



Facultad de Ciencias Económicas y Empresariales
ICADE

EL ATRACTIVO DEL *PRIVATE EQUITY* POR PAÍS

Autor: Manuel Conde Escabias
Director: María Coronado Vaca

MADRID | Junio 2024

Resumen

El presente trabajo analiza el atractivo los países como potenciales destinos de inversión por parte de gestoras de *private equity*. Destaca la importancia de analizar el contexto socioeconómico de un país con el fin d evaluar si presenta las condiciones favorables necesarias para el desempeño positivo de dicha inversión. Para ello, el Trabajo toma como referencia el Índice de Atractivo de *Private Equity* elaborado por el IESE con el fin de descubrir si existen modelos más simples capaces de predecir dicho atractivo. Como efecto, se realizará un estudio exhaustivo de los datos objetos de estudio con el fin de identificar un menor número de potenciales variables que capaces de explicar el atractivo de cada país a efecto de posibles inversiones de capital de riesgo. Asimismo, se investigará si existen modelos alternativos capaces de estimar con mejor efectividad el atractivo de dichas regiones.

Palabras clave

Private equity, índice, modelos, atractivo

Abstract

This present paper analyses the attractiveness of countries as potential investment destinations for private equity managers. It highlights the importance of analysing the socio-economic context of a country in order to assess whether it presents the necessary favourable conditions for the positive performance of such an investment. To this end, the paper takes as a reference the Private Equity Attractiveness Index developed by the IESE in order to discover whether there are simpler models capable of predicting this attractiveness. As a result, an exhaustive study of the data under study will be carried out in order to identify a smaller number of potential variables capable of explaining the attractiveness of each country for the purpose of possible venture capital investments. We will also investigate whether there are alternative models capable of better estimating the attractiveness of these regions.

Key words

Private equity, index, models, attractiveness

Índice

1. INTRODUCCIÓN.....	6
1.1. JUSTIFICACIÓN DEL TEMA.....	6
1.2. OBJETIVOS	6
1.3. METODOLOGÍA.....	7
1.4. ESTRUCTURA DEL TRABAJO.....	7
2. PRIVATE EQUITY.....	8
2.1. HISTORIA DEL <i>PRIVATE EQUITY</i>	8
2.2. <i>PRIVATE EQUITY</i> EN EL MUNDO ACTUAL	12
2.3. IMPORTANCIA DE ENTENDER EL ATRACTIVO DEL <i>PRIVATE EQUITY</i> POR PAÍS.....	13
3. DATOS Y METODOLOGÍA.....	15
3.1. DESCRIPCIÓN DE LOS DATOS	15
3.2. PREPARACIÓN DE LOS DATOS	20
3.3. METODOLOGÍA.....	22
4. ANÁLISIS EXPLORATORIO DE LOS DATOS	23
4.1. ANÁLISIS DE CORRELACIONES.....	24
4.2. ANÁLISIS DE LAS DISTRIBUCIONES	25
4.3. <i>CLUSTERING</i>	26
4.4. ANÁLISIS DE COMPONENTES PRINCIPALES.....	29
5. MODELOS PROPUESTOS.....	30
5.1. MODELOS PARA PREDECIR LOS <i>SCORES</i>	31
5.1.1. REGRESIÓN LINEAL	31
5.1.2. ÁRBOL DE DECISIÓN	32
5.1.3. RED NEURONAL.....	33
5.1.4. MÁQUINAS DE VECTOR SOPORTE.....	33
5.2. MODELOS PARA PREDECIR LA INVERSIÓN DE <i>PRIVATE EQUITY</i>	33
5.2.1. REGRESIÓN LINEAL	34
5.2.2. ÁRBOL DE DECISIÓN	34
5.2.3. RED NEURONAL.....	34
5.2.4. MÁQUINAS DE VECTOR SOPORTE.....	35
6. RESULTADOS	36
7. CONCLUSIONES.....	39
8. BIBLIOGRAFÍA (INSERT BIBLIOGRAFÍA AL FINAL).....	ERROR! BOOKMARK NOT DEFINED.
BIBLIOGRAPHY	40
9. ANEXOS	42

1. Introducción

1.1. Justificación del tema

El conocimiento acerca del entorno de una posible inversión es un factor crucial a la hora de evaluar una potencial aportación de capital o adquisición de un activo. Por ello, es imprescindible que un inversor esté familiarizado con el contexto socioeconómico de su posible inversión antes de acometerla.

En este sentido, poseer información relevante acerca de cada país puede permitir a las gestoras de capital de riesgo (*private equity*) tomar decisiones de inversión fundamentadas en aspectos que favorezcan dicha inversión (Groh, 2009). Este conocimiento no sólo favorece a los *private equities*, que sabrán cómo gestionar su inversión en ese entorno, sino que impulsará el crecimiento en el país destino de la inversión. Dado que el capital es el medio principal por el que familias, empresas y entidades públicas de un país son capaces de subsistir y progresar, la entrada de capital fomentará el desarrollo de estos agentes. Este desarrollo es especialmente importante para países emergente, donde la menor visibilidad internacional dificulta la inversión por parte de fondos de capital de riesgo. A modo ilustrativo, más del 60% de las gestoras a nivel global realizan sus inversiones en Estados Unidos o en Europa (Preqin, 2024), ignorando potenciales oportunidades de inversión atractivas en otras regiones.

No obstante, la obtención de esta información y la realización de análisis pertinentes es un proceso que requiere grandes esfuerzos y recursos. Por ello, resulta conveniente definir un índice capaz de tener en cuenta los factores que determinen el atractivo de cada país como destino de inversión por parte de un *private equity*.

1.2. Objetivos

El autor busca descubrir si existen ciertas variables capaces de explicar con alta precisión el atractivo de los países como destinos de inversión para *private equities*. Para ello, el Trabajo se basará en el *Venture Capital and Private Equity Attractiveness Index* elaborado por el IESE. Tomando este índice como referencia, se analizarán si existe un menor número de variables capaz de obtener resultados muy parecidos a los obtenidos por el Índice y busca descubrir si existen posibles modelos capaces de generar unas predicciones más acertadas.

1.3. Metodología

La metodología aplicada a lo largo de este Trabajo es cuantitativa, puesto que tanto los análisis como los siguientes pasos implementados están basados en datos y en los resultados estadísticos obtenidos. Mediante este enfoque, se hace uso de diferentes técnicas y herramientas estadísticas con las que se recogen, analizan e interpretan los resultados numéricos. Asimismo, esta perspectiva permite obtener unas conclusiones fundamentadas sobre hechos medibles y cuantificables. Consecuentemente, los potenciales inversores de *private equity* interesados en analizar el contexto socioeconómico de un país poseen unos resultados fácilmente comparables para calibrar el atractivo de potenciales inversiones en regiones determinadas.

1.4. Estructura del trabajo

El presente Trabajo sigue una estructura secuencial, en la que se comienza por definir el contexto objeto de estudio, se tratan de los datos a analizar, se realiza un análisis exploratorio de los datos para finalmente incorporarlos a los modelos propuestos y obtener los respectivos resultados. De esta forma, el Trabajo se orienta de forma deductiva y natural, en aras de fomentar la lógica e interpretabilidad de los análisis realizados.

Asimismo, cabe mencionar que los modelos predictivos llevados a cabo están divididos en función de los objetivos: aquellos relacionados con predecir el score del Índice en el que se basa este Trabajo y aquellos enfocados en predecir la inversión de capital de riesgo en cada país. A través de esta segmentación, se dividen los distintos procedimientos implementados y se obtiene una mejor interpretación de los resultados.

2. *Private equity*

El concepto *private equity* o capital de riesgo hace referencia a inversiones en el capital de compañías privadas (i.e. que no cotizadas) y, por lo tanto, no son accesibles para el público general (Gompers & Kaplan, 2022). No obstante, el término *private equity* se usa comúnmente para referirse a la gestora de fondos de capital de riesgo, encargada de administrar dichas inversiones. Como efecto, un *private equity* canaliza el capital desde los inversores hasta las compañías privadas, actuando a modo de entidad intermediaria.

2.1. Historia del *private equity*

Resulta complicado precisar el origen exacto del capital de riesgo es difícil de precisar, ya que, hasta mediados del siglo XX, las inversiones privadas se llevaban a cabo de forma independiente a través de individuos o grupos de inversores que hacían uso de su propio capital (Sheyner, 2018). No obstante, 1946 es comúnmente referido como el año que marcó el inicio del *private equity* debido a la fundación de empresas como American Research and Development Corporation (ARDC) y J.H. Whitney & Company (JHW), que fueron las primeras en recaudar capital de terceros que posteriormente sería usado para realizar inversiones.

Durante los años 60 y 70, la industria del capital privado empezó a centrarse en empresas de reciente creación o *startups* enfocadas en el ámbito tecnológico. Durante esta época, surgieron gestoras de *private equity* como TA Associates y Apax Partners, que realizaron inversiones exitosas en empresas como Genentech, Electronic Arts o Federal Express. También en estos años se popularizaron las compras apalancadas (LBO, por sus siglas en inglés) que aprovechaban niveles elevados de deuda para realizar las adquisiciones in tener que destinar mucho capital propio. Entre los precursores de esta práctica destacan inversores como Warren Buffet (Berkshire Hathaway), Víctor Posner (DWG Corporation), Nelson Peltz (Triarc) y Saul Steinberg (Reliance Industries). Por otra parte, durante la década de los años 70, se produjo un cambio regulatorio en Estados Unidos con la modificación de la Ley de Seguridad de los Ingresos de Jubilación de los Empleados (ERISA), que permitió a los fondos de pensiones asignar un porcentaje de sus posibles inversiones en fondos de capital privado, incrementando sustancialmente las fuentes de recaudación para las gestoras. Este auge generalizado del sector fomentó la creación de firmas de *private equity* actualmente reconocidas a nivel mundial como Blackstone, Carlyle, KKR, Blackstone, Bain Capital y Cinven, así como transacciones récord como la de RJR Nabisco en 1989, que fue la mayor LBO de la historia

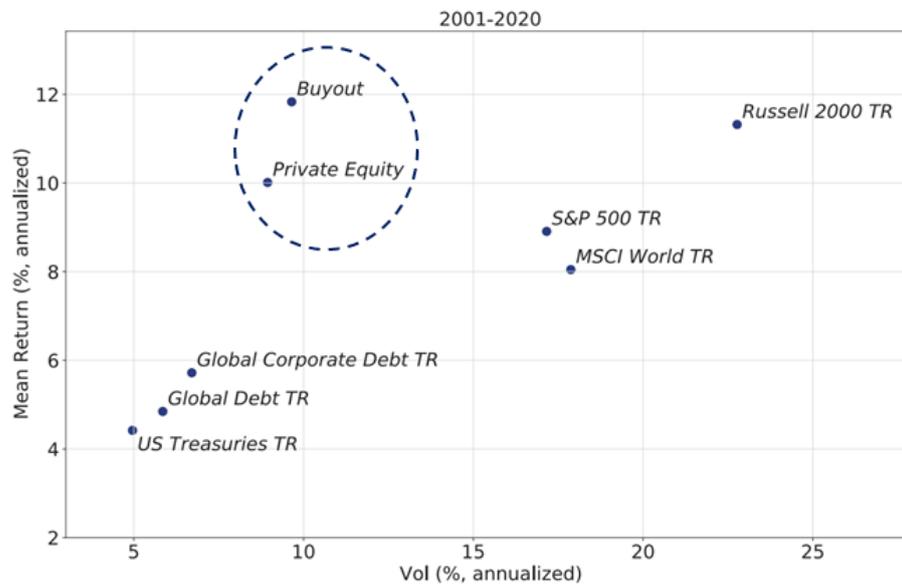
durante 17 años. No obstante, los elevados niveles de apalancamiento de esta etapa y el colapso del mercado de bonos basura en 1989 provocó la quiebra de muchas compañías participadas por *private equities*.

Desde entonces, y junto con la llegada del nuevo milenio, se ha revitalizado el sector del *private equity* donde las transacciones ocurren con mayor frecuencia y por mayores importes de compraventa. Asimismo, se ha pivotado de la connotación hostil que tradicionalmente ha recibido el *private equity* hacia un enfoque que asocia a estas empresas con socios estratégicos que buscan la creación de valor en las empresas a través de mejoras operativas (Sheyner, 2018).

El capital privado presenta ciertas ventajas en comparación con otras categorías de activos financieros para los inversores, destacándose las siguientes: (i) retornos superiores, (ii) diversificación, y (iii) acceso a oportunidades de inversión privadas.

- a. **Retornos superiores:** a lo largo de las últimas dos décadas, los fondos de capital de riesgo han generado retornos muy superiores (netos de comisiones) en relación con otros activos de inversión disponibles en los mercados cotizados (Harris, Jenkinson, & Kaplan, 2013). Además, gracias a su menor volatilidad anualizada, esta clase de activos presenta un perfil de riesgo-retorno muy ventajoso en comparación con los mercados cotizados (Higson & Stucke, 2012). Según el gráfico inferior, en las dos últimas décadas, los fondos de *private equity* y de *buyout* han conseguido una combinación óptima de retornos (10% y 12%, respectivamente) y volatilidad (8% y 9%, respectivamente) en promedio, superando los resultados de la renta variable, los bonos, las letras del tesoro y los índices bursátiles.

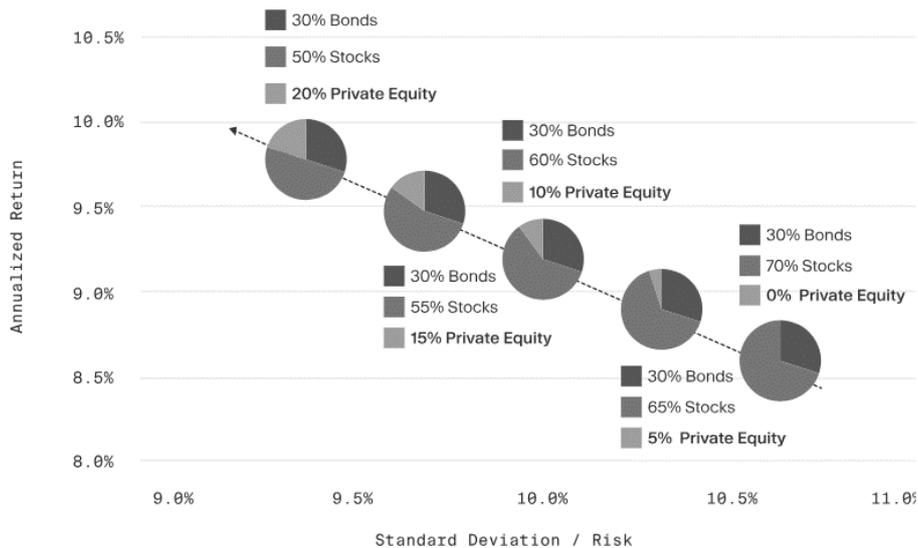
Figura 1. Retornos y volatilidades anualizadas (%) para distintos activos de inversión



Fuente: Ivashina, 2022, basada en datos de Preqin.

- a. **Diversificación:** la óptima combinación de riesgo-retorno que ofrece el *private equity* como activo de inversión promueve a que los inversores incluyan esta categoría dentro de sus carteras. Como efecto, dado su naturaleza privada e ilíquida, los fondos de capital de riesgo tienen un comportamiento que no suele estar directamente correlacionado con las fluctuaciones del mercado de valores o de deuda (Binfare, y otros, 2022). Esta ausencia de correlación provoca que las carteras con una mayor proporción de *private equity* obtengan logren rendimientos sensiblemente superiores y volatilidades significativamente inferiores relativo a otros activos del mercado (Espinosa, 2024).

Figura 2. Retornos y volatilidades de carteras compuestas por acciones, bonos y *private equity* durante los últimos 25 años (hasta 30 de junio 2018)



Fuente: Espinosa, 2024.

- a. **Acceso a oportunidades privadas de inversión:** el número de empresas privadas actuales a nivel mundial supera el 99% del total, pero la exposición del inversor individual medio a estas empresas es solo del 10.4% (Lau, 2024). Este desajuste natural en la proporción de la cartera de los inversores deja entrever el atractivo de un amplio universo de oportunidades de inversión privadas. Como resultado, el *private equity* hace que sea posible canalizar el capital de dichos inversores, tanto individuales como institucionales, en empresas privadas. A través de los fondos que gestionan dichas empresas de capital de riesgo, los inversores son capaces de acceder al accionariado de compañías en las que no podrían haber podido invertir a través de los mercados cotizados.

A modo de resumen, el *private equity* es un activo de inversión muy atractivo dado que ofrece unos retornos superiores a otras alternativas de inversión, la ventaja de diversificar la cartera y la posibilidad de acceder a un amplio universo de oportunidades de inversión. Dicho esto, una vez se ha establecido el contexto histórico del *private equity* y se han analizado las ventajas que proporciona invertir en el *private equity* a nivel general, resulta relevante estudiar la importancia actual del *private equity* a nivel global.

2.2. *Private equity* en el mundo actual

A día de hoy, se estima que el sector de *private equity* tiene \$8 billones de activos bajo gestión que han crecido a una tasa anual media compuesta de casi el 20% (McKinsey&Company, 2024). Estos datos ponen sobre relieve la importancia del sector del *private equity* en el panorama global y la clara tendencia de crecimiento que está experimentando el sector.

El capital disponible para invertir se sitúa alrededor de los \$3.9 billones, donde el 30% está enfocado en el segmento de *buyout* (Bain&Company, 2024). Dentro de este segmento, que comúnmente se utiliza como sinónimo de *private equity*, las inversiones en Estados Unidos y Europa han concentrado históricamente más del 70% del valor total. Del mismo modo, el número de gestoras de capital de riesgo sigue una distribución similar, donde el 59% de las mismas está orientada a invertir en activos en Estados Unidos y Europa (Preqin, 2024). Este hecho refleja la alta concentración que existe de fondos de capital de riesgo en Estados Unidos y Europa, prestando menos atención a otras regiones. Asimismo, la evolución del *private equity* ha variado significativamente en función de la región objeto de estudio. Las regiones de Norte América y Europa destacan como aquellas zonas con mayor crecimiento en términos de recaudación (8% y 6% anual, respectivamente), mientras que Asia y otras partes del mundo han crecido su capital recaudado de una forma más moderada (2% y 4% anual, respectivamente) (McKinsey&Company, 2024).

Además de esta concentración, el sector de *private equity* está experimentando dificultades a la hora de invertir el capital, alcanzando máximos históricos en términos de capital disponible para la inversión de \$3.9 billones. Asimismo, el nivel de inversión ha crecido proporcionalmente menos que el capital disponible, lo que subraya el incremento en las dificultades de las gestoras para distribuir el capital en oportunidades atractivas. A modo ilustrativo, la ratio del valor de las inversiones sobre el capital disponible a nivel global era de 72% en 2018 y actualmente se sitúa en torno al 37% (Bain&Company, 2024). Estos obstáculos a la hora de invertir son la consecuencia una mayor competitividad en el sector, producto, a su vez, del incremento del capital disponible para invertir y del un aumento en el número de gestoras, que actualmente se aproxima a las 30,000 empresas, lo que supone un crecimiento del 60% con respecto a hace cinco años (Warren, 2021).

Como consecuencia de lo expuesto, las gestoras de *private equity* deben explorar otras áreas en las que encontrar oportunidades de inversión atractivas. Asimismo, resulta crucial

indagar acerca del entorno en el que esta inversión se lleva a cabo. Por ello, conviene analizar los aspectos fundamentales que promueven o que frenan las potenciales inversiones de *private equity* en cada país, para lo que se estudiará el contexto económico y social de cada país con vistas a descubrir potenciales entornos atractivos para la inversión de capital de riesgo.

2.3. Importancia de entender el atractivo del *private equity* por país

Para evaluar el atractivo de un país a efectos de posibles inversiones de capital riesgo es crucial comprender el entorno socioeconómico de las distintas regiones. No obstante, la falta de información exhaustiva y relevante acerca de cada región limita los países en los que las gestoras de *private equity* centran sus inversiones (Groh, 2009). La recolección de los datos necesarios, así como su consiguiente interpretación, requiere grandes esfuerzos en términos económicos y de tiempo, lo que supone un obstáculo adicional para pivotar hacia otros países como nuevos destinos de inversión (Feil, 2023). Además, la rapidez con la que evolucionan ciertos países, especialmente aquellos denominados como emergentes, crea la necesidad de estar constantemente actualizando los datos y las proyecciones a futuro (Groh, 2009).

Sin embargo, un seguimiento y análisis detallado de los distintos entornos en los que se puede realizar una inversión puede desembocar en ventanas de oportunidades. A modo ilustrativo, hace 40 años, China era un país con una economía poco productiva, sin crecimiento, centralizada y desconectada de los mercados internacionales (Annamalah, 2023) pero, tras un giro en su política hacia la liberalización, el país ha experimentado uno de los mayores progresos jamás visto. Desde 1979, año en el que se implementaron medidas de liberalización y se abrió la economía al comercio e inversiones internacionales, el país ha crecido a una tasa anual media del 10% (Banco Mundial, 2024) y ha conseguido sacar a más de 800 millones de personas de la pobreza. En palabras del Banco Mundial, China ha experimentado “el crecimiento sostenido más rápido en la historia de las economías principales” (Morrison, 2019). Esta frase no sólo pone de manifiesto el espectacular desempeño de la economía China, sino que refleja el gran potencial de país como entorno favorable a la inversión. Evidencia de esto se puede encontrar en el aumento de gestoras de *private equity* en China, que ha pasó de 6 en 1992 a 17,044 en 2015 (Fang, Nofsinger, Song, & Wang, 2018), y en el 24% de crecimiento anual en la recaudación de fondos, hasta alcanzar los \$1,149 billones en 2019 (Baan, Leung, Naumann, Pandit, & Ramsbottom, 2020). En términos de retornos históricos

para fondos de private equity, se comprueba como China ha generado una TIR neta media del 18,5%, comparado con el 16,2% en Estados Unidos y el 16,5% en Europa (Preqin, 2024).

El ejemplo de la evolución de China pone de manifiesto el gran potencial que existe para el *private equity* analizar los países que conformarán el entorno de sus posibles inversores. A partir de una los análisis sobre métricas económicas, sociales y financieras, un inversor es capaz de anticiparse al resto de agentes de mercado y aprovechar la tendencia de crecimiento del país como viento de cola para sus inversiones de capital de riesgo. Siguiendo esta línea, resulta relevante continuar analizando las características y evolución de otros países con el fin de identificar los posibles siguientes entornos favorables para la entrada de *private equities*. El hecho de encontrar un país donde exista un desajuste entre la oferta y demanda de capital así como una tendencia económica favorable implicaría tener acceso a un potencial de oportunidades de inversión muy atractivo. En cuanto al desajuste entre oferta y demanda de capital, existe cierto círculo vicioso por el que los *private equities* están dispuestos a aportar capital en la actividad emprendedora de un país pero ésta, a su vez, necesita financiación para desarrollarse. Como efecto, pese a que un país con mayores niveles de emprendimiento crea un universo de mayores oportunidades de inversión atractivas para las gestoras de *private equity*, la dificultad de acceder a la financiación afecta directamente al contexto emprendedor y al desarrollo económico de un país (Green, 1998).

Dicho esto, comprender el contexto integral de un país como potencial destino de inversión no sólo hace referencia a aquellos países emergentes o con una menor cobertura por el sector, sino a todos. Pese a que un país que actualmente se encuentre menos desarrollado tiene, por naturaleza, mayor potencial de mejora y crecimiento, existe un mayor riesgo de una inversión actual en el mismo. Como efecto, resulta igual de interesante evaluar el entorno de países que actualmente son elegidos como los destinos predilectos de inversión (ej. Estados Unidos) para confirmar o rebajar el atractivo para potenciales inversiones.

Con el objetivo de realizar un análisis común aplicado a los distintos países a nivel global, resulta relevante generar un ranking que determine el atractivo de cada región para una inversión de *private equity*. Para ello, el trabajo se basará en el *Venture Capital and Private Equity Attractiveness Index* del IESE que comprende variables económicas, financieras y sociales para realizar un ranking de 125 países. Este índice busca servir a la comunidad inversora preparando y analizando grandes cantidades de datos socioeconómicos con el fin de

obtener un resultado compuesto que recoja el nivel de atracción del país para una inversión de capital de riesgo.

3. Datos y metodología

3.1. Descripción de los datos

El *Venture Capital and Private Equity Attractiveness Index* o Índice de Atractivo del *Private Equity* es un índice elaborado anualmente por el IESE que mide el atractivo de 125 países para la inversión por parte de gestoras de capital riesgo basado en una serie de factores económicos, sociales y financieros. Este índice fue publicado por primera vez en 2006 de la mano de los profesores Alexander Groh, Heinrich Liechtenstein, Karsten Lieser y Markus Biesinger, que actualmente continúan siendo los editores de este Índice.

Este índice realiza un seguimiento del desarrollo socioeconómico e institucional de los países, proporcionando información sobre el momento oportuno para las inversiones, basado en criterios socioeconómicos clave. No obstante, cabe mencionar que dicho índice no tiene en cuenta la selección de equipos de gestión de fondos individuales o los niveles de valoración, sino que evalúa el marco general del país. Para examinar con precisión el atractivo de un país para las inversiones de capital de riesgo, se consideran ciertas variables clave. Estas variables, que a su vez estarán posteriormente divididas en subconjuntos de criterios, conforman la columna vertebral del Índice de Atractivo de *Private Equity* y son las siguientes:

a. **Actividad económica:** el estado de la economía de un país desempeña un papel crucial en la determinación de su atractivo para las inversiones en *private equity*. El tamaño y nivel de actividad de la economía, las expectativas de crecimiento y los niveles de empleo, sirven como baremo de la prosperidad general, espíritu emprendedor y entorno empresarial saludable de un país. De esta manera, unas expectativas de rápido crecimiento económico ayudan a apoyar la inversión en el país, aspecto favorable en el contexto de los países emergentes (Gompers & Lerner, What drives venture fundraising?, 1998). Asimismo, existe una relación histórica positiva entre el crecimiento del PIB y las inversiones de *private equity* (Romain & Van Pottelsberghe, 2004), lo que subraya la importancia del entorno económico general del país. Sin embargo, pueden existir factores adicionales al crecimiento general de la

economía que determinen el atractivo de un país para la inversión de *private equities*.

b. Profundidad del mercados de capitales: la estructura y la profundidad del mercado de capitales de un país son fundamentales para apoyar las actividades de *private equity*. Por ello, resulta imperativo analizar las características específicas que se pueden encontrar en los mercados de cada país. Como defiende Black y Gilson (1998), las gestoras de *private equity* requieren mercados de capital robustos para fomentar las inversiones, y aquellas economías con una mayor dependencia de la financiación bancaria suelen ser menos capaces de crear una infraestructura eficiente. Asimismo, existe una relación directa positiva entre la capitalización de las empresas en mercados bursátiles y el número de compañías cotizadas con las inversiones de capital de riesgo (Schertler, 2003). Estas inversiones, por lo tanto, serán mayores en mercados de capitales profundos y con mayor liquidez (Gompers & Lerner, 2000). Como efecto, la calidad de la infraestructura de un país para facilitar las inversiones es un factor crucial que influye en el atractivo para una gestora de *private equity*.

c. Tributación: los regímenes fiscales influyen significativamente en la entrada y salida de negocios (Cullen & Gordon, 2002), por lo que afectan a la actividad empresarial. No obstante, y pese a que es común encontrar subrayado la importancia de las tasas impositivas en la actividad corporativa, es complejo encontrar un vínculo directo con las inversiones de *private equity*. Aunque los altos tipos impositivos corporativos generalmente se consideran un disuasivo, la relación entre la tributación y las inversiones de VC/PE es compleja. Algunos países con altos tipos impositivos atraen grandes inversiones de gestoras de capital de riesgo a la vez que existen países con tasas más bajas (especialmente emergentes) con menores niveles de inversión. Este hecho se puede deber a la importancia de tener un sistema tributario y de transacciones. Como efecto, se considerará los aspectos tributarios pero se les asignará un menor peso.

d. **Protección del inversor y gobierno corporativo:** la calidad de la protección del inversor y del gobierno corporativo es fundamental para atraer inversiones de capital de riesgo. Según establece Roe (2004), las economías más desarrolladas están enfocadas en crear un entorno robusto de protección del inversor. Asimismo, se descubre que existe una estrecha relación entre la calidad del contexto regulatorio de un país y los niveles de inversión por parte de *private equities* (Fleming, Schwienbacher, & Cumming, 2006). Entre los aspectos más relevantes, se encuentran las normas contables, protección de derechos de propiedad (Desai, Gompers, & Lerner, 2006) o la armonización regulatoria (Johan & Cumming, 2005). Consecuentemente, el entorno regulatorio de un país así como las políticas de protección del accionista y gobierno corporativo son aspectos clave para atraer la inversión de capital de riesgo. Dada la naturaleza a largo plazo de las inversiones de *private equity* y las relaciones con inversores institucionales, la confianza en el marco legal de las inversiones y en los intereses de los accionistas sobre el fondo es de importancia crucial.

e. **Contexto humano y social:** el entorno humano y social abarca factores como la educación y la flexibilidad del mercado laboral, pero también cargas sociales, que afecta al proceso de toma de decisiones de inversión. A modo de evidencia, un mercado laboral rígido afecta negativamente a la atracción de inversiones por parte de gestoras de *private equity* (Blanchard, 1997). Asimismo, el grado de corrupción, actividad criminal, economía sumergida y carga burocrática en un país actúa a modo de barrera de entrada para la actividad emprendedora y para el atractivo del país como destino de inversión de capital de riesgo (Djankov, Porta, Lopez-de-Silanes, & Shleifer, 2002).

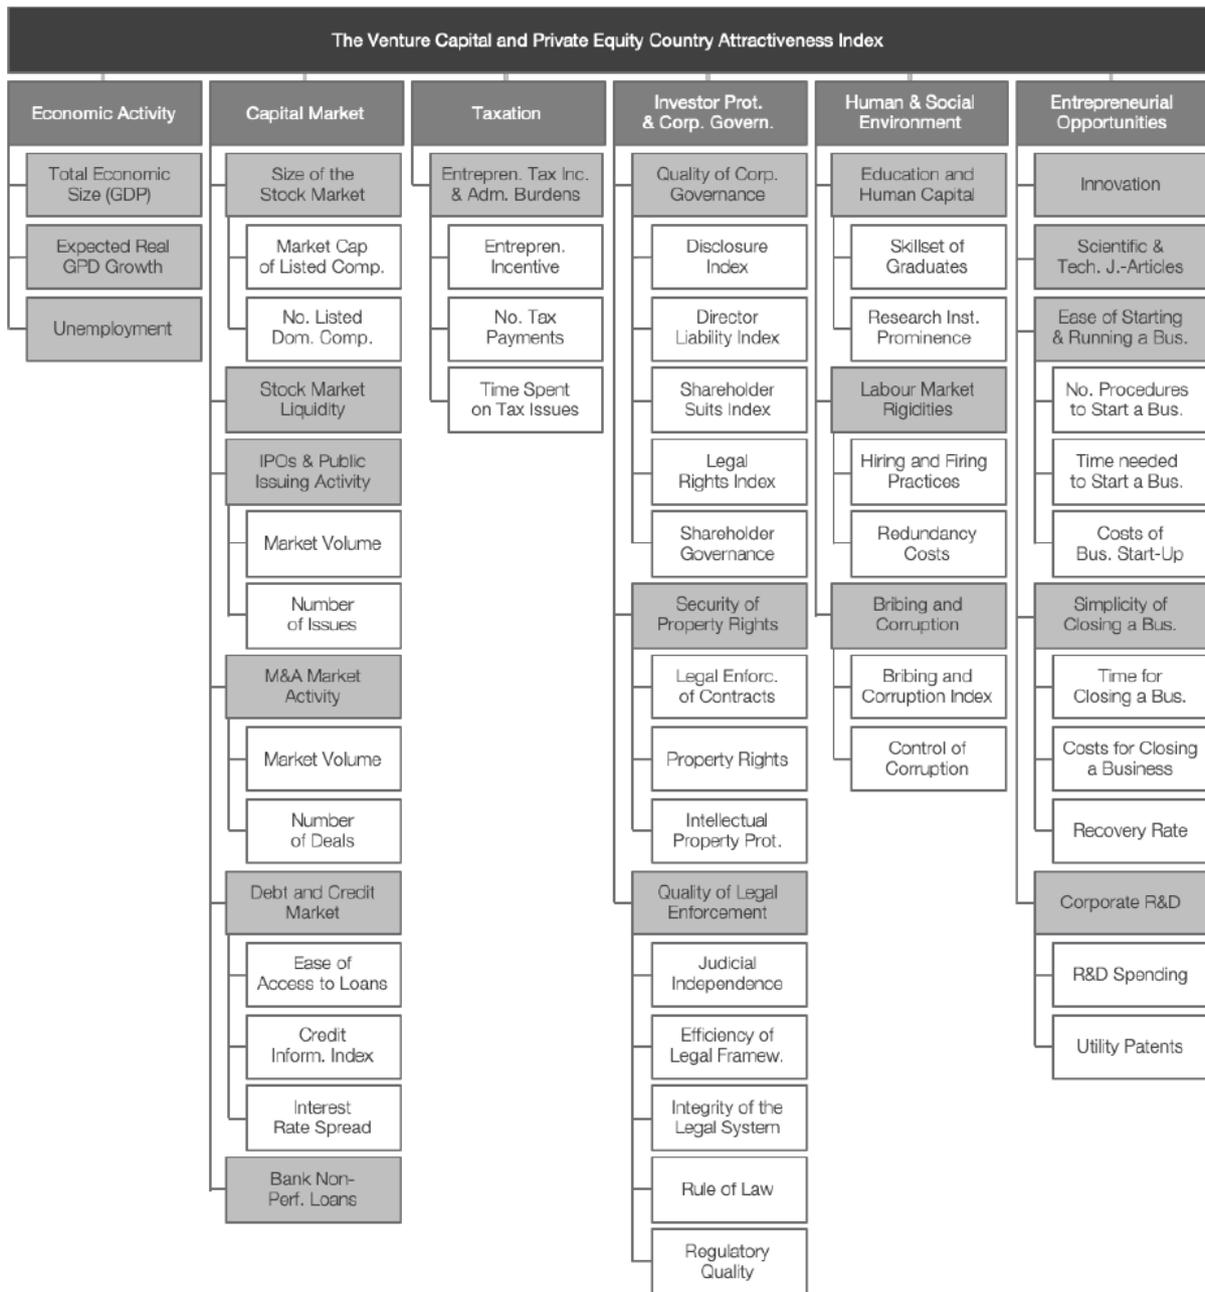
f. **Cultura de emprendimiento:** la cultura emprendedora de un país y el universo de potenciales oportunidades de inversión viables son factores relevantes para las inversiones de *private equity*. Este ámbito incluye la capacidad de innovación del país, la producción de investigación y desarrollo (I+D) y la facilidad para iniciar y operar un negocio. Los altos niveles de innovación y un fuerte sector de I+D generalmente se correlacionan con un

aumento de la actividad de capital de riesgo (Gompers & Lerner, 1998). Además, el proceso creación y cierre de negocios afecta directamente al espíritu emprendedor de un país. Por ello, los largos procedimientos necesarios, el exceso de normativas y la documentación requerida suponen obstáculos para la actividad empresarial de un país y la consecuente menor inversión (Djankov, Porta, Lopez-de-Silanes, & Shleifer, 2002). Como efecto, se requiere un entorno que fomente las actividades empresariales y ofrezca amplias oportunidades de negocio será esencial para atraer las inversiones de *private equity*.

En resumen, el Índice propuesto por el IESE establece que estas seis agrupaciones de variables (actividad económica, profundidad del mercado de capitales, tributación, protección del inversor y gobierno corporativo, entorno humano y social, y cultura emprendedora) son interdependientes y colectivamente determinan el atractivo de un país para las inversiones de *private equity*. De esta manera, el Índice de Atractivo de *Private Equity* por países proporciona una medida integral para guiar a los inversores en la toma de decisiones más informadas sobre la asignación de capital.

Estas seis variables principales son el resultado del producto ponderado de otras variables que, a modo de subconjuntos de criterios, se agrupan por ámbito determinado. Como efecto, el conjunto de datos total está compuesto por 46 variables independientes, que se organizan conforme a la siguiente estructura:

Figura 3. Diagrama de variables que componen el PE&VC Attractiveness Index



Fuente: The Venture Capital and Private Equity Country Attractiveness Index 2023, Groh et al., 2023.

3.2. Preparación de los datos

La recolección de los datos necesarios requirió acceder a varias plataformas de alcance internacional, entre las que destacan el Banco Mundial, el Fondo Monetario Internacional y el Foro Económico Mundial.

Sin embargo, debido a restricciones en el acceso a otras plataformas de las que se nutre el Índice (ej. Refinitiv Eikon), el autor seleccionó las alternativas disponibles (ej. FactSet). En total, ocho de las 46 variables que requieren una fuente externa tuvieron que extraer sus datos de otras fuentes. Dichas variables son las relacionadas con los mercados de capitales (utilizando FactSet en vez de Refinitiv Eikon), el número de artículos científicos publicados (usando el Banco Mundial en vez de Elsevier) y el número de patentes (usando World Population Review en vez de Euromonitor Internacional junto con otras fuentes). Este desajuste en los datos recabados en relación con los utilizados para obtener el score del Índice provoca que la correlación entre los resultados originales y los calculados no sea perfecta (i.e. 100%), sino que del 82.5% para el *score* y del 83.2% para el ranking.

Para obtener este resultado y ranking calculado, se empezó por fusionar los distintos conjuntos de datos, normalizar las variables, tratar los valores omitidos y normalizar las variables:

- a. **Fusionar bases de datos:** el objetivo de este paso es generar un conjunto de datos completo, homogéneo y fácilmente manipulable en fases posteriores. Para ello, se unificaron todas las fuentes de datos en formato Excel (desde PDF o CSV, entre otros formatos iniciales), sencillamente exportable al entorno de Rstudio; se homogeneizaron los nombres de los países (e.g. Slovak Republic a Slovakia, Hong Kong SAR a Hong Kong, Turkiye a Turkey etc.); y, se estructuró el conjunto de datos siguiendo el orden alfabético de los países, con el fin de facilitar el tratamiento futuro de los datos.
- b. **Normalizar las variables:** para normaliza las variables, se implementará el método de normalización estándar o escalado Z-score. Esta técnica asegura que todas las variables tengan la misma escala (media de 0 y desviación estándar de 1), lo que evita sesgar a los modelos que sean sensibles a la escala, y mitiga la influencia de los valores atípicos. La fórmula empleada es la siguiente:

$$z = \frac{x - \mu}{\sigma}$$

- z es el valor normalizado
 - x es el valor original
 - μ es la media de los valores de x
 - σ es la desviación estándar de los valores de x
- c. **Tratar los valores omitidos:** debido al uso de distintas fuentes de datos, el conjunto utilizado presenta valores omitidos. Como efecto, el autor planteó dos alternativas para sustituir dichos valores omitidos: (i) sustituir por cero o (ii) sustituir por la media de los datos de cada país. Al aplicar la primera opción, se estaría introduciendo un sesgo en el modelo al asegurar que esos países tienen el peor resultado. En contraste, la sustitución de los valores omitidos por la media de la variable permite aprovechar la tendencia hacia la media como medida mitigadora. Dicho esto, cabe mencionar que los valores omitidos representan una parte muy minoritaria de los datos (menos del 10%).
- d. **Calcular los *scores* y el ranking:** en el cálculo de los *scores* de los distintos países se implementó un método de agregación aritmética, lo que implica realizar una suma ponderada de todos los valores de cada país. Como resultado, si se analiza la fortaleza de la relación entre el *score* y el ranking inicial de Índice con aquellos calculados, se obtiene una correlación del 82% y del 83%, respectivamente.

Una vez obtenido el conjunto de datos que conformarán las variables independientes, se pasó a extraer los datos de inversiones de *private equity* por país. Esto se debe a que, para validar el modelo, el Índice se cruza con los niveles de inversión de capital de riesgo en cada país, estableciendo que unos mayores niveles de inversión justifican un mayor atractivo por parte de las gestoras de *private equity*. Para ello, se accedió a la plataforma Preqin (la plataforma con datos de inversiones alternativas más extensa) para recabar información sobre las inversiones de *buyout* y *venture capital*. Los datos recogidos hacen referencia al período entre el 01/01/2020 y el 31/12/2022 para los 125 países objeto de estudio, resultando en la obtención de un total de 122.406 inversiones distintas. Estas inversiones serán agregadas por país para lograr obtener el total de inversiones de *private equity* en cada región.

3.3. Metodología

En lo que concierne a los diferentes tipos de modelos utilizados en los análisis, el autor ha destacado los siguientes debido a varios motivos:

a. Regresión lineal:

La regresión lineal es un método estadístico utilizado para modelar la relación entre una variable dependiente y una o varias independientes, ajustando una ecuación lineal a un conjunto de datos. Este método es especialmente relevante por su simplicidad y facilidad de interpretación, que lo convierte en un punto de partida idóneo para predecir los *scores* de los distintos países del Índice de Atractivo de *Private Equity*. La regresión lineal proporciona una comprensión clara de cómo cada variable explicativa impacta al índice, lo que ayuda a identificar aquellos factores más influyentes.

b. Árboles de decisión:

El árbol de decisión es un modelo de aprendizaje supervisado no paramétrico, que se utiliza tanto para tareas de clasificación como de regresión. Para ello, empieza por dividir los datos en subconjuntos basados en los valores de las características de entrada, creando una estructura similar a un árbol donde cada nodo u ‘hoja’ representa una decisión basada en un atributo, y cada rama representa el resultado de esa decisión. Este método es altamente interpretable y fácil de visualizar, lo que lo convierte en una herramienta útil para entender el proceso de toma de decisiones detrás de las predicciones del Índice de Atractivo de *Private Equity*. Los árboles de decisión son capaces de capturar relaciones no lineales entre las variables predictoras y el índice, proporcionando una comprensión más matizada de los factores en juego. Sin embargo, los árboles de decisión son propensos al sobreajuste o *overfitting*, especialmente con conjuntos de datos de menores dimensiones.

c. Red neuronal:

Una red neuronal es un modelo de *machine learning* cuyo proceso de toma de decisiones emula el funcionamiento de las neuronas en un cerebro humano. Dicha red está compuesta por capas (entrada, oculta y salida) y por nodos, que se conectan entre sí y poseen sus propias ponderaciones y umbrales asociados. Las ponderaciones ayudan a analizar la

importancia de cada variable, donde las más grandes contribuyen en mayor medida a la salida que otras entradas. Tras esto, se multiplican todos los datos de entrada por sus ponderaciones y se suman, cuyo resultado se utiliza para aplicar una función de activación que determina la salida. Si dicha salida excede un umbral determinado, el nodo se activa y los datos resultantes se trasladan a la siguiente capa. La red neuronal puede ser utilizada tanto para problemas de regresión como de clasificación. Como efecto, resulta relevante implementar este modelo en el contexto de *private equity* por país para capturar posibles relaciones complejas y no lineales entre los datos.

d. Máquinas de vector soporte:

Una máquina de vector soporte (o SVM, por sus siglas en inglés) es un tipo de algoritmo de aprendizaje supervisado que clasifica los datos al encontrar un hiperplano que maximice la distancia entre cada categoría. Este hiperplano busca maximizar el margen entre las clases más cercanas, lo que implica buscar distribuir el mayor espacio posible entre los datos de clases diferentes. La ventaja de este modelo es que permite manipular la falta de linealidad trasladar a un espacio de mayores dimensiones los datos, donde luego poder identificar un hiperplano que distinga entre clases.

Tras explicar los distintos modelos que se van a emplear a lo largo de los análisis predictivos así como definir su potencial utilidad, conviene realizar un estudio detallado del conjunto de datos con el fin de alcanzar una mejor comprensión sobre los mismos.

4. Análisis exploratorio de los datos

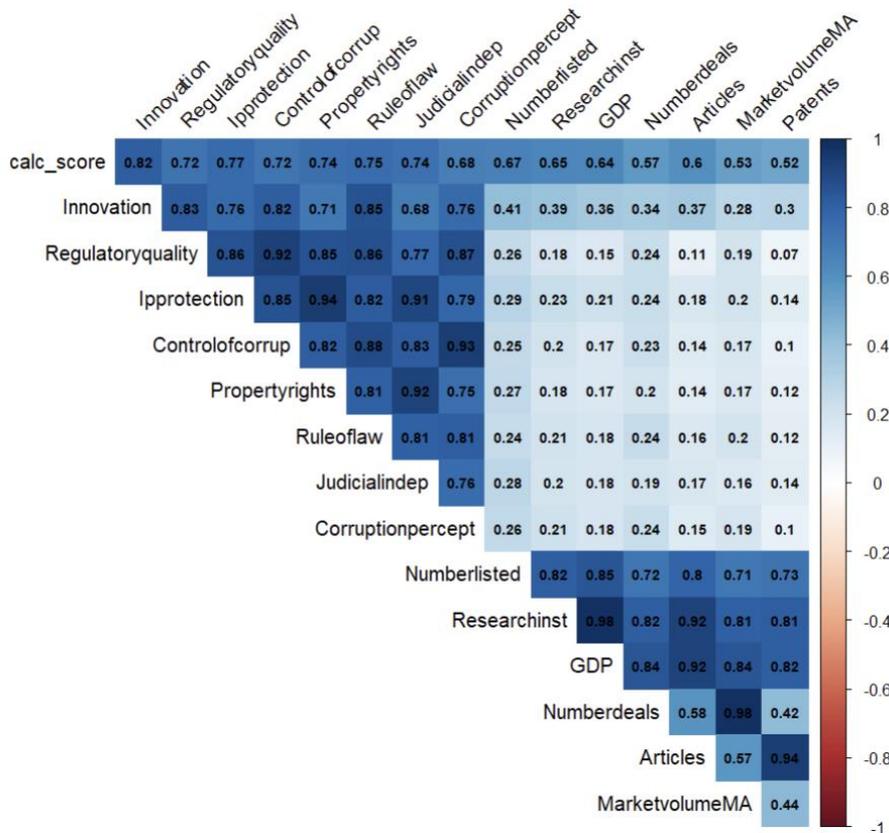
El análisis exploratorio de los datos (o EDA, por sus siglas en inglés) es un paso fundamental de cara a entender el conjunto de datos que se desea utilizar. A través de los distintos análisis, se podrán identificar las variables más relevantes, tendencias subyacentes y potenciales agrupaciones entre países debido a características similares. Para ello, el autor realizará los siguientes análisis: (i) correlaciones, (ii) componentes principales, (iii) distribuciones y (iv) *clustering*.

4.1. Análisis de correlaciones

La correlación entre dos variables hace referencia al grado de relación lineal entre ellas, es decir, a la medida en que el cambio en una variable está asociado con cambios en la otra. Como efecto, las correlaciones son fundamentales para entender las potenciales relaciones que pueden existir entre las distintas variables del conjunto de datos.

En este caso, para analizar dichas relaciones se ha implementado una matriz de correlaciones, que ayuda a visualizar el grado de relación entre cada una de las variables usadas para componer el Índice. Sin embargo, para descubrir qué variables son aquellas más correlacionadas dentro del conjunto, se realizó una segunda matriz con un *cutoff* a partir del 0.8. Este corte a partir de un nivel de correlación del 0.8 implica que las variables resultantes serán altamente explicativas entre sí y tendrán el potencial de convertirse en aquellas variables más importantes dentro de los modelos predictivos. Como resultado, las variables más correlacionadas con el *score* de cada país (por encima del corte de 0.8) son: (i) nivel de innovación, (ii) protección de la propiedad intelectual, (iii) calidad regulatoria, (iv) control de la corrupción, (v) derechos de propiedad, (vi) Estado de Derecho, (vii) independencia judicial, (viii) percepción de la corrupción, (ix) número de compañías cotizadas, (x) número de instituciones de investigación, (xi) PIB, (xii) número de transacciones de M&A, (xiii) tamaño del mercado cotizado, (xiv) número de publicaciones científicas, (xv) volumen de las operaciones de M&A y (xvi) número de patentes.

Figura 4. Matriz de correlaciones entre variables a partir de un corte del 0.8

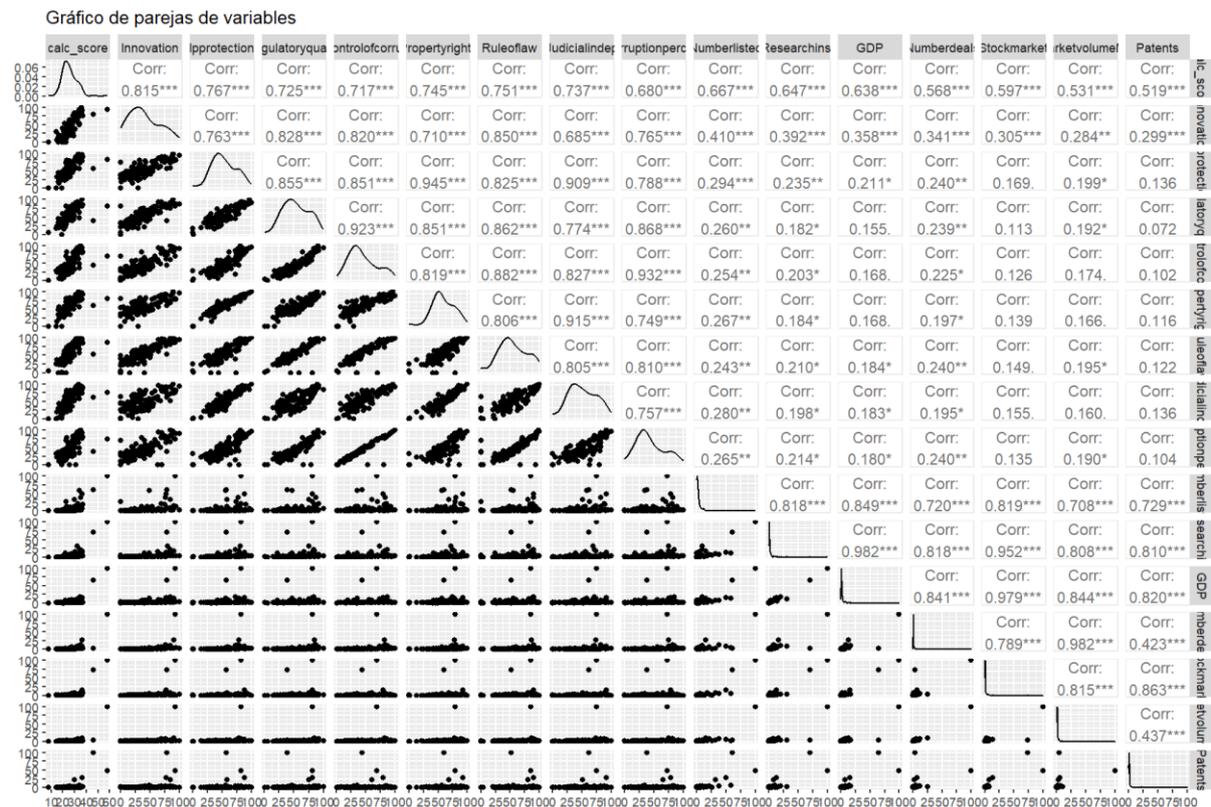


Fuente: Elaboración propia.

4.2. Análisis de las distribuciones

Una vez estudiadas las correlaciones, resulta relevante analizar las distribuciones de las distintas variables utilizadas para calcular el Índice. Por ello, se llevó a cabo una visualización de las distintas parejas de variables, con el objetivo de observar las relaciones entre los datos. Asimismo, el gráfico resultante también refleja las distribuciones de los valores de cada variable, que ayudan a comprender cómo se reparten los países en cada uno de los indicadores económicos, sociales y culturales seleccionados.

Figura 5. Gráfico de parejas de variables



Fuente: Elaboración propia

Adicionalmente, será conveniente analizar la variable de respuesta (*score calculado*) mediante resúmenes estadísticos y visualizaciones de la distribución de sus datos. Como resultado, se observa que el *score* medio de los 125 países seleccionados es de 40.3, pero con valores atípicos como Estados Unidos (100.0), China (78.3) o Siria (8.1). Asimismo, los *scores* de los países están ligeramente sesgados a la derecha, con un valor de sesgo de 1.2, y presentan una distribución leptocúrtica con las colas más anchas y un pico pronunciado, dado índice de curtosis de 4.1.

4.3. Clustering

La técnica de *clustering* o de análisis de conglomerados tiene como objetivo identificar grupos de observaciones similares. Como efecto, resulta altamente relevante aplicar este método en el contexto de este estudio ya que analizará si existen agrupaciones de países con características parecidas.

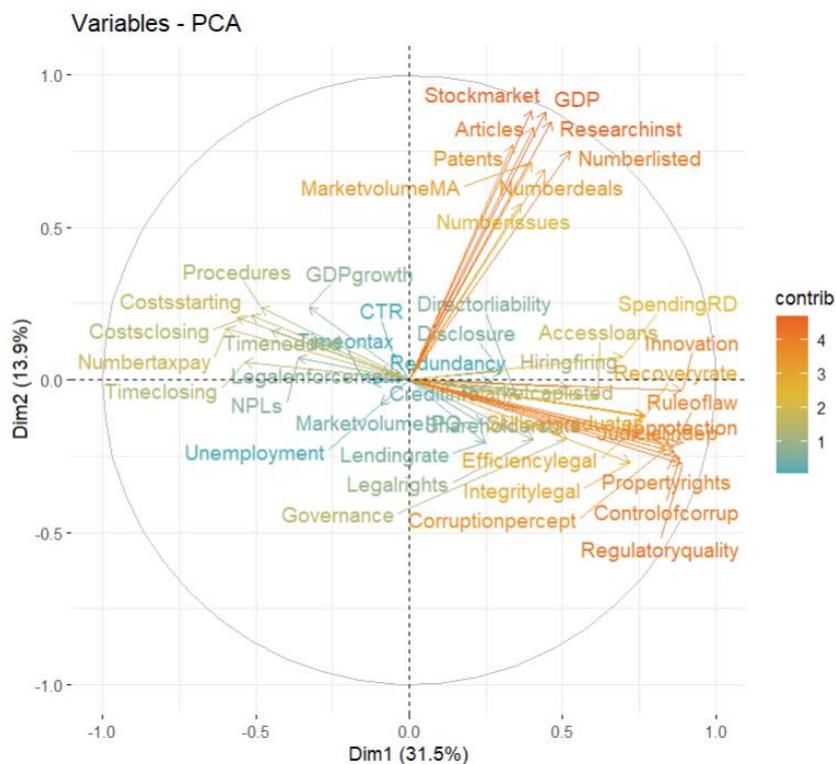
Para lograr identificar estos *clusters*, se empezará por crear un dendrograma o diagrama de árbol capaz de visualizar el orden jerárquico de un conjunto de datos. En este caso, se realizará

4.4. Análisis de componentes principales

El análisis de componentes principales (o PCA, por sus siglas en inglés) es una técnica estadística que permite reducir la dimensionalidad del conjunto de datos mientras intenta preservar la mayor variabilidad posible. El objetivo de esta técnica es identificar aquellos componentes principales que explican la variabilidad en las variables explicativas.

Tras realizar el análisis, se observa cómo a partir del componente principal número 16, la varianza acumulada explicada es del 86%. Este dato sugiere que es posible reducir significativamente el número de posibles variables explicativas a la vez que capturar gran parte de la información del conjunto de datos original. Además, en el gráfico inferior, se percibe cómo las variables que más contribuyen a la formación de los componentes principales coinciden con aquellas que presentan unos mayores niveles de correlación (analizado en el apartado 4.1.). Como efecto, se procederá a seleccionar un subconjunto de 16 variables entre el conjunto original de 46 variables que presenten unos mayores niveles de correlación y de contribución en los componentes principales.

Figura 8. Contribución de cada variable a los componentes principales



Fuente: Elaboración propia.

5. Modelos propuestos

Como se ha mencionado anteriormente, este estudio tiene el objetivo principal de comprobar si existen modelos con un menor número de variables capaces de predecir (1) el *scoring* de los países en el Índice de Atractivo del *Private Equity* y (2) la inversión de *private equity* en los distintos países. Para ello, el autor propone aplicar los siguientes tipos de modelos a ambos análisis: (i) regresión lineal, (ii) árbol de decisión, (iii) red neuronal y (iv) máquinas de vector soporte.

En todos los modelos, para entrenar y validar los modelos, dado las bajas dimensiones del conjunto de datos, se realizará una validación cruzada *k-folds* puesto que maximiza el uso de los datos disponibles al usar cada observación tanto para entrenamiento como para *test*. Dicho esto, para seleccionar qué modelo es más efectivo, se calcularán los errores RMSE y NDCG para observar la desviación de los *scores* y del ranking, respectivamente. La métrica RMSE (*Root Mean Squared Error*) hace referencia al error medio entre los scores iniciales y los predichos. Una de las grandes ventajas de calcular esta medida es que el resultado está en unidades de la variable de respuesta, facilitando la interpretación. Por otro lado, la métrica NDCG (*Normalized Discounted Cumulative Gain*) sirve para evaluar la calidad de los rankings en base a los *scores* calculados por cada modelo. Esta medida permite comparar la importancia de los países en los rankings y cómo varían de un modelo a otro, siendo la fórmula la siguiente:

$$\text{NDCG} = \frac{\text{DCG}}{\text{IDCG}} \quad \text{donde} \quad \text{CG} = \sum_{i=1}^n \text{rel}_i \quad \text{y} \quad \text{DCG} = \sum_{i=1}^n \frac{\text{rel}_i}{\log_2(i+1)}$$

- rel_i = relevancia de cada *score* en la posición 'i'

La comparación de estos errores en cada uno de los modelos propuestos ayudará a comprobar si existe un modelo con un menor número de variables capaz de predecir con precisión el *score* del Índice del IESE así como evaluar potenciales modelos alternativos que predigan la inversión de *private equity* por país.

5.1. Modelos para predecir los *scores*

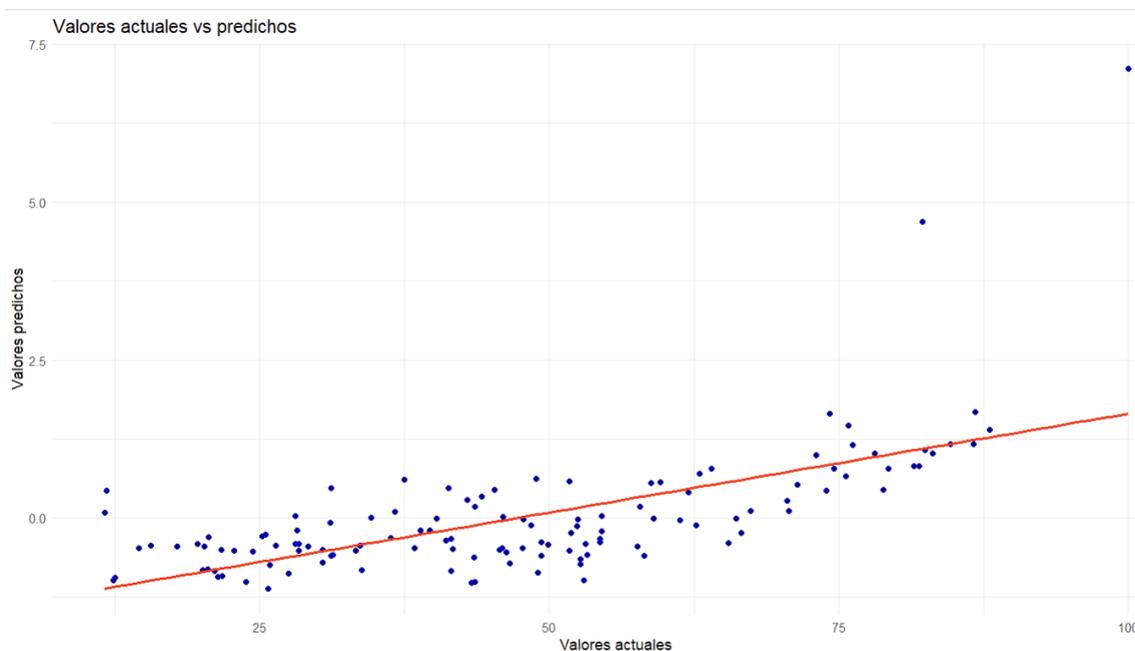
5.1.1. Regresión lineal

En este caso, se realizarán dos modelos de regresión lineal, uno que utilice todas las variables originales para la predicción y otro que se centre en las más significativas, identificadas en el apartado anterior. Cabe mencionar que dada la naturaleza del Índice del IESE, calculado mediante una suma ponderada de valores, la regresión lineal tendrá un mejor potencial de ajustarse de mejor manera a los *scores* iniciales.

a. Modelo de regresión lineal con todas las variables

Se empezará analizando la precisión de un modelo de regresión que incluya todas las variables independientes definidas en el Índice de Atractivo del *Private Equity* con el fin de evaluar cuánto se ajustan las predicciones a los valores originales. En este caso, se observa cómo las 46 variables se ajustan bien al modelo con una variación en el *scoring* muy baja.

Figura 9. Valores predichos con todas las variables vs los valores originales del Índice



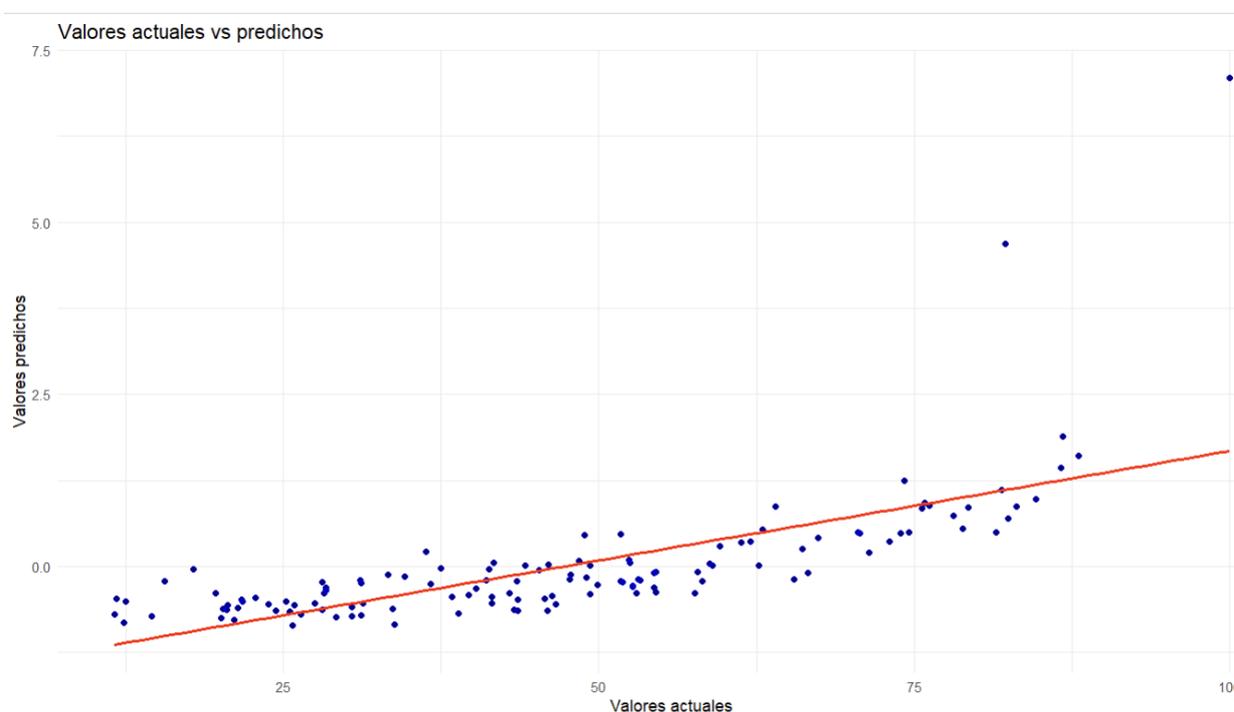
Fuente: Elaboración propia.

Métrica	Resultado
R^2	1.0
RMSE	0.499
NDCG	0.982

b. Modelo de regresión lineal con las variables más correlacionadas

Al seleccionar las 16 variables más correlacionadas del conjunto de datos, se observa cómo, pese a la gran precisión del modelo anterior, la regresión lineal con un menor número de variables obtiene un mejor resultado (RMSE de 0.389 y NDCG de 0.990). Como resultado, se comprueba que, para predecir el *score*, que hace referencia al atractivo de *private equity* por país, es más conveniente usar un menor número de variables independientes.

Figura 10. Valores predichos con las variables más correlacionadas vs los valores calculados del Índice



Fuente: Elaboración propia.

Tipo de error	Resultado
R^2	0.7
RMSE	0.389
NDCG	0.990

5.1.2. Árbol de decisión

En el árbol de decisión generado en este estudio, se aprecia cómo el modelo no es capaz de ajustarse bien a la variación de la variable dependiente. Asimismo, obtiene un RMSE

significativamente mayor al de los otros modelos comparables y relativamente mayor fallo en términos de NDCG.

Tipo de error	Resultado
R ²	0.5
RMSE	0.886
NDCG	0.955

5.1.3. Red neuronal

Al incluir las 16 variables seleccionadas previamente dentro de la red neuronal, se obtienen unos resultados muy positivos: la red explica un 72% de la varianza del *score* por país, se obtiene un error medio bajo y las predicciones del *score* son casi idénticas a las originales.

Tipo de error	Resultado
R ²	0.719
RMSE	0.467
NDCG	0.991

5.1.4. Máquinas de vector soporte

El modelo de SVM resultó ser un gran predictor del *score* del índice, con un coeficiente de determinación de casi 76% y un NDCG de 0.991. El hecho de que en este modelo se obtengan muy buenas predicciones se puede deber a que es un modelo más complejo que una simple regresión lineal o un árbol de decisión, por lo que tiene más probabilidad de modelar las relaciones subyacentes.

Tipo de error	Resultado
R ²	0.756
RMSE	0.427
NDCG	0.991

5.2. Modelos para predecir la inversión de *private equity*

Una vez evaluado cómo se ajustan los distintos tipos de modelos al *scoring* del Índice de Atractivo para el *Private Equity* del IESE, conviene estudiar si estos modelos son capaces de

predecir la inversión de capital de riesgo en cada país. Como se ha comprobado anteriormente, dado que un menor número de variables consigue explicar una gran parte de la varianza de los datos, se usarán los resultados obtenidos del PCA como conjunto de datos. En este caso, dado que se pretenderá calcular índices alternativos, no se calculará el error NDCG para evaluar su dispersión con respecto al ranking del IESE.

5.2.1. Regresión lineal

Pese a que la regresión lineal ha sido un muy buen predictor de cara al score del Índice del IESE, el modelo no es capaz de explicar gran parte de la variabilidad de las inversiones de *private equity* por país (R^2 de 0.474). Este hecho se puede deber a que, dado que los scores se habían calculado a partir de una suma ponderada, la regresión captaba eficientemente la linealidad. Sin embargo, con el cambio de variable dependiente a las inversiones de *private equity*, el modelo puede no captar de forma eficaz características más complejas o no lineales de los datos.

Tipo de error	Resultado
R^2	0.474
RMSE	0.374

5.2.2. Árbol de decisión

En cuanto a la implementación del árbol de decisión como modelo predictivo de las inversiones de capital de riesgo por país, se observa en la memoria que, a través de la validación cruzada, el resultado no es un diagrama de árbol sino un único nodo. Este único nodo no permite ajustar de forma correcta el modelo al conjunto de datos, por lo que habría que analizar las potenciales causas de este resultado.

5.2.3. Red neuronal

Para esta red neuronal, el autor decidió realizar el modelo en el entorno Python para poder usar el paquete *tensorflow*. A través de este, y tras preparar los datos siguiendo lo realizado en los modelos previos (estandarización de los datos y sustitución de los valores omitidos por la media de la variable), se dividió los datos en un conjunto de entrenamiento (80%) y de test (20%). A continuación, se pasó a realizar el modelo de red neuronal formado

por 3 capas de 128, 64 y 32 neuronas, respectivamente, todas con activación ‘relu’ y se aplicó un *learning rate* de 0.01, 100 *epochs* y *early stopping*. Este modelo fue aplicado a dos análisis: (i) se usó el modelo con todas las variables originales y (ii) se realizó PCA y se incluyó en el modelo aquellas más relevantes.

- a. En el primer modelo, que incluía todas las variables originales, se observó que el modelo obtiene un error (o pérdida) se observó que el modelo obtiene un error (o pérdida) de 0.1 en *epoch* 10, pero se obtiene un R^2 de 0.45 y un RMSE de 0.14. Este bajo ajuste a los datos de test puede deberse a la dimensionalidad del conjunto de datos, ya que las variables (46) tienen un gran tamaño en relación al número de observaciones (125). Por ello, el autor busca reducir la dimensionalidad mediante la realización del análisis de componentes principales (PCA).
- b. Tras realizar el PCA, se observa que a partir de la variable número 16 se explica un 85% de la varianza. Como efecto, al seleccionar estas 16 primeras variables y se implementan en la red neuronal, con los mismos hiperparámetros mencionados anteriormente, se alcanza un error de 0.1 en la *epoch* 30. Dicho esto, se obtienen unos resultados mucho más favorables, con un R^2 de 0.77 y un RMSE de 0.09.

Tras realizar ambos modelos, se concluye que, debido a la dimensionalidad del conjunto de datos, una red neuronal que incorpore las variables resultantes de un PCA genera unos mejores resultados y resuelve el problema de *overfitting*.

Tipo de error	Resultado todas variables	Resultado PCA
R^2	0.445	0.774
RMSE	0.138	0.088

5.2.4. Máquinas de vector soporte

Al aplicar un modelo de SVM con la nueva variable dependiente, se observa que el modelo se ajusta relativamente bien a la variabilidad de la misma con un coeficiente de determinación de 0.629. Este mejor desempeño comparado con el modelo de regresión lineal se puede deber a su capacidad para manejar alta dimensionalidad, su robustez ante el *overfitting* y valores atípicos, y su versatilidad para capturar relaciones no lineales a través de funciones kernel.

Tipo de error	Resultado
R^2	0.629
RMSE	0.402

6. Resultados

Los modelos analizados en este Trabajo reflejan que la selección del subconjunto de variables que más correlacionadas están dentro del conjunto de datos genera prácticamente los mismos *scores* que aquellos obtenidos en el Índice de Atractivo del *Private Equity*. Si se compara los resultados obtenidos en los modelos orientados a predecir el *score* original del Índice, se aprecia cómo las predicciones son casi idénticas, con un error NDCG siempre por encima de 0.95 (siendo 1 el valor de máxima similitud). Dentro de los modelos que mejor realizan esta predicción, destacan la regresión lineal, la red neuronal y la máquina de vector soporte, cuyos coeficientes de determinación superan el 0.7, presentan bajos errores de RMSE (entre 0.3 y 0.5) y altos valores de NDCG (0.99).

Con respecto al ranking elaborado a partir de las inversiones de *private equity* por país, resulta relevante recordar que las variables utilizadas para la predicción son producto de un análisis PCA previo. A partir de este, se escogieron las 16 variables que más contribuían a explicar la variabilidad de los datos (86% de la varianza), en línea con aquellas más correlacionadas, como variables independientes en los modelos predictivos analizados. Los resultados cosechados revelan conclusiones similares. En este caso, la red neuronal y la máquina de vector soporte obtuvieron los valores más positivos, explicando una gran proporción de la varianza de la variable dependiente así como errores RSME muy bajos. No obstante, cabe mencionar que entre ambos algoritmos, la red neuronal tuvo un rendimiento mucho mejor, alcanzando un coeficiente de determinación de 0.77 y un error RMSE extremadamente bajo (0.09). Este hecho se puede deber a que dicho modelo es más complejo y elaborado que el SVM, siendo capaz de capturar las relaciones más complejas y no lineales de los datos de las variables dependientes y del valor de la inversión por *private equity* en cada país.

Como consecuencia de lo expuesto, no resulta sorprendente entrever que las predicciones de rankings de países son coherentes y consistentes con los reflejado en el Índice inicial. No obstante, cabe destacar que existen países que han logrado mantener su posición con respecto a los modelos alternativos propuestos (ej. Estados Unidos, Dinamarca) pero existen otros donde los algoritmos alternativos han estimado de forma consistente otros puestos (ej. Bangladesh, Rumanía), reflejando la consideración de relaciones subyacentes entre los datos y potencialmente ofreciendo una mejor alternativa de ranking.

Figura 11. Ranking de países a 2023 basado en el score del Índice del IESE

Country	Rank				Country	Rank			
	Original	Linear Regression	Neural Network	SVM		Original	Linear Regression	Neural Network	SVM
United States	1	1	1	1	Bangladesh	64	50	80	95
United Kingdom	2	3	3	3	Colombia	65	24	101	30
Japan	3	5	8	4	South Africa	66	31	81	31
Canada	4	4	9	5	Jordan	67	53	94	32
Germany	5	7	6	6	Kenya	68	61	110	90
South Korea	6	12	5	8	Nigeria	69	92	25	81
Singapore	7	10	22	16	Belarus	70	56	55	72
China	8	2	2	2	Peru	71	48	52	62
Australia	9	8	10	10	Ukraine	72	81	20	53
France	10	6	7	7	Russian Fedt	73	37	43	23
Netherlands	11	32	33	25	Sri Lanka	74	110	112	105
Norway	12	97	38	102	Argentina	75	114	35	109
Denmark	13	65	61	63	Mauritius	76	99	47	113
Switzerland	14	59	54	40	Jamaica	77	46	19	44
Hong Kong	15	21	21	17	Ghana	78	58	91	57
Finland	16	95	65	76	Tanzania	79	52	102	79
Israel	17	28	29	18	Panama	80	111	41	114
India	18	14	4	9	Serbia	81	94	40	75
Belgium	19	55	116	55	Rwanda	82	54	100	51
Malaysia	20	9	26	13	Namibia	83	113	66	117
Spain	21	19	12	14	Uruguay	84	86	45	84
Italy	22	11	23	11	Georgia	85	93	88	93
Taiwan	23	20	28	15	Ivory Coast	86	105	120	107
Ireland	24	18	32	19	Macedonia	87	78	83	66
Thailand	25	35	34	27	Azerbaijan	88	82	74	97
Saudi Arabia	26	70	11	42	Mongolia	89	22	70	43
Poland	27	47	51	29	Ecuador	90	98	71	104
Sweden	28	33	14	21	Botswana	91	125	67	125
New Zealand	29	29	30	41	Montenegro	92	85	117	91
Czech Republic	30	38	58	33	Bosnia Herz	93	112	18	116
Austria	31	117	36	96	Uganda	94	34	76	49
Estonia	32	72	108	65	Zambia	95	89	86	100
United Arab Emirat	33	107	106	101	Senegal	96	103	68	92
Portugal	34	71	39	73	Malawi	97	39	64	35
Indonesia	35	115	13	89	Algeria	98	116	75	118
Romania	36	87	50	71	Armenia	99	96	73	106
Turkey	37	83	15	56	Dominican R	100	42	48	45
Mexico	38	30	114	22	Moldova	101	62	79	60
Brazil	39	13	24	12	Zimbabwe	102	123	105	122
Philippines	40	23	69	28	Kyrgyzstan	103	68	99	74
Lithuania	41	74	104	61	Bolivia	104	76	49	70
Greece	42	80	98	59	Albania	105	25	17	24
Latvia	43	57	90	52	Lebanon	106	91	37	85
Egypt	44	124	96	123	Cambodia	107	27	124	38
Hungary	45	66	42	58	Guatemala	108	41	60	64
Bulgaria	46	120	115	119	Burkina Fasc	109	49	109	46
Pakistan	47	64	111	82	El Salvador	110	45	72	69
Chile	48	44	78	48	Ethiopia	111	102	62	111
Cyprus	49	118	63	115	Madagascar	112	16	107	20
Morocco	50	109	93	112	Paraguay	113	67	46	78
Luxembourg	51	73	77	88	Cameroon	114	90	121	87
Slovenia	52	100	82	98	Mali	115	75	103	77
Kazakhstan	53	106	53	108	Mozambique	116	63	125	86
Tunisia	54	101	89	94	Nicaragua	117	26	123	36
Oman	55	121	87	124	Benin	118	79	122	80
Kuwait	56	17	57	26	Syria	119	40	84	50
Iceland	57	122	113	121	Lesotho	120	43	44	39
Qatar	58	104	16	103	Angola	121	36	97	54
Malta	59	88	92	110	Burundi	122	15	85	34
Vietnam	60	69	59	67	Mauritania	123	51	119	47
Croatia	61	119	118	120	Chad	124	60	95	37
Slovakia	62	77	56	83	Venezuela	125	108	31	68
Bahrain	63	84	27	99					

Fuente: Elaboración propia

Figura 12. Ranking de países a 2023 basado en las inversiones de private equity

Country	Rank					Country	Rank				
	Original	Linear Regression (All)	Linear Regression	Neural Network	SVM		Original	Linear Regression (All)	Linear Regression	Neural Network	SVM
United States	1	1	1	1	1	Bangladesh	64	88	111	106	101
United Kingdom	2	6	4	4	4	Colombia	65	91	90	96	89
Japan	3	3	3	3	3	South Africa	66	29	47	49	56
Canada	4	7	5	5	5	Jordan	67	34	43	42	42
Germany	5	8	8	8	6	Kenya	68	37	92	85	85
South Korea	6	11	11	9	10	Nigeria	69	122	112	107	106
Singapore	7	10	16	15	17	Belarus	70	104	63	72	71
China	8	2	2	2	2	Peru	71	124	109	113	112
Australia	9	14	7	7	7	Ukraine	72	35	78	91	96
France	10	15	20	14	14	Russian Federatio	73	89	36	40	45
Netherlands	11	16	13	13	11	Sri Lanka	74	67	86	81	78
Norway	12	30	17	19	18	Argentina	75	114	98	101	100
Denmark	13	12	15	17	16	Mauritius	76	28	45	38	38
Switzerland	14	9	10	12	9	Jamaica	77	69	60	63	64
Hong Kong	15	5	9	10	13	Ghana	78	49	75	76	68
Finland	16	20	14	11	12	Tanzania	79	58	84	87	81
Israel	17	18	21	24	26	Panama	80	59	114	117	113
India	18	4	6	6	8	Serbia	81	86	87	94	88
Belgium	19	32	23	23	22	Rwanda	82	22	44	46	43
Malaysia	20	13	27	27	30	Namibia	83	41	69	52	55
Spain	21	26	33	32	29	Uruguay	84	66	32	33	33
Italy	22	40	22	28	27	Georgia	85	46	54	60	50
Taiwan	23	36	19	21	25	Ivory Coast	86	112	124	125	116
Ireland	24	39	26	25	24	Macedonia	87	80	105	102	104
Thailand	25	62	50	53	49	Azerbaijan	88	96	52	47	60
Saudi Arabia	26	47	31	29	32	Mongolia	89	100	97	100	95
Poland	27	72	56	66	59	Ecuador	90	103	117	120	120
Sweden	28	17	12	16	15	Botswana	91	27	68	56	52
New Zealand	29	19	18	18	20	Montenegro	92	53	59	62	65
Czech Republic	30	55	42	43	41	Bosnia Herzegovi	93	106	118	116	119
Austria	31	33	28	22	23	Uganda	94	90	103	92	94
Estonia	32	52	29	31	28	Zambia	95	82	120	122	114
United Arab Emir.	33	24	30	30	31	Senegal	96	93	76	77	77
Portugal	34	48	41	41	40	Malawi	97	74	73	73	69
Indonesia	35	25	38	39	44	Algeria	98	57	79	79	83
Romania	36	101	65	61	61	Armenia	99	43	66	65	63
Turkey	37	38	49	54	54	Dominican Repub	100	76	107	103	98
Mexico	38	81	80	69	86	Moldova	101	116	96	108	103
Brazil	39	60	48	45	47	Zimbabwe	102	78	116	109	122
Philippines	40	44	77	83	82	Kyrgyzstan	103	109	101	98	109
Lithuania	41	70	51	48	46	Bolivia	104	125	125	123	124
Greece	42	68	74	75	72	Albania	105	63	113	114	105
Latvia	43	99	61	59	58	Lebanon	106	64	95	90	93
Egypt	44	73	58	51	48	Cambodia	107	97	110	105	102
Hungary	45	120	81	88	79	Guatemala	108	123	99	95	97
Bulgaria	46	108	72	80	76	Burkina Faso	109	95	88	93	84
Pakistan	47	105	71	71	74	El Salvador	110	117	94	99	90
Chile	48	50	37	37	35	Ethiopia	111	92	91	97	92
Cyprus	49	56	34	44	37	Madagascar	112	118	104	111	115
Morocco	50	61	67	58	62	Paraguay	113	113	122	118	118
Luxembourg	51	23	24	20	21	Cameroon	114	65	102	104	111
Slovenia	52	94	64	64	57	Mali	115	110	108	110	107
Kazakhstan	53	77	70	74	70	Mozambique	116	84	106	115	110
Tunisia	54	102	83	82	75	Nicaragua	117	111	121	119	121
Oman	55	71	40	35	39	Benin	118	75	82	89	87
Kuwait	56	115	55	57	53	Syria	119	83	46	50	67
Iceland	57	21	25	26	19	Lesotho	120	79	62	70	73
Qatar	58	54	35	34	34	Angola	121	85	119	124	117
Malta	59	51	53	55	51	Burundi	122	119	93	86	91
Vietnam	60	87	57	67	66	Mauritania	123	121	123	121	123
Croatia	61	107	100	112	99	Chad	124	31	89	78	108
Slovakia	62	98	85	84	80	Venezuela	125	42	115	68	125
Bahrain	63	45	39	36	36						

Fuente: Elaboración propia

7. Conclusiones

El presente Trabajo busca analizar el atractivo de los países para potenciales inversiones por parte de gestoras de *private equity*. Dada la importancia de conocer el entorno de una posible inversión, se realiza un estudio que sea capaz de cuantificar el atractivo de cada país. Además, resulta de especial importancia puesto que la entrada de capital en una región es crucial a la hora de determinar y fomentar el desarrollo económico de ese país y el bienestar de sus ciudadanos. Como efecto, resulta de especial importancia para aquellos países emergentes o en vías de desarrollo que no cuentan con cobertura en los mercados internacionales y pueden tener el potencial de ofrecer grandes oportunidades de inversión.

Dadas las altas restricciones en materia de costes económicos y de tiempo que padecen los equipos de las gestoras de capital de riesgo, se busca analizar si existe un modelo simplificado (compuesto por un menor número de variables) capaz de predecir los mismos resultados que el Índice de Atractivo de *Private Equity* elaborado por el IESE. Además, plantea la posibilidad de definir modelos predictivos que sean mejores a la hora de calibrar las relaciones subyacentes y complejas entre las distintas variables.

Los resultados obtenidos concuerdan con que el uso de un subconjunto de 16 variables con respecto a las 46 definidas por el Índice del IESE con capaces de estimar con gran precisión el *score* de cada país. Asimismo, durante este Trabajo también se comprueba la eficacia de modelos alternativos para estimar el atractivo de los países en términos de inversión de *private equity*. Los modelos que obtuvieron mejores resultados en ambos objetivos son las redes neuronales y las máquinas de vector soporte, dada su capacidad para recoger las relaciones complejas y no lineales entre las distintas variables. El efecto de plantear esto modelos altamente eficientes en la predicción es que el ranking de países permaneció relativamente parecido al planteado por el Índice del IESE salvo por ciertas particularidades que convendrá indagar más a fondo con el objetivo de descubrir si existen atractivas oportunidades de inversión por parte de *private equities* en esa región.

8. Bibliography

- Annamalah, S. (2023). *Case Study: The Exponential model of China Economy: Recognition based on Contingent Assets*. SEGi University.
- Baan, W., Leung, N., Naumann, I., Pandit, V., & Ramsbottom, O. (2020). *In search of alpha: Updating the playbook for private equity in China*. McKinsey & Company.
- Bain&Company. (2024). *Global Private Equity 2024*. Bain & Company.
- Binfare, M., Brown, G., Ghent, A., Hu, W., Lundblad, C., Maxwell, R., . . . Yi, L. (2022). *Performance Analysis and Attribution with Alternative Investments*. Institute for Private Capital.
- Blanchard, O. (1997). *The Medium Run*. Brookings Papers on Economic Activity.
- Cullen, J., & Gordon, R. (2002). *Taxes and Entrepreneurial Activity: Theory and Evidence for the U.S.* University of Michigan and University of California at San Diego.
- Desai, M., Gompers, P., & Lerner, J. (2006). *Institutions, Capital Constraints and Entrepreneurial Firm Dynamics: Evidence from Europe*. National Bureau of Economic Research.
- Djankov, S., Porta, R. L., Lopez-de-Silanes, F., & Shleifer, A. (2002). *The Regulation of Entry*. *The Quarterly Journal of Economics*.
- Espinosa, P. (2024). *Why invest in private equity?* Moonfare.
- Fang, H., Nofsinger, J., Song, Z., & Wang, S. (2018). *Private equity performance and capital flows: Evidence from China*. In *Emerging Markets Review* (pp. 223-244). Elsevier.
- Feil, C. (2023). *The Untapped Potential of Private Equity in Emerging Markets*. Impact Entrepreneur.
- Fleming, G., Schwienbacher, A., & Cumming, D. (2006). *Legality and Venture Capital Exits*. *Journal of Corporate Finance*.
- Gilson, R., & Black, B. (1998). *Venture Capital and the Structure of Capital Markets: Banks Versus Stock Markets*. *Journal of Financial Economics*.
- Gompers, P., & Kaplan, S. (2022). *Advanced Introduction to Private Equity*. Elgar Advanced Introductions.
- Gompers, P., & Lerner, J. (1998). *What drives venture fundraising?* National Bureau of Economic Research .
- Gompers, P., & Lerner, J. (2000). *Money chasing deals? The impact of funds inflows on the valuation of private equity*. *Journal of Financial Economics*.

- Green, P. (1998). Dimensions of perceived entrepreneurial obstacles. In P. Reynolds, *Frontiers of Entrepreneurship Research* (pp. 48-49). Babson College: Center for Entrepreneurial Studies .
- Groh, A. (2009). *Private Equity in Emerging Markets*. IESE Business School.
- Harris, R., Jenkinson, T., & Kaplan, S. (2013). Private Equity Performance: What Do We Know? *Journal of Finance*, Fama-Miller Working Paper, Chicago Booth Research.
- Higson, C., & Stucke, R. (2012). The Performance of Private Equity. Coller Institute of Private Equity at London Business School.
- Ivashina, V. (2022). *When the Tailwind Stops: The Private Equity Industry in the New Interest Rate Environment*. Centre for Economic Policy Research.
- Johan, S., & Cumming, D. (2005). Regulatory Harmonization and the Development of Private Equity Markets. *Journal of Banking & Finance*.
- Lau, K. (2024). *Investors' Private Equity exposure continues to soar*. Private Equity International.
- McKinsey&Company. (2024). *McKinsey Global Private Markets Review 2024*. McKinsey & Company.
- Morrison, W. (2019). *China's Economic Rise: History, Trends, Challenges, and Implications for the United States*. Congressional Research Service.
- Roe, M. (2004). *Political Determinants of Corporate Governance*. Oxford.
- Romain, A., & Van Pottelsberghe, B. (2004). *The determinants of venture capital: A panel analysis of 16 OECD countries*. Université Libre de Bruxelles.
- Schertler, A. (2003). *Driving Forces of Venture Capital Investments in Europe: A Dynamic Panel Data Analysis*. Kiel Institute for the World Economy.
- Sheyner, D. (2018). *Private Equity Interview Course*. Wall Street Oasis.
- Warren, E. (2021). *Private Equity: By the Numbers*. Senator Elizabeth Warren.

9. Anexos

Anexo 1. Scoring y ranking original del *Venture Capital and Private Equity Attractiveness Index 2023* del IESE

Country	Rank	Score	Country	Rank	Score	Country	Rank	Score
United States	1	100.0	Latvia	43	53.3	Georgia	85	34.6
United Kingdom	2	88.0	Egypt	44	53.1	Ivory Coast	86	33.8
Japan	3	86.8	Hungary	45	53.0	Macedonia	87	33.7
Canada	4	86.6	Bulgaria	46	52.7	Azerbaijan	88	33.3
Germany	5	84.6	Pakistan	47	52.7	Mongolia	89	31.3
Korea, South	6	83.1	Chile	48	52.5	Ecuador	90	31.2
Singapore	7	82.4	Cyprus	49	52.4	Botswana	91	31.2
China	8	82.2	Morocco	50	51.9	Montenegro	92	31.1
Australia	9	81.9	Luxembourg	51	51.7	Bosnia-Herzegovina	93	30.4
France	10	81.5	Slovenia	52	51.7	Uganda	94	30.4
Netherlands	11	79.3	Kazakhstan	53	49.9	Zambia	95	29.2
Norway	12	78.8	Tunisia	54	49.3	Senegal	96	28.4
Denmark	13	78.1	Oman	55	49.3	Malawi	97	28.4
Switzerland	14	76.2	Kuwait	56	49.0	Algeria	98	28.2
Hong Kong	15	75.8	Iceland	57	48.9	Armenia	99	28.1
Finland	16	75.6	Qatar	58	48.4	Dominican Republic	100	28.1
Israel	17	74.6	Malta	59	47.8	Moldova	101	27.5
India	18	74.2	Vietnam	60	47.7	Zimbabwe	102	26.4
Belgium	19	73.9	Croatia	61	46.6	Kyrgyzstan	103	25.9
Malaysia	20	73.0	Slovakia	62	46.3	Bolivia	104	25.7
Spain	21	71.4	Bahrain	63	46.0	Albania	105	25.5
Italy	22	70.7	Bangladesh	64	45.9	Lebanon	106	25.2
Taiwan	23	70.5	Colombia	65	45.7	Cambodia	107	24.4
Ireland	24	67.4	South Africa	66	45.3	Guatemala	108	23.3
Thailand	25	66.6	Jordan	67	44.2	Burkina Faso	109	22.8
Saudi Arabia	26	66.1	Kenya	68	43.6	El Salvador	110	21.8
Poland	27	65.5	Nigeria	69	43.6	Ethiopia	111	21.7
Sweden	28	64.0	Belarus	70	43.5	Madagascar	112	21.4
New Zealand	29	63.0	Peru	71	43.3	Paraguay	113	21.1
Czech Republic	30	62.7	Ukraine	72	42.9	Cameroon	114	20.6
Austria	31	62.0	Russian Federation	73	41.7	Mali	115	20.5
Estonia	32	61.3	Sri Lanka	74	41.5	Mozambique	116	20.2
United Arab Emirates	33	59.6	Argentina	75	41.5	Nicaragua	117	20.1
Portugal	34	59.0	Mauritius	76	41.3	Benin	118	19.6
Indonesia	35	58.8	Jamaica	77	41.1	Syria	119	17.9
Romania	36	58.2	Ghana	78	40.3	Lesotho	120	15.6
Turkey	37	57.8	Tanzania	79	39.7	Angola	121	14.6
Mexico	38	57.6	Panama	80	38.9	Burundi	122	12.5
Brazil	39	54.5	Serbia	81	38.4	Mauritania	123	12.4
Philippines	40	54.5	Rwanda	82	37.5	Chad	124	11.8
Lithuania	41	54.4	Namibia	83	36.7	Venezuela	125	11.6
Greece	42	54.4	Uruguay	84	36.3			

Anexo 2. Hiperparámetros utilizado para realizar la red neuronal en Python

```
model = tf.keras.models.Sequential([
    layers.InputLayer(input_shape=(k,)),
    layers.Dense(128, activation='relu'),
    layers.Dropout(0.2),
    layers.Dense(64, activation='relu'),
    layers.Dropout(0.2),
    layers.Dense(32, activation='relu'),
    layers.Dense(1)
])
```

```
model.compile(optimizer=tf.keras.optimizers.Adam(learning_rate=0.001),
              loss='mean_squared_error',
              metrics=['mean_squared_error', r2])
```

```
history = model.fit(X_train, y_train,
                    epochs=100,
                    validation_split=0.2,
                    verbose=1,
                    callbacks=[early_stopping])
```

Anexo 3. 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, Manuel Conde Escabias, estudiante del Doble Grado de ADE y Business Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "*Private Equity* y el atractivo del *Lower Middle Market* español", 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:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
5. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.

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: 05/06/2024

Firma: _____

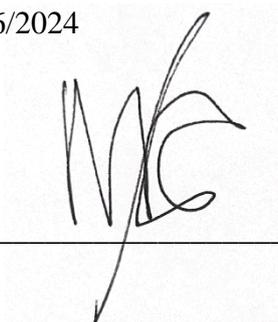
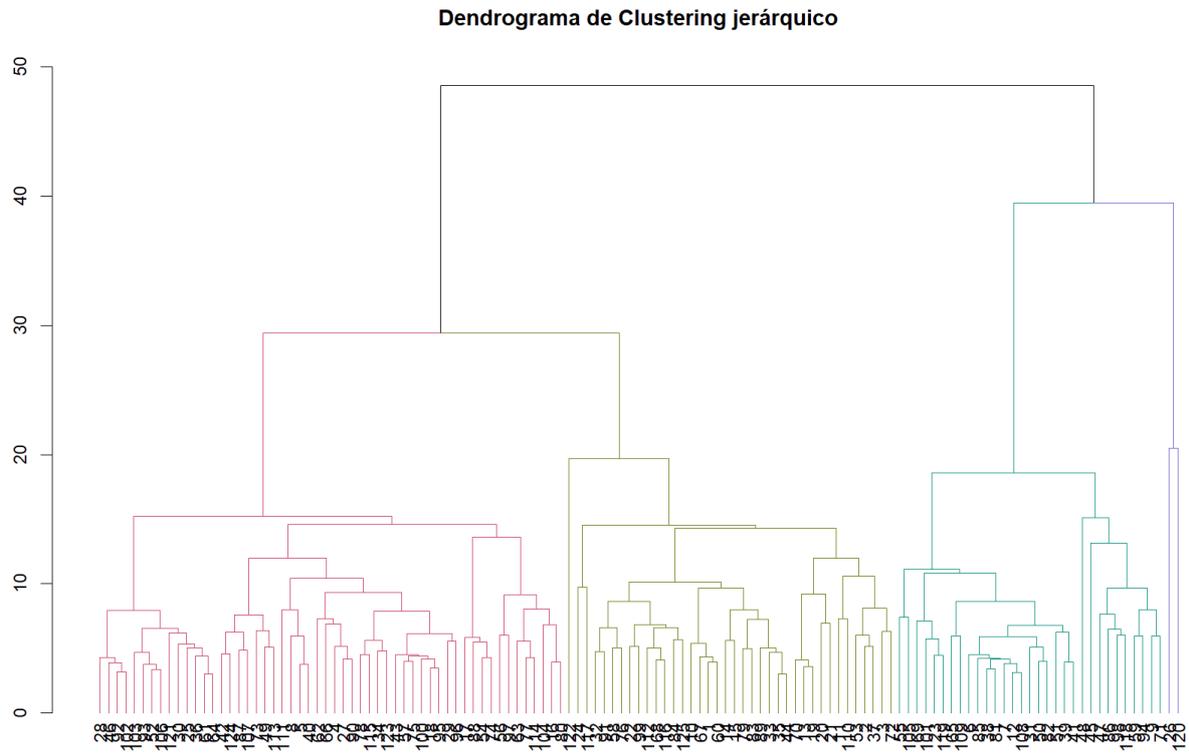


Figura x. Dendrograma de clustering jerárquico



Fuente: Elaboración propia.