, 2023. *Blackrock*. [En línea] Available at: <https://www.blackrock.com/us/individual/insights/fixed-income-factor-investing> [Último acceso: 28 3 2024].

Blitz, D. & van Vliet, P., 2007. The Volatility Effect: Lower Risk Without Lower Return. *Journal of Portfolio Management*, 34(1), pp. 102-103.

Bloomberg Fixed Income Indices, 2023. *Bloomberg US Corporate Index*, s.l.: s.n.

Breiman, L., 2001. Random Forests. *Machine Learning*, Volumen 45, pp. 5-32.

Breiman, L., Olshen, R. A., Stone, C. J. & Friedman, J., 1984. *Classification and Regression Trees*, s.l.: Wadsworth International Group.

Carhart, M. M., 1997. On Persistence in Mutual Fund Performance. *The Journal of Finance*, 52(1), pp. 57-82.

CFA Institute, 2023. *CFA Institute*. [En línea] Available at: <https://www.cfainstitute.org/en/professional-insights-stories/gaining-broader-perspective-guide-esg-investment-approaches> [Último acceso: 29 3 2024].

Chan, L. K., Hamao, Y. & Lakonishok, J., 1991. Fundamentals and Stock Returns in Japan. *Journal of Finance*, Volumen 46, pp. 1739-1789.

Cherief, A., Ben Slimane, M., Dumas, J.-M. & Fredj, H., 2022. *Credit Factor Investing with Machine Learning techniques*, s.l.: Amundi Asset Management.

Clark, G. L., Andreas, F. & Viehs, M., 2015. *From the Stockholder to the Stakeholder: How Sustainability Can Drive Financial Outperformance*. [En línea] Available at: <https://ssrn.com/abstract=2508281> [Último acceso: 30 3 2024].

Compact UN Global, 2004. *Who cares wins: Connecting financial markets to a changing world*, Nueva York: s.n.

Coqueret, G. & Guida, T., 2023. *Machine Learning for Factor Investing*. 1 ed. Florida: CRC Press.

Core, J. E., Guay, W. R. & Rusticus, T. O., 2006. Does Weak Governance Cause Weak Stock Returns? An Examination of Firm Operating Performance and Investors' Expectations. *The Journal of Finance*, 61(2), pp. 655-687.

Core, J. E., Holthausen, R. W. & Larcker, D. F., 1999. Corporate governance, chief executive officer compensation, and firm performance. *Journal of Financial Economics*, 51(3), pp. 371-406.

Correia, M., Richardson, S. & Tuna, I., 2012. Value Investing in Credit Markets. *Review of Accounting Studies*, 17(3), pp. 572-609.

Deloitte, 2021. *Qué son los criterios ESG y para qué sirven*. [En línea] Available at: <https://www2.deloitte.com/es/es/blog/sostenibilidad-deloitte/2021/que-son-criterios-esg-para-que-sirven.html> [Último acceso: 29 3 2024].

Derwall, J., Huij, J. & de Zwart, G. J., 2009. *The Short-Term Corporate Bond Anomaly*, s.l.: SSRN.

Fama, E. F. & French, K. R., 1992. The Cross-Section of Expected Stock Returns. *The Journal of Finance*, 47(2), pp. 427-465.

Fama, E. F. & French, K. R., 1993. Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), pp. 3-56.

Fama, E. F. & French, K. R., 2004. The Capital Asset Pricing Model: Theory and Evidence. *Journal of Economic Perspectives*, 18(3), pp. 25-46.

Fama, E. F. & French, K. R., 2015. A five-factor asset pricing model. *Journal of Financial Economics*, Volumen 116, pp. 1-22.

Fan, J. H. & Michalski, L., 2020. Sustainable factor investing: Where doing well meets doing good. *International Review of Economics and Finance*, Volumen 70, pp. 230-256.

Frazzini, A. & Pedersen, L. H., 2014. Betting Against Beta. *Journal of Financial Economics*, 111(1), pp. 1-25.

Friede, G., Busch, T. & Bassen, A., 2015. ESG and financial performance: aggregated evidence from more than 2000 empirical studies. *Journal of Sustainable Finance & Investment*, 5(4), pp. 210-233.

García, S., 2021. *CAPM*, Madrid: Universidad Pontificia de Comillas.

Garg, V. K. & Kalai, A., 2018. *Supervised Unsupervised Learning*, s.l.: MIT.

Gebhardt, W. R., Hvidkjaer, S. & Swaminathan, B., 2005. Stock and Bond Interaction: Does Momentum Spill Over?. *Journal of Financial Economics*, 75(3), pp. 651-690.

Ghojogh, B. & Crowley, M., 2023. *The Theory Behind Overfitting, Cross Validation, Regularization, Bagging, and Boosting: Tutorial*, s.l.: University of Waterloo.

Giese, G. y otros, 2019. Foundations of ESG Investing: How ESG Affects Equity Valuation, Risk, and Performance. *The Journal of Portfolio Management*, 45(5), pp. 1-15.

Jimeno, R. & González, C. I., 2022. *The Role of a Green Factor in Stock Prices. When Fama & French Go Green*, s.l.: Banco de España.

Görge, M., Wilkens, M. & Ohlson, H., 2020. CARIMA – A Capital Market-Based Approach to Quantifying and Managing Transition Risks. En: *NGFS Occasional Paper - Case Studies of Environmental Risk Analysis Methodologies*. s.l.:s.n., pp. 540-559.

Goss, A. & Roberts, G. S., 2011. The impact of corporate social responsibility on the cost of bank loans. *Journal of Banking & Finance*, 35(7), pp. 1794-1810.

- Harvey, R. C. & Liu, Y., 2019. *A Census of the Factor Zoo*. [En línea] Available at: <https://ssrn.com/abstract=3341728> [Último acceso: 26 3 2024].
- Hastie, T., Tibshirani, R. & Friedman, J., 2009. *The Elements of Statistical Learning*, 2 ed. s.l.:Springer.
- Heckel, T. y otros, 2021. Out-Performing Corporate Bonds Indices With Factor Investing. *Bankers Markets & Investors, Special Issue Bond Factors Investing*, Issue 165, pp. 1-12.
- Hodson, T. O., 2022. Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geosci. Model Dev*, Volumen 15, pp. 5481-5487.
- Houweling, P. & van Zundert, J., 2017. Factor Investing in the Corporate Bond Market. *Financial Analysts Journal*, 73(2), pp. 100-115.
- Huck, N., 2019. Large data sets and machine learning: Applications to statistical arbitrage. *European Journal of Operational Research*, Volumen 278, pp. 330-342.
- Jagannathan, R. & Ma, T., 2003. Risk Reduction in Large Portfolios: Why Imposing the Wrong Constraints Helps. *The Journal of Finance*, 58(4), pp. 1651-1683.
- Jegadeesh, N. & Titman, S., 1993. Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. *The Journal of Finance*, 48(1), pp. 65-91.
- Jiang, T., Gradus, J. L. & Rosellini, A. J., 2020. Supervised Machine Learning: A Brief Primer. *Behavior Therapy*, 51(5), pp. 675-687.
- Jostova, G., Nikolova, S., Philipov, A. & Stahel, C. W., 2013. Momentum in Corporate Bond Returns. *Review of Financial Studies*, 26(7), pp. 1649-1693.
- Kim, S. & Li, Z., 2021. Understanding the Impact of ESG Practices in Corporate Finance. *Sustainability*, 13(7).
- Konar, S. & Cohen, M. A., 2001. Does the Market Value Environmental Performance?. *The Review of Economics and Statistics*, 83(2), pp. 281-289.
- Krauss, C., Do, X. A. & Huck, N., 2017. Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, Volumen 259, pp. 689-702.
- Lintner, J., 1965. Security Prices, Risk, and Maximal Gains From Diversification. *The Journal of Finance*, 20(4), pp. 587-615.
- Malibari, N., Katib, I. & Mehmood, R., 2023. *Systematic Review on Reinforcement Learning in the field of Fintech*, s.l.: Cornell University.
- Mangram, M. E., 2013. A simplified perspective of the Markowitz portfolio theory. *Global Journal of Business Research*, 7(1), pp. 59-70.
- Markowitz, H., 1952. Portfolio Selection. *Journal of Finance*, 7(1), pp. 71-91.
- Melas, D., Nagy, Z. & Kulkarni, P., 2016. *Factor Investing and ESG Integration*, s.l.: MSCI Research Insight.
- Mendizábal Zubeldia, A., Miera Zabalza, L. M. & Zubia Zubiaurre, M., 2002. El modelo de Markowitz en la gestión de carteras. *Cuadernos de Gestión - Universidad del País Vasco*, 2(1), pp. 33-46.
- Mitchell, T. M., 1997. *Machine Learning*. s.l.:McGraw Hill.
- Mossin, J., 1966. Equilibrium in a Capital Asset Market. *Econometrica*, 34(4), pp. 768-783.
- Nielsen, F. & Subramanian, R. A., 2008. Far From the Madding Crowd - Volatility Efficient indexes. *MSCI Barra Research Insights*.
- Perold, A. F., 2004. The Capital Asset Pricing Model. *Journal of Economic Perspectives*, 18(3), pp. 3-24.
- Pollman, E., 2022. *The Making and Meaning of ESG*, s.l.: ECGI Working Paper Series in Law.

- Rapach, D. E. & Zhou, G., 2019. *Time-Series and Cross-Sectional Stock Return Forecasting: New Machine Learning Methods*, s.l.: Washington University in St. Louis.
- Raschka, S., 2018. *Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning*, s.l.: University of Wisconsin-Madison.
- Rosenberg, B., Reid, K. & Lanstein, R., 1985. Persuasive Evidence of Market Inefficiency. *Journal of Portfolio Management*, Volumen 11, pp. 9-17.
- Rubinstein, M., 2002. Markowitz's "Portfolio Selection": A Fifty-Year Retrospective. *The Journal of Finance*, 57(3), pp. 1041-1045.
- Samuel, A. L., 1959. Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), pp. 210-229.
- Sharpe, W. F., 1964. Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *The Journal of Finance*, 19(3), pp. 425-442.
- Singh, S., 2018. *Medium*. [En línea] Available at: <https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229> [Último acceso: 3 6 2024].
- Soe, A. M. & Xie, H., 2016. *Factor-Based Investing in Fixed Income: A Case Study of the U.S. Investment-Grade Corporate Bond Market*, s.l.: S&P Dow Jones Indices Research Fixed Income.
- Stattman, D., 1980. Book Values and Stock Returns. *The Chicago MBA: A Journal of Selected Papers*, Volumen 4, pp. 25-45.
- Tobin, J., 1958. Estimation of Relationships for Limited Dependent Variables. *Econometrica*, 26(1), pp. 24-36.
- Treynor, J. L., 1961. *Market Value, Time, and Risk*, s.l.: SSRN.
- Universidad Pontificia de Comillas, 2021. *Characterization of machine learning models*, Madrid: s.n.
- Universidad Pontificia de Comillas, 2021. *Random Forests*, Madrid: s.n.