



**FACULTAD DE ADMINISTRACIÓN Y DIRECCIÓN DE EMPRESAS**

**IDENTIFICACIÓN Y EVALUACIÓN DE  
EMPRESAS OBJETIVO EN OPERACIONES DE  
LEVERAGED BUYOUT: ANÁLISIS TEÓRICO Y  
DESARROLLO DE UN MODELO DE SCORING  
FINANCIERO.**

**TRABAJO FIN DE GRADO**

Carlota Rodríguez Martín de Eugenio

Clave: 202004544

5º E3-Analytics. Derecho y Business Analytics

Finanzas Corporativas

Tutor: Carlos Bellón Núñez-Mera

Madrid

Junio, 2025

## **RESUMEN**

Este trabajo analiza las características clave que convierten a una empresa en un objetivo atractivo para una operación de adquisición apalancada (LBO), partiendo de una revisión exhaustiva de la literatura académica sobre el tema. A partir de dicha revisión, se identifican las variables financieras y operativas más relevantes asociadas al éxito de estas transacciones, como los flujos de caja libre, el apalancamiento previo, la estabilidad operativa o la valoración relativa. Con base en estas variables, se construye un modelo de scoring implementado en Python, que permite puntuar empresas de una base de datos genérica según su atractivo potencial como targets de LBO. El modelo se estructura en diferentes versiones que permiten tanto una evaluación agregada como una por dimensiones, y puede adaptarse según el perfil del inversor. El trabajo concluye proponiendo mejoras futuras orientadas a su validación empírica y aplicabilidad práctica.

## **PALABRAS CLAVE**

Leveraged buyouts (LBO), adquisiciones apalancadas, empresa objetivo, private equity, flujos de caja libre, modelo de scoring, análisis financiero, Python, selección de targets.

## **ABSTRACT**

This paper analyzes the key characteristics that make a company an attractive target for a leveraged buyout (LBO), based on an exhaustive review of the academic literature on the subject. From this review, the most relevant financial and operational variables associated with the success of these transactions are identified, such as free cash flows, previous leverage, operational stability or relative valuation. Based on these variables, a scoring model implemented in Python is built, which allows scoring companies from a generic database according to their potential attractiveness as LBO targets. The model is structured in different versions that allow both an aggregate and a dimension-based evaluation, and can be adapted according to the investor's profile. The paper concludes by proposing future improvements aimed at its empirical validation and practical applicability.

## **KEY WORDS**

Leveraged buyouts (LBO), target company, private equity, free cash flows, scoring model, financial analysis, Python, target selection.

## INDICE

<b>1. INTRODUCCIÓN Y PLANTEAMIENTO DEL PROBLEMA</b> .....	<b>6</b>
<b>2. MARCO TEÓRICO Y CONCEPTUAL DE LOS LBO</b> .....	<b>8</b>
2.1. DEFINICIÓN Y PRINCIPALES CARACTERÍSTICAS DE UN LBO.....	8
2.2. EVOLUCIÓN HISTÓRICA DE LAS LBO.....	10
2.3. FUENTES DE CREACIÓN DE VALOR EN UN LBO .....	13
2.3.1. <i>Reducción del conflicto de agencia y mejora en la eficiencia operativa</i> .....	13
2.3.2. <i>Optimización de la estructura de capital y beneficios fiscales</i> .....	14
2.3.3. <i>Reestructuración corporativa: enajenación de divisiones o activos no estratégicos</i> .....	15
2.3.4. <i>Mejora en la gobernanza y control más cercano</i> .....	15
2.3.5. <i>Expansión de múltiples y salida rentable</i> .....	16
2.4. TEORÍAS Y EVIDENCIA SOBRE LA SELECCIÓN DE EMPRESAS OBJETIVO EN LBO.....	17
2.4.1. <i>Hipótesis del flujo de caja libre</i> .....	18
2.4.2. <i>Hipótesis de infravaloración y revaluación</i> .....	18
2.4.3. <i>Hipótesis de tamaño y complejidad</i> .....	19
2.4.4. <i>Hipótesis del crecimiento-recursos (mismatch)</i> .....	20
2.4.5. <i>Hipótesis de apalancamiento y capacidad de deuda</i> .....	20
2.4.6. <i>Hipótesis de control y estructura de propiedad</i> .....	21
<b>3. POR QUÉ ESTUDIAR LAS CARACTERÍSTICAS DEL TARGET</b> .....	<b>23</b>
<b>4. CARACTERÍSTICAS DE UNA EMPRESA TARGET IDEAL PARA UN LBO Y SUS VARIABLES CUANTITATIVAS</b> .....	<b>24</b>
4.1. FLUJOS DE CAJA LIBRE ELEVADOS, ESTABLES Y PREDECIBLES.....	24
4.2. CRECIMIENTO MODERADO CON POTENCIAL DE MEJORA .....	25
4.3. BAJO NIVEL DE DEUDA PREVIO Y CAPACIDAD DE ENDEUDAMIENTO. ....	26
4.4. TAMAÑO EMPRESARIAL MEDIO.....	27
4.5. VALORACIÓN ATRACTIVA E INFRAVALORACIÓN RELATIVA. ....	28
4.6. RIESGO FINANCIERO Y OPERATIVO MODERADO.....	29
4.7. RESUMEN DE LAS VARIABLES ESCOGIDAS.....	31
<b>5. MODELO SCORING</b> .....	<b>35</b>
5.1. ORIGEN DE LA BASE DE DATOS.....	35
5.2. SELECCIÓN Y JUSTIFICACIÓN DE VARIABLES. ....	36
5.3. DEPURACIÓN Y CONSTRUCCIÓN DE LA BASE DE DATOS.....	37
5.4. CONSTRUCCIÓN DEL MODELO EN PYTHON.....	39
5.4.1. <i>Filtro opcional por tamaño</i> .....	40
5.4.2. <i>Normalización de variables</i> .....	41
5.4.3. <i>Modelo de scoring sencillo</i> .....	42
5.4.4. <i>Modelo de scoring por dimensiones</i> .....	43
5.5. RESULTADOS Y SALIDA DEL MODELO. ....	44
5.5.1. <i>Resultados sin filtro por tamaño</i> .....	44
5.5.2. <i>Resultados con filtro por tamaño</i> .....	48
<b>6. CONCLUSIÓN</b> .....	<b>52</b>
<b>7. ANEXO 1: VARIABLES NECESARIAS PARA EXPORTAR DESDE SABI</b> .....	<b>54</b>
<b>8. ANEXO 2: MODELO DE PYTHON</b> .....	<b>55</b>
<b>9. BIBLIOGRAFÍA</b> .....	<b>61</b>

## LISTADO DE ABREVIATURAS

Abreviatura	Descripción
EE.UU.	Estados Unidos
Et al.	y otros
IS	Impuesto de Sociedades
IPO	Initial Public Offering
LBOs	Leveraged buyouts
MBO	Management Buyout
NIF	Número de identificación fiscal
OPV	Oferta Pública de Venta
P2P	Private to Public transaction
SPV	Special Purpose Vehicle
ROE	Return on Equity

## 1. INTRODUCCIÓN Y PLANTEAMIENTO DEL PROBLEMA

En la década de 1980 se popularizaron las adquisiciones apalancadas, o, más conocidas como, leveraged buyouts (LBOs), en las que una empresa es adquirida mediante un alto nivel de deuda externa y una porción relativamente pequeña de capital propio por parte de un inversor financiero especializado (Kaplan & Strömberg, 2009). Este tipo de operaciones, formaron parte de la “década de los grandes acuerdos”, en concreto, tuvieron un auge inicial significativo en Estados Unidos durante los años ochenta (Renneboog *et al.*, 2007). Desde entonces, los LBOs han evolucionado y resurgido en diferentes oleadas, incluyendo una ola a fines de los 1990s y mediados de los 2000s, hasta convertirse en una herramienta establecida dentro del panorama de fusiones y adquisiciones corporativas (Kaplan & Strömberg, 2009, p.125). En esencia, como veremos a lo largo del trabajo, el atractivo de un LBO radica en la capacidad de generar elevados rendimientos para los inversores mediante la combinación de financiarse con deuda externa y llevar a cabo mejoras internas en la empresa adquirida (Jensen, 1986).

Sin embargo, no todas las empresas son candidatas adecuadas para una adquisición apalancada. La correcta elección de la empresa objetivo es fundamental para el éxito de la transacción (Sudarsanam *et al.*, 2011). La evidencia empírica muestra una variación considerable en los resultados posteriores: mientras algunas adquisiciones apalancadas logran mejorar significativamente el desempeño operativo y la creación de valor, otras experimentan dificultades financieras o no alcanzan las mejoras esperadas (Kaplan & Stein, 1993). Estas diferencias en resultados suelen atribuirse, en parte, a las características intrínsecas de la empresa objetivo-seleccionada (Cohn *et al.*, 2022). Por ejemplo, una empresa con flujos de caja estables y significativos puede soportar mejor la carga de deuda de un LBO y ofrecer mayores oportunidades de mejora, mientras que una empresa financieramente frágil o con un flujo de caja volátil podría enfrentar riesgos de incumplimiento más altos tras la adquisición apalancada (Renneboog *et al.*, 2007).

En el contexto de este trabajo, nos proponemos abordar la siguiente pregunta clave: **¿Cuáles son las principales cualidades que convierten a una empresa en un objetivo atractivo para una operación de LBO?** Se trata de una pregunta de gran relevancia, tanto desde un enfoque teórico como desde una aplicación práctica.

En primer lugar, desde el punto de vista teórico, analizar las características del target en operaciones de LBO permite contrastar distintas teorías financieras acerca del funcionamiento del mercado del control corporativo, así como comprender cómo se genera valor mediante cambios en las estructuras de propiedad (Jensen, 1986). En esta línea, se han propuesto diversas hipótesis que tratan de explicar qué

tipo de firmas resultan más propensas a ser adquiridas mediante un LBO, como la hipótesis del flujo de caja libre, la hipótesis de la infrautilización de recursos o la hipótesis de infravaloración de la empresa (Palepu, 1986). De tal forma que, a lo largo de este trabajo, se busca validar estas teorías y profundizar en el funcionamiento las operaciones de LBO.

En segundo lugar, desde el punto de vista práctico, comprender el perfil y saber identificar correctamente la empresa objetivo en una operación de LBO es esencial para los distintos agentes del mercado, como pueden ser los inversores de capital privado, los bancos de inversión y los distintos equipos directivos. Además, entender correctamente las características de las empresas objetivo y como consecuencia llevar a cabo una selección adecuada, incrementa la probabilidad de éxito de la inversión y reduce el riesgo de incurrir en problemas financieros posteriores (Sudarsanam *et al.*, 2011). En otras palabras, la construcción de un modelo eficaz de selección de targets podría servir como una buena herramienta para filtrar empresas con una alta probabilidad de ser adquiridas con éxito mediante un LBO, optimizando así el proceso de *screening* de oportunidades de inversión (Palepu, 1986).

El objetivo de este trabajo es doble. Primero, se pretende realizar una revisión exhaustiva de la literatura académica con el fin de identificar las características clave que definen a las empresas que han sido objetivos exitosos en LBOs. En segundo lugar, a partir del marco teórico derivado de dicha revisión, se desarrollará un modelo de *scoring* financiero implementado en Python, que permita evaluar y puntuar empresas en función de su atractivo como posibles objetivos de LBO. En la revisión de literatura identificaremos factores financieros, operativos y de gobierno corporativo que diversos estudios han vinculado con la probabilidad de que una empresa sea adquirida en un LBO o con el desempeño posterior de esas operaciones (Renneboog *et al.*, 2007). Posteriormente, se justificará la inclusión de cada variable en el modelo propuesto a partir de la evidencia teórica y empírica recopilada, estableciendo así una conexión clara entre la fundamentación conceptual y su aplicación práctica.

Finalmente, a partir de la base de datos encontrada y el código de Python, se elaborará un modelo cuantitativo y automatizado de evaluación financiera, que nos permitirá identificar y clasificar empresas en función de su potencial atractivo para ser adquiridas mediante una operación de compra apalancada.

## 2. MARCO TEÓRICO Y CONCEPTUAL DE LOS LBO

### 2.1. Definición y principales características de un LBO

Un LBO es una operación de adquisición de una empresa en la cual el comprador financia una parte sustancial del precio de compra mediante deuda, la cual suele estar garantizada por los propios activos y flujos de caja de la empresa adquirida. Esta financiación apalancada se complementa con una aportación de capital significativamente menor por parte del adquirente (Kaplan & Strömberg, 2009).

En términos prácticos, en un LBO típico la estructura de capital de la empresa resultante tras la operación queda altamente apalancada con la deuda representando habitualmente entre un 60 % y un 70 % del precio de compra. El porcentaje restante suele ser financiado mediante una aportación de capital por parte del adquirente, que por lo general suele ser un fondo de *private equity*. Asimismo, es frecuente que el equipo directivo de la empresa adquirida también financie una parte a través de mecanismos como el de coinversión, *managment rollover equity* o un *management buyout* (MBO) (Rosenbaum & Pearl, 2009).

La arquitectura de la deuda empleada en un LBO puede alcanzar un grado considerable de sofisticación en función del tamaño de la operación, la calidad crediticia del *target* y las condiciones del mercado de deuda. En este sentido, suele estructurarse en varios niveles con diferentes prioridades de pago y perfiles de riesgo: desde deuda *senior* garantizada por activos, hasta tramos de deuda subordinada, *mezzanine* e, incluso, en ciertos casos, nos podemos encontrar con instrumentos híbridos. Posteriormente, la deuda asumida será atendida con los flujos de caja generados por la propia empresa adquirida y, en algunas ocasiones, mediante la venta de activos no esenciales (*asset divestitures*) (Rosenbaum & Pearl, 2009). Como consecuencia del espacio limitado de este trabajo, esta descripción ofrece solo una visión general; en la práctica, el diseño del apalancamiento puede variar significativamente según las características específicas de cada operación

En las operaciones de LBO, la entidad que adquiere la empresa objetivo suele ser un fondo de inversión especializado, conocido como fondo de *private equity*. Estos fondos emplean un vehículo específico, *special purpose vehicle* (SPV) para llevar a cabo la adquisición de la empresa objetivo. Así, la SPV actúa como sociedad instrumental encargada de formalizar la oferta de la empresa objetivo (Kaplan & Strömberg, 2009). El fondo de *private equity* suele ser quien aporta la parte correspondiente al capital propio y, una vez completada la transacción, suele asumir un papel activo en la gestión estratégica y operativa de la empresa adquirida. Su enfoque se centra particularmente en la implementación de

mejoras operativas destinadas a incrementar la rentabilidad y el valor de la empresa durante un horizonte de inversión de medio plazo (Cohn, Hotchkiss & Towery, 2022). Al finalizar este periodo de tenencia, el fondo busca una vía de salida que le permita cristalizar la rentabilidad esperada.

Las vías de salida más habituales en un LBO incluyen: (i) la salida a bolsa mediante una oferta pública de venta (OPV), (ii) la venta estratégica a otra empresa del sector (*trade sale*), (iii) la venta secundaria a otro fondo de capital privado (*secondary buyout*), (iv) la liquidación o quiebra (*bankruptcy or receivership*) y, en algunos casos, (v) la simple retención del activo en cartera por un tiempo prolongado si no se dan condiciones favorables de mercado (Sudarsanam, Wright, & Huang, 2011).

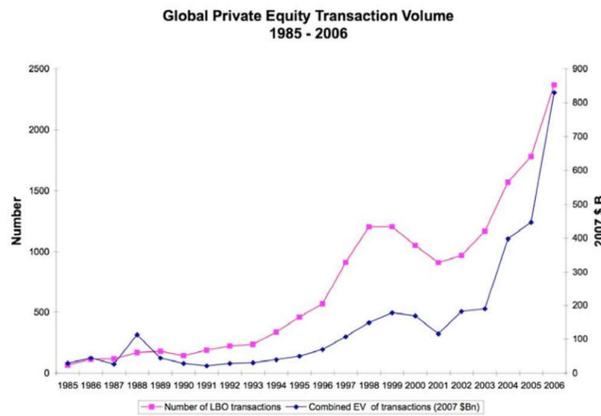
La motivación para emplear un alto apalancamiento radica en parte en el efecto amplificador de los retornos para los accionistas: al financiar la mayor parte de la adquisición con deuda, cualquier aumento en el valor de la empresa *post-LBO* se traduce en un rendimiento multiplicado sobre la pequeña porción de capital invertido (Berk & DeMarzo, 2020). No obstante, este elevado nivel de apalancamiento implica un riesgo financiero considerable. La empresa adquirida asume compromisos relevantes de pago de intereses y amortización del capital, por lo que un rendimiento operativo inferior al previsto puede derivar rápidamente en situaciones de tensión financiera o, en casos más extremos, en incumplimientos de pago (*default*) (Andrade & Kaplan, 1998). Por ello, los inversores que llevan a cabo LBOs son extremadamente cuidadosos cuando analizan la capacidad de la empresa objetivo para generar flujos de caja suficientes y estables que soporten la carga de la deuda propuesta (Opler & Titman, 1993).

En resumen, un LBO se define por su estructura financiera altamente apalancada y por la toma de control de una empresa con el fin de reestructurarla o gestionarla activamente para incrementar su valor. Para que esta estrategia sea efectiva, deben de cumplirse ciertas condiciones fundamentales: (i) que la empresa adquirida genere flujos de caja suficientes y estables para hacer frente al servicio de la deuda, (ii) que existan oportunidades de mejora operativa o de revalorización bajo una nueva gestión y estructura de propiedad, y (iii) que el precio de adquisición permita, tras el efecto del apalancamiento, obtener retornos atractivos para los nuevos propietarios (Kaplan & Stein, 1993). Estas condiciones nos llevan de nuevo a preguntarnos sobre qué rasgos debe tener la empresa objetivo para cumplir con dichas condiciones. Por tanto, en los siguientes apartados abordaremos en profundidad este asunto.

## 2.2. Evolución histórica de las LBO

Los LBO han pasado por diversas etapas históricas claramente diferenciadas, cada una de ellas marcada por el contexto económico y financiero imperante, así como por las enseñanzas aprendidas de experiencias pasadas. No obstante, debido a las limitaciones de espacio, a continuación, se ofrece únicamente un repaso breve de dichas etapas, destacando sus rasgos más representativos.

El crecimiento global de este fenómeno puede observarse de manera ilustrativa en la Figura 1 que muestra la evolución del número y volumen de transacciones de LBO patrocinadas por fondos de *private equity* a nivel mundial. Como podemos observar en la Figura 1, entre 1970 y junio de 2007 se registraron 17.171 operaciones de este tipo, con un volumen agregado que refleja la expansión progresiva del mercado en oleadas sucesivas.



**Figura 1: Transacciones a nivel mundial de LBO de 1985 a 2006.**

*Fuente: Kaplan y Strömberg (2008).*

La primera gran ola de LBOs ocurrió en los años ochenta, particularmente en EE.UU. Esta fue impulsada por un entorno de desregulación financiera, y especialmente, por la innovación en los mercados de deuda. Una fuente clave de financiación fueron los bonos de alto rendimiento comúnmente conocidos como *junk bonds*, desarrollados por Michael Milken, cuya flexibilidad y disponibilidad permitieron estructurar operaciones de gran envergadura con altos niveles de apalancamiento (Singh, 2020). Durante esta etapa se llevaron a cabo algunas de las adquisiciones apalancadas más emblemáticas, como la compra de RJR Nabisco<sup>1</sup> en 1988 liderada por Kohlberg Kravis Roberts (KKR),

<sup>1</sup> La adquisición apalancada (LBO) de RJR Nabisco, ejecutada en 1988 por Kohlberg Kravis Roberts & Co. (KKR), fue la operación más grande de su época, alcanzando un valor récord de aproximadamente 25.000 millones de dólares. Esta transacción se convirtió en el símbolo por excelencia de los excesos financieros que caracterizaron el auge de las compras apalancadas durante la década de 1980, reflejando tanto

considerada en su momento la mayor adquisición apalancada de la historia y símbolo de los excesos financieros de la década. Esta operación no solo evidenció la capacidad de los fondos para movilizar volúmenes masivos de capital mediante deuda, sino también los riesgos estructurales y los conflictos de interés que surgen en las adquisiciones apalancadas de gran escala (Burrough & Helyar, 1990, p.52).

Kaplan y Stein (1993) documentan que, a medida que avanzaba la década de 1980, la creciente competencia por cerrar acuerdos provocó un aumento progresivo en los precios de adquisición, así como el uso de estructuras de capital cada vez más agresivas, caracterizadas por un elevado apalancamiento. Esta dinámica, impulsada por la presión por desplegar capital y obtener retornos atractivos, contribuyó hacia finales de la década a un incremento significativo en el número de fracasos de LBO, al poner en riesgo la sostenibilidad financiera de muchas operaciones. De hecho, tras la crisis crediticia de comienzos de los años noventa, un número significativo de adquisiciones apalancadas realizadas durante la etapa anterior entraron en dificultades financieras. En este contexto, Andrade y Kaplan (1998) muestran que, si bien la mayoría de estas operaciones lograron evitar el colapso, aproximadamente un tercio enfrentó algún grado de *distress* financiero. Este dato subraya los riesgos inherentes a estructuras de capital excesivamente apalancadas, especialmente en entornos marcados por la contracción del crédito y la desaceleración económica.

La segunda ola cobró fuerza a finales de los 90 y durante la década de los 2000, expandiéndose más allá de Estados Unidos hacia Europa y otros mercados desarrollados (Wright et al., 2006). Este periodo, conocido también como “*the age of mega-buyouts*”, estuvo marcado por un auge impulsado por la institucionalización del capital privado, que disponía entonces de fondos significativamente mayores para invertir. También se vieron favorecidos por un contexto caracterizado por tipos de interés bajos, menor presión fiscal, controles accionariales menos estrictos y una regulación más favorable (Singh, 2020; Kaplan & Strömberg, 2009). Asimismo, aunque las lecciones derivadas de la ola anterior promovieron en algunos casos una mayor cautela, el mercado de LBOs volvió a alcanzar niveles récord en vísperas de la crisis financiera global. Un ejemplo emblemático fue la adquisición apalancada de TXU Corp. en 2007 por aproximadamente 45.000 millones de dólares, liderada por KKR y TPG, considerada en su momento la mayor operación de este tipo en la historia (Bocconi Students Investment Club [BSIC], 2023).

La crisis de 2008 supuso otro enfriamiento drástico de este mercado: el crédito se contrajo y muchas empresas adquiridas poco antes vieron caer su desempeño, dificultando el servicio de la deuda

---

la agresividad financiera como la ambición estratégica que definieron aquel periodo en el mercado corporativo estadounidense (Burrough & Helyar, 1990, p. 52)

adquirida. No obstante, estudios de esta época sugieren que, pese al entorno adverso, las adquisiciones apalancadas realizadas a mediados de los 2000 generaron incrementos de valor operativos para las empresas, aunque menores que en los 80 (Guo *et al.*, 2011).

Durante la década de 2010 e inicios de 2020, los LBO continuaron siendo una estrategia clave dentro del capital privado, aunque con adaptaciones significativas. Entre los cambios más destacados se encuentra la creciente adopción de estrategias *buy-and-build*, mediante las cuales los fondos adquieren una empresa plataforma y, durante el período de tenencia, llevan a cabo adquisiciones sucesivas de compañías más pequeñas con el fin de conformar grupos empresariales de mayor tamaño y aprovechar economías de escala (Hammer *et al.*, 2022). Asimismo, en operaciones de gran envergadura, se consolidó el uso de los *club deals*: estructuras en las que varios fondos de *private equity* se asocian para ejecutar adquisiciones de tamaño excepcional, compartiendo tanto el capital invertido como los riesgos inherentes a la transacción (Officer *et al.*, 2010).

La prolongada disponibilidad de financiación barata tras la crisis financiera de 2008, impulsada por políticas monetarias expansivas, favoreció un renovado auge de las operaciones de *leveraged buyout* (LBO) durante la segunda mitad de la década de 2010 (Axelson *et al.*, 2013). En este contexto, los autores documentan que el nivel de apalancamiento en los LBO más recientes está determinado en mayor medida por las condiciones del mercado crediticio que por las características específicas de las empresas objetivo. En entornos donde el crédito es abundante y su coste es bajo, los fondos de *private equity* tienden a estructurar transacciones con elevados niveles de deuda de manera generalizada y con escasa distinción según el perfil financiero de las compañías adquiridas. Este hallazgo pone de relieve que, si bien la selección del target sigue siendo un factor clave, variables macroeconómicas como la disponibilidad y el coste del dinero pueden incidir de forma determinante tanto en la estructura financiera de la operación como en el precio de adquisición.

A lo largo de las distintas etapas históricas, los LBO han sido objeto tanto de elogios como de críticas. Por un lado, se ha resaltado su capacidad para introducir mecanismos que corrigen ineficiencias en la gestión corporativa, alinean los intereses de los directivos con los de los accionistas y fomentan mejoras operativas significativas tras los procesos de reestructuración (Jensen, 1989). Sin embargo, diversos autores han advertido sobre los efectos adversos asociados al elevado nivel de endeudamiento característico de estas operaciones, al aumentar el riesgo de insolvencia y generar posibles impactos negativos sobre otros *stakeholders*, como empleados o acreedores comerciales. Asimismo, se ha expresado preocupación por conductas oportunistas por parte de los nuevos propietarios, tales como la extracción anticipada de dividendos o el cobro de comisiones de gestión excesivas, o prácticas que

pueden comprometer la sostenibilidad financiera de la empresa a largo plazo (Shleifer & Summers, 1988). En cualquier caso, la evidencia empírica señala que los resultados de los LBOs son heterogéneos y dependen tanto de las condiciones específicas de cada transacción como de las características intrínsecas de la empresa objetivo, lo que subraya la relevancia de comprender en profundidad el perfil del *target* adecuado para maximizar las probabilidades de éxito.

### **2.3. Fuentes de creación de valor en un LBO**

Lejos de ser una mera construcción financiera, los LBOs se conciben como intervenciones estratégicas capaces de transformar el desempeño de una empresa. La creación de valor en este contexto no proviene únicamente del apalancamiento financiero, sino de un conjunto de palancas operativas, fiscales y organizativas que, correctamente implementadas, pueden traducirse en retornos extraordinarios. En este apartado, exploraremos las principales fuentes de valor asociadas a las adquisiciones apalancadas.

#### *2.3.1. Reducción del conflicto de agencia y mejora en la eficiencia operativa.*

Jensen (1986) propuso la hipótesis del flujo de caja libre, según la cual las empresas con escasa supervisión y elevados excedentes de liquidez, es decir, flujos de caja disponibles una vez cubiertas todas las oportunidades de inversión con valor presente neto positivo, tienden a destinar esos recursos a proyectos poco rentables o retener el dinero dentro de la empresa en lugar de distribuirlo como dividendos. Este comportamiento responde al interés de los directivos por expandir el tamaño o la visibilidad de la empresa bajo su control, aun cuando ello no maximice el valor para los accionistas, generando así los denominados conflictos de agencia entre los directivos y los accionistas (Jensen, 1986).

En este sentido, las adquisiciones apalancadas se presentan como una herramienta eficaz para mitigar dichos conflictos: al imponer una elevada carga de deuda, se obliga a la empresa a canalizar los flujos de caja hacia el servicio de la deuda, lo cual funciona como un mecanismo disciplinario que restringe el uso discrecional del efectivo por parte de la dirección (Jensen, 1986).

Adicionalmente, los LBO suelen ir acompañados de esquemas de incentivos alineados con la creación de valor, ya que los nuevos propietarios, generalmente los fondos de *private equity*, otorgan participaciones accionariales significativas o paquetes retributivos basados en el desempeño del equipo gestor (Liebeskind *et al.*, 1992). En línea con esta perspectiva, diversos estudios empíricos, recogidos por Liebeskind *et al.* (1992), evidencian mejoras sustanciales en el desempeño tras un *management buyout* (MBO). En particular, Smith (1990) documenta un incremento en los retornos operativos antes de impuestos, atribuible en gran medida a una gestión más eficiente del capital de trabajo. Asimismo,

se observaron mejoras en la productividad total de los factores, lo que refuerza la tesis de que las adquisiciones apalancadas pueden corregir ineficiencias estructurales y operativas preexistentes en las empresas objetivo (Liebeskind et al., 1992, p. 74).

### 2.3.2. Optimización de la estructura de capital y beneficios fiscales.

Al incrementar el apalancamiento financiero, las operaciones de LBO aprovechan una de las principales ventajas fiscales asociadas al uso de deuda: la deducibilidad de los intereses. En numerosos sistemas tributarios, como los de España o Estados Unidos, los pagos de intereses se consideran gasto financiero deducible del impuesto sobre sociedades. Esto genera escudos fiscales que permiten reducir la carga tributaria efectiva, incrementando así el valor de la empresa al elevar el flujo de caja neto disponible para los accionistas (Modigliani & Miller, 1963). En consecuencia, la deuda se convierte en una herramienta fundamental para maximizar la rentabilidad neta una vez pagados los impuestos.

Durante el auge de los grandes LBO en Estados Unidos en la década de 1980, una proporción considerable del valor creado se atribuía precisamente a este ahorro fiscal. Kaplan (1989) estimó que, en su muestra de *management buyouts* de empresas cotizadas, el valor presente de los escudos fiscales generados por la deuda oscilaba entre el 21 % y el 143 % de la prima pagada a los antiguos accionistas, lo que demuestra que el componente fiscal podía no solo representar una parte sustancial del valor generado, sino incluso superar el precio pagado por la adquisición. De forma complementaria, Newbould et al. (1992, p. 54) analizaron 42 LBOs y concluyeron que, antes de la entrada en vigor de la *Tax Reform Act* de 1986, el ahorro fiscal derivado de la deducibilidad de intereses permitía, bajo un horizonte de cinco años, reducir impuestos en un importe equivalente al 48,4 % de la prima pagada en la adquisición. Sin embargo, tras dicha reforma, que redujo el tipo impositivo e introdujo restricciones a la deducción, este beneficio estimado se redujo al 21,8 %. Estos hallazgos reflejan cómo el marco legal puede condicionar de forma decisiva el atractivo fiscal del apalancamiento en los LBO.

En el caso de España, aunque los intereses de la deuda siguen siendo deducibles en el Impuesto sobre Sociedades, esta deducción está sujeta a límites cuantitativos. Concretamente, la normativa vigente (Ley 27/2014, art. 16) establece una limitación general del 30 % del beneficio operativo (EBITDA) para los gastos financieros netos, con un mínimo deducible adicional de 1 millón de euros anuales. La trasposición de la Directiva ATAD (Directiva (UE) 2016/1164 del Consejo de 12 de julio de 2016) ha reforzado este marco restrictivo, reduciendo parcialmente el atractivo fiscal del endeudamiento excesivo. No obstante, el escudo fiscal continúa siendo un componente clave en la estructura de los LBO, especialmente en aquellas operaciones diseñadas para optimizar el retorno sobre el capital invertido (ROE) una vez considerados los impuestos.

Además del componente fiscal, la estructura de capital post-LBO suele estar cuidadosamente diseñada para optimizar el coste medio de capital. Los fondos de *private equity* tienden a reemplazar fuentes de financiación más costosas, como el *equity* dilutivo o la deuda subordinada, por tramos de deuda estructurados de forma estratégica. El objetivo es alcanzar un nivel de apalancamiento que se considere óptimo desde el punto de vista financiero y operativo, sin comprometer la viabilidad de la empresa ni incrementar excesivamente el riesgo de insolvencia (Roden & Lewellen, 1995).

### 2.3.3. Reestructuración corporativa: enajenación de divisiones o activos no estratégicos.

Una vez completada la adquisición, muchos LBOs conllevan procesos de reestructuración corporativa orientados a optimizar la eficiencia operativa y estratégica de la empresa adquirida. Entre las acciones más frecuentes se encuentra la enajenación de divisiones no estratégicas o activos prescindibles, con un doble propósito: por un lado, generar ingresos extraordinarios que suelen destinarse a la amortización anticipada de la deuda contraída en la operación; y por otro, reenfocar la compañía en aquellas unidades de negocio más rentables o con mayor potencial de crecimiento (Liebeskind et al., 1992). Esta estrategia permite concentrar los recursos financieros y directivos en actividades verdaderamente rentables, eliminando así áreas de negocio que absorben capital o atención sin generar valor proporcional. De esta forma, se busca mejorar tanto la rentabilidad operativa como la sostenibilidad del negocio en el largo plazo.

Adicionalmente, cuando el LBO implica la salida de la empresa del mercado bursátil (*public-to-private transaction* o P2P), el cambio en la estructura de propiedad otorga una mayor flexibilidad al equipo gestor. Al convertirse en una entidad privada, la empresa queda exenta de las presiones del mercado de capitales y del escrutinio asociado al cumplimiento de objetivos trimestrales, típicos de las sociedades cotizadas. Esta liberación del foco cortoplacista facilita la adopción de decisiones estratégicas con un horizonte temporal más amplio, como la racionalización de la cartera de negocios o la inversión en sectores clave. En este sentido, Wright et al. (2007), señalan que las transacciones P2P permiten a los fondos de *private equity* alinear mejor los incentivos entre propiedad y gestión, captar el valor latente en compañías infravaloradas por el mercado y ejecutar transformaciones estratégicas sin la presión constante de los accionistas. Así, la reestructuración tras un LBO no solo tiene una dimensión financiera, sino que también puede servir como catalizador para una redefinición profunda del modelo de negocio.

### 2.3.4. Mejora en la gobernanza y control más cercano.

Uno de los efectos más relevantes tras un LBO es la transformación en la estructura de gobernanza corporativa. La propiedad, que anteriormente podía estar ampliamente distribuida entre accionistas

públicos, pasa a concentrarse en el fondo de private equity que lidera la operación y, en muchos casos, también en el equipo directivo, mediante esquemas de coinversión o planes de incentivos basados en acciones (Sudarsanam, Wright & Huang, 2011). Esta concentración accionarial contrasta con la estructura típica de las empresas cotizadas, donde la dispersión accionarial puede generar problemas de control y reducir los incentivos para una supervisión activa (Jensen & Meckling, 1976).

Desde el punto de vista de la teoría de la agencia, esta nueva configuración facilita la implementación de mecanismos de control más eficaces y orientados a la maximización del valor para los accionistas. De acuerdo con Jensen y Meckling (1976), a medida que los directivos incrementan su participación en el capital de la empresa, sus intereses tienden a alinearse más estrechamente con los de los accionistas, reduciendo los costes de agencia y favoreciendo decisiones que maximizan el valor económico de la firma.

Asimismo, es habitual que los nuevos propietarios reconfiguren el consejo de administración, incorporando representantes del fondo de *private equity* e instaurando sistemas de control estratégico más rigurosos. Esta supervisión activa suele acompañarse de la definición de metas operativas y financieras concretas, lo que permite una mayor disciplina en la gestión (Kaplan & Strömberg, 2009). En este contexto, el consejo actúa no solo como órgano de supervisión, sino también como promotor de decisiones orientadas a la eficiencia y al rendimiento del capital invertido.

Múltiples estudios han evidenciado que las empresas bajo el control de fondos de *private equity*, adoptan estructuras de gobierno corporativo más sólidas, caracterizadas por una mayor alineación de incentivos, una toma de decisiones más racional y estructuras organizativas más eficientes (Cohn, Hotchkiss & Towery, 2022). En suma, la mejora en la gobernanza constituye uno de los pilares fundamentales del valor añadido que los fondos de *private equity* buscan generar tras una adquisición apalancada.

### *2.3.5. Expansión de múltiplos y salida rentable.*

Una de las fuentes clave de retorno en las operaciones de LBO es la posibilidad de vender la empresa, al finalizar el período de tenencia, por un múltiplo superior al que se pagó en la adquisición. Esta expansión de múltiplo puede derivarse tanto de factores internos, como el crecimiento de ingresos, la mejora en la rentabilidad o el reposicionamiento estratégico de la empresa, como de factores externos favorables, tales como la reducción de las tasas de descuento o un entorno de mercado más optimista donde las valoraciones sectoriales se eleven (Kaplan & Strömberg, 2009).

Más allá de depender exclusivamente de la evolución del mercado, los fondos de *private equity* suelen trabajar activamente en transformar la compañía para que, al momento de su desinversión, resulte atractiva a un perfil de comprador que la valore por encima del precio inicial. Si bien contar con la expansión de múltiplos es arriesgado, en la práctica ha contribuido a los retornos de muchas operaciones exitosas, especialmente en épocas de mercados alcistas (Kaplan & Strömberg, 2009).

En este sentido, Hammer et al. (2022) destacan el papel fundamental del denominado *multiple arbitrage* dentro de las estrategias *buy-and-build*: al escalar la empresa mediante adquisiciones selectivas, los fondos logran crear plataformas consolidadas que acceden a múltiplos de salida superiores, incluso sin necesidad de sinergias operativas inmediatas. Esta dinámica permite beneficiarse de una reevaluación estructural del activo, especialmente cuando el tamaño, la diversificación o la posición competitiva mejoran sustancialmente. No obstante, aunque la expansión de múltiplos representa una fuente relevante de creación de valor, también conlleva riesgos importantes, particularmente en contextos de corrección de mercado o deterioro macroeconómico. Axelson, Jenkinson, Strömberg y Weisbach (2013) señalan que, durante periodos de crédito abundante, tanto el nivel de endeudamiento como los precios pagados en las operaciones de LBO pueden estar influenciados por condiciones externas temporales. Esto incrementa el riesgo de que se produzca una reducción posterior en los múltiplos de salida.

En síntesis, la creación de valor en los LBOs se fundamenta en una combinación de palancas: la corrección de ineficiencias internas, el aprovechamiento de escudos fiscales, la reestructuración operativa y financiera, la mejora de la gobernanza corporativa y, potencialmente, la expansión de múltiplos en el momento de la salida.

#### **2.4. Teorías y evidencia sobre la selección de empresas objetivo en LBO**

La literatura académica ha investigado de forma sistemática los factores que explican por qué determinadas empresas son más propensas a convertirse en objetivos de adquisiciones apalancadas. Estas investigaciones han dado lugar a una serie de hipótesis basadas en las características estructurales, financieras y organizativas de las firmas objetivo. Muchas de estas hipótesis tienen su origen en estudios generales sobre el mercado de control corporativo (M&A), pero han sido adaptadas al contexto específico de los LBOs, donde el apalancamiento financiero, la reestructuración operativa y la reconfiguración de incentivos juegan un rol central. A continuación, se presentan las principales hipótesis y hallazgos empíricos que sustentan el análisis del presente trabajo.

#### 2.4.1. Hipótesis del flujo de caja libre.

Planteada por Jensen (1986), esta hipótesis sostiene que las empresas con excedentes elevados de caja y escasas oportunidades de crecimiento rentables tienden a incurrir en sobreinversión o a financiar proyectos de baja rentabilidad, generando así costes de agencia. Estas empresas se convierten en candidatas naturales para una adquisición apalancada, ya que el endeudamiento forzado tras una LBO limita el uso discrecional de los recursos y obliga a priorizar decisiones orientadas a la creación de valor actuando, por tanto, como un mecanismo de control externo. Lehn y Poulsen (1989) aportan evidencia a favor de la hipótesis del flujo de caja libre al mostrar que las empresas objeto de LBOs en los años ochenta presentaban, en promedio, mayores flujos de caja libres y menores tasas de crecimiento que sus pares no adquiridas. Como recogen Roden y Lewellen (1995), “*the evidence is consistent with the hypothesis that going-private transactions are more likely to occur in firms with high levels of free cash flow and limited investment opportunities*” (Lehn & Poulsen, 1989, citado en Roden & Lewellen, 1995, p. 78).

Sin embargo, investigaciones posteriores han matizado esta visión. Renneboog, Simons y Wright (2007), analizando el contexto británico, no hallan una relación significativa entre LBOs y niveles inusualmente altos de flujo de caja libre, señalando que la infravaloración bursátil previa fue un factor más determinante. Esto sugiere que la validez de la hipótesis del flujo de caja libre está condicionada por el entorno de mercado (Renneboog et al., 2007).

#### 2.4.2. Hipótesis de infravaloración y revaluación.

Más allá de su influencia incidental en determinadas operaciones, la infravaloración bursátil ha sido planteada en la literatura como un criterio autónomo de selección de empresas objetivo en LBOs. La lógica subyacente es sencilla: adquirir una compañía “barata” cuya cotización en el mercado no refleja adecuadamente su valor intrínseco o el potencial de revalorización bajo una nueva estructura de propiedad y gestión.

Palepu (1986) formalizó esta hipótesis en su modelo de predicción de adquisiciones, evidenciando que las empresas con múltiplos bajos de *market-to-book* (M/B) y *price-to-earnings* (P/E) presentaban mayor probabilidad de ser adquiridas. Esta relación sugiere que los compradores identifican oportunidades de generar valor a partir de activos infravalorados por el mercado, ya sea por ineficiencias operativas, desalineación de incentivos o baja visibilidad entre inversores.

Consistente con esto, Renneboog *et al.* (2007) encontraron en el contexto del mercado británico que las empresas objeto de LBO presentaban valoraciones bursátiles significativamente bajas en relación con

sus fundamentales. Además, observaron que cuanto mayor era el grado de infravaloración previo a la transacción, mayor era la prima obtenida por los inversores al momento del LBO. Estos hallazgos refuerzan la idea de que la infravaloración no solo actúa como un criterio de selección, sino también como una fuente directa de rentabilidad: permite al comprador capturar la diferencia entre el precio de adquisición y el valor potencial que puede desbloquearse mediante una gestión más eficiente o una estructura de propiedad más alineada.

Por tanto, los indicadores de valoración relativa, como los múltiplos M/B y P/E, se convierten en variables clave dentro de cualquier modelo de identificación de objetivos potenciales para una LBO. Sin embargo, cabe destacar que obtener estos indicadores puede resultar complejo, especialmente cuando se analizan empresas no cotizadas o de menor tamaño, debido a la falta de información pública sobre su valor de mercado.

#### *2.4.3. Hipótesis de tamaño y complejidad:*

La hipótesis de tamaño y complejidad sugiere que existe una relación inversa entre el tamaño de una empresa y su probabilidad de ser adquirida mediante un LBO. Palepu (1986) argumenta que las empresas de gran tamaño tienden a ser menos propensas a ser adquiridas debido a los desafíos que plantean en términos de financiación, integración y gestión, así como por la existencia de estructuras más sofisticadas de defensa frente a adquisiciones hostiles.

En el contexto específico de los LBOs, esta relación adquiere especial relevancia. Las empresas medianas se consideran candidatas óptimas para este tipo de transacciones, ya que su escala permite estructurar financieramente la operación de forma viable sin requerir volúmenes de deuda desproporcionados, y al mismo tiempo ofrecen márgenes relevantes de mejora operativa (Renneboog et al., 2007). Por otro lado, las empresas demasiado pequeñas pueden carecer del atractivo económico suficiente o de escala para justificar los costes fijos asociados a una operación apalancada.

Además, las empresas más pequeñas tienden a recibir menor cobertura y presentan niveles inferiores de liquidez en el mercado bursátil, lo que puede contribuir a su infravaloración relativa (Brar et al., 2009). Este fenómeno refuerza la idea de que el tamaño no solo afecta la viabilidad financiera de un LBO, sino también su potencial de generación de valor.

En consecuencia, el tamaño intermedio de una empresa suele considerarse una característica favorable en la selección de objetivos para un LBO. No obstante, su efecto puede verse condicionado por otros factores, como el nivel de apalancamiento previo, la estructura de propiedad o las oportunidades de reestructuración. Por ello, el tamaño debe interpretarse como un determinante relevante, pero no

aislado, dentro del conjunto de variables que configuran el perfil atractivo de una empresa *target* en este tipo de operaciones.

#### 2.4.4. Hipótesis del crecimiento-recursos (*mismatch*).

Esta hipótesis sugiere que las empresas con desequilibrio entre sus oportunidades de crecimiento y los recursos disponibles son empresas objetivo. Específicamente, Palepu (1986) indica que tanto empresas de bajo crecimiento, pero con abundantes recursos (exceso de liquidez o activos infrautilizados), como empresas de alto crecimiento, pero con recursos limitados (falta de capital para invertir), podrían ser objetivos atractivos (Palepu, 1986). En el primer caso, el LBO puede aportar disciplina y reorientar recursos ociosos; en el segundo, un fondo de *private equity* podría aportar el capital y la gestión necesaria para explotar plenamente las oportunidades de crecimiento, monetizando así ese potencial. Cohn et al. (2022), en un estudio de empresas privadas adquiridas por fondos, hallan evidencia de esto: identifican que los compradores de *private equity* se enfocan en dos perfiles aparentemente opuestos de rentabilidad – empresas en el quintil más bajo de rentabilidad (posibles “*turnarounds*”) y empresas en el quintil más alto de rentabilidad (posibles “*plataformas de crecimiento*”) – mientras que las de rentabilidad media son menos propensas a ser adquiridas (Cohn et al., 2022). Esto concuerda con la hipótesis de crecimiento-recursos: en ambos extremos hay un desajuste que el cambio de control como consecuencia de un LBO puede corregir.

#### 2.4.5. Hipótesis de apalancamiento y capacidad de deuda:

Dado el papel central que desempeña la financiación vía deuda en los LBOs, la estructura de capital previa de la empresa objetivo adquiere una relevancia crucial en el proceso de selección. En particular, las compañías con un bajo nivel de endeudamiento previo resultan especialmente atractivas para los fondos de *private equity*, ya que presentan una mayor capacidad de apalancamiento (*debt capacity*) sin incurrir en un riesgo excesivo de insolvencia. Además, un bajo apalancamiento inicial suele implicar la existencia de un escudo fiscal infrautilizado, lo que permite optimizar la estructura fiscal de la operación una vez ejecutado el LBO (Renneboog et al., 2007).

Roden y Lewellen (1995) aportan evidencia empírica en esta línea, al observar que, en las operaciones de LBO llevadas a cabo en Estados Unidos durante los años ochenta, la proporción de la transacción financiada mediante deuda guardaba una relación inversa con el nivel de endeudamiento previo de la empresa objetivo. Asimismo, encontraron una relación positiva entre el uso intensivo de deuda y la estabilidad de los flujos de caja, lo que sugiere que los inversores valoran no solo una baja carga financiera previa, sino también la capacidad de la empresa para generar ingresos recurrentes y previsibles que permitan atender al servicio de la deuda.

En consecuencia, los fondos de *private equity* tienden a favorecer empresas con bajo endeudamiento y alta cobertura de intereses, ya que ello proporciona un margen financiero amplio para estructurar la operación sin comprometer la viabilidad futura de la empresa. Esta hipótesis complementa otras variables de selección, como la rentabilidad, la liquidez o la gobernanza, al enfocarse específicamente en la sostenibilidad del apalancamiento post-adquisición y en el aprovechamiento de los beneficios fiscales asociados al uso intensivo de deuda.

#### 2.4.6. *Hipótesis de control y estructura de propiedad:*

Por último, la configuración previa de la propiedad y el gobierno corporativo influye de forma decisiva en la viabilidad y rentabilidad de una operación de leveraged buyout (LBO). Según Renneboog, Simons y Wright (2007), las empresas públicas con una estructura accionarial dispersa, es decir, sin accionistas dominantes ni participación significativa de inversores institucionales, presentan mayores márgenes de mejora tras ser adquiridas, debido a la falta de un control efectivo previo. En estas situaciones, los incentivos para una gestión eficiente suelen estar debilitados, lo que abre espacio para crear valor mediante una reestructuración del control.

Los mismos autores encuentran que cuanto menor es la participación accionarial del equipo directivo antes del LBO, mayores son las primas y mejoras de valor obtenidas tras la operación. Este hallazgo respalda la hipótesis de realineamiento de incentivos: al otorgar al equipo gestor una participación accionarial significativa tras el LBO, se produce una convergencia entre los intereses de los directivos y los nuevos propietarios, lo que favorece decisiones orientadas a maximizar el valor.

Por el contrario, la presencia previa de inversores institucionales u otros accionistas activos se asocia con retornos post-LBO más reducidos. Esto podría explicarse por el hecho de que estos actores ya ejercen presión sobre la gestión en favor de la eficiencia, limitando así el margen de mejora adicional que un LBO puede capturar.

El análisis de la literatura especializada muestra que no existe un perfil único de empresa objetivo para un LBO, sino un conjunto de características que, en diferentes combinaciones, incrementan la probabilidad de ser seleccionada para este tipo de transacción. Las hipótesis revisadas permiten identificar patrones recurrentes en operaciones exitosas: exceso de liquidez no canalizado hacia crecimiento, infravaloración bursátil, tamaño intermedio, desajuste entre recursos y oportunidades, bajo endeudamiento y estructuras de control difusas.

Estas variables actúan de forma interrelacionada y definen un perfil integral de *target* sobre el cual los fondos de *private equity* pueden aplicar sus palancas de creación de valor. Comprender estas hipótesis

resulta fundamental para diseñar modelos predictivos rigurosos y eficaces de selección de *targets* en el contexto de adquisiciones apalancadas.

### 3. POR QUÉ ESTUDIAR LAS CARACTERÍSTICAS DEL TARGET

Analizar las características de la empresa objetivo en un LBO es fundamental por varias razones. En primer lugar, la correcta selección del *target* es uno de los factores más determinantes en el éxito de una inversión apalancada. Tanto es así, que Jenkinson y Sousa (2015) afirman que incluso un equipo gestor motivado y una impecable ejecución posterior a la adquisición difícilmente podrá compensar la compra de una empresa con problemas estructurales insalvables o con características incompatibles con una alta nivel de endeudamiento. Un *target* mal analizado puede aumentar significativamente el riesgo de quiebra o la necesidad de una reestructuración forzada (Sudarsanam *et al.*, 2011).

En segundo lugar, desde una perspectiva puramente teórica, estudiar las características de los *targets* permite constatar hipótesis y teorías clásicas de las finanzas corporativas. En este sentido, las adquisiciones apalancadas son a menudo consideradas “laboratorios naturales” para teorías de agencia y disciplina (Jensen, 1989). En este sentido, nuestro trabajo se fundamenta en gran parte por la literatura de predicción de objetivos de adquisición iniciada por (Palepu, 1986) y continuada por muchos otros autores quienes la extienden específicamente al subgrupo de adquisiciones apalancadas.

En tercer lugar, existe una motivación práctica y metodológica: la posibilidad de construir un modelo cuantitativo implementado en Python que sea capaz de filtrar una base de datos de empresas y señalar aquellas con una mayor probabilidad de ser objeto de una compra apalancada. Este herramienta es de gran utilidad para que los bancos de inversión, fondos de *private equity*, y analistas busátiles puedan hacer una primera criba del universo de empresas, analizando únicamente aquellas empresas con mayor *fit* para una transacción apalancada (Saada, 2021). De tal forma que los fondos de *private equity* pueden enfocar sus esfuerzos de *due diligence*, los analistas bursátiles prever qué compañías podrían recibir ofertas de compra apalancada; incluso directivos de empresas podrían evaluar si su empresa podría estar en la mira de un LBO y tomar las medidas oportunas (Maloney *et al.*, 1993).

En conclusión, estudiar las características de los potenciales *targets* es importante porque determina en gran medida: el éxito de la operación contrasta y enriquece teorías financieras, y permite desarrollar modelos predictivos útiles. Por tanto, en el siguiente apartado trataremos de sintetizar el perfil de la empresa objetivo idea para una LBO según la literatura, sirviendo de puente entre la teoría expuesta anteriormente y la elaboración del modelo de *scoring*.

#### **4. CARACTERÍSTICAS DE UNA EMPRESA TARGET IDEAL PARA UN LBO Y SUS VARIABLES CUANTITATIVAS**

A partir del marco teórico revisado en los apartados anteriores, es posible delinear el perfil de características que configuran a una empresa como objetivo ideal para una adquisición apalancada (LBO). Aunque no todas las operaciones exitosas cumplen estrictamente con todos estos criterios, como bien hemos podido ver, la literatura académica identifica un conjunto de rasgos recurrentes que, en combinación, incrementan la probabilidad de éxito en este tipo de transacciones.

Este perfil no debe entenderse como una condición excluyente, sino como una guía estructurada basada en patrones empíricos. De hecho, muchas adquisiciones rentables se han llevado a cabo sobre empresas que cumplían parcialmente estas condiciones. Las características más relevantes pueden agruparse en torno a las siguientes seis dimensiones.

##### **4.1. Flujos de caja libre elevados, estables y predecibles.**

Uno de los atributos más consistentemente citados en la literatura sobre empresas objetivo en operaciones de LBO es la capacidad de generar flujos de caja libres significativos, estables y predecibles. Este rasgo combina un buen nivel de rentabilidad operativa con una baja intensidad de capital, de manera que una porción considerable del EBITDA se convierte en efectivo disponible para cubrir obligaciones financieras (Jensen, 1986).

Desde una perspectiva práctica, esta característica es crucial. Tras un LBO, la empresa adquirida debe hacer frente a cargas financieras considerables, derivadas principalmente del pago de intereses y amortización de la deuda utilizada para financiar la adquisición. Por tanto, disponer de flujos de caja elevados y constantes no solo garantiza la capacidad de servicio de la deuda, sino que también puede permitir su amortización anticipada, generando un margen adicional para distribuir dividendos o realizar nuevas inversiones (Opler & Titman, 1993). En este sentido, son especialmente atractivas las empresas que, si bien pueden operar en sectores considerados poco dinámicos, generan caja de forma consistente y requieren bajos niveles de reinversión para mantener su actividad (Baker & Montgomery, 1994).

La cuantificación de esta característica se realiza mediante indicadores financieros que miden tanto la generación de efectivo como su estabilidad en el tiempo. Entre las variables más utilizadas se encuentran:

- *EBITDA y flujo de caja libre (FCF)*: Indicadores que permiten estimar la capacidad de generación de caja operativa. Su relación con las ventas (FCF/ventas) proporciona una medida de eficiencia en la conversión de ingresos en efectivo disponible (Renneboog et al., 2007).
- *Variabilidad histórica del flujo de caja*: La estabilidad del flujo es tan importante como su nivel absoluto. Empresas con ingresos altamente volátiles, especialmente en sectores cíclicos o dependientes de factores externos como precios de *commodities*, presentan un mayor riesgo de impago en periodos de contracción. Para evaluar la estabilidad, se suele emplear la desviación estándar del EBITDA o del flujo de caja operativo a lo largo de varios ejercicios. Cuanto menor sea dicha desviación, mayor será la predictibilidad de los flujos (Roden & Lewellen, 1995).

En consecuencia, el candidato ideal desde esta perspectiva presenta un alto margen EBITDA, baja intensidad de capital y baja variabilidad de resultados.

#### **4.2. Crecimiento moderado con potencial de mejora.**

Aunque pueda parecer contraintuitivo frente a las inversiones tradicionales orientadas a sectores de alto crecimiento, la literatura especializada sostiene que el perfil de crecimiento más atractivo para un LBO no es el exponencial, sino el moderado pero mejorable. Las empresas que experimentan un crecimiento muy acelerado suelen requerir continuas inyecciones de capital para financiar su expansión, lo cual es más compatible con estructuras de financiación basadas en *equity*. Además, su valoración depende en gran medida de expectativas a largo plazo más inciertas, lo que dificulta el enfoque característico de los LBOs, centrado en retornos relativamente predecibles dentro de un horizonte de cinco a siete años (Mehran & Peristiani, 2010).

En cambio, las empresas en fases de madurez con un crecimiento orgánico positivo, pero no explosivo, se consideran candidatas más adecuadas. Estas firmas suelen generar excedentes de caja suficientes para hacer frente al servicio de la deuda, y al mismo tiempo ofrecen oportunidades de mejora bajo una nueva estructura de propiedad y gestión (Palepu, 1986). En este sentido, Mehran y Peristiani (2010) destacan que el target ideal presenta una tasa de crecimiento alineada o ligeramente inferior a la del PIB o al promedio de su sector, lo que indica la existencia de una “brecha de eficiencia”. Esta brecha representa el margen potencial que puede capturarse mediante una gestión más agresiva, una asignación más eficiente de recursos o una estrategia comercial más eficaz.

Para cuantificar esta característica, se emplean distintas métricas:

- *Tasa de crecimiento compuesta (CAGR)* de ventas, activos o EBITDA en los últimos 5 años, como indicadores de crecimiento sostenido pero no excesivo.

- *Variación porcentual histórica de activos, ventas o número de empleados*, como en el estudio de Roden y Lewellen (1995), que usan estos indicadores para construir una variable de crecimiento (GROWTH) representativa del perfil típico de los objetivos LBO.
- *Ratio market-to-book (M/B)*, como proxy de las expectativas de crecimiento implícitas en la valoración de mercado. Un valor bajo o intermedio en este indicador puede sugerir que el mercado no reconoce del todo el potencial de la empresa, lo cual deja margen para que un nuevo propietario capture valor mediante estrategias de reactivación del crecimiento (Roden & Lewellen, 1995).

En resumen, la empresa *target* ideal desde la perspectiva del crecimiento no es aquella que se expande rápidamente e implica un alto riesgo, sino aquella que muestra crecimiento moderado, con capacidad de generación de caja y con margen de mejora operativo o estratégico. En palabras de Ambrose y Megginson (1992), se trata de empresas cuyos mercados principales no están saturados ni en declive, y que ofrecen una base sólida sobre la cual implementar mejoras que aceleren su expansión futura bajo la propiedad de un fondo de private equity.

#### **4.3. Bajo nivel de deuda previo y capacidad de endeudamiento.**

Otra característica esencial de una empresa objetivo en una operación de LBO es que presente un bajo nivel de endeudamiento previo. Esta condición permite disponer de un amplio margen para estructurar financiación vía deuda en la adquisición, maximizando los beneficios derivados del escudo fiscal de los intereses sin incurrir en riesgos excesivos de insolvencia (Renneboog et al., 2007). En cambio, una empresa altamente apalancada ofrece escaso espacio para añadir deuda adicional sin comprometer su estabilidad financiera o violar cláusulas contractuales. Asimismo, un bajo endeudamiento previo suele estar asociado a un mayor pago de impuestos corporativos, lo que incrementa el valor del escudo fiscal potencial (Newbould et al., 1992).

Para cuantificar esta condición, se emplean diversos indicadores financieros:

- *Ratios de apalancamiento*, como Deuda/Activos Totales o Deuda/Patrimonio Neto (Debt-to-Equity), reflejan la carga financiera inicial de la empresa. Un valor bajo indica que la firma tiene margen para asumir mayor apalancamiento sin comprometer su solvencia.
- *Deuda/EBITDA*, que compara la deuda total con la capacidad anual de generación de beneficios antes de intereses, impuestos, depreciaciones y amortizaciones. Una proporción baja sugiere que la empresa puede asumir niveles adicionales de deuda hasta alcanzar múltiplos típicos en estructuras LBO (por ejemplo, entre 4x y 6x EBITDA).

- *Cobertura de intereses (EBIT/Intereses)*, que mide la capacidad de la empresa para atender los pagos de intereses con sus beneficios operativos. Un índice alto indica holgura financiera para absorber mayores costes financieros derivados del nuevo apalancamiento (Roden & Lewellen, 1995).

Roden y Lewellen (1995) encuentran evidencia empírica robusta en este sentido: la proporción de deuda en los LBO está inversamente correlacionada con el nivel de apalancamiento inicial del objetivo, y directamente relacionada con la estabilidad de sus flujos operativos.

Por último, la calidad del activo también incide en la capacidad de endeudamiento. En particular, una elevada proporción de activos tangibles (como inmuebles, maquinaria o equipos) respecto al total de activos facilita el acceso al crédito, ya que estos activos pueden servir como garantía ante los acreedores. Stulz y Johnson (1985) sostienen que una mayor tangibilidad de activos constituye un proxy efectivo de la capacidad de respaldo para nueva deuda.

En conjunto, una empresa con bajo endeudamiento previo, alta cobertura de intereses, baja relación Deuda/EBITDA y un volumen relevante de activos tangibles representa un candidato óptimo desde la perspectiva de estructuración financiera en un LBO.

#### **4.4. Tamaño empresarial medio.**

El tamaño moderado de la empresa objetivo es otro atributo clave en el perfil ideal para una adquisición apalancada (LBO), ya que incide tanto en la viabilidad financiera de la operación como en su ejecución práctica. Las empresas de tamaño medio ofrecen una escala suficiente para generar flujos de caja relevantes, al tiempo que presentan menor complejidad estructural y organizativa que las grandes corporaciones, lo que facilita tanto su análisis como su integración operativa tras la adquisición

Brar et al. (2009) encuentran que las empresas medianas presentan una mayor probabilidad de ser adquiridas, debido a que permiten una mejor justificación de los costes fijos asociados a la transacción, como los relacionados con el proceso de due diligence o los honorarios legales. Además, su dimensión facilita la estructuración de la financiación, haciendo posible acceder a deuda bancaria sin requerir consorcios complejos (*club deals*) ni emisiones de deuda sindicada de gran escala (Wright et al., 2006).

En esta línea, Palepu (1986) documenta una relación negativa entre el tamaño de la empresa, medido por sus ventas o activos, y su probabilidad de ser adquirida, apoyando la hipótesis de que las grandes corporaciones son menos susceptibles a adquisiciones, ya sea por su coste elevado, su complejidad organizativa o por disponer de defensas más sólidas contra movimientos hostiles.

Desde la óptica de los fondos de *private equity*, los objetivos de tamaño intermedio encajan mejor con los volúmenes de inversión típicos de sus fondos, así como con estructuras de deuda manejables a través de un número limitado de entidades financieras (Wright et al., 2006). En cambio, las operaciones sobre empresas de gran escala, conocidas como mega-LBOs, suelen requerir múltiples fondos en formato club deal, lo que incrementa la complejidad de gobernanza y reduce la flexibilidad estratégica.

Para cuantificar el tamaño empresarial, se emplean medidas directas de escala como:

- *Ingresos anuales (ventas netas)*
- *Total de activos*
- *Capitalización de mercado, en el caso de empresas cotizadas*
- *Número de empleados*

Con frecuencia, se utiliza el logaritmo natural de estas variables para permitir comparaciones más proporcionadas entre empresas de diferentes sectores o regiones (Roden & Lewellen, 1995).

En resumen, el target ideal en un LBO es una empresa de tamaño medio dentro de su industria: lo suficientemente grande como para generar flujos de caja estables y justificar la operación, pero no tan grande como para dificultar su adquisición o requerir estructuras de financiación complejas.

#### **4.5. Valoración atractiva e infravaloración relativa.**

Una de las condiciones más valoradas por los compradores en una operación de leveraged buyout (LBO) es que la empresa objetivo se encuentre a un precio razonable, o preferiblemente infravalorado respecto a sus fundamentales. En términos prácticos, esto se traduce en la existencia de múltiplos bursátiles bajos, tales como el EV/EBITDA, el P/E o el market-to-book. Cuanto menor es la valoración inicial de la compañía, mayor es el potencial de revalorización futura y, por tanto, mayor la oportunidad de capturar retornos atractivos en el momento de la desinversión.

Renneboog et al. (2007) encontraron una relación positiva entre la infravaloración de mercado previa al LBO y las ganancias generadas por los fondos de *private equity*. Esta infravaloración puede deberse, entre otros factores, a una brecha de información entre el mercado y la dirección de la empresa, donde esta última puede conocer capacidades internas, márgenes de mejora u oportunidades estratégicas no reflejadas en el precio de cotización. En tales casos, la dirección podría verse motivada a llevar a cabo un *management buyout* (MBO) con el apoyo de un fondo, con el fin de monetizar ese potencial oculto (Lowenstein, 1985).

Otros estudios también sugieren que un historial reciente de bajo rendimiento bursátil; por ejemplo, un desempeño inferior al del índice de referencia; puede funcionar como señal de infravaloración, atrayendo la atención de compradores que perciben una oportunidad de arbitraje de valor (Powell & Yawson, 2005). Asimismo, un ratio P/B (Precio/Valor en Libros) inferior a 1 puede indicar la existencia de activos subutilizados o subvalorados que podrían reactivarse o venderse bajo una nueva propiedad (Scellato & Ughetto, 2013).

Desde una perspectiva cuantitativa, los múltiplos de valoración más comúnmente utilizados para identificar infravaloración son:

- **Precio/Beneficio (P/E):** Mide cuántas veces el mercado paga por las ganancias de la empresa. Un P/E bajo en comparación con empresas comparables del sector sugiere un posible descuento de valoración.
- **Precio/Valor en Libros (P/B) o Market-to-Book:** Indica cuánto valora el mercado a la empresa en relación con su patrimonio neto contable. Un valor bajo puede señalar activos infravalorados o un modelo de negocio con potencial no reconocido.
- **Valor Empresa/EBITDA (EV/EBITDA):** Es uno de los múltiplos más usados en fusiones y adquisiciones. Un EV/EBITDA por debajo del promedio de la industria sugiere que la empresa ofrece más flujo operativo por unidad de inversión, lo cual es especialmente atractivo para operaciones LBO centradas en la generación de caja.

Sudarsanam et al. (2011) y otros estudios han documentado que las empresas que fueron objeto de *buyouts* presentaban, en promedio, múltiplos significativamente más bajos en estos indicadores en la fecha previa al anuncio, lo que confirma que la infravaloración relativa es una constante en el perfil objetivo.

En resumen, el *target* ideal desde el punto de vista de la valoración es una empresa que presente múltiplos bursátiles bajos en comparación con sus pares, lo cual indica una oportunidad de mejora en su valoración mediante reestructuración operativa, cambios estratégicos o simplemente una mejor comunicación con el mercado.

#### **4.6. Riesgo financiero y operativo moderado**

Finalmente, otra característica esencial de una empresa objetivo en un LBO exitoso es que presente un riesgo financiero y operativo moderado. Si bien existen casos documentados de *buyouts* exitosos sobre compañías en dificultades —conocidos como *turnarounds*—, estadísticamente la mayoría de los LBOs

se enfocan en empresas financieramente sanas y estables. Esto se debe a que la alta carga de deuda posterior al *buyout* deja poco margen de maniobra para afrontar crisis preexistentes (Sudarsanam et al., 2011).

De hecho, Sudarsanam et al. (2011) estudiaron cómo el riesgo de quiebra del objetivo, medido por indicadores como el Z-score de Altman antes de la adquisición, influye en el desempeño del LBO. Sus resultados revelaron que las empresas con mayor riesgo de insolvencia previa tienden a registrar peores resultados post-LBO y mayores tasas de fracaso en la salida. En consecuencia, los targets más habituales son empresas que ya cuentan con niveles de liquidez, cobertura de intereses y apalancamiento relativamente sólidos antes de la operación, de manera que la nueva deuda no las empuje inmediatamente a una zona de estrés financiero.

En cuanto al riesgo operativo, se prefieren empresas con ingresos y costes relativamente estables. Un negocio con alta volatilidad operativa es más vulnerable a shocks del entorno, lo que podría comprometer su capacidad de atender los compromisos financieros derivados del LBO. Por ello, se valoran modelos de negocio con ingresos recurrentes y bajo nivel de variabilidad en los resultados.

Para cuantificar y controlar estos riesgos, se emplean las siguientes métricas:

- **Riesgo de mercado (sistemático):** Se evalúa mediante el beta apalancado ( $\beta$ ) de la acción. Una beta baja o cercana a 1 indica que la empresa es menos sensible a los movimientos del mercado y, por tanto, menos volátil. En un LBO, donde la capacidad de cumplir obligaciones financieras es crítica, un beta moderado es preferible. Además, se analiza la volatilidad histórica de los retornos accionarios, medida a través de la desviación estándar de las rentabilidades diarias o mensuales, como proxy de la estabilidad general del valor de mercado (Officer et al., 2010).
- **Riesgo operativo específico:** Se emplean medidas de variabilidad de los resultados operativos, como la desviación estándar del EBITDA, del margen EBITDA o del flujo de caja operativo a lo largo de varios años (por ejemplo, 5 años). Roden & Lewellen (1995) utilizan específicamente la desviación estándar del EBITD (EBIT + depreciación) para captar la variabilidad de ingresos, donde un valor bajo indica mayor estabilidad y menor riesgo operativo.
- **Riesgo financiero (riesgo de insolvencia):** Se utilizan indicadores como el Z-score de Altman, que combina distintas variables contables para estimar la probabilidad de quiebra. Un valor de Z-score dentro de la “zona segura” sugiere una situación financiera sólida. Asimismo, se puede

incorporar el índice de cobertura de intereses (EBIT/Intereses), que mide la capacidad actual de la empresa para afrontar pagos financieros, siendo un valor alto indicativo de holgura.

En resumen, el perfil óptimo de riesgo en un LBO exige un equilibrio: la empresa no debe estar en situación de *distress* financiero, pero tampoco ser excesivamente conservadora o desaprovechar capacidad de apalancamiento. Un riesgo financiero y operativo moderado asegura que la compañía pueda absorber el endeudamiento adicional sin comprometer su viabilidad y maximiza las probabilidades de éxito de la operación.

En conclusión, la selección efectiva de una empresa objetivo para una operación de *leveraged buyout* (LBO) se basa en la combinación e interrelación de una serie de características clave. Estas incluyen: alta generación y estabilidad de flujo de caja libre, crecimiento moderado, pero con potencial de mejora, bajo nivel de endeudamiento previo, tamaño empresarial medio, valoración atractiva e indicios de infravaloración, estructura accionarial dispersa con margen para optimizar la gobernanza, y un perfil de riesgo financiero y operativo controlado. Cada una de estas dimensiones puede capturarse mediante variables financieras específicas, lo que permite construir una base cuantitativa sólida. Esta base no solo facilita la evaluación individual de empresas, sino que también sirve como fundamento para el desarrollo de modelos predictivos rigurosos, capaces de identificar de manera sistemática candidatos ideales para transacciones LBO.

#### **4.7. Resumen de las variables escogidas**

La siguiente tabla recoge las principales variables financieras consideradas a lo largo del trabajo. Para cada variable se especifica su fórmula o forma de cálculo. Es importante señalar que algunas de las variables identificadas en la literatura no pudieron incluirse en el modelo de scoring por limitaciones prácticas, como la falta de datos de mercado para empresas no cotizadas. Aun así, se incluyen en esta sección por su relevancia conceptual y su potencial aplicabilidad en futuras investigaciones o contextos con mayor disponibilidad de información.

<b>Dimensión clave</b>	<b>Indicador cuantitativo</b>	
<b>Flujos de caja elevados y estables</b>	EBITDA / Ventas	$\frac{EBITDA}{Revenue}$ (por cada año fiscal)
	FCF / Ventas	$\frac{FCF}{Revenue}$ (por cada año fiscal)
	Desviación estándar EBITDA (últimos 5 años)	$\sigma$ (EBITDA anual últimos 5 años)
<b>Crecimiento moderado con potencial de mejora</b>	CAGR de ventas (últimos 5 años)	$\frac{Revenue Y2^{\frac{1}{n}}}{Revenue Y1} - 1$
	CAGR de activos (últimos 5 años)	$\frac{Activos\ totales\ Y2}{Activos\ totales\ Y1}$ (por cada año fiscal)
	EBITDA (últimos 5 años)	$\frac{FCF}{Revenue}$ (por cada año fiscal)
	Market-to-book	$\frac{Implied\ Equity\ Value}{Book\ Value}$
<b>Bajo nivel de endeudamiento previo</b>	Deuda / Activos totales	$\frac{Net\ Debt}{Total\ Assets}$
	Deuda / EBITDA	$\frac{Net\ Debt}{EBITDA}$
	EBIT / Intereses (cobertura)	$\frac{EBIT}{Interest\ expense}$
	% de activos tangibles sobre activos totales	$\frac{Tangible\ Assets}{Total\ Assets}$
<b>Tamaño empresarial medio.</b>	Logaritmo de ingresos anuales	$\log (Revenue)$
	Logaritmo de activos totales	$\log (Total\ Assets)$
	Logaritmo de empleados	$\log (Number\ of\ employees)$

<b>Valoración atractiva e infravaloración relativa</b>	P/E ratio	$\frac{\text{Implied Equity Value}}{\text{Net Earnings}}$
	P/B ratio (market-to-book)	$\frac{\text{Implied Equity Value}}{\text{Book value}}$
	EV/EBITDA ratio	$\frac{\text{EV (Implied Equity Value + Net debt)}}{\text{EBITDA}}$
<b>Riesgo financiero y operativo moderado</b>	Z-score de Altman	$Z = 1.3 \left( \frac{\text{Activo Corriente} - \text{Pasivo Corriente}}{\text{Activos Contables}} \right) + 1.4 \left( \frac{\text{Reservas}}{\text{Activos totales}} \right) + 3.3 \left( \frac{\text{EBIT}}{\text{Activos Totales}} \right) + 0.6 \left( \frac{\text{Capitalización bursátil}}{\text{Pasivos Totales}} \right) + 1.0 \left( \frac{\text{Ventas netas}}{\text{Activas Totales}} \right)$
	Beta apalancada (riesgo de mercado)	[obtener de plataformas financieras: Bloomberg, Yahoo finance, Reuters]
	Desviación estándar EBITDA	$\sigma$ (EBITDA anual últimos 5 años)

## 5. MODELO SCORING

Un modelo de scoring es una herramienta cuantitativa que permite asignar una puntuación a distintos elementos, en este caso, empresas, en función de un conjunto de variables predefinidas. Su objetivo es facilitar la comparación y clasificación de esas entidades según su adecuación a un perfil deseado. En el contexto de este trabajo, el modelo de scoring desarrollado evalúa el grado de atractivo de distintas empresas como potenciales objetivos de adquisición apalancada, a partir de criterios extraídos de la literatura académica. Para ello, se calculan ratios financieros clave, se normalizan mediante percentiles y se agregan en un indicador sintético que permite ordenar a las empresas según su encaje teórico con un perfil ideal de *target*.

### 5.1. Origen de la base de datos.

Para la realización del modelo de Python que explicaré a continuación, se ha construido una base de datos específica mediante un proceso estructurado en varias etapas. En primer lugar, se extrajo información de la plataforma especializada MergerMarket, aplicando criterios específicos para identificar transacciones relevantes. Estos criterios fueron:

- **Geografía del objetivo:** España.
- **Sector comprador:** Banca, gestión de fondos, seguros, banca de inversión, corretaje de inversiones, finanzas principales, alquiler y *leasing*, *brokers* de valores y materias primas, fondos soberanos, capital riesgo/*private equity* y servicios financieros.
- **Tipo de operación:** *Buyout* o estrategia de *Buy-and-build* por parte de *Private Equity*.
- **Periodo temporal:** Todas las operaciones anunciadas entre el 31/12/1997 y el 20/05/2025.

Inicialmente, esta búsqueda en MergerMarket proporcionó una muestra amplia de 1.958 empresas. A continuación, se aplicó un filtro adicional, consistente en seleccionar únicamente aquellas compañías cuya información sobre deuda neta (*Net Debt*) estuviera disponible. Este paso limitó la muestra inicial a 137 empresas.

Seguidamente, se realizó un proceso manual para obtener el Número de Identificación Fiscal (NIF) de cada empresa mediante la herramienta Infonif. Este paso intermedio permitió verificar la disponibilidad de información contable detallada en la base de datos SABI (Sistema de Análisis de Balances Ibéricos).

De las 137 empresas iniciales con deuda neta conocida, se logró obtener el NIF de 129 empresas, lo que hizo posible su posterior búsqueda en SABI.

Finalmente, se procedió a la extracción de variables financieras específicas desde la base de datos SABI. Este paso supuso una reducción adicional de la muestra, ya que, de las 129 empresas iniciales, solamente se consiguió información contable completa y suficiente para 109 empresas. Las restantes 20 empresas no disponían de información suficiente en la plataforma SABI, bien por ausencia del NIF en la base de datos o por insuficiencia de datos reportados.

La información extraída se exportó en formato Excel, generando una base de datos que cubre información financiera correspondiente a los últimos cinco años disponibles para cada empresa. Aunque la muestra final de 109 empresas puede considerarse limitada y no necesariamente representativa en términos estadísticos, sí constituye una base suficiente para probar y validar la efectividad práctica del modelo cuantitativo desarrollado en Python, cuyo objetivo último es identificar las 10 empresas más idóneas como potenciales objetivos de una operación de compra apalancada.

En el **¡Error! No se encuentra el origen de la referencia.** se incluye un listado detallado de todas las variables financieras específicas que deben exportarse desde la base de datos SABI para poder replicar y utilizar correctamente el modelo cuantitativo desarrollado en Python con cualquier muestra de empresas que se desee analizar.

## **5.2. Selección y justificación de variables.**

La selección de las variables financieras utilizadas en el modelo responde a una combinación de fundamentos teóricos y criterios empíricos ampliamente respaldados por la literatura académica sobre adquisiciones apalancadas. Tal y como se desarrolla en profundidad en los apartados 2 y 4 de este trabajo, el objetivo principal de esta selección es identificar aquellas métricas que mejor capturan el perfil financiero de una empresa que pudiera ser considerada *target* en una operación de este tipo.

Los ratios calculados permiten evaluar dimensiones clave como la rentabilidad operativa, la capacidad de generar caja libre, el nivel de endeudamiento previo, la solvencia financiera, la estructura de activos, la estabilidad operativa, la capacidad de crecimiento y el tamaño de la empresa. Esta selección está alineada con los trabajos analizados en los apartados anteriores, como es el caso de Kaplan y Strömberg (2009), Cohn et al. (2022) o Axelson et al. (2013), quienes destacan que estas variables son determinantes tanto en la decisión de inversión inicial como en el diseño de la estructura financiera de la operación.

Entre los indicadores utilizados, el margen EBITDA y el margen de *free cash flow* permiten medir la rentabilidad operativa y la capacidad de generación de caja libre de la empresa, ambos esenciales para medir la capacidad de hacer frente a la deuda *post-LBO*. Los ratios Deuda Neta/EBITDA y Deuda/Activos reflejan el grado de apalancamiento financiero previo y, por tanto, la capacidad de la empresa para soportar deuda adicional tras la adquisición. La cobertura de intereses, junto con el Z-score de Altman (en su versión adaptada para empresas no cotizadas), aportan una visión complementaria de la solvencia y el riesgo financiero. Por otro lado, el ratio de tangibilidad (inmovilizado sobre activos) se incluye porque los activos tangibles suelen servir como colateral en la estructuración de deuda senior. Los logaritmos del volumen de ventas, activos y empleados actúan como indicadores del tamaño empresarial, mientras que el crecimiento histórico (medido como CAGR de ventas, EBITDA y activos) permite identificar el potencial de mejora futura bajo nueva gestión. Finalmente, la volatilidad del EBITDA actúa como indicador del riesgo operativo, siendo este un elemento crítico en el contexto de una estructura de capital altamente apalancada.

En un primer planteamiento del modelo se contempló la inclusión de variables de mercado como el ratio P/E (price-to-earnings), P/B (price-to-book), EV/EBITDA o la beta del *equity*. Sin embargo, no fue posible integrarlas en el modelo final. La principal limitación radica en que la mayoría de las empresas de la muestra no son cotizadas, por lo que no existe información pública sobre su valor de mercado ni sobre su cotización histórica. Además, las pocas empresas españolas cotizadas disponibles en bases como Bloomberg o Yahoo Finance tienden a pertenecer al IBEX 35 y presentan un tamaño significativamente superior al target típico de un LBO, lo que introduciría un sesgo considerable en el análisis. Incluso se valoró la posibilidad de estimar la beta a partir de empresas comparables del mismo sector, pero la falta de consistencia entre sectores y la dificultad para obtener una muestra homogénea llevaron a descartar esa alternativa. En consecuencia, se decidió centrar el modelo exclusivamente en ratios de naturaleza contable, asegurando así la aplicabilidad del modelo sobre una muestra realista y la posibilidad de replicarlo fácilmente con otras empresas privadas.

### **5.3. Depuración y construcción de la base de datos.**

Una vez definida la muestra de empresas y seleccionadas las variables financieras clave, el siguiente paso fue construir una base de datos estructurada y limpia que permitiera su posterior análisis y tratamiento mediante programación en Python.

Para ello, se utilizó un archivo Excel exportado desde la plataforma SABI, en el que se recogían todas las variables necesarias para el cálculo de los ratios definidos en el modelo. El procesamiento de esta base de datos se llevó a cabo utilizando el entorno Google Colab, por su compatibilidad con Python y su facilidad para trabajar en la nube sin necesidad de instalación local.

En primer lugar, subimos la base de datos desde nuestro ordenador.

```
from google.colab import files
uploaded = files.upload() # Selecciona el export de SABI desde tu ordenador
```

Elegir archivos Ningún archivo seleccionado Upload widget is only available when the cell has been executed in the current browser session. Please rerun this cell to enable.  
Saving SABI\_Export\_24.xlsx to SABI\_Export\_24.xlsx

**Figura 2. Código Python: Subir la base de datos**

Posteriormente, se emplearon las librerías *pandas* y *numpy* para trabajar con estructuras de datos en forma de tabla y realizar cálculos. Una vez cargado el archivo, se procedió a limpiar y estandarizar los nombres de las columnas para facilitar su manipulación:

```
import pandas as pd
import numpy as np

# Cargar el archivo Excel
df = pd.read_excel("SABI_Export_24.xlsx", sheet_name="Resultados")

# Limpiar nombres de columnas
df.columns = df.columns.str.strip().str.replace('\n', ' ').str.replace('€', 'EUR').str.replace('.', '', regex=False)
```

**Figura 3. Código Python: Limpieza y estandarización de la base de datos**

A continuación, se identificaron aquellas columnas que contenían datos financieros y se convirtieron a formato numérico. Esto fue fundamental para evitar errores en los cálculos posteriores, ya que algunas celdas podían contener caracteres no numéricos, espacios o valores nulos:

```
# Convertir columnas a numérico
cols_to_numeric = [col for col in df.columns if 'EUR' in col or 'empleados' in col.lower()]
for col in cols_to_numeric:
    df[col] = pd.to_numeric(df[col], errors='coerce')
```

**Figura 4. Código Python: Limpieza y estandarización de la base de datos**

Una vez procesado el archivo, se creó un nuevo *DataFrame* (*ratios*) que contenía exclusivamente las variables necesarias para el cálculo de los distintos indicadores financieros del modelo. Entre ellas se incluyeron datos como ingresos de explotación, EBITDA, EBIT, cash flow, deuda neta, tesorería, gastos financieros, activos totales, amortizaciones, inmovilizado, capital suscrito, pasivo fijo, activo circulante y resultado del ejercicio, todos ellos correspondientes al último año disponible.

Finalmente, se validó la correcta carga de la información visualizando las primeras cinco filas del nuevo *DataFrame*, con el fin de confirmar que los datos estaban correctamente estructurados y listos para su transformación en ratios financieros:

```

# Crear DataFrame para ratios
ratios = pd.DataFrame()
ratios['Nombre'] = df['Nombre']
ratios['Ingresos'] = df['Ingresos de explotación EUR Últ año disp']
ratios['EBITDA'] = df['EBITDA EUR Últ año disp']
ratios['EBIT'] = df['EBIT EUR Últ año disp']
ratios['Cash_Flow'] = df['Cash flow EUR Últ año disp']
ratios['Deuda'] = df['Pasivo líquido EUR Últ año disp']
ratios['Tesoreria'] = df['Tesorería EUR Últ año disp']
ratios['Gastos_Financieros'] = df['Gastos financieros EUR Últ año disp']
ratios['Activos'] = df['Total activo EUR Últ año disp']
ratios['Amortizaciones'] = df['Dotaciones para amortiz de inmovil EUR Últ año disp']
ratios['Empleados'] = df['Número empleados Últ año disp']
ratios['Inmovilizado'] = df['Inmovilizado material EUR Últ año disp']
ratios['Activo_Circulante'] = df['Activo circulante EUR Últ año disp']
ratios['Pasivo_Fijo'] = df['Pasivo fijo EUR Últ año disp']
ratios['Capital_Suscrito'] = df['Capital suscrito EUR Últ año disp']
ratios['Resultado'] = df['Resultado del Ejercicio EUR Últ año disp']

# Mostrar las 5 primeras filas del DataFrame
ratios.head(5)

```

Figura 5. Código Python: Creación del DataFrame

#### 5.4. Construcción del modelo en Python.

El primer paso en la construcción del modelo consistió en transformar los datos contables, extraídos de la base de datos SABI, en una serie de ratios financieros clave. Estos ratios no solo facilitan la comparación entre empresas de diferente tamaño y sector, sino que además reflejan dimensiones estratégicas esenciales para evaluar su idoneidad como objetivo de una operación de LBO. Para ello se calcularon los ratios sobre la base del último año disponible, excepto las variables de crecimiento y volatilidad, que requieren series temporales. Una vez, calculados, se consolidaron en *el DataFrame ratios\_finales*, sirviendo como input para los dos modelos de *scoring* desarrollados en secciones posteriores.

```

[3] ratios['EBITDA_Margin'] = ratios['EBITDA'] / ratios['Ingresos']
ratios['FCF'] = ratios['EBIT'] + ratios['Amortizaciones']
ratios['FCF_Margin'] = ratios['FCF'] / ratios['Ingresos']
ratios['Deuda_Neta'] = ratios['Deuda'] - ratios['Tesoreria']
ratios['Deuda_Neta_EBITDA'] = ratios['Deuda_Neta'] / ratios['EBITDA']
ratios['Deuda_Activos'] = ratios['Deuda'] / ratios['Activos']
ratios['Cobertura_Intereses'] = ratios['EBIT'] / ratios['Gastos_Financieros']
ratios['Tangibilidad'] = ratios['Inmovilizado'] / ratios['Activos']
ratios['Log_Ventas'] = np.log(ratios['Ingresos'])
ratios['Log_Activos'] = np.log(ratios['Activos'])
ratios['Log_Empleados'] = np.log(ratios['Empleados'])

```

Figura 6. Código Python: Cálculo de los ratios financieros

```

▶ # Calculamos el crecimiento (CAGR)
def cagr(t0, tn, n=4):
    return ((tn / t0)**(1/n)) - 1

ratios['CAGR_Ventas'] = cagr(df['Ingresos de explotación EUR Año - 4'], df['Ingresos de explotación EUR Últ año disp'])
ratios['CAGR_EBITDA'] = cagr(df['EBITDA EUR Año - 4'], df['EBITDA EUR Últ año disp'])
ratios['CAGR_Activos'] = cagr(df['Total activo EUR Año - 4'], df['Total activo EUR Últ año disp'])

```

**Figura 7. Código Python: Cálculo del Compound Annual Growth Rate**

```

▶ #Calculamos la volatilidad del EBITDA (riesgo operativo)
ebitda_hist = df[[
    'EBITDA EUR Últ año disp',
    'EBITDA EUR Año - 1',
    'EBITDA EUR Año - 2',
    'EBITDA EUR Año - 3',
    'EBITDA EUR Año - 4'
]]
ratios['Volatilidad_EBITDA'] = ebitda_hist.std(axis=1) / ebitda_hist.mean(axis=1)

```

**Figura 8. Código Python: Cálculo de la volatilidad del EBITDA**

```

[] # Calculamos el Z-score de altman
# Fórmula Z" = 0.717*A + 0.847*B + 3.107*C + 0.420*D + 0.998*E
ratios['A'] = (ratios['Activo_Circulante'] - ratios['Pasivo_Fijo']) / ratios['Activos']
ratios['B'] = ratios['Resultado'] / ratios['Activos']
ratios['C'] = ratios['EBIT'] / ratios['Activos']
ratios['D'] = ratios['Capital_Suscrito'] / ratios['Deuda']
ratios['E'] = ratios['Ingresos'] / ratios['Activos']
ratios['Z_score'] = (
    0.717 * ratios['A'] +
    0.847 * ratios['B'] +
    3.107 * ratios['C'] +
    0.420 * ratios['D'] +
    0.998 * ratios['E']
)

```

**Figura 9. Código Python: Cálculo del Z-Score de altman**

#### 5.4.1. Filtro opcional por tamaño

Dado que el perfil de empresa objetivo en una operación de LBO suele estar condicionada por su escala, el modelo desarrollado incorpora una funcionalidad adicional que permite al usuario filtrar las empresas en función del tamaño.

En términos prácticos, no es lo mismo adquirir una gran empresa cotizada, como es el caso de Naturgy o Iberdrola, que la de una pyme industrial de carácter familiar. Por tanto, esta función resulta especialmente útil para adaptar el modelo a los distintos tipos de inversores. Además, esta funcionalidad resulta especialmente valiosa en el caso de bases de datos con empresas de tamaños muy diversos.

El filtro está implementado como un bloque opcional dentro del código y puede activarse (True) o desactivarse (False) libremente. Cuando está activado (filtrar\_por\_tamaño = True), el usuario puede definir un rango mínimo y máximo de tamaño, expresado en función de los ingresos del último año disponible. Este rango se establece mediante dos variables ajustables: limite\_inferior y limite\_superior.

Por ejemplo, un usuario podría restringir el análisis a empresas con una facturación entre 10 y 500 millones de euros, lo que acotaría el universo analizado a un segmento típicamente atractivo para operaciones LBO en el *middle market* español.

Esta funcionalidad se ejecuta antes del cálculo de los ratios y filtra directamente el DataFrame ratios, eliminando aquellas empresas fuera del rango establecido.

```
[ ] # Cambiar a True si se quiere activar el filtro o a False si quiere desactivarlo.
    filtrar_por_tamaño = True

# Definir los límites del tamaño (puedes ajustar valores en millones)
limite_inferior = 10_000_000 # por ejemplo: empresas con ingresos > 10M €
limite_superior = 500_000_000 # por ejemplo: empresas con ingresos < 500M €

if filtrar_por_tamaño:
    ratios = ratios[
        (ratios['Ingresos'] >= limite_inferior) &
        (ratios['Ingresos'] <= limite_superior)
    ]
```

**Figura 10. Código Python: Filtro opcional por tamaño**

#### 5.4.2. Normalización de variables

Antes de calcular los scores, los ratios financieros se transformaron para que fueran comparables entre sí. En primer lugar, se invirtieron aquellos donde valores más bajos son preferibles, como el ratio Deuda Neta / EBITDA o la volatilidad del EBITDA, de forma que un valor más alto siempre indique mejor desempeño.

Después, todos los ratios se normalizaron a percentiles (escala de 0 a 1), lo que permite comparar empresas independientemente del tamaño o sector. Esta transformación facilita el cálculo del *score* final y mejora la interpretación visual de los resultados.

```

▶ # Copia de seguridad
ratios_scoring = ratios.copy()

# Lista de ratios a incluir en el score
ratios_usados = [
    'EBITDA_Margin', 'FCF_Margin', 'Deuda_Neta_EBITDA', 'Deuda_Activos',
    'Cobertura_Intereses', 'Tangibilidad', 'Log_Ventas', 'Log_Activos',
    'CAGR_Ventas', 'CAGR_EBITDA', 'CAGR_Activos', 'Volatilidad_EBITDA', 'Z_score'
]

# Invertir aquellos donde valores altos son negativos
ratios_scoring['Inv_Deuda_Neta_EBITDA'] = -ratios_scoring['Deuda_Neta_EBITDA']
ratios_scoring['Inv_Deuda_Activos'] = -ratios_scoring['Deuda_Activos']
ratios_scoring['Inv_Volatilidad_EBITDA'] = -ratios_scoring['Volatilidad_EBITDA']

# Reemplazar los originales por los invertidos donde corresponda
ratios_para_score = [
    'EBITDA_Margin',
    'FCF_Margin',
    'Inv_Deuda_Neta_EBITDA',
    'Inv_Deuda_Activos',
    'Cobertura_Intereses',
    'Tangibilidad',
    'Log_Ventas',
    'Log_Activos',
    'CAGR_Ventas',
    'CAGR_EBITDA',
    'CAGR_Activos',
    'Inv_Volatilidad_EBITDA',
    'Z_score']

# Normalizar a percentiles
for col in ratios_para_score:
    col_percentil = col + "_pct"
    ratios_scoring[col_percentil] = ratios_scoring[col].rank(pct=True)

```

**Figura 11. Código Python: Normalización de variables**

#### 5.4.3. Modelo de scoring sencillo

El modelo de *scoring* sencillo se construye a partir de los ratios financieras previamente normalizados, calculando la media aritmética de sus percentiles. Este enfoque parte de la premisa de que todas las variables tienen la misma importancia, y por tanto, cada ratio contribuye por igual al *score* final.

Este sistema genera el llamado LBO Score, que permite clasificar a todas las empresas de la base de datos en función de su perfil financiero total. Cuanto más alto es el LBO Score, más atractiva se considera la empresa como objetivo para una operación de compra apalancada.

Este modelo es útil en fases iniciales para hacer un primer filtrado o priorizar un conjunto amplio de empresas. Además, puede visualizarse gráficamente mediante rankings o diagramas de tipo radar.

```

# Calcular el score promedio (ponderación igual para empezar)
percentil_cols = [c + "_pct" for c in ratios_para_score]
ratios_scoring['LBO_Score'] = ratios_scoring[percentil_cols].mean(axis=1)

# Crear ranking descendente
ratios_scoring['Ranking_LBO'] = ratios_scoring['LBO_Score'].rank(ascending=False)

# Mostrar las 10 mejores empresas como targets
ratios_scoring[['Nombre', 'LBO_Score', 'Ranking_LBO']].sort_values(by='LBO_Score', ascending=False).head(10)
# Filtrar empresas que NO están extinguidas
ratios_scoring = ratios_scoring[~ratios_scoring['Nombre'].str.contains(r'\(EXTINGUIDA\)', case=False, na=False)]

```

**Figura 11. Código Python: Modelo sencillo de scoring**

#### 5.4.4. Modelo de scoring por dimensiones

El segundo modelo introduce un enfoque más estructurado. En lugar de hacer el promedio de todos los ratios por igual, los indicadores se agrupan en cinco dimensiones clave: rentabilidad, endeudamiento, solidez financiera, tamaño y crecimiento.

Para cada dimensión se calcula un *sub-score*, que representa el desempeño medio de la empresa en esa categoría. A continuación, estos *sub-scores* se combinan mediante una media ponderada, aplicando pesos que reflejan la relevancia teórica de cada dimensión en un LBO. Por ejemplo, en este trabajo se otorga más peso a la rentabilidad y a la solvencia, ya que son determinantes para el repago de la deuda. Sin embargo, estos pesos son ajustables, cualquiera que utilice el modelo podrá cambiarlos.

```

[ ] # Definir las dimensiones y sus ratios
dimensiones = {
    'Rentabilidad': ['EBITDA_Margin_pct', 'FCF_Margin_pct'],
    'Endeudamiento': ['Inv_Deuda_Neta_EBITDA_pct', 'Inv_Deuda_Activos_pct', 'Cobertura_Intereses_pct'],
    'Solidez': ['Tangibilidad_pct', 'Z_score_pct', 'Inv_Volatilidad_EBITDA_pct'],
    'Tamaño': ['Log_Ventas_pct', 'Log_Activos_pct'],
    'Crecimiento': ['CAGR_Ventas_pct', 'CAGR_EBITDA_pct', 'CAGR_Activos_pct']
}

# Calcular sub-scores por dimensión
for nombre, columnas in dimensiones.items():
    ratios_scoring[f'Score_{nombre}'] = ratios_scoring[columnas].mean(axis=1)

# Pesos para cada dimensión AJUSTABLES!!!!!!!!!!!!!!
pesos = {
    'Rentabilidad': 0.25,
    'Endeudamiento': 0.2,
    'Solidez': 0.2,
    'Tamaño': 0.15,
    'Crecimiento': 0.2
}

# Calcular LBO Target Score ponderado
ratios_scoring['LBO_Target_Score'] = sum(
    ratios_scoring[f'Score_{dim}'] * peso
    for dim, peso in pesos.items()
)

# Mostrar top 10 empresas con mejor score
ratios_scoring[['Nombre', 'LBO_Target_Score'] + [f'Score_{d}' for d in dimensiones.keys()]]\
    .sort_values(by='LBO_Target_Score', ascending=False).head(10)

```

**Figura 12. Código Python: Modelo de scoring por dimensiones**

Este modelo, denominado LBO Target Score, proporciona una visión flexible, y permite ajustar el análisis según el tipo de inversor, el contexto del mercado o los objetivos estratégicos. Además, ofrece

comparativas entre empresas por dimensión, algo muy útil para identificar no solo qué empresas destacan, sino también en qué son fuertes o débiles.

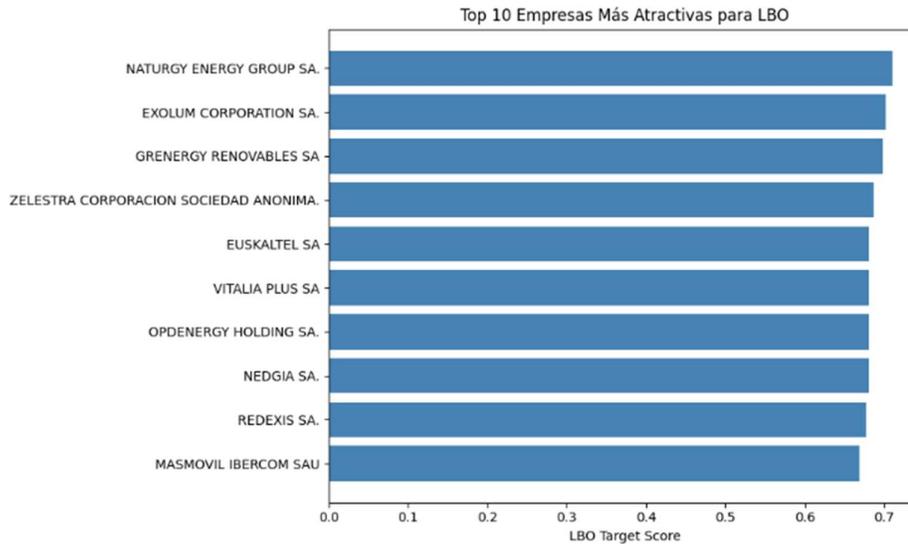
### 5.5. Resultados y salida del modelo.

En esta sección se presentan los resultados obtenidos tras la aplicación del modelo sobre la base de datos construida a partir de la información financiera extraída de SABI. Se muestran los *outputs* del modelo bajo dos escenarios: (i) sin aplicar ningún filtro de tamaño y (ii) aplicando un filtro para acotar la muestra a empresas de tamaño medio. En ambos casos se comparan los resultados obtenidos tanto con el modelo de scoring sencillo como con el modelo por dimensiones.

#### 5.5.1. Resultados sin filtro por tamaño

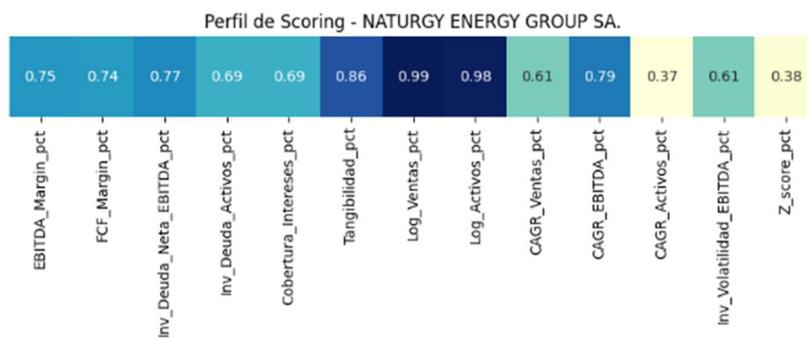
En esta primera versión se evaluaron todas las empresas de la muestra, independientemente de su tamaño.

##### a) Modelo de scoring sencillo



**Figura 13. Ranking de empresas según el modelo de scoring sencillo (sin filtro de tamaño).**

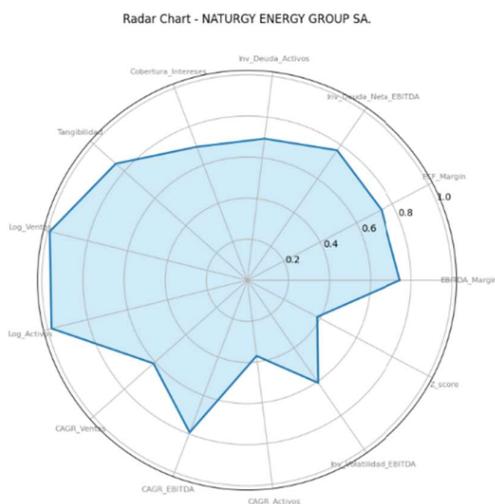
En este escenario, el modelo de scoring sencillo se aplica sobre la totalidad de las empresas de la muestra, sin ninguna restricción de tamaño. Como podemos observar en el ranking que muestra la Figura 13, Naturgy Energy Group, S.A. es considerada la empresa con mayor atractivo para una LBO, seguida por Exolum Corporation, S.A. y Greenergy Renovables, S.A.



**Figura 14. Perfil financiero normalizado de la empresa líder: Naturgy Energy Group, S.A.**

En el *heatmap* de la Figura 14 se muestra el perfil de Naturgy Energy Group, S.A.; podemos observar puntuaciones muy elevadas, por encima del percentil 0,75, en los márgenes de EBITDA, FCF, apalancamiento relativo, tangibilidad, tamaño de ventas y tamaño de activos. Estos resultados sugieren una estructura operativa eficiente, un elevado nivel de activos tangibles y un nivel bajo de endeudamiento previo. No obstante, se observan percentiles más bajos en variables como el crecimiento de ventas y activos, y en el Z-score, que advierten de una posible madurez financiera o un menor dinamismo.

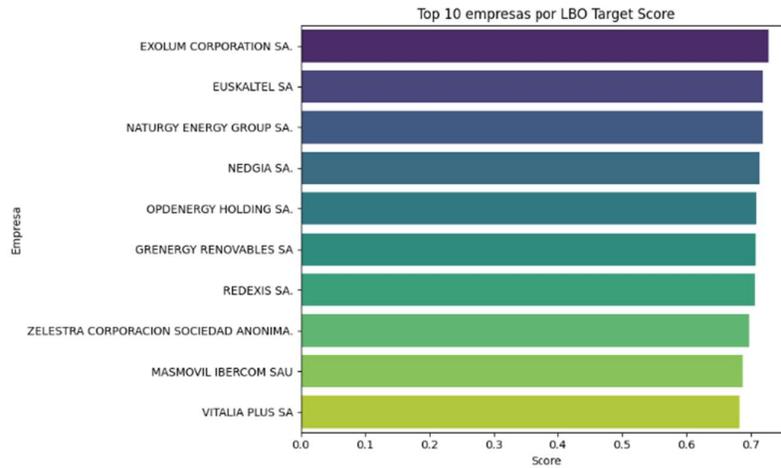
El radar chart que podemos observar en la Figura 15 muestra cómo Naturgy Energy Group, S.A., destaca de forma consistente en casi todas las dimensiones, especialmente en la eficiencia y en la escalabilidad, pero con menor desempeño en el crecimiento de activos y el riesgo de distress (Z-score).



**Figura 15. Radar chart de Naturgy Energy Group, S.A. según el modelo sencillo.**

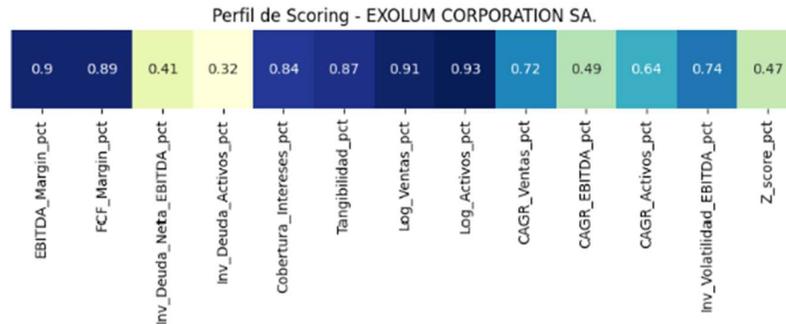
b) Modelo de scoring por dimensiones

En este segundo enfoque, se aplica el modelo ponderado por dimensiones estratégicas sin aplicar aun el filtro por tamaño. A diferencia del scoring sencillo del apartado anterior, en este modelo los ratios no se ponderan por igual, sino que han sido agrupados en cinco bloques: rentabilidad, endeudamiento, solidez financiera, tamaño y crecimiento, cada uno con su propio sub-score.



**Figura 16. Ranking de empresas según el modelo de scoring por dimensiones (sin filtro de tamaño)**

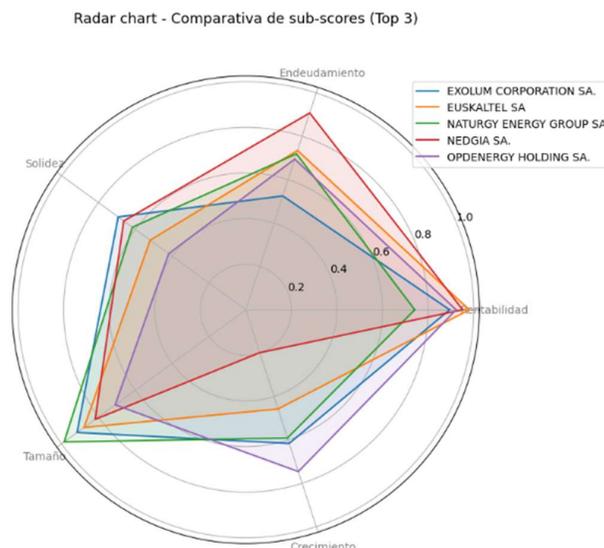
Como podemos observar en la Figura 16, Exolum Corporation, S.A. pasa a ocupar el primer puesto del ranking superando a Naturgy, sociedad líder en el modelo sencillo. Esto se debe a que Exolum Corporation, S.A. obtiene puntuaciones más equilibradas en varias dimensiones clave. A esta le siguen sociedades que repiten en el top, aunque en diferente orden, como Euskaltel, S.A. y Nedgia, S.A.



**Figura 17. Perfil financiero normalizado de la empresa líder: Exolum Corporation, S.A.**

El perfil financiero de Exolum Corporation, S.A. muestra percentiles muy altos de rentabilidad (EBITDA y FCF Margin), tamaño (logaritmo de ventas y activos), tangibilidad y cobertura de

intereses. Sin embargo, estas fortalezas se ven compensadas con puntuaciones más discretas en endeudamiento (Deuda/EBITDA, Deuda/Activos) y crecimiento (especialmente en EBITDA y activos).



**Figura 18. Radar chart comparativo por sub-scores – Top 5 empresas (modelo por dimensiones)**

Como podemos observar en la Figura 18, permite observar visualmente las diferencias entre las cinco mejores empresas. Exolum destaca en rentabilidad y solidez, mientras que Euskaltel y Nedgia sobresalen en endeudamiento (lo cual puede ser favorable si tienen capacidad de absorber más deuda).

En comparación con el modelo sencillo del apartado a, este enfoque por dimensiones ofrece una visión más equilibrada y estratégica. Permite no solo saber qué empresas están mejor posicionadas en el ranking global, sino también por qué lo están, y en qué ejes concretos tienen margen de mejora.

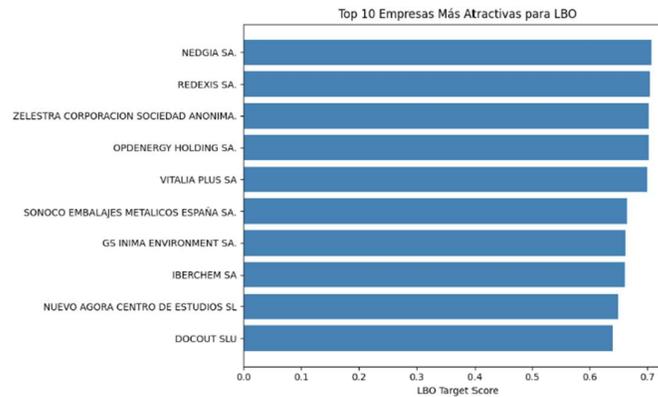
Cabe destacar que, al no aplicarse un filtro por tamaño en los dos apartados anteriores, el modelo puede situar en las primeras posiciones del ranking a empresas de gran tamaño, cuya solidez financiera es indiscutible, pero que no necesariamente encajan en el perfil de inversión típico de un fondo enfocado a un segmento de empresas más pequeñas. Esta limitación justifica la necesidad de incorporar una opción para filtrar la base de datos por tamaño, permitiendo así adaptar el análisis a decisiones de inversión más realistas y enfocados a operaciones LBO viables en términos de escala.

### 5.5.2. Resultados con filtro por tamaño

#### a) Modelo de scoring sencillo

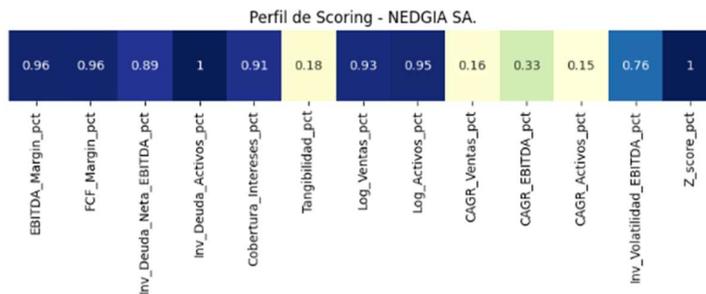
En este apartado se presentan los resultados obtenidos en el modelo de scoring sencillo tras haber activado el filtro por tamaño, de forma que únicamente se consideren empresas con un volumen de ingresos comprendido entre 10 y 500 millones de euros.

Haber incluido el filtro por tamaño, responde a una limitación observada en los análisis anteriores, donde el modelo, al no discriminar por tamaño, situaba en el top del ranking a empresas financieramente sólidas, si bien excesivamente grandes.



**Figura 19. Ranking de empresas según el modelo de scoring sencillo (con filtro de tamaño).**

Tal y como podemos observar en la Figura 19, tras aplicar el filtro del tamaño, la empresa Nedgia, S.A pasa a encabezar el ranking, seguida de REDEXIS S.A., Zelestra Corporación Sociedad Anónima y otras empresas que, en el análisis anterior, estaban en posiciones intermedias o no destacaban. Este cambio en el ranking muestra como el filtro permite identificar targets más adecuados desde el punto de vista del tamaño realista de la operación.

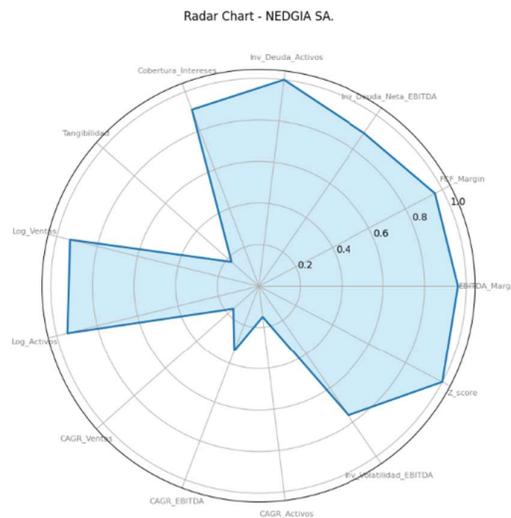


**Figura 20. Perfil financiero normalizado de la empresa líder: Nedgia, S.A.**

El perfil financiero de Nedgia, S.A., representado en la Figura 20, destaca por valores excepcionalmente altos en variables clave como EBITDA Margin, FCF Margin, cobertura de intereses, apalancamiento bajo (Deuda/EBITDA y Deuda/Activos), y un Z-score elevado, lo cual indica que se trata de una sociedad con una estructura financiera sólida y un bajo riesgo de quiebra. Además, presenta una baja volatilidad del EBITDA, lo que refuerza su perfil como empresa estable y predecible.

Sin embargo, el perfil también muestra ciertas debilidades: concretamente, el nivel de activos tangibles es bajo y un crecimiento limitado en ventas y activos, ambos con percentiles inferiores a 0.20, lo cual podría limitar su capacidad de expansión bajo una nueva gestión.

Este contraste de variables se visualiza claramente en el radar chart de Nedgia, S.A. (Figura 21), donde la forma asimétrica revela un perfil con fortalezas financieras claras, pero áreas de mejora como es el caso del crecimiento o la tangibilidad de sus activos.



**Figura 21. Radar chart de Nedgia, S.A. según el modelo sencillo.**

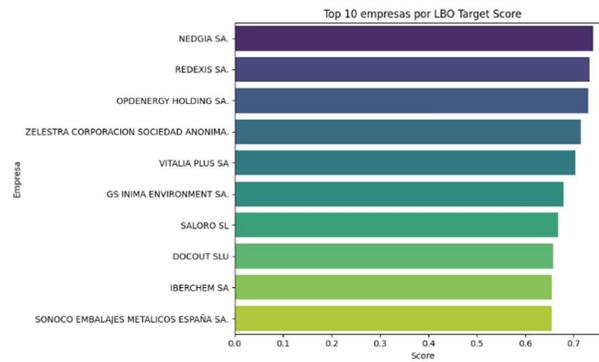
En resumen, la activación del filtro por tamaño permite que el modelo se enfoque en empresas más alineadas con el perfil operativo, financiero y estratégico que buscan los fondos de capital riesgo, mejorando la utilidad práctica del sistema de scoring como herramienta de screening inicial.

#### b) Modelo de scoring por dimensiones

En este último bloque de resultados se analiza el modelo de scoring por dimensiones aplicando el filtro por tamaño, es decir limitando la muestra a empresas cuyos ingresos se encuentran dentro de un rango, en este caso con un volumen de ingresos comprendido entre 10 y 500 millones de euros. Tal y como

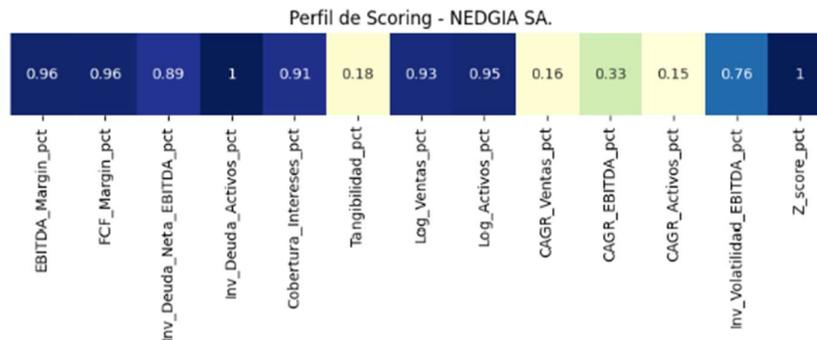
hemos establecido anteriormente, el modelo permite eliminar a las grandes sociedades cuyo perfil no se ajusta al tipo de operación LBO llevada a cabo por los fondos de *private equity*.

La Figura 22, que podemos ver a continuación, muestra el ranking de las 10 empresas con mejor LBO Target Score ponderado según las 5 dimensiones, definidas anteriormente. A diferencia de la versión sin filtro, en esta ocasión destacan sociedades de tamaño medio con scores equilibrados.

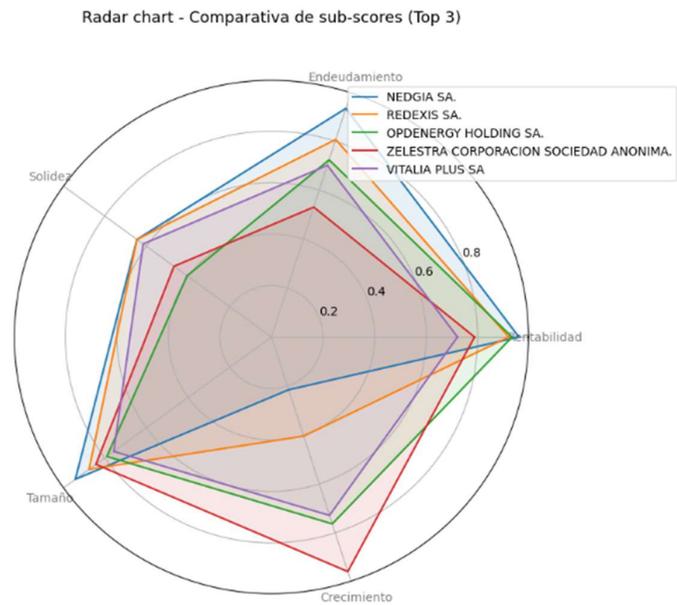


**Figura 22. Ranking de empresas según el modelo de scoring por dimensiones (con filtro de tamaño)**

Nedgia, S.A. sigue encabezando el ranking de empresas. La Figura 23, correspondiente al perfil de la empresa líder tras aplicar el filtro, revela una distribución de sub-score consistente. Como bien hemos explicado anteriormente, Nedgia, S.A. presenta buenos resultados de rentabilidad y endeudamiento, factores esenciales para ser considerado un objetivo ideal para una LBO.



**Figura 23. Perfil financiero normalizado de la empresa líder: Nedgia, S.A.**



**Figura 24. Radar chart comparativo por sub-scores – Top 5 empresas (modelo por dimensiones)**

Finalmente, la Figura 24, muestra un gráfico comparativo de las cinco mejores empresas. Este permite visualizar como se posiciona cada una de ellas en las cinco dimensiones del modelo. A diferencia de los casos sin filtro, en este análisis se observa una mayor homogeneidad en los perfiles, con empresas que no necesariamente lideran en todas las dimensiones, pero presentan una combinación sólida y equilibrada.

Comparando este último modelo con los apartados anteriores, se aprecia cómo el uso del filtro por tamaño ayuda a depurar la muestra y detectar *targets* más realistas. Además, al aplicar el modelo por dimensiones, se consigue una interpretación más realista del perfil financiero de cada empresa, permitiendo que los resultados no estén excesivamente condicionados por el tamaño de la sociedad o por una única variable fuerte. Este enfoque puede ser particularmente útil en la práctica profesional de los fondos de capital privado.

## 6. CONCLUSIÓN

El presente trabajo ha tenido como objetivo central identificar y caracterizar el perfil financiero óptimo de una empresa objetivo para una operación de adquisición apalancada, combinando para ello un exhaustivo análisis teórico con el desarrollo de un modelo cuantitativo de scoring implementado en Python. Esta aproximación dual, tanto conceptual como empírica, ha permitido avanzar en la comprensión del funcionamiento de los LBOs. A la vez, he podido construir un herramienta replicable y útil para el análisis preliminar de oportunidades de inversión.

A lo largo del trabajo se ha demostrado que el éxito de una operación de LBO depende en gran medida de la adecuada elección del *target*, y que dicha elección puede guiarse a partir de un conjunto de características financieras, operativas y estructurales que la literatura ha identificado como recurrentes en operaciones exitosas. Estas incluyen: elevada generación de flujos de caja libre, estabilidad operativa, bajo nivel de endeudamiento previo, tamaño medio, valoración atractiva (o infravalorada), y riesgo financiero moderado. Adicionalmente, factores como la estructura de propiedad y la capacidad de mejora bajo una nueva gestión refuerzan el potencial del *target* como plataforma de creación de valor.

La implementación del modelo de scoring ha permitido trasladar estas variables teóricas a un marco cuantitativo, haciendo posible la evaluación sistemática de empresas mediante indicadores normalizados. Además, la introducción de dos modelos, uno sencillo y otro por dimensiones, ha aportado flexibilidad y profundidad al análisis, facilitando tanto la identificación de *targets* con perfiles sólidos como la evaluación detallada de sus fortalezas y debilidades relativas. Asimismo, la incorporación de filtros opcionales por tamaño ha mejorado la capacidad del modelo para ajustarse a distintos contextos y tipos de inversores, lo que refuerza su aplicabilidad en situaciones reales como puede ser el caso de una *due diligence* preliminar.

Más allá de los resultados cuantitativos, el trabajo también ha permitido extraer algunas reflexiones. En primer lugar, aunque el modelo aporte una aproximación a la selección de *targets*, debe entenderse como una herramienta de apoyo y no como un sustituto del juicio de un experto ni del análisis cualitativo. La idoneidad de una empresa como objetivo de LBO no solo depende del análisis financiero, sino que, además, depende de múltiples factores como puede ser la industria, la situación macroeconómica, la estrategia del fondo de *private equity*. Por tanto, el modelo desarrollado debe complementarse con un análisis estratégico más amplio.

En segundo lugar, se ha constatado que, aunque ciertos patrones son comunes entre los *targets* exitosos, no existe un perfil único ni rígido. En la práctica, los fondos de *private equity* pueden identificar

oportunidades atractivas en empresas que no cumplan todos los criterios establecidos, siempre que se fundamente en una decisión estratégica racional y se diseñe un plan de creación de valor sólido.

En tercer lugar, el trabajo ha permitido visualizar de forma concreta cómo interactúan distintas variables en la configuración del perfil financiero de una empresa. Por ejemplo, una empresa con alta rentabilidad y baja deuda puede parecer un objetivo ideal, pero si su crecimiento es limitado o su valoración es excesiva, el potencial de retorno puede verse reducido. Del mismo modo, empresas con niveles de endeudamiento moderados pero con márgenes operativos altos y potencial de expansión pueden constituir apuestas interesantes, especialmente si se plantea una estrategia de *buy-and-build*.

Desde un punto de vista metodológico, una posible línea de mejora del trabajo sería ampliar la base de datos utilizada, incluyendo una mayor variedad de sectores, países y tipologías de empresa. Asimismo, la validación empírica del modelo, por ejemplo, contrastando su capacidad predictiva con operaciones LBO reales del pasado, constituiría un paso importante para perfilar sus resultados y mejorar su aplicabilidad.

Finalmente, desde una perspectiva más amplia, este trabajo pone de manifiesto cómo la aplicación de herramientas analíticas y tecnológicas puede contribuir significativamente a la toma de decisiones financieras complejas. En un entorno cada vez más competitivo y basado en datos, contar con instrumentos que permitan filtrar y priorizar oportunidades de inversión se convierte en una ventaja estratégica relevante.

En conclusión, este trabajo ha permitido, por un lado, sistematizar el conocimiento académico disponible sobre las características clave de las empresas objetivo en LBOs y, por otro, trasladar ese conocimiento a una herramienta práctica y replicable. El modelo de scoring propuesto constituye un primer paso en la dirección de una mayor profesionalización del análisis previo a la inversión, y abre la puerta a futuras investigaciones orientadas a perfeccionar y adaptar esta herramienta a las necesidades cambiantes de los mercados financieros.

## **7. ANEXO 1: Variables necesarias para exportar desde SABI**

A continuación, se presenta un listado claro y conciso de las variables financieras específicas que deben exportarse desde la base de datos SABI para utilizar correctamente el modelo desarrollado en Python. Todas ellas deben extraerse para los últimos cinco años disponibles:

- Ingresos de explotación (último año disponible y cuatro años anteriores)
- EBITDA (último año disponible y cuatro años anteriores)
- EBIT (último año disponible y cuatro años anteriores)
- Cash Flow (último año disponible y cuatro años anteriores)
- Resultado del ejercicio (último año disponible y cuatro años anteriores)
- Pasivo fijo (último año disponible y cuatro años anteriores)
- Pasivo líquido (último año disponible y cuatro años anteriores)
- Tesorería (último año disponible y cuatro años anteriores)
- Capital suscrito (último año disponible y cuatro años anteriores)
- Gastos financieros (último año disponible y cuatro años anteriores)
- Total activo (último año disponible y cuatro años anteriores)
- Activo circulante (último año disponible y cuatro años anteriores)
- Inmovilizado material (último año disponible y cuatro años anteriores)
- Inmovilizado intangible (último año disponible y cuatro años anteriores)
- Dotaciones para amortización del inmovilizado (último año disponible y cuatro años anteriores)
- Dividendos (último año disponible y cuatro años anteriores)
- Número de empleados (último año disponible y cuatro años anteriores)

Estas variables son fundamentales para la aplicación efectiva del modelo cuantitativo desarrollado en Python, ya que permiten calcular los ratios financieros clave que definen la idoneidad de una empresa como objetivo potencial en LBOS.

## 8. ANEXO 2: Modelo de Python

A continuación, se presenta el código del modelo desarrollado en Python para la evaluación de empresas objetivo en operaciones de LBO. Para consultar el código completo de forma interactiva y en un entorno reproducible, se puede acceder al siguiente enlace de Google Colab: [Acceder al código de Google Colab](#).

### BASE DE DATOS.

**PASO 1: Subimos la base de datos.** Es importante que tengamos la base de datos en nuestro ordenador.

```
from google.colab import files
uploaded = files.upload() # Selecciona SABI_Export_24.xlsx desde tu ordenador
```

**PASO 2: Limpiamos y preparamos la base de datos.**

```
import pandas as pd
import numpy as np

# Cargar el archivo Excel
df = pd.read_excel("SABI_Export_24.xlsx", sheet_name="Resultados")

# Limpiar nombres de columnas
df.columns = df.columns.str.strip().str.replace('\n', ' ').str.replace('€', 'EUR').str.replace('.', '', regex=False)

# Convertir columnas a numérico
cols_to_numeric = [col for col in df.columns if 'EUR' in col or 'empleados' in col.lower()]
for col in cols_to_numeric:
    df[col] = pd.to_numeric(df[col], errors='coerce')

# Crear DataFrame para ratios
ratios = pd.DataFrame()
ratios['Nombre'] = df['Nombre']
ratios['Ingresos'] = df['Ingresos de explotación EUR Últ año disp']
ratios['EBITDA'] = df['EBITDA EUR Últ año disp']
ratios['EBIT'] = df['EBIT EUR Últ año disp']
ratios['Cash_Flow'] = df['Cash flow EUR Últ año disp']
ratios['Deuda'] = df['Pasivo líquido EUR Últ año disp']
ratios['Tesoreria'] = df['Tesorería EUR Últ año disp']
ratios['Gastos_Financieros'] = df['Gastos financieros EUR Últ año disp']
ratios['Activos'] = df['Total activo EUR Últ año disp']
ratios['Amortizaciones'] = df['Dotaciones para amortiz de inmovil EUR Últ año disp']
ratios['Empleados'] = df['Número empleados Últ año disp']
ratios['Inmovilizado'] = df['Inmovilizado material EUR Últ año disp']
ratios['Activo_Circulante'] = df['Activo circulante EUR Últ año disp']
ratios['Pasivo_Fijo'] = df['Pasivo fijo EUR Últ año disp']
ratios['Capital_Suscrito'] = df['Capital suscrito EUR Últ año disp']
ratios['Resultado'] = df['Resultado del Ejercicio EUR Últ año disp']

# Mostrar las 5 primeras filas del DataFrame
ratios.head(5)

PASO 3: Calculamos los ratios financieros
ratios['EBITDA_Margin'] = ratios['EBITDA'] / ratios['Ingresos']
ratios['FCF'] = ratios['EBIT'] + ratios['Amortizaciones']
ratios['FCF_Margin'] = ratios['FCF'] / ratios['Ingresos']
ratios['Deuda_Neta'] = ratios['Deuda'] - ratios['Tesoreria']
ratios['Deuda_Neta_EBITDA'] = ratios['Deuda_Neta'] / ratios['EBITDA']
ratios['Deuda_Activos'] = ratios['Deuda'] / ratios['Activos']
ratios['Cobertura_Intereses'] = ratios['EBIT'] / ratios['Gastos_Financieros']
```

```

ratios['Tangibilidad'] = ratios['Inmovilizado'] / ratios['Activos']
ratios['Log_Ventas'] = np.log(ratios['Ingresos'])
ratios['Log_Activos'] = np.log(ratios['Activos'])
ratios['Log_Empleados'] = np.log(ratios['Empleados'])

```

#### PASO 4: CÁLCULO DE CRECIMIENTO (CAGR)

```
def cagr(t0, tn, n=4):
```

```
    return ((tn / t0)**(1/n)) - 1
```

```
ratios['CAGR_Ventas'] = cagr(df['Ingresos de explotación EUR Año - 4'], df['Ingresos de explotación EUR Últ año disp'])
```

```
ratios['CAGR_EBITDA'] = cagr(df['EBITDA EUR Año - 4'], df['EBITDA EUR Últ año disp'])
```

```
ratios['CAGR_Activos'] = cagr(df['Total activo EUR Año - 4'], df['Total activo EUR Últ año disp'])
```

#### PASO 5: RIESGO OPERATIVO (Volatilidad EBITDA)

```
ebitda_hist = df[[
```

```
    'EBITDA EUR Últ año disp',
```

```
    'EBITDA EUR Año - 1',
```

```
    'EBITDA EUR Año - 2',
```

```
    'EBITDA EUR Año - 3',
```

```
    'EBITDA EUR Año - 4'
```

```
]]
```

```
ratios['Volatilidad_EBITDA'] = ebitda_hist.std(axis=1) / ebitda_hist.mean(axis=1)
```

#### PASO 6: Z-SCORE DE ALTMAN (modificado para no cotizadas)

```
# Fórmula Z" = 0.717*A + 0.847*B + 3.107*C + 0.420*D + 0.998*E
```

```
ratios['A'] = (ratios['Activo_Circulante'] - ratios['Pasivo_Fijo']) / ratios['Activos']
```

```
ratios['B'] = ratios['Resultado'] / ratios['Activos']
```

```
ratios['C'] = ratios['EBIT'] / ratios['Activos']
```

```
ratios['D'] = ratios['Capital_Suscrito'] / ratios['Deuda']
```

```
ratios['E'] = ratios['Ingresos'] / ratios['Activos']
```

```
ratios['Z_score'] = (
```

```
    0.717 * ratios['A'] +
```

```
    0.847 * ratios['B'] +
```

```
    3.107 * ratios['C'] +
```

```
    0.420 * ratios['D'] +
```

```
    0.998 * ratios['E']
```

```
)
```

#### PASO 7: MOSTRAMOS LOS RATIOS CALCULADOS

```
# Seleccionar solo las columnas de ratios finales
```

```
ratios_finales = ratios[[
```

```
    'Nombre',
```

```
    'EBITDA_Margin',
```

```
    'FCF_Margin',
```

```
    'Deuda_Neta_EBITDA',
```

```
    'Deuda_Activos',
```

```
    'Cobertura_Intereses',
```

```
    'Tangibilidad',
```

```
    'Log_Ventas',
```

```
    'Log_Activos',
```

```
    'Log_Empleados',
```

```
    'CAGR_Ventas',
```

```
    'CAGR_EBITDA',
```

```
    'CAGR_Activos',
```

```
    'Volatilidad_EBITDA',
```

```
    'Z_score'
```

```
]]
```

```
# Mostrar los primeros resultados
ratios_finales.head(10)
```

### FILTRO OPCIONAL POR TAMAÑO.

```
#Cambiar a True si se quiere activar el filtro o a False si se quiere desactivarlo.
```

```
filtrar_por_tamaño = True
```

```
#Definir los límites del tamaño (puedes ajustar valores en millones)
```

```
limite_inferior= 10_000_000 #por ejemplo: empresas con ingresos > 10M€
```

```
limite_superior= 500_000_000 #por ejemplo: empresas con ingresos < 500€
```

```
if filtrar_por_tamaño:
```

```
    ratios=ratios[
        (ratios['Ingresos'] >= limite_inferior) &
        (ratios['Ingresos'] <= limite_superior)
    ]
```

### MODELO DE SCORING SENCILLO.

#### PASO 8: MODELO DE SCORING

```
# Copia de seguridad
```

```
ratios_scoring = ratios.copy()
```

```
# Lista de ratios a incluir en el score
```

```
ratios_usados = [
    'EBITDA_Margin', 'FCF_Margin', 'Deuda_Neta_EBITDA', 'Deuda_Activos',
    'Cobertura_Intereses', 'Tangibilidad', 'Log_Ventas', 'Log_Activos',
    'CAGR_Ventas', 'CAGR_EBITDA', 'CAGR_Activos', 'Volatilidad_EBITDA', 'Z_score'
]
```

```
# Invertir aquellos donde valores altos son negativos
```

```
ratios_scoring['Inv_Deuda_Neta_EBITDA'] = -ratios_scoring['Deuda_Neta_EBITDA']
```

```
ratios_scoring['Inv_Deuda_Activos'] = -ratios_scoring['Deuda_Activos']
```

```
ratios_scoring['Inv_Volatilidad_EBITDA'] = -ratios_scoring['Volatilidad_EBITDA']
```

```
# Reemplazar los originales por los invertidos donde corresponda
```

```
ratios_para_score = [
    'EBITDA_Margin',
    'FCF_Margin',
    'Inv_Deuda_Neta_EBITDA',
    'Inv_Deuda_Activos',
    'Cobertura_Intereses',
    'Tangibilidad',
    'Log_Ventas',
    'Log_Activos',
    'CAGR_Ventas',
    'CAGR_EBITDA',
    'CAGR_Activos',
    'Inv_Volatilidad_EBITDA',
    'Z_score'
]
```

```
# Normalizar a percentiles
```

```
for col in ratios_para_score:
```

```
    col_percentil = col + "_pct"
```

```
    ratios_scoring[col_percentil] = ratios_scoring[col].rank(pct=True)
```

```

# Calcular el score promedio (ponderación igual para empezar)
percentil_cols = [c + "_pct" for c in ratios_para_score]
ratios_scoring['LBO_Score'] = ratios_scoring[percentil_cols].mean(axis=1)

# Crear ranking descendente
ratios_scoring['Ranking_LBO'] = ratios_scoring['LBO_Score'].rank(ascending=False)

# Mostrar las 10 mejores empresas como targets
ratios_scoring[['Nombre', 'LBO_Score', 'Ranking_LBO']].sort_values(by='LBO_Score', ascending=False).head(10)
# Filtrar empresas que NO están extinguidas
ratios_scoring = ratios_scoring[~ratios_scoring['Nombre'].str.contains(r'(EXTINGUIDA)', case=False, na=False)]

```

## PASO 9: RANKING DE EMPRESAS GLOBAL

```

import matplotlib.pyplot as plt

# Top 10 empresas por LBO Score
top10 = ratios_scoring.sort_values(by='LBO_Score', ascending=False).head(10)

```

```

# Barplot horizontal
plt.figure(figsize=(10, 6))
plt.barh(top10['Nombre'], top10['LBO_Score'], color='steelblue')
plt.xlabel("LBO Target Score")
plt.title("Top 10 Empresas Más Atractivas para LBO")
plt.gca().invert_yaxis() # El más alto arriba
plt.tight_layout()
plt.show()

```

## PASO 10: PERFIL DE LA EMPRESA LIDER

### 10.1 Heatmap de ratios normalizados (empresa top)

```

import seaborn as sns

# Empresa top (primera del ranking)
empresa_top = top10.iloc[0]['Nombre']
ratios_normalizados = [c for c in ratios_scoring.columns if c.endswith('_pct')]

# Crear heatmap de esa empresa
vals = ratios_scoring[ratios_scoring['Nombre'] == empresa_top][ratios_normalizados]
plt.figure(figsize=(10, 1))
sns.heatmap(vals, cmap="YlGnBu", annot=True, cbar=False)
plt.title(f"Perfil de Scoring - {empresa_top}")
plt.yticks([])
plt.show()

```

### 10.2 Radar Chart

```

# Radar chart de los ratios normalizados de una empresa
from math import pi

empresa = ratios_scoring[ratios_scoring['Nombre'] == empresa_top]
labels = [col.replace('_pct', '') for col in ratios_normalizados]
values = empresa[ratios_normalizados].values.flatten().tolist()
values += values[:1] # Cerrar círculo

# Radar plot
angles = [n / float(len(labels)) * 2 * pi for n in range(len(labels))]
angles += angles[:1]

```

```

plt.figure(figsize=(8, 8))
ax = plt.subplot(111, polar=True)
plt.xticks(angles[:-1], labels, color='grey', size=8)
ax.plot(angles, values, linewidth=2, linestyle='solid')
ax.fill(angles, values, 'skyblue', alpha=0.4)
plt.title(f"Radar Chart - {empresa_top}", size=12, y=1.1)
plt.show()

```

## MODELO DE SCORING POR DIMENSIONES.

### PASO 11: MODELO DE SCORING

Dividimos los ratios en 5 grandes dimensiones, cada una con un sub-score (promedio de sus variables normalizadas).

Luego, calculamos el LBO Target Score como una combinación ponderada de estos sub-scores.

# Definir las dimensiones y sus ratios

```

dimensiones = {
    'Rentabilidad': ['EBITDA_Margin_pct', 'FCF_Margin_pct'],
    'Endeudamiento': ['Inv_Deuda_Neta_EBITDA_pct', 'Inv_Deuda_Activos_pct', 'Cobertura_Intereses_pct'],
    'Solidez': ['Tangibilidad_pct', 'Z_score_pct', 'Inv_Volatilidad_EBITDA_pct'],
    'Tamaño': ['Log_Ventas_pct', 'Log_Activos_pct'],
    'Crecimiento': ['CAGR_Ventas_pct', 'CAGR_EBITDA_pct', 'CAGR_Activos_pct']
}

```

# Calcular sub-scores por dimensión

for nombre, columnas in dimensiones.items():

```

    ratios_scoring[f'Score_{nombre}'] = ratios_scoring[columnas].mean(axis=1)

```

# Pesos para cada dimensión AJUSTABLES!!!!!!!!!!!!

```

pesos = {
    'Rentabilidad': 0.25,
    'Endeudamiento': 0.2,
    'Solidez': 0.2,
    'Tamaño': 0.15,
    'Crecimiento': 0.2
}

```

# Calcular LBO Target Score ponderado

```

ratios_scoring['LBO_Target_Score'] = sum(
    ratios_scoring[f'Score_{dim}'] * peso
    for dim, peso in pesos.items()
)

```

# Mostrar top 10 empresas con mejor score

```

ratios_scoring[['Nombre', 'LBO_Target_Score'] + [f'Score_{d}' for d in dimensiones.keys()]]\
    .sort_values(by='LBO_Target_Score', ascending=False).head(10)

```

### PASO 12: RANKING DE EMPRESAS GLOBAL

```

import matplotlib.pyplot as plt
import seaborn as sns

```

# Top 10 empresas

```

top10 = ratios_scoring.sort_values(by='LBO_Target_Score', ascending=False).head(10)

```

```

plt.figure(figsize=(10, 6))
sns.barplot(x='LBO_Target_Score', y='Nombre', data=top10, palette='viridis')
plt.title('Top 10 empresas por LBO Target Score')
plt.xlabel('Score')
plt.ylabel('Empresa')

```

```
plt.tight_layout()
plt.show()
```

### PASO 13: PERFIL DE LA EMPRESA LIDER

```
import seaborn as sns

# Empresa top (primera del ranking)
empresa_top = top10.iloc[0]['Nombre']
ratios_normalizados = [c for c in ratios_scoring.columns if c.endswith('_pct')]

# Crear heatmap de esa empresa
vals = ratios_scoring[ratios_scoring['Nombre'] == empresa_top][ratios_normalizados]
plt.figure(figsize=(10, 1))
sns.heatmap(vals, cmap="YlGnBu", annot=True, cbar=False)
plt.title(f'Perfil de Scoring - {empresa_top}')
plt.yticks([])
plt.show()
```

### PASO 14: RADAR CHART TOP 5

```
from math import pi

# Seleccionamos las 5 mejores empresas
empresas_top3 = top10['Nombre'].values[:5]
subscores = [f'Score_{d}' for d in dimensiones.keys()]
labels = list(dimensiones.keys())

# Ángulos para el radar chart
angles = [n / float(len(labels)) * 2 * pi for n in range(len(labels))]
angles += angles[:1] # cerrar círculo

plt.figure(figsize=(8, 8))

for nombre in empresas_top3:
    valores = ratios_scoring[ratios_scoring['Nombre'] == nombre][subscores].values.flatten().tolist()
    valores += valores[:1] # cerrar círculo
    plt.polar(angles, valores, label=nombre)
    plt.fill(angles, valores, alpha=0.1)

plt.xticks(angles[:-1], labels, color='grey', size=10)
plt.title('Radar chart - Comparativa de sub-scores (Top 5)', size=13, y=1.1)
plt.legend(loc='upper right', bbox_to_anchor=(1.3, 1))
plt.tight_layout()
plt.show()
```

## 9. BIBLIOGRAFÍA

Andrade, G., & Kaplan, S. N. (1998). *How costly is financial (not economic) distress? Evidence from highly leveraged transactions*. **Journal of Finance**, **53**(5), 1443–1493.

Axelson, U., Jenkinson, T., Strömberg, P., & Weisbach, M. S. (2013). *Borrow cheap, buy high? The determinants of leverage and pricing in buyouts*. **Journal of Finance**, **68**(6), 2223–2267. <https://doi.org/10.1111/jofi.12082>

Berk, J., & DeMarzo, P. (2020). *Corporate Finance* (5<sup>a</sup> ed.). Pearson.

Bocconi Students Investment Club. (2023, September). *The TXU LBO – The rise and fall of the biggest buyout ever*. [https://bsic.it/wp-content/uploads/2023/09/TXUDeal\\_Combined\\_Final.pdf](https://bsic.it/wp-content/uploads/2023/09/TXUDeal_Combined_Final.pdf)

Brar, G., Giamouridis, D., & Liodakis, M. (2009). *Predicting European takeover targets*. **European Financial Management**, **15**(2), 430–450.

Burrough, B., & Helyar, J. (1990). *Barbarians at the Gate: The Fall of RJR Nabisco*. Harper & Row.

Cohn, J. B., Hotchkiss, E. S., & Towery, E. (2022). *Sources of value creation in private equity buyouts of private firms*. Working Paper, University of Texas at Austin, January 2022. (p.1-50)

Guo, S., Hotchkiss, E. S., & Song, W. (2011). *Do buyouts (still) create value?*. **Journal of Finance**, **66**(2), 479–517.

Hammer, B., Marcotty-Dehm, N., Schweizer, D., & Schwetzler, B. (2022). *Pricing and value creation in private equity-backed buy-and-build strategies*. *Journal of Corporate Finance*, **77**, 102285, 1-28.

Jensen, M. C. (1986). *Agency costs of free cash flow, corporate finance, and takeovers*. **American Economic Review**, **76**(2), 323–329.

Jensen, M. C. (1989). *Eclipse of the public corporation*. **Harvard Business Review**, **67**(5), 61–74.

Jensen, M. C., & Meckling, W. H. (1976). *Theory of the firm: Managerial behavior, agency costs and ownership structure*. **Journal of Financial Economics**, **3**(4), 305–360.

Kaplan, S. (1989). *Management Buyouts: Evidence on Taxes as a Source of Value*. *The Journal of Finance*, **44**(3), 611–632. <https://doi.org/10.2307/2328773>

Kaplan, S. N., & Stein, J. C. (1993). *The evolution of buyout pricing and financial structure in the 1980s*. **Quarterly Journal of Economics**, **108**(2), 313–357.

- Kaplan, S. N., & Strömberg, P. (2009). *Leveraged buyouts and private equity*. **Journal of Economic Perspectives**, **23**(1), 121–146.
- Lehn, K., & Poulsen, A. (1989). *Free cash flow and stockholder gains in going private transactions*. **Journal of Finance**, **44**(3), 771–787.
- Liebeskind, J., Wiersema, M., & Hansen, G. (1992). *LBOs, corporate restructuring, and the incentive–intensity hypothesis*. **Financial Management**, **21**(1), 73–88.
- Lowenstein, L. (1985). *Management buyouts*. **Columbia Law Review**, **85**(3), 730–784.
- Maloney, M. T., McCormick, R. E., & Mitchell, M. L. (1993). *Managerial decision making and capital structure*. **Journal of Business & Economic Statistics**, **11**(4), 427–436.
- Mehran, H., & Peristiani, S. (2010). *Financial visibility and the decision to go private*. **Review of Financial Studies**, **23**(2), 519–547.
- Modigliani, F., & Miller, M. H. (1963). *Corporate income taxes and the cost of capital: A correction*. **American Economic Review**, **53**(3), 433–443.
- Officer, M. S., Ozbas, O., & Sensoy, B. A. (2010). *Club deals in leveraged buyouts*. *Journal of Financial Economics*, **98**(2), 214–240.
- Opler, T., & Titman, S. (1993). *The determinants of leveraged buyout activity: Free cash flow vs. financial distress costs*. **Journal of Finance**, **48**(5), 1985–1999.
- Palepu, K. G. (1986). *Predicting takeover targets: A methodological and empirical analysis*. **Journal of Accounting and Economics**, **8**(1), 3–35.
- Renneboog, L., Simons, T., & Wright, M. (2007). *Why do public firms go private in the UK? The impact of private equity investors on the performance of target firms*. **Journal of Corporate Finance**, **13**(4), 591–628.
- Roden, D. M., & Lewellen, W. G. (1995). *Corporate capital structure decisions: Evidence from leveraged buyouts*. **Financial Management**, **24**(2), 76–87.
- Rosenbaum, J., & Pearl, J. (2009). *Investment Banking: Valuation, Leveraged Buyouts, and Mergers & Acquisitions*. John Wiley & Sons.
- Shleifer, A., & Summers, L. H. (1988). *Breach of trust in hostile takeovers*. En A. J. Auerbach (Ed.), **Corporate Takeovers: Causes and Consequences** (pp. 33–68). University of Chicago Press.

Singh, H. (2020, January 18). *Evolving of leveraged buyouts: A new era or back to square one?* NYU Journal of Law & Business. <https://www.nyuilb.org/single-post/2020/01/18/evolving-of-leveraged-buyouts-a-new-era-or-back-to-square-one>

Sudarsanam, S., Wright, M., & Huang, J. (2011). *Target bankruptcy risk and its impact on going-private buyout performance and exit*. **Corporate Governance: An International Review**, 19(3), 240–258.

Wright, M., Renneboog, L., Simons, T., & Scholes, L. (2006). *Leveraged buyouts in the UK and continental Europe: Retrospect and prospect*. **Journal of Applied Corporate Finance**, 18(3), 38–55.

Wright, M., Thompson, S., & Robbie, K. (1992). *Venture capital and management-led leveraged buyouts: A European perspective*. **Journal of Business Venturing**, 7(1), 47–71.

## 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, [Nombre completo del estudiante], estudiante de [nombre del título] de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "[Título del trabajo]", 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. **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. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Estudios multidisciplinares:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
7. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
8. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
9. **Generador previo de diagramas de flujo y contenido:** Para esbozar diagramas iniciales.
10. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
11. **Generador de datos sintéticos de prueba:** Para la creación de conjuntos de datos ficticios.
12. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
13. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
14. **Generador de encuestas:** Para diseñar cuestionarios preliminares.
15. **Traductor:** Para traducir textos de un lenguaje a otro.

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: 17 de junio de 2025

Firma: \_\_\_\_\_



Carlota Rodríguez Martín de Eugenio