

TRABAJO DE INVESTIGACIÓN FINAL

Evaluación de la precisión de un simulador de valuación empresarial en operaciones reales de M&A.

Autor/es:

Murua, Mariano Agustin - LU: 1135399

Solari, Matias - LU: 1137004

Carrera:

Lic Finanzas

Tutor/a:

Favata, Federico

Año:

2026

Dedicatoria

Dedicamos este trabajo de investigación a todos los compañeros y profesores que nos acompañaron a lo largo de estos años en la universidad. Especialmente a Federico Favata por acompañarnos en el desarrollo del presente trabajo y a Karina Elizabeth Diaz por guiarnos en el taller de Investigación Final. Finalmente, agradecer a nuestras familias por su apoyo a lo largo de nuestra carrera académica.

Resumen

El presente trabajo tiene por objetivo desarrollar y validar un simulador de valuación de empresas aplicado a operaciones de fusiones y adquisiciones (M&A) en el sector tecnológico estadounidense, para los períodos 2019, 2021 y 2025. Mediante un enfoque de valuación relativa basado en el múltiplo EV/Sales ajustado por el Descuento por Falta de Mercado (DLOM), el simulador estima el valor de empresas de capital privado utilizando como referencia un grupo de comparables cotizantes. La metodología combina la construcción técnica del múltiplo con ajustes propios del capital cerrado, validando la precisión del modelo a través del Error Porcentual Absoluto Medio (MAPE). La investigación se enmarca en la literatura financiera sobre valuación relativa, asimetría de información y particularidades del capital privado. Los resultados esperados indican que el simulador alcanzará un MAPE inferior al 10%, demostrando que un modelo basado en fundamentos financieros, debidamente ajustado, puede estimar el valor de empresas en transacciones de M&A con alta precisión.

Palabras clave: fusiones y adquisiciones, valuación relativa, EV/Sales, capital privado, DLOM

Abstract

This paper aims to develop and validate a company valuation simulator applied to mergers and acquisitions (M&A) transactions in the United States technology sector for the periods 2019, 2021, and 2025. Through a relative valuation approach based on the EV/Sales multiple, adjusted for the Discount for Lack of Marketability (DLOM), the simulator estimates the value of privately held companies using a publicly traded peer group as reference. The methodology combines the technical construction of the multiple with private capital-specific adjustments, validating the model's accuracy through the Mean Absolute Percentage Error (MAPE). The research is grounded in the financial literature on relative valuation, information asymmetry, and the structural characteristics of closely held firms. Expected results indicate that the simulator will achieve a MAPE below 10%, demonstrating that a financially grounded model, properly adjusted for private company conditions, can estimate M&A transaction values with high precision.

Keywords: mergers and acquisitions, relative valuation, EV/Sales, private equity, DLOM

Contenido

Dedicatoria.....	1
Resumen.....	2
Abstract.....	2
1. Introducción.....	6
2. Planteamiento del problema.....	7
3. Objetivos.....	8
a. Objetivo general.....	8
b. Objetivos particulares.....	8
4. Hipótesis.....	8
5. Marco Teórico.....	8
a. Fusiones y Adquisiciones (M&A).....	9
i. Concepto y tipología.....	9
ii. Oleadas históricas de M&A.....	9
iii. El Sector Tecnológico como Contexto de Análisis.....	10
b. Valuación de Empresas en Contextos de M&A.....	11
i. Fundamentos de la valuación empresarial.....	11
ii. Métodos de valuación.....	12
iii. Valuación relativa y el múltiplo EV/Sales.....	14
iv. Construcción técnica y componentes del ratio EV/Sales.....	14
c. EV/Sales frente a otros múltiplos.....	15
d. Selección y construcción del Peer Group.....	16
e. Modelización financiera y el rol de los simuladores.....	17
f. Particularidades de las Empresas de Capital Privado.....	18
i. Diferencias respecto a empresas cotizantes.....	18
ii. Asimetría de información.....	19
iii. Descuento por Falta de Mercado (DLOM).....	19
iv. Índice de volatilidad: VIX.....	20
g. Prima de Control y Factores de Ajuste en Transacciones de M&A.....	21
i. La prima de control.....	21
ii. Sinergias y otros factores de ajuste.....	21
h. Evaluación de la Precisión del Simulador: El MAPE.....	22
i. Test de Wilcoxon y Correlación de Spearman.....	23
6. Metodología.....	24
a. Enfoque metodológico.....	24
b. Fuentes de datos.....	24
c. Consideraciones previas y delimitaciones.....	25
d. Construcción del simulador.....	28
i. Visión general del sistema.....	28
ii. Jerarquización del código.....	28
iii. Concatenación entre bloques.....	28

iv. Secuencia detallada de los bloques.....	29
1. Bloque 1 — Simulador de Valuación.....	29
2. Bloque 2 — Análisis Estadístico de Error.....	30
3. Bloque 3 — Resumen Comparativo Inter-Anual.....	31
e. Dependencias del sistema.....	31
7. Análisis de Resultados.....	32
a. Validación cruzada con fuentes primarias.....	32
b. Sector Tecnología.....	32
c. Sector Consumo Básico: incorporación como análisis complementario.....	34
d. Sesgo, ajustes y capacidad predictiva comparada.....	35
e. Prima de control y sinergias como factores explicativos del error.....	38
8. Conclusión.....	40
a. Síntesis y contraste de resultados.....	40
b. Jerarquía de los hallazgos.....	40
i. Primer nivel: la incompatibilidad estructural entre datos y múltiplo.....	40
ii. Segundo nivel: el impacto de los ajustes de revenues sobre la naturaleza del error.....	41
iii. Tercer nivel: la asimetría sectorial.....	42
c. Limitaciones y líneas de investigación futura.....	43
Anexos.....	46
Anexo A: Transacciones de M&A.....	46
A.1 Sector Tecnológico 2019.....	46
A.2 Sector Tecnológico 2021.....	46
A.3 Sector Tecnológico 2025.....	47
A.4 Sector Consumo 2019.....	47
A.5 Sector Consumo 2021.....	47
A.6 Sector Consumo 2025.....	48
A.7 Lista múltiplos EV/SALES Damodaran.....	49
Anexo B: Código del Simulador de Valuación.....	51
B.1 Bloque 1 — Simulador de Valuación.....	51
B.2 Bloque 2 — Análisis Estadístico de Error.....	53
B.3 Bloque 3 — Resumen Comparativo Inter-Anual.....	54
Anexo C: Resultados del Simulador.....	56
C.1 Sector Tecnología — Ventas BMG.....	56
C.1.1 Año 2019.....	56
C.1.2 Año 2021.....	56
C.1.3 Año 2025.....	56
C.1.4 Conjunto de los tres años (2019, 2021 y 2025).....	57
C.2 Sector Tecnología — Ventas Ajustadas.....	57
C.2.1 Año 2019.....	57
C.2.2 Año 2021.....	57

C.2.3 Año 2025.....	58
C.2.4 Conjunto de los tres años (2019, 2021 y 2025).....	58
C.3 Sector Consumo Básico— Ventas BMG.....	58
C.3.1 Año 2019.....	58
C.3.2 Año 2021.....	59
C.3.3 Año 2025.....	59
C.3.4 Conjunto de los tres años (2019, 2021 y 2025).....	59
C.4 Sector Consumo Básico— Ventas Ajustadas.....	60
C.4.1 Año 2019.....	60
C.4.2 Año 2021.....	60
C.4.3 Año 2025.....	60
C.4.4 Conjunto de los tres años (2019, 2021 y 2025).....	61
C.5 Cuadro Comparativo entre Combinaciones.....	61
Anexo D: Librerías.....	62
Bibliografía.....	62

1. Introducción

La valuación de empresas constituye uno de los pilares fundamentales de las finanzas corporativas, adquiriendo especial relevancia en los procesos de fusiones y adquisiciones (M&A). Determinar el valor de una compañía con precisión no solo condiciona el éxito de una transacción, sino que define la estrategia de negociación de las partes y el impacto económico sobre el adquirente.

Desde el área de las finanzas corporativas, la valuación de empresas privadas ha sido históricamente un campo de estudio complejo. Damodaran (2009) sostiene que los profesionales de las finanzas enfrentan desde hace tiempo el desafío de valorar con precisión empresas que no se ajustan a las metodologías convencionales, es decir, compañías que resisten una valuación sencilla. Esta dificultad se acentúa en el caso de las empresas de capital cerrado, ya que no disponen de precios de mercado observables ni de información financiera de acceso público, lo que genera una marcada asimetría informativa. Pratt, Reilly y Schweih (1995) destacan que los atributos de comerciabilidad y control accionario son consideraciones fundamentales en cualquier proceso de valuación de empresas cerradas, dado que la imposibilidad de liquidar una participación en el mercado público eleva sustancialmente el riesgo para el inversor. En este contexto, la aplicación del Descuento por Falta de Mercado (DLOM) emerge como un ajuste técnico indispensable para reflejar la iliquidez inherente a este tipo de compañías.

El presente trabajo propone el desarrollo y la validación empírica de un simulador de valuación empresarial orientado específicamente a operaciones de M&A entre empresas de capital privado y público concretadas en el sector tecnológico de los Estados Unidos durante los años 2019, 2021 y 2025. La elección no es arbitraria: estos fueron los que superaron el volumen de transacciones promedio de la última década, mientras que el sector tecnológico fue el que registró la mayor cantidad de operaciones en dichos años, lo que convierte en escenarios representativos y con suficientes datos para sostener un análisis comparativo robusto. La estructura del trabajo se organiza en tres ejes: el marco teórico sobre la valuación de un M&A, el desarrollo metodológico del simulador mediante la selección de transacciones reales y el análisis comparativo de resultados.

La relevancia del trabajo reside en la brecha entre los modelos académicos disponibles y su aplicabilidad real. Gaughan (2017) subraya que una valuación adecuada puede ser el factor determinante entre una transacción exitosa y una fallida, es por eso que se

busca cubrir la necesidad de herramientas más precisas. El simulador propuesto busca cubrir esa brecha, evaluando su performance mediante el Error Porcentual Absoluto Medio (MAPE) con la hipótesis de que este se mantendrá por debajo del 10% respecto a los precios de cierre reales. La elección del tema nace de la observación directa de las limitaciones que enfrentan las empresas privadas para acceder a herramientas de valuación confiables, representando este trabajo una síntesis entre el rigor académico de la Licenciatura en Finanzas y la vocación por generar conocimiento aplicable al mercado.

2. Planteamiento del problema

La valuación de empresas es vital en procesos de fusiones y/o adquisiciones permitiendo la estimación de un valor objetivo para la transacción. En el presente, este proceso se enfrenta a barreras que limitan la valuación, siendo principalmente la asimetría de información en compañías de capital privado como también la ineficiencia en tiempos, costos y la rigidez de los modelos de valuación tradicionales.

Los modelos de valuación muchas veces no son utilizables en la práctica debido a la dificultad de obtener las métricas necesarias para arribar a un resultado confiable. Como indica Sherman (2012), una valuación mediante análisis comparable puede no ser posible o puede arrojar resultados poco realistas debido a que las métricas necesarias para tomar decisiones cruciales podrían no estar disponibles. Además, uno de los principales objetivos de la información financiera de una compañía privada es mostrar altos beneficios en sus EEEF en búsqueda de atraer inversores, mientras que las empresas de capital privado no están centradas en la maximización de beneficios sino en minimizar la carga fiscal.

Bajo este escenario, la investigación tiene como propósito desarrollar un simulador que ajuste estas dificultades, permitiendo arribar a una valuación de M&A proporcionando un rango de valor intrínseco que demuestre precisión al ser comparado con los cierres de las transacciones efectivas. El estudio se justifica principalmente por la eficiencia que otorga el simulador al proceso actual de M&A y, por ende, un impacto en el costo de la adquirente. Como así también permitir comprender si la asimetría de información en empresas de capital privado es un factor determinante que dificulte o impida arribar a una valuación confiable.

En base a lo expuesto anteriormente se buscará responder a lo largo del trabajo de investigación las siguientes preguntas:

¿Cómo varía el nivel de precisión de un simulador de valuación basado en fundamentos financieros al estimar el valor de empresas en transacciones reales de M&A en EEUU durante los años 2019, 2021 y 2025?

¿Cómo afecta la asimetría de la información en la metodología de valuación?

¿A qué factores responden las diferencias sistemáticas entre el valor estimado y el valor final negociado?

3. Objetivos

a. Objetivo general

Determinar la capacidad del simulador de valuación para calcular el valor de transacciones de fusiones y adquisiciones partiendo del método de valuación relativa, tomando como base el estudio de transacciones en EEUU durante los años 2019, 2021 y 2025.

b. Objetivos particulares

Examinar el impacto de las primas de control y las sinergias como factores explicativos de las subvaluaciones del modelo frente al precio final negociado.

Establecer relación entre las subvaluaciones (precio real > simulado) que responden a la aplicación de Descuentos por Falta de Mercado (DLOM).

Analizar el impacto de los factores que responden a las desviaciones entre el valor intrínseco estimado y el precio final negociado.

4. Hipótesis

El simulador de valuación de empresas presenta un MAPE (Error Porcentual Absoluto Medio) menor al 10% respecto a los valores determinados en las transacciones reales utilizadas como base para el mismo.

5. Marco Teórico

Como parte del marco teórico, en el presente trabajo se abordarán los conceptos fundamentales de las Fusiones y Adquisiciones (M&A) y los pilares técnicos de la valuación empresarial, con especial énfasis en el enfoque de valuación relativa y el uso de múltiplos. Por consiguiente, se explayará sobre las particularidades que presentan las empresas de capital privado analizando el efecto de la asimetría de información y la aplicación de ajustes críticos como el Descuento por Falta de Mercado (DLOM) y la

Prima de Control. Finalmente, se abordará la metodología estadística para evaluar la precisión del simulador propuesto mediante el Error Porcentual Absoluto Medio (MAPE), situando el análisis en el contexto dinámico del sector tecnológico estadounidense.

a. Fusiones y Adquisiciones (M&A)

i. Concepto y tipología

Las fusiones y adquisiciones (M&A, por sus siglas en inglés *mergers and acquisitions*) constituyen operaciones de reorganización estructural mediante las cuales dos o más compañías combinan sus activos, pasivos y operaciones. Gaughan (2017) distingue entre fusión, como la unión de dos entidades que dan lugar a una nueva, y adquisición, como la compra por parte de una empresa de una participación mayoritaria en otra. Estas transacciones pueden ser horizontales (entre competidores del mismo sector), verticales (entre empresa y proveedor o distribuidor) o conglomeradas (entre empresas de sectores no relacionados). Desde una perspectiva estratégica, las motivaciones que impulsan una operación de M&A son variadas: búsqueda de sinergias operativas o financieras, acceso a nuevos mercados, incorporación de tecnología o talento humano, y la consecución de economías de escala, entre otras (Ghosh, 2017). La correcta identificación de estas motivaciones resulta esencial para entender las primas pagadas por encima del valor intrínseco de la empresa objetivo.


ii. Oleadas históricas de M&A

La literatura documenta la existencia de ciclos u "ondas" en la actividad de M&A fuertemente correlacionadas con las condiciones del mercado de capitales y el ciclo económico. Mascareñas (2013) identifica seis grandes oleadas desde finales del siglo XIX, cada una caracterizada por una tipología dominante de transacciones y un contexto macroeconómico particular. Los períodos seleccionados en la presente investigación (2019, 2021 y 2025) corresponden a etapas de elevada actividad transaccional en el sector tecnológico de los Estados Unidos donde se supera el volumen promedio de la última década, lo cual los convierte en muestras representativas y metodológicamente pertinentes. Según el informe de Bain & Company (2026), el año 2025 fue catalogado como el año del "gran rebote" en actividad de M&A a nivel global, luego de un período de contracción post-pandemia con el sector tecnológico como principal motor. J.P. Morgan (2026) refuerza esta perspectiva en su outlook anual de M&A, destacando el rol de los activos de

inteligencia artificial y plataformas digitales como objetivos predilectos de adquisición. Comprender esta dinámica transaccional y el alto volumen de operaciones exige adentrarse en los mecanismos técnicos que determinan los precios pactados, es decir, en los fundamentos de la valuación.

Desde una perspectiva macroeconómica, Weston, Mitchell y Mulherin (2004) sostienen que las M&A cumplen una función de eficiencia asignativa en la economía: permiten reasignar recursos desde usos de menor valor hacia usos de mayor valor, y que su ocurrencia en oleadas responde a shocks económicos e industriales específicos tales como cambios regulatorios, avances tecnológicos o fluctuaciones en el costo del capital.

Figura 1. Volumen y cantidad de acuerdos 2016-2019



Fuente: Elaboración propia en base a J.P. Morgan (2026)

iii. El Sector Tecnológico como Contexto de Análisis

El sector tecnológico ha sido seleccionado como universo de análisis por su posición dominante en la actividad global de M&A durante los períodos estudiados (2019, 2021 y 2025). Este sector presenta características diferenciales que impactan directamente sobre los procesos de valuación: alta proporción de activos intangibles (patentes, algoritmos, marcas, bases de datos), modelos de negocio basados en el crecimiento de usuarios más que en la rentabilidad corriente, y una elevada dispersión en los múltiplos de valuación entre subsectores (software, hardware, fintech, e-commerce, inteligencia artificial). La literatura documenta que las primas de control en el sector tecnológico son sistemáticamente superiores al promedio del mercado, en gran medida porque las

adquisiciones persiguen objetivos estratégicos vinculados a la eliminación de competidores potenciales, la adquisición de talento humano especializado (acqui-hires) o el acceso a tecnologías disruptivas (Alexandridis et al., 2022). Esta particularidad refuerza la necesidad de un simulador que incorpora los ajustes metodológicos adecuados para estimar valores en un sector donde los modelos tradicionales de valuación presentan mayores limitaciones.

b. Valuación de Empresas en Contextos de M&A

i. Fundamentos de la valuación empresarial

La valuación de empresas constituye el proceso mediante el cual se estima el valor económico de una compañía con el fin de facilitar la toma de decisiones en transacciones, reestructuraciones o análisis de inversión. Al profundizar en este proceso, la literatura financiera exige trazar una distinción estructural crítica entre dos dimensiones de valor: el Enterprise Value (Valor de la Empresa o Valor Operativo) y el Equity Value (Valor del Patrimonio Accionario). Según Koller, Goedhart y Wessels (2020) el Enterprise Value representa el valor total del núcleo operativo del negocio, independientemente de cómo esté financiado; por lo tanto, es el valor disponible para todos los proveedores de capital (tanto acreedores como accionistas). Por el contrario, el Equity Value constituye el valor residual que pertenece exclusivamente a los accionistas, el cual se obtiene matemáticamente al deducir del Enterprise Value la deuda financiera y sumarle la caja y equivalentes (Damodaran, 2012). Independientemente de la dimensión que se busque medir, Damodaran (2009) establece que toda valuación se apoya sobre tres pilares fundamentales: los flujos de caja que el activo generará en el futuro, la tasa de crecimiento esperada de dichos flujos y la tasa de descuento que refleja el riesgo asociado.

En el contexto de M&A, la valuación adquiere una dimensión adicional: la negociación entre partes con asimetrías de información y distintas percepciones del valor estratégico de la transacción. En este ecosistema transaccional, el enfoque metodológico predominante —y el adoptado por el simulador propuesto— recae sobre el Enterprise Value. Como argumenta Sherman (2012), la utilización del Enterprise Value permite evaluar el desempeño puramente operativo de la firma objetivo, neutralizando las distorsiones generadas por su estructura de capital actual. Dado que en las operaciones de M&A el adquirente habitualmente asume el control total y reestructura la deuda de la compañía comprada, aislar el valor del negocio de sus

decisiones previas de apalancamiento resulta esencial para realizar comparaciones relativas objetivas (Caselli, 2010).

Como introducción al principio fundamental que resulta especialmente relevante para el presente trabajo: *"intrinsic value is unobservable. An opportunity to create value exists where price and intrinsic value differ"* (Bruner, 2004, p. 3) [el valor intrínseco es inobservable. Una oportunidad de crear valor existe precisamente donde el precio y el valor intrínseco difieren]. Esta premisa es la que justifica la construcción de un simulador: no para determinar un precio exacto, sino para acotar un rango de valor intrínseco que sirva como referencia objetiva en la negociación.

ii. Métodos de valuación

Se reconocen tres grandes enfoques metodológicos para la valuación de empresas. El primero es el enfoque de ingresos, cuyo exponente principal es el Descuento de Flujos de Caja (DCF) que estima el valor presente de los flujos futuros esperados utilizando una tasa de descuento ajustada por riesgo. El segundo es el enfoque de mercado o valuación relativa, que determina el valor de la empresa a partir de múltiplos observados en empresas comparables cotizantes o en transacciones precedentes. El tercero es el enfoque de activos, basado en el valor de reposición o liquidación de los activos netos de la compañía.

La elección de la valuación relativa como metodología central del simulador no es arbitraria, sino el resultado de una evaluación sistemática de la aplicabilidad de cada enfoque al contexto específico de empresas de capital privado en operaciones de M&A. El DCF presenta limitaciones estructurales críticas en este contexto: requiere proyecciones de flujos de caja futuros y una tasa de descuento ajustada por riesgo que, en ausencia de información financiera auditada y pública, se vuelven supuestos altamente subjetivos y difícilmente verificables. Damodaran (2009) advierte que el DCF aplicado a empresas privadas convierte al modelo en una cadena de estimaciones sobre estimaciones, dado que sus variables de entrada —flujos de caja, tasa de crecimiento y costo de capital— son todas inobservables. Esta limitación se acentúa en el sector tecnológico, donde las empresas frecuentemente no son rentables en sus etapas de crecimiento, tornando inoperante cualquier proyección basada en utilidades históricas. El enfoque de activos resulta igualmente inadecuado para este universo de análisis: las empresas tecnológicas concentran su valor en activos intangibles —propiedad intelectual, bases de usuarios, algoritmos y capital humano— que no

figuran en el balance a valor de mercado ni son susceptibles de valuación por costo de reposición o liquidación sin incurrir en estimaciones de alta discrecionalidad (DePamphilis, 2022).

Respecto de la valuación relativa, el propio Sherman (2012) advierte que:

in some cases, a comparable analysis may not be possible or may yield unrealistic results. If the target company is closely held, comparable company or transaction analysis may be difficult or impossible, as the metrics necessary to make crucial judgments may not be available. [En algunos casos, un análisis comparable puede no ser posible o puede arrojar resultados poco realistas. Si la empresa objetivo es de capital cerrado, el análisis comparable puede ser difícil o imposible, ya que las métricas necesarias para tomar decisiones cruciales podrían no estar disponibles]

(Sherman, 2012, p. 189)

La literatura evidencia además que los estudios empíricos sobre precisión de modelos de valuación en M&A son escasos y presentan limitaciones que el presente trabajo busca subsanar. Kaplan y Ruback (1995) constituyen el antecedente más relevante: validaron la precisión del DCF contra 51 transacciones reales completadas entre 1983 y 1989 obteniendo estimaciones dentro del 10% del valor de cierre. Sin embargo, su análisis se circunscribió a operaciones de alto apalancamiento con empresas públicas, sin contemplar los ajustes requeridos por la iliquidez y la asimetría informativa de las firmas de capital cerrado. Por su parte, Liu, Nissim y Thomas (2002) evaluaron la precisión de distintos múltiplos de valuación concluyendo que aquellos basados en ventas presentan el menor rendimiento relativo frente a métricas de utilidad o flujo de caja. Esta evidencia, lejos de invalidar la elección del EV/Sales, refuerza su selección en el presente trabajo: precisamente cuando las métricas de utilidad son inobservables o están distorsionadas por incentivos fiscales —condición estructural de las empresas privadas— el múltiplo de ventas emerge como la única base comparativa disponible y metodológicamente consistente. Officer (2007), al valorar empresas privadas en M&A mediante análisis comparable, documentó que estas transacciones se cierran sistemáticamente a múltiplos menores que las equivalentes públicas, confirmando la necesidad de ajustes como el DLOM. No se identifican en la literatura estudios que validen empíricamente la precisión de un simulador basado en el múltiplo EV/Sales

frente a transacciones reales de M&A en el sector tecnológico estadounidense, incorporando simultáneamente los ajustes por iliquidez propios del capital privado. Esta brecha constituye la razón de ser del presente trabajo.

iii. Valuación relativa y el múltiplo EV/Sales

El múltiplo *Enterprise Value to Sales* (EV/Sales) relaciona el valor operativo total de la firma con sus ingresos operativos. Su elección como métrica central en el simulador se justifica por su robustez ante las particularidades contables de las empresas privadas. Como señala Sherman, “(...) a closely held private company's management may be a sole entrepreneur or small group that wishes to minimize the earnings shown on its financial reports in order to minimize the tax burden.” [La gerencia de una empresa privada de capital cerrado puede estar conformada por un único empresario o un grupo pequeño cuyo objetivo es minimizar las utilidades expuestas en sus estados financieros para así reducir su carga impositiva] (Sherman, 2012, p. 142). El proceso de valuación relativa consiste en seleccionar un grupo de empresas públicas comparables a la firma objetivo (el “peer group”) y calcular el múltiplo promedio. Dicho múltiplo se aplica sobre los ingresos de la empresa target para estimar su EV. La selección del peer group constituye uno de los pasos más críticos del análisis, ya que la falta de comparables adecuados puede introducir sesgos significativos en la estimación. Precisamente, esta dificultad metodológica en la selección y ajuste de métricas se vuelve aún más compleja frente a empresas no cotizantes, lo que obliga a considerar las limitaciones estructurales del capital privado.

iv. Construcción técnica y componentes del ratio EV/Sales

Para la implementación del simulador propuesto, resulta imperativo desglosar la arquitectura financiera del múltiplo EV/Sales. El Enterprise Value (EV) representa el valor total del negocio independientemente de su estructura de capital, disponible para todos los proveedores de capital — tanto acreedores como accionistas. Según Koller, Goedhart y Wessels (2020), el EV se obtiene sumando el valor de mercado del patrimonio común y preferido y la deuda financiera que devenga intereses, deduciendo la caja y equivalentes — activos que pertenecen a los accionistas y no forman parte del valor operativo del negocio. El ratio se perfecciona al dividir este valor por las Ventas Brutas Operativas de los últimos doce meses (TTM). La utilización de las ventas como denominador proporciona una base de valuación más estable y menos sujeta a manipulaciones contables que las métricas de utilidad (Sherman, 2012).

$$\frac{EV}{Sales} = \frac{Market\ Value\ of\ Equity + Market\ Value\ of\ Debt - Cash\ \&\ Equivalents}{Sales}$$

c. EV/Sales frente a otros múltiplos

Si bien el Enterprise Value constituye la dimensión de valor predominante en los procesos de M&A, la literatura financiera reconoce múltiples denominadores posibles para la construcción de ratios comparativos: EV/EBITDA, EV/EBIT y EV/Sales son los más utilizados en la práctica profesional. La elección del denominador no es neutral — determina sobre qué variable se ancla la comparación y, por ende, qué distorsiones se amplifican o mitigan en el resultado. Koller, Goedhart y Wessels (2020) señalan que el EV/EBITDA es el múltiplo de mayor adopción en transacciones de M&A, dado que el EBITDA aproxima el flujo de caja operativo libre de distorsiones contables por depreciación y amortización, facilitando comparaciones entre empresas con distintas políticas de inversión en activos fijos. Sin embargo, esta ventaja presupone que el EBITDA es una métrica positiva y confiable — condición que no se cumple en una porción significativa del universo de análisis del presente trabajo. En el sector tecnológico, es frecuente que empresas en etapas de crecimiento operen con EBITDA negativo o cercano a cero, lo que torna al ratio EV/EBITDA matemáticamente inoperante o produce valores extremos que distorsionan el múltiplo del peer group (Damodaran, 2009). La misma limitación aplica al EV/EBIT, cuyo denominador se ve adicionalmente afectado por las políticas de amortización de intangibles — partida de especial relevancia en empresas tecnológicas con alta proporción de activos adquiridos. Liu, Nissim y Thomas (2002) documentan que los múltiplos basados en ventas presentan menor precisión relativa que los basados en utilidades cuando estas son positivas y estables. No obstante, los propios autores reconocen que esa conclusión se invierte en contextos donde las métricas de utilidad son negativas, inobservables o sistemáticamente distorsionadas, precisamente la condición estructural de las empresas de capital privado del sector tecnológico, cuya gestión financiera está orientada a la minimización de la carga fiscal antes que a la maximización del beneficio reportado (Sherman, 2012). En este marco, el EV/Sales emerge como el único múltiplo de Enterprise Value que opera con una variable financiera disponible, positiva y comparable en la totalidad del universo de análisis: los ingresos por ventas son la línea del estado de resultados menos susceptible de manipulación contable y la más

frecuentemente reportada incluso en empresas de capital cerrado, independientemente de su etapa de madurez o rentabilidad.

d. Selección y construcción del Peer Group

El *peer group* —o grupo de empresas comparables— constituye el conjunto de compañías cotizantes que actúa como referencia de mercado para la estimación del múltiplo EV/Sales aplicable a la empresa objetivo. Su construcción no representa un paso auxiliar del proceso de valuación relativa sino su fundamento cardinal: un *peer group* inadecuado invalida de forma irreversible el múltiplo resultante, con independencia de la rigurosa técnica con la que este sea aplicado con posterioridad sobre los estados financieros de la empresa *target*. Bhojraj y Lee (2002) documentan empíricamente que la calidad en la selección de comparables determina en mayor medida la precisión del resultado que la elección del múltiplo específico utilizado, subrayando que el criterio de selección de pares es, en sí mismo, una decisión metodológica de primer orden.

Los criterios de construcción del peer group reconocidos en la literatura financiera responden a tres dimensiones: sectorial, financiera y temporal. La dimensión sectorial exige que las empresas seleccionadas pertenezcan al mismo sector o subsector de actividad que la empresa target, medido bajo una clasificación estandarizada dado que empresas de distintos sectores presentan estructuras de ingresos, márgenes y perfiles de riesgo heterogéneos que distorsionan la comparabilidad del múltiplo (Damodaran, 2012). La dimensión financiera requiere que el tamaño de las empresas sea comparable al del target en términos de ventas, con el fin de controlar las diferencias sistemáticas en múltiplos asociadas al tamaño relativo de la firma. La dimensión temporal establece que los datos utilizados para el cálculo del múltiplo deben corresponder al mismo período de referencia que los de la empresa target —típicamente los últimos doce meses (TTM, Trailing Twelve Months)— para evitar distorsiones derivadas de cambios en las condiciones de mercado.

En lo que respecta al tamaño óptimo del peer group, Cooper y Lambertides (2016) demuestran que utilizar entre cinco y diez empresas comparables seleccionadas por similitud sectorial y financiera genera estimaciones tan precisas como las obtenidas con la totalidad del sector, reduciendo simultáneamente el ruido estadístico introducido por compañías cuyas características estructurales se alejan significativamente del target. Este hallazgo es especialmente relevante en el sector tecnológico, donde la

dispersión de múltiplos entre subsectores (software, hardware, fintech, inteligencia artificial) es sustancialmente mayor que en sectores industriales tradicionales. La comprensión de cómo se construye e interpreta el peer group resulta indispensable para entender la arquitectura técnica del múltiplo EV/Sales.

e. Modelización financiera y el rol de los simuladores

En el ámbito de las finanzas corporativas, un simulador actúa como una herramienta de soporte a la decisión que permite automatizar cálculos complejos y realizar análisis de sensibilidad de forma eficiente. Al respecto, se destaca:

There are three important points that need to be made about all valuation. The first is to adhere to the principle of parsimony, which essentially states that you do not use more inputs than you absolutely need to value an asset. The second is to recognize that there is a trade-off between the additional benefits of building in more detail and the estimation costs (and error) with providing the detail. The third is to understand that models don't value companies—you do- [Hay tres puntos importantes que conviene destacar sobre toda valoración. El primero es adherirse al principio de parsimonia, que básicamente establece que no se deben utilizar más datos de los estrictamente necesarios para valorar un activo. El segundo es reconocer que existe una compensación entre los beneficios adicionales de incorporar más detalles y los costos (y errores) de estimación que conlleva proporcionarlos. El tercero es comprender que los modelos no valoran las empresas; lo hace usted.]

(Damodaran, 2012, p. 21)

La implementación de un simulador en el proceso de M&A no busca reemplazar el juicio profesional sino mitigar la incertidumbre mediante la cuantificación rápida de escenarios, permitiendo a los analistas enfocarse en la interpretación estratégica de los resultados en lugar de en la carga mecánica de datos.

DePamphilis (2022) argumenta que los modelos financieros aplicados a M&A deben evaluarse no solo por su capacidad predictiva, sino también por sus limitaciones estructurales: la calidad de los supuestos de entrada, la disponibilidad de información comparable y la sensibilidad de los resultados ante cambios en las variables clave. En

este sentido, la utilización del MAPE como métrica de precisión del simulador propuesto en el presente trabajo responde directamente a esta necesidad de evaluación sistemática de la fiabilidad del modelo.

f. Particularidades de las Empresas de Capital Privado

i. Diferencias respecto a empresas cotizantes

En el contexto de las finanzas corporativas, se distinguen dos grandes categorías de empresas según la naturaleza de su estructura de capital. Las empresas de capital público son aquellas cuyas acciones se negocian libremente en mercados organizados —como el NYSE o el NASDAQ— lo que implica la existencia de un precio de mercado observable, obligaciones de reporte periódico ante organismos regulatorios como la SEC, y estados financieros auditados de acceso público. Berk y DeMarzo (2020) señalan que esta condición impone sobre la empresa una disciplina informativa continua, dado que, el precio de la acción incorpora en tiempo real las expectativas del mercado sobre sus flujos futuros. Las empresas de capital privado, en cambio —conocidas en la literatura anglosajona como *closely held companies*— son aquellas cuya propiedad está concentrada en un número reducido de accionistas y cuyas participaciones no se transan en mercados secundarios organizados, eximiéndolas de las obligaciones de divulgación pública propias de las empresas cotizantes. Entre las características estructurales que las distinguen de las cotizantes se destacan: la ausencia de precio de mercado observable, la menor calidad y auditoría de la información financiera disponible, la concentración de la propiedad en pocos accionistas y la existencia de restricciones a la transferencia de participaciones (Pratt et al., 1995). Damodaran (2012) precisa que el valor de una empresa privada se obtiene mediante el mismo constructo que el de una pública —el valor presente de los flujos de caja esperados descontados a una tasa apropiada—, pero que las diferencias entre ambos tipos de firma se manifiestan en cómo se estiman los inputs del modelo, dado que la información disponible es sustancialmente más limitada en historia y profundidad. Caselli (2010) agrega que la estructura de propiedad concentrada genera dinámicas de gobernanza particulares: la alineación directa entre propiedad y gestión reduce los conflictos de agencia clásicos pero profundiza la opacidad informativa hacia el exterior. Esta distinción no es meramente formal, define el universo de información disponible para cualquier proceso de valuación, constituye la fuente primaria de la asimetría informativa que caracteriza a las operaciones de M&A con empresas de

capital cerrado y genera un descuento que debe ser considerado en la estimación del valor.

ii. Asimetría de información

La asimetría de información en empresas de capital privado constituye uno de los principales desafíos para arribar a una valuación confiable. Este concepto, proveniente de la teoría económica clásica, refiere a situaciones en las que una de las partes de una transacción dispone de información relevante que la otra desconoce. En el contexto de M&A, la empresa objetivo conoce su real situación financiera, sus pasivos contingentes, sus perspectivas de negocio y sus riesgos operativos, mientras que el adquirente debe inferirlos a partir de la información provista durante el proceso de due diligence. Alexandridis et al. (2022) documentan que esta asimetría tiene un impacto directo sobre las primas de adquisición y los retornos para los accionistas de la empresa adquirente. La reducción de la asimetría informativa a través de mejores mecanismos de due diligence y de modelos de valuación más robustos es, precisamente, uno de los objetivos perseguidos por el simulador propuesto en la presente investigación. La manifestación más concreta de esta asimetría sobre el valor de las empresas privadas se traduce en un ajuste técnico necesario: el Descuento por Falta de Mercado.

iii. Descuento por Falta de Mercado (DLOM)

El Descuento por Falta de Mercado (DLOM) captura la penalización de valor que sufre una participación en una empresa privada debido a su iliquidez relativa frente a una posición equivalente en una compañía cotizante. La estimación del DLOM es objeto de amplio debate académico y profesional, y su cuantificación varía según la metodología empleada. Entre los enfoques más utilizados se encuentran los estudios de acciones restringidas (restricted stock studies), que comparan el precio de acciones cotizantes con el de sus contrapartes ilíquidas y los estudios de opciones put (pre-IPO studies) que estiman el costo de la iliquidez a través del valor de una opción de venta sintética. En la práctica, los DLOMs aplicados en transacciones de M&A se sitúan típicamente en un rango del 20% al 40%, aunque su magnitud específica depende del tamaño de la empresa, la industria y las condiciones del mercado (Pratt et al., 1995).

La decisión de incorporar el Descuento por Falta de Mercado (DLOM) como una variable central en el simulador desarrollado no responde únicamente a un criterio de prudencia financiera, sino a una necesidad de consistencia metodológica. Dado que el

modelo estima el valor de la firma utilizando el enfoque de valuación relativa —extrayendo múltiplos (EV/Sales) de un *peer group* compuesto por empresas públicas—, se genera una discrepancia estructural conocida como el "premio por liquidez" (Pratt, 2008). Las empresas cotizantes gozan de la capacidad de convertir sus activos en efectivo de forma casi instantánea y con costos de transacción mínimos. Por el contrario, una empresa de capital cerrado en el sector tecnológico enfrenta un proceso de salida que puede extenderse entre seis y doce meses, requiriendo procesos de auditoría (*Due Diligence*) y asesoramiento legal altamente costosos (Sherman, 2012).

iv. Índice de volatilidad: VIX

El instrumento seleccionado como proxy de las condiciones de volatilidad de mercado es el Índice de Volatilidad CBOE, universalmente conocido por su ticker VIX. Introducido en 1993 por el Chicago Board Options Exchange (CBOE), el VIX es considerado el barómetro de referencia global para medir el sentimiento de los inversores y la volatilidad del mercado. Técnicamente, el VIX es un benchmark financiero diseñado para estimar en tiempo real la volatilidad esperada del índice S&P 500, calculado a partir de los precios de cotización bid/ask de las opciones sobre el S&P 500 con vencimientos cercanos, proporcionando una medida instantánea de cuánta fluctuación espera el mercado en los próximos 30 días. Por esta razón, es frecuentemente denominado en la literatura financiera como el "*índice del miedo*" (*fear gauge*): cada valor del índice expresa el cambio porcentual anualizado esperado en el S&P 500 para los 30 días siguientes, derivado de la teoría de opciones y de los precios vigentes en el mercado de opciones.

La escala interpretativa del VIX está ampliamente consolidada en la práctica financiera. Valores por debajo de 20 reflejan un entorno de calma y estabilidad relativa en el mercado; valores entre 20 y 30 indican volatilidad moderada y mayor percepción de riesgo por parte de los inversores; valores superiores a 30 señalan estrés significativo de mercado, históricamente asociados a correcciones o eventos de incertidumbre macroeconómica pronunciada. En los períodos analizados en el presente trabajo —2019, 2021 y 2025— el VIX registró niveles que recorren toda esta escala: 2019 se caracterizó por condiciones de baja volatilidad (VIX promedio por debajo de 20), 2021 mostró una compresión progresiva del índice tras el pico de la pandemia, y 2025 reflejó episodios de estrés moderado asociados al rebote de actividad transaccional post-contracción. Esta variabilidad entre períodos hace del VIX una variable de control

especialmente pertinente para el presente análisis.

g. Prima de Control y Factores de Ajuste en Transacciones de M&A

i. La prima de control

La prima de control (control premium) representa el sobreprecio que un adquirente paga por encima del valor de mercado de la empresa objetivo con el fin de obtener el control efectivo sobre sus decisiones estratégicas y operativas. Este sobreprecio refleja el valor esperado de los beneficios que el adquirente prevé obtener mediante el control: la posibilidad de reestructurar la empresa, modificar su política de dividendos, integrar con sus propias operaciones y capturar las sinergias resultantes. Gaughan (2017) documenta que las primas de control en transacciones de M&A han oscilado históricamente entre el 20% y el 40% sobre el precio de mercado previo al anuncio, aunque este rango presenta alta dispersión en función del sector, del tamaño de la transacción y del contexto competitivo del proceso de negociación. En el sector tecnológico, las primas tienden a ser más elevadas dada la valoración estratégica de los activos intangibles, la propiedad intelectual y la base de usuarios.

ii. Sinergias y otros factores de ajuste

Las diferencias sistemáticas entre el valor intrínseco estimado de una empresa y el precio final negociado en una transacción de M&A responden a múltiples factores, siendo las sinergias y la prima de control los más relevantes. Las sinergias pueden clasificarse en operativas (reducción de costos, incremento de ingresos por complementariedad) y financieras (beneficios fiscales, mejora en la estructura de capital). Su cuantificación es inherentemente incierta y constituye una fuente significativa de dispersión en los precios de cierre. Adicionalmente, las condiciones del mercado al momento de la transacción, el grado de competencia en el proceso de negociación (empresas target versus empresas adquirentes), la urgencia del vendedor y la percepción del riesgo regulatorio son factores que modulan el precio final. El simulador desarrollado en esta investigación incorpora estos factores como variables de análisis para interpretar las desviaciones entre el valor estimado y el precio de cierre observado. Habiendo definido las variables que explican estas desviaciones, resulta imperativo establecer una métrica estadística robusta para medir con qué grado de exactitud el simulador logra aproximarse a los precios reales de mercado.

Sudarsanam (2010) advierte que, pese a que la creación de valor mediante sinergias constituye la motivación declarada de la mayoría de las adquisiciones, "the odds of

positive and significant value creation for acquirer shareholders may even be less than 50%, which is what one would get with the toss of a fair coin" (Sudarsan, 2010, p. 2) [las probabilidades de creación de valor positiva y significativa para los accionistas del adquirente pueden ser incluso menores al 50%, equivalentes a lo que se obtendría con el lanzamiento de una moneda al aire]. Esta paradoja refuerza la importancia de contar con herramientas de valuación que permitan discriminar entre el valor estratégico esperado y el precio efectivamente pagado.

h. Evaluación de la Precisión del Simulador: El MAPE

El Error Porcentual Absoluto Medio (MAPE) es una de las métricas más utilizadas en la literatura de pronósticos y modelización cuantitativa. Lewis (1982) lo define de la siguiente forma, "*The mean absolute percentage error (MAPE), as the name suggests, is the mean or average value of the absolute forecasting errors as a percentage of the respective data value. As such it can be defined as:*" [El Error Porcentual Absoluto Medio (MAPE), como su nombre lo indica, es el valor medio o promedio de los errores de pronóstico absolutos expresados como porcentaje del valor real correspondiente. Como tal, puede definirse de la siguiente manera:]. (Lewis, 1982, p. 40)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Valor Real_i - Valor Estimado_i}{Valor Real_i} \right| \times 100$$

Lewis (1982) establece una escala interpretativa del MAPE ampliamente adoptada en la práctica: valores inferiores al 10% indican una capacidad predictiva altamente precisa, entre el 10% y el 20% se considera una precisión buena, entre el 20% y el 50% razonable, y por encima del 50% imprecisa. La hipótesis del presente trabajo postula que el simulador alcanzará un MAPE inferior al 10%, lo que implicaría una precisión altamente satisfactoria para fines de valuación en M&A. La elección del MAPE como métrica principal responde a su interpretabilidad como indicador relativo independiente de la escala absoluta de las transacciones analizadas, lo que facilita la comparación entre operaciones de distintos tamaños. No obstante, es importante señalar sus limitaciones: el MAPE puede ser sensible a valores reales cercanos a cero y penaliza de forma asimétrica las subestimaciones frente a las sobreestimaciones. Teniendo clara la herramienta metodológica para medir el margen de error, corresponde delimitar el ecosistema de mercado donde interactúan todas las dinámicas expuestas: el sector tecnológico.

El recorrido conceptual desarrollado en el presente marco teórico permite comprender la arquitectura analítica sobre la que se construye el simulador propuesto. Las fusiones y adquisiciones constituyen un fenómeno cíclico de alta complejidad estratégica, cuyo volumen en los períodos seleccionados —2019, 2021 y 2025— y cuya concentración en el sector tecnológico ofrecen un universo de análisis representativo y metodológicamente pertinente. La valuación relativa mediante el múltiplo EV/Sales emerge como el enfoque más robusto ante la indisponibilidad de métricas de utilidad confiables en empresas de capital privado, mientras que los ajustes por DLOM y prima de control permiten aproximar la estimación a las condiciones reales de negociación. La asimetría de información, documentada como factor determinante de las primas de adquisición, representa tanto la limitación estructural del problema como la justificación central de la herramienta propuesta. Finalmente, el MAPE provee el criterio estadístico objetivo para evaluar si el simulador logra superar esa brecha. En conjunto, estos elementos configuran el andamiaje teórico que sustenta la hipótesis central de la investigación: que un modelo basado en fundamentos financieros, debidamente ajustado por las particularidades del capital privado, puede estimar el valor de empresas en transacciones de M&A con un margen de error inferior al 10%.

i. Test de Wilcoxon y Correlación de Spearman

La evaluación de la precisión del simulador no se agota en la magnitud del error promedio que mide el MAPE: requiere además determinar si ese error presenta dirección sistemática y si guarda relación con características observables de las empresas analizadas. Para ello, el presente trabajo incorpora dos herramientas estadísticas no paramétricas que no asumen normalidad en la distribución del error, condición que los errores de valuación raramente cumplen dada la asimetría inherente a las distribuciones de precios de M&A.

El test de rangos con signo de Wilcoxon (1945) es una prueba no paramétrica que evalúa si la mediana de una distribución difiere significativamente de cero. En el contexto del simulador, se aplica sobre la distribución del error porcentual para contrastar la hipótesis nula de que el sesgo mediano es igual a cero —es decir, que el modelo no sobreestima ni subestima de forma sistemática—. Un resultado con $p < 0,05$ indica la existencia de sesgo sistemático y revela que el error es de naturaleza determinística: el modelo falla consistentemente en la misma dirección. Un resultado con $p > 0,05$ indica ausencia de sesgo sistemático, lo que implica que el error es estocástico y sus desviaciones se distribuyen sin predominancia estructural de signo.

Esta distinción es metodológicamente crítica: un error determinístico requiere modificar los datos de entrada del modelo, mientras que uno estocástico admite correcciones mediante calibraciones empíricas. La elección de Wilcoxon sobre la alternativa paramétrica —el test t de Student— responde a que la distribución del error porcentual en valuación de empresas presenta típicamente asimetría y colas pesadas, lo que invalida el supuesto de normalidad requerido por la prueba t.

La correlación de rangos de Spearman (1904) es una medida de asociación monótona entre dos variables que opera sobre los rangos de los datos en lugar de sus valores absolutos, por lo que no requiere linealidad ni normalidad. Su coeficiente, que toma valores entre -1 y $+1$, cuantifica la intensidad y dirección de la relación entre variables ordinales o continuas no normales. En el presente trabajo se utiliza para evaluar si existe una relación sistemática entre el tamaño de la empresa objetivo —medido por el logaritmo de sus ventas— y el error absoluto porcentual producido por el simulador. Un coeficiente de Spearman significativamente positivo indicaría que el modelo es menos preciso para empresas más grandes; uno negativo, que lo es más. La ausencia de correlación significativa indicaría que el error es independiente del tamaño, lo que fortalece la validez del simulador como herramienta aplicable a empresas de distintas escalas dentro del universo analizado.

6. Metodología

a. Enfoque metodológico

El presente trabajo adopta un enfoque cuantitativo de carácter descriptivo-comparativo. Se parte de datos financieros observables —precios de cierre de transacciones finalizadas reales por el 100% del control— para construir un modelo de estimación de valor y evaluar su precisión mediante indicadores estadísticos. Este enfoque es consistente con la tradición de investigación empírica en valuación financiera, que busca formular y contrastar hipótesis de precisión a partir de evidencia numérica objetiva (Kaplan y Ruback, 1995). Las transacciones de M&A son eventos históricos con precios de cierre observables, lo que permite una comparación directa entre el valor estimado por el simulador y el precio efectivamente pagado por el adquirente.

b. Fuentes de datos

El diseño metodológico se corresponde directamente con el objetivo general: determinar la precisión de un simulador de valuación en transacciones reales de M&A entre empresas de capital privado y público.

Los datos utilizados en el presente trabajo provienen de dos fuentes complementarias, cada una con un rol metodológico específico y diferenciado.

La primera fuente es Bloomberg Terminal, plataforma de referencia global en el ámbito financiero profesional e institucional de la cual se extraen exclusivamente los datos de cada transacción analizada: el precio de cierre de la operación y las ventas brutas operativas de la empresa target (ver Anexo A). Bloomberg Terminal provee acceso a datos históricos verificables sobre transacciones de M&A y estados financieros con estándares de calidad y auditoría reconocidos por la industria financiera, consistentes con los requeridos en investigaciones empíricas de este tipo (DePamphilis, 2022). En los casos en que las ventas de la empresa objetivo no estén disponibles en Bloomberg, la transacción será excluida del análisis a fin de preservar la consistencia metodológica y evitar supuestos no verificables que introduzcan sesgo en el cálculo del MAPE.

La segunda fuente es la base de datos pública de Aswath Damodaran, actualizada anualmente y de acceso abierto de la cual se extrae el múltiplo EV/Sales sectorial utilizado como referencia en el simulador (Damodaran A, s.f.a).

c. Consideraciones previas y delimitaciones

Para el desarrollo y validación del simulador de valuación, se asumen los siguientes principios operativos que delimitan el alcance, las fuentes de datos y los supuestos del modelo:

i) Período de análisis. El estudio comprende tres años puntuales: 2019, 2021 y 2025. La elección responde a que los tres años superaron el volumen de transacciones promedio de la última década en el sector tecnológico de los Estados Unidos (Bain & Company, 2026; J.P. Morgan, 2026). Los tres años ofrecen además un contraste de condiciones de mercado valioso: 2019 representa un ciclo de expansión pre-pandemia, 2021 el boom post-COVID con tasas de interés históricamente bajas, y 2025 el rebote tras un período de contracción (Bain & Company, 2026).

ii) Universo de análisis. La elección del sector responde a que fue el que registró la mayor cantidad de operaciones de M&A en los períodos seleccionados, y a que sus características estructurales —alta proporción de activos intangibles, modelos de negocio basados en el crecimiento de usuarios y ausencia de rentabilidad en etapas tempranas— hacen especialmente relevante la elección del múltiplo de ventas como base de valuación (Alexandridis et al., 2022).

iii) Tipo de transacción. Todas las transacciones analizadas corresponden a

adquisiciones de empresas de capital privado. Este esquema es el que genera la asimetría informativa y la necesidad de ajuste por DLOM que fundamentan el simulador: las empresas cotizantes disponen de información pública auditada, mientras que la empresa target de capital cerrado presenta restricciones estructurales de información que el modelo debe contemplar (Pratt et al., 1995; Damodaran, 2012).

iv) Monto mínimo de transacción. Se incluyen únicamente operaciones con precio de cierre superior a USD 50 millones, con el fin de asegurar que se trata de operaciones con un proceso formal de valuación, cobertura suficiente en bases de datos financieras.

v) Costos transaccionales. Los costos de asesoría legal y financiera y de due diligence no se incorporan al modelo. El objetivo es evaluar la precisión del múltiplo de valuación puro antes de considerar los costos de proceso, siguiendo el criterio de parsimonia establecido por Damodaran (2012): no utilizar más inputs de los estrictamente necesarios para valorar un activo.

vi) Prima de control. No se incorpora como variable de ajuste en el simulador. Si bien la literatura documenta que las primas oscilan históricamente entre el 20% y el 40% (Gaughan, 2017), su cuantificación requiere información sobre la estructura de negociación que no está disponible de forma sistemática para empresas de capital privado. Las desviaciones atribuibles a la prima de control se analizan en la sección de resultados como factor explicativo.

vii) Aplicación del DLOM. El DLOM se aplica dentro de un rango del 25% al 40% sobre el valor base estimado, de acuerdo con la evidencia empírica sobre descuentos por iliquidez en empresas de capital cerrado (Pratt et al., 1995). La determinación del punto exacto dentro del rango para cada transacción se realiza en base a las condiciones del mercado al momento de la operación, evaluadas a través del índice VIX como proxy de volatilidad general.

La decisión de incorporar el Descuento por Falta de Mercado (DLOM) como variable central en el simulador no responde únicamente a un criterio de prudencia financiera, sino a una necesidad de consistencia metodológica: dado que el modelo estima el valor de la firma a través de múltiplos, se genera una discrepancia estructural conocida como el "premio por liquidez" (Pratt, 2008). Las empresas cotizantes gozan de la capacidad de convertir sus activos en efectivo de forma casi instantánea y con costos de transacción mínimos, mientras que una empresa de capital cerrado en el sector tecnológico enfrenta un proceso de salida que puede extenderse entre seis y doce

meses, requiriendo procesos de due diligence y asesoramiento legal altamente costosos (Sherman, 2012). La cuantificación del DLOM se fundamenta en los dos estudios empíricos de referencia en la materia: Willamette Management Associates (WMA) realizó 23 estudios pre-IPO durante el período 1975-2002 sobre 1.007 transacciones aplicando ajustes por condiciones de mercado mediante múltiplos Price/Earnings de industria entre el momento de la transacción privada y el de la IPO documentando descuentos medianos en el rango del 20% al 40% (Pratt et al., 1995). Emory (1980-2000), en una serie de 10 estudios sobre 346 transacciones, corrobora la existencia estructural del descuento aunque arroja valores más elevados —media del 46%— debido en parte a que el 78% de sus observaciones corresponden a opciones sobre acciones y a que no realiza ajuste temporal entre la transacción privada y la IPO, lo que en períodos de alta volatilidad tiende a sobreestimar el DLOM resultante. Por su mayor rigor metodológico y mejor alineación con la práctica de M&A, el presente trabajo adopta el marco de referencia de WMA, ajustando no obstante el piso del rango del 20% al 25%, dado que ambas series están desactualizadas —el último dato disponible es de 2002— y que el sector tecnológico presenta particularidades estructurales que elevan el costo de iliquidez por encima del promedio del mercado: en particular, la concentración del valor en activos intangibles de difícil auditoría externa y la extensión típica del proceso de due diligence en este segmento (Alexandridis et al., 2022; Sherman, 2012). El techo del rango se mantiene en el 40%, en línea con la evidencia empírica y la práctica profesional en transacciones de empresas privadas de tamaño medio.

La calibración del punto específico dentro del rango 25%-40% se fundamenta en la relación empíricamente documentada entre volatilidad de mercado y nivel del DLOM. Chaffe (1993) demostró que la volatilidad es uno de los inputs fundamentales del descuento al modelarlo como el valor de una opción put cuya vida equivale al período de restricción de la inversión; Longstaff (1995) complementa este enfoque demostrando que el período de tenencia y la volatilidad explican sustancialmente el nivel del DLOM, pudiendo este ser potencialmente elevado incluso cuando el período de iliquidez es corto. En consecuencia, se utiliza el nivel promedio del índice VIX en los tres meses previos al cierre de cada transacción como proxy de las condiciones de volatilidad del mercado al momento de la operación: un VIX superior a 20 puntos se asocia a un DLOM en el tramo alto del rango, reflejando mayor incertidumbre y menor liquidez percibida por los inversores, mientras que condiciones de mercado estables

permiten aplicar descuentos en el tramo inferior del mismo.

viii) Métrica de precisión. La precisión del simulador se evalúa mediante el MAPE (Error Porcentual Absoluto Medio), calculado sobre el conjunto total de transacciones analizadas. La hipótesis central postula que este valor será inferior al 10%, lo que según la escala de Lewis (1982) indica una capacidad predictiva altamente precisa.

d. Construcción del simulador

i. Visión general del sistema

El programa desarrollado para esta investigación consiste en tres bloques de código articulados de manera secuencial y jerárquica, implementados en el lenguaje Python dentro de un entorno Jupyter Notebook (ver Anexo B). Cada bloque constituye un módulo funcional independiente que, a la vez, depende de los datos producidos por el anterior, conformando así un pipeline de valuación, validación y comparación interanual.

ii. Jerarquización del código

La arquitectura del sistema sigue una jerarquía de tres niveles, donde cada nivel resuelve un tipo de problema diferente:

Nivel 1: Bloque 1 — Módulo de valuación (nivel de transacción): opera sobre una empresa a la vez, produce un valor estimado puntual y lo almacena en un historial acumulativo.

Nivel 2: Bloque 2 — Módulo de análisis estadístico (nivel de muestra): toma el historial completo por año y calcula métricas de error, correlaciones y tests de sesgo sobre el conjunto de transacciones.

Nivel 3: Bloque 3 — Módulo comparativo (nivel de estudio): consolida los resultados de todos los años analizados y genera una visión transversal del comportamiento del modelo a lo largo del tiempo.

Dentro de cada bloque, las funciones también están organizadas jerárquicamente. En el Bloque 1, por ejemplo, la función `main()` actúa como orquestador y llama secuencialmente a `paso0_target()`, `paso1_2_multiplo_damodaran()`, `paso3_dlom()` y `paso4_valor()`, cada una de las cuales encapsula una etapa discreta del proceso de valuación. Las funciones auxiliares (`pedir_numero()`, `pedir_opcion()`, `pedir_fecha()`, `usd()`, `pct()`) resuelven operaciones de bajo nivel y son reutilizadas por las funciones principales.

iii. Concatenación entre bloques

La concatenación entre bloques se realiza a través de dos mecanismos complementarios: el archivo `historial_valuaciones{año}.xlsx` como contrato de datos entre el Bloque 1 y el Bloque 2, y la variable `resultados` como contrato en memoria entre el Bloque 2 y el Bloque 3.

Al finalizar cada sesión del Bloque 1, el historial de transacciones valuadas se exporta a un archivo Excel con nombre parametrizable (`historial_valuaciones.xlsx` por defecto). El Bloque 2 consume ese archivo —uno por año de análisis— y produce un diccionario de métricas por año que queda almacenado en la variable `resultados`. El Bloque 3, a su vez, valida la existencia de resultados antes de ejecutarse y la consume directamente. Este diseño asegura que la cadena de procesamiento sea reproducible: si se desea incorporar un nuevo año, basta con generar el archivo Excel correspondiente y agregar el año a la lista “ANIOS” del Bloque 2; el Bloque 3 incorporará automáticamente ese año en la comparación interanual sin requerir ninguna modificación adicional.

iv. Secuencia detallada de los bloques

1. Bloque 1 — Simulador de Valuación

El Bloque 1 implementa el método de valuación relativa por múltiplos comparables, con base en los datos sectoriales publicados por Damodaran (EV/Sales) y ajuste por descuento por falta de liquidez (DLOM) calibrado por el índice VIX. El flujo interno sigue los pasos descritos a continuación:

1. Ingreso de datos del target (`paso0_target`): el usuario ingresa el nombre de la empresa y sus ventas anuales en dólares. La función valida que el valor sea positivo antes de continuar.
2. Selección del múltiplo EV/Sales (`paso1_2_multiplo_damodaran`): se carga el archivo `damodaran_ev_sales.csv` (ver Anexo A.7), se presentan las industrias disponibles y el usuario selecciona industria y año. La función devuelve el múltiplo correspondiente junto con su identificación.
3. Cálculo del DLOM (`paso3_dlom`): se descarga el VIX diario de Yahoo Finance para los 91 días previos a la fecha de cierre indicada por el usuario. Con ese promedio, la función `calcular_dlom()` interpola linealmente dentro del rango WMA ajustado (25% – 40%), dividido en dos tramos según el umbral $VIX = 20$.
4. Cálculo del valor estimado y registro (`paso4_valor`): se calcula el valor final, se muestra un resumen ejecutivo con análisis de sensibilidad y se registra la

transacción en el historial interno.

El cálculo central del valor estimado responde a la siguiente expresión:

$$\text{Valor Estimado} = \text{Ventas empresa target} * \frac{EV}{Sales} * (1 - DL\text{OM})$$

La interpolación del DLOM dentro del rango WMA se realiza por tramos. Para un VIX menor o igual a 20, el descuento oscila entre 25,0% y 32,5%; para un VIX superior a 20, oscila entre 32,5% y 40,0%. El análisis de sensibilidad presentado al usuario muestra simultáneamente los escenarios optimista (DLOM = 25%), base (DLOM calibrado) y conservador (DLOM = 40%).

2. Bloque 2 — Análisis Estadístico de Error

El Bloque 2 evalúa la precisión del simulador comparando los valores estimados por el Bloque 1 con los valores reales de mercado obtenidos de Bloomberg. Para cada año definido en la lista “ANIOS”, la función analizar_anio() ejecuta la siguiente secuencia:

1. Cálculos centrales: se computan el múltiplo implícito de mercado, el error porcentual (Error_Pct) y su valor absoluto. Adicionalmente, se fusiona la tabla con los múltiplos Damodaran para calcular el factor de inflación de ventas Bloomberg.
2. Filtro de outliers: se excluye el 5% inferior y el 5% superior de la distribución del error (percentiles P5 y P95), trabajando sobre el 90% central de la muestra.
3. Diagnóstico visual: se generan tres gráficos: un scatter log/log de Ventas vs. Error porcentual, un histograma de la distribución del error y un gráfico de barras del hit ratio por umbral de tolerancia (10%, 20%, 30%, 50%, 100%).
4. Pruebas estadísticas: se realizan regresión lineal y correlación de Spearman entre el logaritmo de las ventas y el error absoluto, test de Wilcoxon para detectar sesgo sistemático y cálculo del MAPE comparado contra el umbral del 10%.
5. Análisis por subindustria: se agrupan las empresas por industria y se calculan MAPE, error mediano y porcentaje de sobreestimación para cada sector, incluyendo un gráfico de barras horizontales.
6. Inflación de ventas Bloomberg: utilizando los múltiplos Damodaran como fuente independiente, se calcula el factor de inflación implícito en los datos de Bloomberg mediante la expresión:

$$Factor = \frac{\frac{Ventas}{Valor\ real}}{EV/SALES * (1 - DLOM)}$$

Un factor mayor a 1 indica que Bloomberg reporta más ventas de las que el modelo requeriría.

Las fórmulas de error utilizadas son las siguientes:

$$Error\ Porcentual = \left(\frac{Valor\ Código - Valor\ Real}{Valor\ Real} \right) * 100$$

$$MAPE = \left(\frac{1}{n} \right) * \sum \left| \frac{Valor\ Real - Valor\ Código}{Valor\ real} \right| * 100$$

$$Múltiplo\ Implícito = \frac{Valor\ Real}{Ventas * (1 - DLOM)}$$

Este múltiplo implícito constituye la variable dependiente contra la cual se compara la estimación del simulador en cada caso, y es el input para el cálculo del error porcentual que alimenta el MAPE.

3. Bloque 3 — Resumen Comparativo Inter-Anual

El Bloque 3 consume directamente la lista de resultados generada por el Bloque 2 en la misma sesión y produce una síntesis comparativa entre los años analizados. La secuencia interna del Bloque 3 comprende las siguientes etapas:

- Tabla resumen de métricas clave por año: consolida MAPE, sesgo mediano, error en percentil 90, hit ratios al 20% y 50%, porcentaje de sobreestimación y factor de inflación Bloomberg.
- Gráficos de barras comparativos: uno por cada métrica relevante (MAPE, error mediano, hit ratio, factor de inflación).
- Box plot conjunto: muestra la distribución del error porcentual de cada año en un único gráfico, facilitando la comparación visual de la dispersión y el sesgo entre períodos.
- Conclusión narrativa automática: el código genera texto interpretativo basado en los valores numéricos, identificando el año de mejor desempeño, la presencia de sesgo sistemático y el comportamiento del factor Bloomberg a lo largo del tiempo.

e. Dependencias del sistema

El programa utiliza exclusivamente librerías del ecosistema científico estándar de Python (Ver Anexo D), complementadas con una librería de acceso a datos financieros. Las librerías `scipy.stats` y `yfinance` son las únicas dependencias externas que requieren

instalación expresa mediante pip. El resto forma parte del stack científico habitual de Python (pandas, numpy, matplotlib, seaborn) y se encuentra preinstalado en la mayoría de los entornos Jupyter. La instalación completa puede realizarse con el siguiente comando:

```
pip install yfinance pandas openpyxl scipy matplotlib seaborn
```


7. Análisis de Resultados

a. Validación cruzada con fuentes primarias

Con el propósito de evaluar la sensibilidad de los resultados ante la calidad del dato de ingresos, se construyó adicionalmente una submuestra de verificación restringida a aquellas empresas target para las cuales fue posible corroborar las ventas mediante fuentes primarias independientes de Bloomberg Terminal: comunicados de prensa emitidos por el adquirente al cierre de la transacción, informes registrados ante la SEC (Form 8-K con estados financieros del target), o memorias anuales auditadas del adquirente que reportan el desempeño previo a la integración. Esta submuestra abarca 7 transacciones en 2019, 4 en 2021 y 12 en 2025 (ver Anexo C), y se analiza en paralelo con la muestra completa Bloomberg para distinguir el error atribuible a la calidad del dato de entrada del error estructural del modelo de valuación.

b. Sector Tecnología

Figura 2 — MAPE Sector Tecnología por configuración y año.



Fuente: Elaboración propia en base a resultados del simulador

Los resultados del Sector Tecnología con ventas BMG (ver Anexo C.1) representan el caso de mayor falla del modelo en todo el análisis. El MAPE alcanzó 26.784,7% en 2019 y, aunque se redujo a ~5.200% en 2021 y 2025, la magnitud del error continuó siendo órdenes de magnitud superior al umbral del 10% en los tres cortes temporales. La muestra conjunta de 60 empresas arrojó un MAPE consolidado de 12.051,9%, con el 91,7% de las valuaciones sobreestimando el valor de mercado y un factor de inflación BMG mediano de 30,06x, lo que implica que el modelo producía valuaciones sistemáticamente 30 veces superiores a las observadas.

Este nivel de error no responde a imprecisión del múltiplo sino a una descalibración estructural entre el numerador y el denominador del ratio. El múltiplo EV/Sales de Damodaran es construido a partir de empresas públicas donde el Enterprise Value y los revenues reportados están calibrados entre sí: el mercado ya incorporó esa definición contable de ingreso en su valuación. Cuando ese múltiplo se aplica a revenues de Bloomberg para empresas privadas, el denominador deja de ser equivalente: Bloomberg mezcla datos auditados, estimaciones propias y reporting voluntario con distinta periodicidad y criterios contables, y además reporta revenues consolidados sin ajustar por eventos corporativos. El test de Wilcoxon confirmó sesgo sistemático de sobreestimación en todos los años ($p < 0,0001$), lo que implica que el error no es aleatorio sino determinístico: el modelo sobreestima de manera consistente.

Frente a este diagnóstico, se incorporó la configuración de ventas ajustadas (ver Anexo C.1). Como se observa en la Figura 2, los resultados mejoran sustancialmente en términos de magnitud: el MAPE consolidado se reduce a 296,6%, una mejora de 40 veces respecto a la configuración BMG. Más relevante aún, el test de Wilcoxon no detecta sesgo sistemático en ningún año con muestra suficiente ($p > 0,05$), la corrección transforma el error de determinístico a estocástico lo que implica que el modelo pasa de sobrevaluar consistentemente a producir errores en ambas direcciones sin predominancia de una.


Sin embargo, la configuración ajustada tampoco cumple la hipótesis de $\text{MAPE} < 10\%$. El sesgo mediano consolidado de $-40,7\%$ indica que el modelo tiende ahora a subestimar moderadamente. Este sesgo negativo es consecuencia directa de la naturaleza de los ajustes: al remover ingresos no recurrentes y realizar correcciones de segmento la base de ventas se reduce respecto a la cifra BMG generando valuaciones más conservadoras. A nivel de subindustria, la totalidad de las categorías —Software, Computer Services, Electronics, Semiconductor, Healthcare IT, Financial Svcs.,

Information Services, Aerospace/Defense— supera el umbral del 10% en todas las configuraciones y años, confirmando que el incumplimiento es una propiedad estructural del modelo para este sector.

c. Sector Consumo Básico: incorporación como análisis complementario

Dado que los resultados del Sector Tecnología resultaron desfavorables tanto en la configuración BMG como en la ajustada, se incorporó el Sector Consumo Básico como análisis complementario. El objetivo no fue extender el alcance del trabajo sino determinar si las limitaciones observadas son intrínsecas al modelo EV/Sales Damodaran o si se amplifican por las características particulares del sector tecnológico. Para ello se aplicó la misma metodología —ventas BMG y ventas ajustadas, filtrado P5–P95, MAPE, Wilcoxon, factor BMG y Hit Ratios— sobre muestras de empresas de consumo básico con cobertura en los mismos tres cortes temporales.

Figura 3 — MAPE comparativo: Sector Tech vs. Sector Consumo




Fuente: Elaboración propia en base a resultados del simulador

La Figura 3 permite contrastar el desempeño de ambos sectores. Los resultados de Consumo BMG (ver Anexo C.3) exhiben los mismos problemas estructurales que el sector tecnológico, aunque con menor magnitud: MAPE consolidado de 623,7% y factor de inflación BMG de 2,14x. El comportamiento del factor por año ilustra además la sensibilidad del modelo a ciclos de mercado: pasó de 0,67x en 2019 (subestimación, sesgo no significativo) a 5,37x en 2021 (sobreestimación severa, Wilcoxon $p = 0,0078$) y retornó a 1,08x en 2025 (neutralidad).

La configuración de Consumo Ajustado (ver Anexo C.4) es la que presenta los mejores indicadores de todo el análisis: MAPE consolidado de 64,3%, sesgo mediano de -10,0%, ausencia de sesgo sistemático en todos los años (Wilcoxon $p > 0,05$) y Hit Ratio <50% del 47,1%. Estos valores no satisfacen el umbral del 10%, pero posicionan a esta configuración como la única con potencial de aplicación en estimaciones exploratorias, siempre con revisión caso a caso. Particularmente relevante es la trayectoria del factor de inflación BMG: 0,42x en 2019, 0,90x en 2021 y 1,16x en 2025. Esta convergencia hacia 1x —neutralidad— no se observa en ninguna otra configuración y sugiere que el modelo gana calibración con el tiempo en este sector, posiblemente a medida que el universo Damodaran incorpora más empresas de consumo comparables a las analizadas.

d. Sesgo, ajustes y capacidad predictiva comparada


Figura 4 — Factor de inflación BMG



Nota: La línea discontinua señala la neutralidad (1x), (>1x = sobreestimación; <1x = subestimación)

Fuente: Elaboración propia en base a resultados del simulador

Figura 5 — Sesgo mediano por configuración y año




Nota: Panel Izquierdo-Tech BMG. Panel derecho-restantes configuraciones.

Fuente: Elaboración propia en base a resultados del simulador

Las Figuras 4 y 5 permiten comparar la dirección del error entre configuraciones. El factor de inflación BMG y el sesgo mediano revelan dos regímenes claramente diferenciados. Tech BMG opera bajo sobreestimación severa y estadísticamente significativa en todos los períodos (Wilcoxon $p < 0,0001$), con un sesgo mediano que cae de 9.156,1% en 2019 a 2.275,5% en 2025 pero se mantiene positivo y determinístico. Las configuraciones ajustadas, en cambio, eliminan el sesgo sistemático: el error pasa de ser unidireccional a estocástico. Este cambio de naturaleza —no sólo de magnitud— es el hallazgo metodológico más relevante del análisis, un modelo con error aleatorio puede corregirse mediante ajustes escalares empíricos; uno con sesgo determinístico requiere modificar su estructura de datos de entrada.

La asimetría sectorial en el efecto de los ajustes es igualmente significativa. En Tecnología, la corrección reduce el factor de 30,06x a 0,56x: el modelo pasa de sobrevaluar masivamente a subvaluar moderadamente, sin encontrar un punto de equilibrio. En Consumo, el ajuste produce un resultado más calibrado —factor de 0,90x en el conjunto— y la trayectoria temporal hacia 1x sugiere convergencia natural. Esta diferencia refleja la mayor homogeneidad definitoria del revenue en consumo básico frente a la dispersión estructural del sector tecnológico.


Figura 6 — Impacto de los ajustes de ventas sobre precisión del modelo



Nota: Barras: MAPE (eje izq., escala log.); línea: Hit Ratio <50% (eje der.)

Fuente: Elaboración propia en base a resultados del simulador

Figura 7 — Hit Ratios por configuración



Fuente: Elaboración propia en base a resultados del simulador

Las Figuras 6 y 7 cuantifican el impacto operacional de los ajustes. En Tecnología, la mejora en MAPE es de 40 veces (de 12.052% a 297%) y el Hit Ratio <50% sube 23,6 puntos porcentuales (de 11,7% a 35,3%). En Consumo, la mejora en MAPE es de 10 veces (de 624% a 64%) y el Hit Ratio <50% sube 33,3 puntos porcentuales (de 13,8% a 47,1%). Consumo Ajustado es el único bloque con desempeño operacionalmente relevante bajo todos los umbrales: 29,4% dentro del HR<20%, 47,1% dentro del

HR<50% y 82,4% dentro del HR<100%. Tech Ajustado muestra un perfil de uso exploratorio: 76,5% de las valuaciones caen dentro de la tolerancia del 100%, lo que indica un orden de magnitud razonable, pero sólo 35,3% dentro del HR<50%, insuficiente para decisiones que requieran precisión.

El contraste entre sectores permite identificar el origen de las limitaciones del modelo. En Tecnología, el problema es estructural e independiente del ciclo: la heterogeneidad de los modelos de negocio tech —y la consiguiente disparidad entre el revenue reportado y el capitalizado por el mercado— hace que el múltiplo EV/Sales no capture adecuadamente el valor de las empresas del sector, ni siquiera con ajustes de comparabilidad. En Consumo, el problema es de menor magnitud y parcialmente atribuible a ciclos de mercado, como lo evidencia la reversión del factor BMG entre 2019 y 2025. Esta distinción sugiere que el modelo tiene mayor aptitud natural para sectores con definiciones de revenue homogéneas y poco volátiles, y que su extensión al sector tecnológico requeriría ajustes metodológicos adicionales —desagregación del múltiplo por subsector, incorporación de métricas de crecimiento o uso de múltiplos alternativos como EV/Gross Profit— para alcanzar niveles de precisión operativamente útiles.

e. Prima de control y sinergias como factores explicativos del error

El simulador estima el valor intrínseco de la empresa target sin incluir la prima de control, dado que su cuantificación requiere información sobre la negociación que no está disponible de forma sistemática para empresas privadas. Esto significa que, cuando el adquirente paga una prima por encima del valor intrínseco —como ocurre en la mayoría de las transacciones de M&A— esa diferencia queda registrada como error de subestimación del modelo. En otras palabras, es esperable que el precio real supere al valor estimado, y la magnitud de esa brecha debería guardar relación con el nivel de prima pagada.


No obstante, antes de interpretar esa brecha como reflejo directo de la prima de control, es necesario advertir una limitación metodológica: la diferencia entre precio real y valor estimado no captura exclusivamente la prima de control, sino que amalgama tres componentes que no es posible separar con los datos disponibles: (i) la prima de control efectivamente pagada, (ii) las sinergias operativas y financieras proyectadas por el adquirente, y (iii) el error residual de calibración del propio modelo, derivado de imprecisiones en los múltiplos de Damodaran o en el DLOM aplicado. Esta limitación

es especialmente crítica en las configuraciones con factor de inflación Bloomberg elevado —como Tecnología BMG, con un factor de 30,06x— donde el error está dominado por la distorsión en los ingresos y cualquier lectura de prima implícita carece de sentido interpretativo. Por esta razón, el análisis que sigue se restringe a las configuraciones de mayor aptitud metodológica: Consumo Ajustado y, con mayor cautela, Tecnología Ajustado.

En ambas configuraciones el sesgo mediano consolidado es negativo: -10,0% en Consumo y -40,7% en Tecnología. La dirección del error es consistente con lo esperado: el modelo tiende a quedarse por debajo del precio de cierre real, en línea con la existencia de primas y sinergias incorporadas en el precio negociado que el simulador no modela.

El análisis por año permite observar patrones adicionales. En el sector Tecnología Ajustado, los sesgos de 2019 (-45,1%) y 2025 (-42,4%) son notablemente estables entre sí y se ubican en el tramo superior del rango de prima de control documentado por Gaughan (2017), lo que es consistente con la evidencia de Alexandridis et al. (2022) respecto a que las transacciones tecnológicas exhiben primas sistemáticamente superiores al promedio de mercado. El año 2021 presenta un sesgo positivo de +118,2%, pero este resultado debe descartarse como referencia analítica dado que la muestra tras el filtro de outliers quedó reducida a apenas dos empresas, careciendo de representatividad estadística. En el sector Consumo Ajustado, el sesgo evoluciona de -57,6% en 2019 a -10,0% en 2021 y se invierte a +15,5% en 2025. La magnitud elevada en 2019 no es atribuible exclusivamente a la prima de control: el factor de inflación de ventas Bloomberg de 0,42x en ese año indica una corrección significativa de los ingresos base, lo que comprime la estimación y amplía artificialmente la brecha con el precio real. En 2021, con un factor de 0,90x y un sesgo de -10,0%, la brecha se aproxima al tramo inferior del rango de mercado. En 2025, el sesgo positivo de +15,5% indica que el modelo sobreestimó el valor en la mayoría de los casos, sugiriendo que las primas efectivamente pagadas en ese período fueron inferiores a lo que el modelo implícitamente descuenta vía el DLOM.

Figura 8 — Sesgo mediano por configuración y año



Nota: Banda: rango esperado de prima de control (20%–40%, Gaughan 2017)

Fuente: Elaboración propia en base a resultados del simulador

El test de Wilcoxon aporta un elemento adicional de diagnóstico: únicamente en Consumo 2019 el sesgo es estadísticamente significativo ($p = 0,0312$), confirmando subestimación sistemática. En todos los demás períodos y sectores, el test no detecta sesgo sistemático, lo que implica que los errores son esencialmente aleatorios alrededor de cero y no responden a un factor estructural omitido de forma uniforme. Esto es coherente con un escenario donde la prima de control y las sinergias no actúan de manera constante entre transacciones, sino que varían según las condiciones específicas de cada operación.

8. Conclusión

a. Síntesis y contraste de resultados

El análisis de las transacciones de M&A en los sectores tecnológico y de consumo básico durante los períodos 2019, 2021 y 2025 permitió caracterizar con precisión tanto la capacidad como los límites del simulador de valuación relativa propuesto. En ninguna de las configuraciones evaluadas el modelo logró situar el error medio por debajo del umbral de precisión planteado: el recorrido entre un MAPE consolidado de 12.051,9% en la configuración tecnológica con datos Bloomberg y un MAPE de 64,3% en la configuración de consumo con revenues ajustados delimita el espacio de rendimiento real del simulador y revela que la magnitud y dirección del error no son

aleatorias sino jerárquicamente explicables. La variación de la precisión entre períodos —donde 2021 exhibe el mayor estrés en consumo BMG con un factor de inflación de 5,37x y 2025 la mayor convergencia con un factor de 1,16x en consumo ajustado— confirma que el ciclo de mercado modula el error pero no lo determina: la fuente y calidad del dato de revenues es el factor de primer orden que subyace a toda la variabilidad observada.

b. Jerarquía de los hallazgos

i. Primer nivel: la incompatibilidad estructural entre datos y múltiplo

La fuente primaria de error reside en la incompatibilidad estructural entre el numerador y el denominador del ratio EV/Sales cuando se aplican revenues de Bloomberg a empresas de capital privado. El múltiplo sectorial de Damodaran se calibra sobre empresas públicas donde el Enterprise Value —derivado de precios de mercado observables— y los ingresos reportados responden a una definición contable consistente y auditada. Las empresas de capital cerrado, en cambio, no tienen obligación de reportar bajo estándares públicos: Bloomberg mezcla datos auditados, estimaciones propias y reporting voluntario bajo criterios dispares, sin ajustar por eventos corporativos —spin-offs, adquisiciones, reclasificaciones de segmento—. El resultado es que la asimetría informativa inherente al capital privado se traduce, en términos operativos, en una brecha de definición entre el revenue utilizado como input del modelo y aquel sobre el que fue construido el múltiplo de referencia. Esa brecha amplifica el error de forma sistemática antes de que el modelo comience a operar: el factor de inflación Bloomberg mediano de 30,06x en tecnología y el sesgo de sobreestimación determinístico confirmado por el test de Wilcoxon ($p < 0,0001$) en todos los años son su expresión cuantitativa más directa.

La naturaleza de esta brecha es reveladora respecto de cómo opera la asimetría de información en la práctica de la valuación relativa. Además de manifestarse como una limitación de acceso a las cifras de la empresa objetivo, la asimetría se expresó como una falla de compatibilidad conceptual entre fuentes: las empresas privadas no están sujetas a los estándares de divulgación pública que rigen a las empresas sobre las que Damodaran construye su múltiplo de referencia (Pratt et al., 1995), por lo que sus revenues, aun siendo observables, no son equivalentes a los que sustentan el múltiplo aplicado. Esta distinción es metodológicamente relevante: la asimetría de información no introdujo ruido aleatorio en el modelo, sino un sesgo sistemático y direccional,

evidenciado por el factor de inflación Bloomberg y confirmado estadísticamente por el test de Wilcoxon. La afectación no se produjo, entonces, por ausencia de datos, sino por la falta de equivalencia conceptual entre el dato disponible para la empresa privada y el dato sobre el que fue calibrado el múltiplo de mercado utilizado como referencia.

ii. Segundo nivel: el impacto de los ajustes de revenues sobre la naturaleza del error

La incorporación de ajustes de comparabilidad sobre la base de revenues —utilizando fuentes de datos alternativas independientes, como la base de datos EDGAR correspondiente de la SEC— produce una transformación que es cualitativamente más relevante que la reducción cuantitativa del MAPE. En tecnología, el error se redujo cuarenta veces (de 12.051,9% a 296,6%); en consumo, diez veces (de 623,7% a 64,3%). Más significativo aún, el test de Wilcoxon dejó de detectar sesgo sistemático en ambos sectores ($p > 0,05$): el modelo pasó de sobrevaluar de manera consistente y previsible a producir errores en ambas direcciones sin predominancia estructural. Esta distinción —entre error determinístico y error estocástico— es central para evaluar la utilidad práctica del simulador: un modelo con sesgo determinístico requiere modificar sus datos de entrada; uno con error aleatorio puede complementarse con calibraciones empíricas y análisis de sensibilidad. La homogeneización del revenue es, por tanto, condición necesaria del funcionamiento del modelo aunque los valores de MAPE post-ajuste evidencian que no es condición suficiente para alcanzar el umbral de precisión propuesto.

El sesgo mediano negativo observado en las configuraciones ajustadas (–40,7% en Tecnología Ajustada y –10,0% en Consumo Ajustado) no es aleatorio: responde directamente a la interacción entre los ajustes de revenues y la aplicación del DLOM en el rango 25%-40%. Al reducir la base de revenues mediante la eliminación de ingresos no recurrentes y las correcciones de segmento, el valor base estimado cae; sobre ese valor ya reducido, el DLOM aplica un descuento adicional de entre un cuarto y un 40% del total. El resultado es un efecto de doble descuento que produce valuaciones sistemáticamente por debajo del precio de cierre efectivamente pagado, especialmente en transacciones donde el adquirente incorporó sinergias y prima de control que el modelo no contempla. Las subvaluaciones, lejos de ser una falla del DLOM como instrumento, confirman que el descuento por iliquidez funciona en la dirección correcta pero que su interacción con los ajustes de revenues genera una compresión del valor estimado que el modelo en su versión actual no calibra de forma diferenciada.

La coherencia entre el sesgo mediano residual de las configuraciones ajustadas y el rango documentado para primas de control en transacciones de M&A —20%–40% según Gaughan (2017)— refuerza esta interpretación. En Tecnología Ajustada, los valores de –45,1% (2019) y –42,4% (2025) se ubican en el extremo superior de dicho rango, y el consolidado de –40,7% lo delimita con precisión; en Consumo Ajustado, el sesgo de –10,0% es consistente con mercados donde la competencia por el control es menor y el componente sinérgico del precio pagado tiende a comprimirse. Esta consistencia no constituye una correlación estadística directa —su demostración formal requeriría datos de prima individual por transacción, no disponibles de forma sistemática para el universo privado—, pero confirma que el error residual post-ajuste no es ruido: es la huella cuantitativa previsible de un factor que el modelo excluye por diseño. El simulador, correctamente aplicado sobre revenues homogéneos, reproduce la prima de control de manera implícita y direccionalmente correcta, lo que transforma la subestimación observada en una señal interpretable y no en un defecto estructural del instrumento.

iii. Tercer nivel: la asimetría sectorial

La extensión del análisis al sector consumo básico permitió identificar que las limitaciones del modelo no son uniformes sino sectorialmente específicas. En tecnología, el problema es estructural e independiente del ciclo: la heterogeneidad de modelos de negocio —SaaS, hardware, servicios por proyecto, plataformas— produce revenues reportados que divergen de la base sobre la que se calibró el múltiplo sectorial, haciendo que ningún ajuste de comparabilidad logre resolver completamente la brecha. En consumo básico, el problema es de menor magnitud y parcialmente atribuible a condiciones de mercado, el factor de inflación Bloomberg mostró una trayectoria de convergencia hacia la neutralidad a lo largo de los tres períodos (0,42x en 2019; 0,90x en 2021; 1,16x en 2025) sugiriendo que el modelo gana calibración natural en sectores con definiciones de revenue más homogéneas. La configuración Consumo Ajustado —MAPE de 64,3%, Hit Ratio <50% de 47,1%, ausencia de sesgo sistemático y 82,4% de las valuaciones dentro de la tolerancia del 100%— es la única que posiciona al simulador como herramienta de orientación válida en etapas exploratorias del proceso de M&A, siempre bajo revisión caso a caso.

Kaplan y Ruback (1995) validaron la precisión del DCF contra 51 transacciones de alto apalancamiento, obteniendo estimaciones dentro del 10% del valor de cierre, pero circunscribiéndose a empresas públicas con información financiera auditada. Liu,

Nissim y Thomas (2002) documentaron que los múltiplos de ventas presentan menor precisión que los de utilidad cuando estas son observables. En ambos casos, el universo de análisis era íntegramente público: los revenues de la empresa objetivo y los revenues sobre los que se construyó el múltiplo de referencia respondían a los mismos estándares contables auditados, por lo que su comparabilidad estaba garantizada por defecto y nunca necesitó ser cuestionada. Los resultados aquí obtenidos demuestran que, en el universo de las empresas privadas, esa equivalencia no existe y constituye el determinante de error de primer orden, previo a cualquier discusión sobre la elección del múltiplo o el nivel del descuento por iliquidez. Officer (2007) confirmó la necesidad del DLOM en transacciones con empresas privadas, este trabajo añade que la aplicación del DLOM calibrado por el VIX es un ajuste de segundo orden y su efecto queda opacado por la brecha de definición de revenues si esta no se resuelve previamente. La contribución específica al conocimiento es, entonces, la identificación de la incompatibilidad de datos como variable de error de primer orden en la valuación relativa de empresas privadas, hallazgo que no estaba presente en la literatura previa.

c. Limitaciones y líneas de investigación futura

Tres limitaciones estructurales condicionan el alcance de las conclusiones. La primera es la calidad y disponibilidad del dato de ingresos: la submuestra de verificación cruzada con fuentes primarias (Form 8-K, comunicados SEC) abarcó 7 transacciones en 2019, 4 en 2021 y 12 en 2025, insuficiente para cuantificar estadísticamente el componente de error atribuible exclusivamente a la fuente Bloomberg en el conjunto completo. La segunda es la exclusión de la prima de control y las sinergias como variables de ajuste: su cuantificación requiere información sobre la estructura de negociación no disponible de forma sistemática para empresas privadas, lo que implica que parte del error residual del modelo es estructuralmente no modelable con la información disponible, no obstante, la consistencia direccional entre el sesgo residual observado y el rango de referencia de Gaughan (2017) sugiere que su magnitud es empíricamente razonable. La tercera es la delimitación temporal a tres cortes puntuales, que no constituyen una serie continua capaz de capturar la dinámica completa del ciclo de M&A.

La jerarquía de fuentes de error identificada delimita con precisión las líneas de investigación con mayor potencial. La prioridad más urgente es el desarrollo de un

protocolo estandarizado de homogeneización y acceso al dato de revenues privados comparable con la definición implícita en el múltiplo de Damodaran, articulable a partir de datos SEC, revenues auditados de transacciones precedentes, o mediante la construcción de un factor de ajuste empírico calibrado por subsector y año. Complementariamente, la incorporación de métricas alternativas como el EV/Gross Profit o el ARR para empresas SaaS permitiría capturar el valor relevante de cada modelo de negocio, en empresas de software por suscripción el revenue total mezcla ingresos de alto margen —las suscripciones— con ingresos de bajo margen —servicios de implementación y consultoría—, lo que hace que el EV/Sales pierda precisión como referencia de valor; el EV/Gross Profit y el ARR permiten aislar el margen estructural del negocio, que son el verdadero driver de valuación en transacciones SaaS. La extensión del análisis a sectores con definiciones de revenue homogéneas —salud, industriales, consumo discrecional— permitiría determinar si los resultados favorables de Consumo Ajustado son generalizables. Finalmente, la incorporación de la prima de control como variable endógena estimable a partir de la estructura del proceso de negociación y la cuantificación de sinergias mediante datos post-cierre reduciría el componente de error transaccional actualmente no modelado. El presente trabajo partió de la premisa de Bruner (2004) de que el valor intrínseco es inobservable y que la oportunidad de crear valor existe donde precio y valor intrínseco difieren. Los resultados confirman que esa brecha es real, compleja y parcialmente modelable: el simulador logra capturar el orden de magnitud del valor —especialmente en la configuración ajustada— pero no alcanza la precisión necesaria para operar como herramienta de referencia autónoma. Esto es consistente con la advertencia de Damodaran (2012) de que los modelos no valoran empresas: lo hacen los profesionales que los utilizan con juicio y comprensión profunda de sus limitaciones. Desde una perspectiva práctica, la implicación más directa para profesionales de finanzas corporativas es que la calidad del dato de revenues es el eslabón crítico de toda la cadena de valuación relativa: ningún refinamiento del múltiplo, del DLOM o de la selección de comparables puede compensar una base de ingresos no homogénea con la referencia de mercado. Desde una perspectiva disciplinar, el trabajo contribuye a la discusión sobre acceso equitativo a herramientas de valuación para empresas privadas de mediana escala, evidenciando que la barrera no es metodológica sino informacional: la tecnología puede democratizar el acceso al modelo, pero no puede suplir la ausencia de estándares de reporte auditados en el sector privado.

El aporte central de esta investigación no reside en haber alcanzado el umbral de precisión propuesto —que los resultados no confirman— sino en haber trazado con rigor metodológico el mapa de las fuentes de error que lo impiden. Ese mapa es, en sí mismo, una contribución al conocimiento: convierte un resultado negativo en una agenda de investigación concreta, progresiva y metodológicamente fundada.

Anexos

Anexo A: Transacciones de M&A

A.1 Sector Tecnológico 2019

Objetivo	Empresa compradora	Valor (mill)	Fecha del acuerdo	Revenue (BMG)	Revenue aj.
Assurance IQ LLC	Prudential Financial Inc	\$ 2,350.00	10/10/2019	\$ 63,274.00	-
Habana Labs Ltd	Intel Corp	\$ 2,000.00	12/16/2019	\$ 70,848.00	-
Cylance Inc	BlackBerry Ltd	\$ 1,400.00	02/21/2019	\$ 932.00	\$ 130.00
SignalFx Inc	Splunk Inc	\$ 1,050.00	10/02/2019	\$ 49,330.00	-
Software Solutions business/Pitney Bowes Inc	Precisely Software Inc	\$ 700.00	12/02/2019	\$ 3,211.00	\$ 341.00
Simplifile LC	Intercontinental Exchange Inc	\$ 335.00	06/12/2019	\$ 4,979.00	-
Building Connected Inc	Autodesk Inc	\$ 275.00	01/23/2019	\$ 2,056.00	-
Endgame Inc	Elastic NV	\$ 220.00	10/08/2019	\$ 160.00	-
QRC LLC	Parsons Corp	\$ 215.00	07/31/2019	\$ 3,560.00	\$ 56.00
MicroPact Inc	Tyler Technologies Inc	\$ 185.00	02/28/2019	\$ 939.00	\$ 70.00
Aporeto Inc	Palo Alto Networks Inc	\$ 150.00	12/23/2019	\$ 2,273.00	-
Altia Systems Inc	GN Store Nord AS	\$ 125.00	02/19/2019	\$ 88.00	-
Tangible Play Inc	Think & Learn Pvt Ltd	\$ 120.00	01/16/2019	\$ 70.00	-
Silicon Microstructures Inc	TE Connectivity Ltd	\$ 95.00	09/27/2019	\$ 13,988.00	-
Alliance Reservations Network LLC	Travel + Leisure Co	\$ 92.00	08/08/2019	\$ 3,931.00	-
Scalar Decisions Inc	CDW Corp/DE	\$ 88.00	02/01/2019	\$ 16,240.00	\$ 188.00
Church Community Builder LLC	Pushpay Holdings Ltd	\$ 87.50	12/12/2019	\$ 67,700.01	-
Gridsmart Technologies Inc	Cubic Corp	\$ 87.00	01/02/2019	\$ 1,202.00	\$ 35.00
Mnubo Inc	Aspentech Corp	\$ 78.30	07/19/2019	\$ 17,408.00	-
VAR Technology Finance North America Inc	People's United Financial Inc	\$ 60.00	01/17/2019	\$ 5,928.00	-
MoNa Mobile Nations LLC	Future PLC	\$ 59.99	03/06/2019	\$ 175.00	\$ 16.40
Cognigo Inc	NetApp Inc	\$ 53.00	05/23/2019	\$ 5,919.00	-
Bonobot Technologies Ltd	Salesforce Inc	\$ 50.00	05/20/2019	\$ 10,540.00	-

A.2 Sector Tecnológico 2021

Objetivo	Empresa compradora	Valor (mill)	Fecha del acuerdo	Revenue (BMG)	Revenue aj.
Tech Data Corp	TD SYNEX Corp	\$ 6,442.90	09/01/2021	\$ 36,998.40	\$ 36,998.42
Boomi Inc	Multiple acquirers	\$ 4,000.00	10/01/2021	\$ 92,501.00	-
E&I Engineering Ltd	Vertiv Holdings Co	\$ 1,800.00	11/02/2021	\$ 285.40	\$ 460.00
Thycotic Software Ltd	Delinea Inc	\$ 1,400.00	04/13/2021	\$ 2,114.70	-
SDS Holdco Inc	Craneware PLC	\$ 400.00	07/13/2021	\$ 71.50	-
Neoway Tecnologia Integrada Assessoria e Negocios SA	BM&FBovespa SA	\$ 323.46	12/29/2021	\$ 1,641.60	-
Gabi Personal Insurance Agency Inc	Experian PLC	\$ 320.00	10/21/2021	\$ 5,179.00	-
Has.to.be GmbH	ChargePoint Holdings Inc	\$ 302.88	10/06/2021	\$ 144.50	-
Returnly Technologies Inc	Affirm Holdings Inc	\$ 300.00	05/03/2021	\$ 509.50	-
Prospera Technologies Ltd	Valmont Industries Inc	\$ 300.00	05/12/2021	\$ 2,895.40	-
Wondery Inc	Amazon.com Inc	\$ 300.00	02/10/2021	\$ 18.90	-
StreamYard Inc	Hop.in Ltd	\$ 250.00	01/07/2021	\$ 96.70	-
Hello Digit Inc	Oportun Financial Corp	\$ 212.90	12/22/2021	\$ 335.10	\$ 35.83
BlackHorse Solutions Inc	Parsons Corp	\$ 203.00	07/06/2021	\$ 3,918.90	-
Sixense Enterprises Inc	Penumbra Inc	\$ 181.45	10/01/2021	\$ 560.40	-
Alsid SAS	Tenable Holdings Inc	\$ 98.00	04/27/2021	\$ 4.50	-
Eximius Design LLC	Wipro Ltd	\$ 80.00	02/26/2021	\$ 8,610.10	-
Talis Clinical LLC	Getinge AB	\$ 65.65	12/23/2021	\$ 29,819.00	-
Activus Connect LLC/Activus Connect PR LLC	Tech Mahindra Ltd	\$ 62.00	12/06/2021	\$ 5,201.80	-
PeriGen Inc	Halma PLC	\$ 58.00	05/06/2021	\$ 1,701.50	-
American Robotics Inc	Ondas Inc	\$ 56.58	08/05/2021	\$ 2.20	\$ 0.01
RxSaver Inc	GoodRx Holdings Inc	\$ 50.00	04/30/2021	\$ 550.70	-
Weav Technologies Inc	Brex Inc	\$ 50.00	08/17/2021	\$ 28,523.00	-

A.3 Sector Tecnológico 2025

Objetivo	Empresa compradora	Valor (mill)	Fecha del acuerdo	Revenue (BMG)	Revenue aj.
Melo Payments Inc	Xero Ltd	\$ 2,500.00	10/15/2025	\$ 1,045.00	\$ 153.00
Sevenrooms Inc	DoorDash Inc	\$ 1,200.00	06/17/2025	\$ 10,722.00	-
SynXis Corp	TPG Inc	\$ 1,100.00	07/07/2025	\$ 3,448.00	\$ 81.00
Evolutioniq Inc	CCC Intelligent Solutions Hold	\$ 730.00	01/06/2025	\$ 944.00	-
Beacon Platform Inc	Cleaver Analytics Holdings Inc	\$ 560.00	04/30/2025	\$ 451.00	\$ 44.00
Harman Connected Services Inc	Wipro Ltd	\$ 375.00	12/01/2025	\$ 10,845.00	-
Ask Sage Inc	BigBear.ai Holdings Inc	\$ 250.00	12/31/2025	\$ 158.00	\$ 25.00
SilverEdge Government Solutions LLC	Science Applications International Corp	\$ 205.00	10/17/2025	\$ 7,444.00	\$ 33.60
GreenScreens AI Inc	Triumph Financial Inc	\$ 160.00	05/08/2025	\$ 415.00	-
Securewise LLC	PDF Solutions Inc	\$ 130.00	03/07/2025	\$ 179.00	-
Cylance Inc	Arctic Wolf Networks Inc	\$ 112.45	02/03/2025	\$ 759.00	-
Chesapeake Technology International Corp	Parsons Corp	\$ 89.00	07/01/2025	\$ 6,750.00	-
Cotsworlds LLC	Moog Inc	\$ 63.00	07/07/2025	\$ 3,609.00	\$ 15.00
Video game business/Niantic Inc	Saudi Public Investment Fund	\$ 3,500.00	05/29/2025	\$ 3,288.30	\$ 1,000.00
Moveworks Inc	ServiceNow Inc	\$ 2,850.00	12/15/2025	\$ 10,987.00	-
Calastone Ltd	SS&C Technologies Holdings Inc	\$ 1,033.72	10/14/2025	\$ 83.10	\$ 103.00
Vistar Media Inc	T-Mobile US Inc	\$ 600.00	02/03/2025	\$ 125,236.30	-
Predibase Inc	Rubrik Inc	\$ 500.00	08/12/2025	\$ 627.90	-
Fictiv Inc	MISUMI Group Inc	\$ 350.00	06/17/2025	\$ 2,546.30	-
Clean Technology Systems Environmental division/Duerr AG	Stellix Capital Management LP	\$ 293.05	10/31/2025	\$ 4,641.80	\$ 447.00
SilverEdge Government Solutions LLC	Science Applications International Corp	\$ 205.00	10/17/2025	\$ 7,444.00	\$ 33.60
GEOST LLC	Rocket Lab Corp	\$ 196.69	08/12/2025	\$ 436.20	-
Blis Global Ltd	T-Mobile US Inc	\$ 175.00	03/03/2025	\$ 125,236.30	-
Planetair LLC	Multiple acquirers	\$ 169.50	06/30/2025	\$ 131.80	\$ 397.00
Paige.ai Inc	Tempus Labs Inc	\$ 81.25	08/22/2025	\$ 693.40	-
Cryptora Business/Alto Solutions Inc	Public Holdings Inc	\$ 65.00	11/13/2025	\$ 2,198.20	-

A.4 Sector Consumo 2019

Objetivo	Empresa compradora	Valor (mill)	Fecha del acuerdo	Revenue (BMG)	Revenue aj.
Drunk Elephant Holdings LLC	Shiseido Co Ltd	\$ 845.00	11/06/2019	\$ 1,094.80	\$ 100.00
Ranir Global Holdings LLC	Perrigo Co PLC	\$ 750.00	07/02/2019	\$ 4,731.70	\$ 287.00
B&R Global Holdings Inc	HF Foods Group Inc	\$ 562.29	11/04/2019	\$ 291.00	-
Tatcha LLC	Unilever NV	\$ 500.00	07/26/2019	\$ 60,216.10	\$ 70.00
ONE Brands LLC	Hershey Co/The	\$ 397.00	09/23/2019	\$ 7,791.10	-
Integral Associates LLC	Green Thumb Industries Inc	\$ 345.27	06/05/2019	\$ 62.50	-
Kelsen Group A/S	CTH Invest SA	\$ 300.00	09/23/2019	\$ 162.80	\$ 162.80
Redwood Holding Group LLC	Cronos Group Inc	\$ 300.00	09/05/2019	\$ 12.10	-
Primal Nutrition LLC	Kraft Heinz Co/The	\$ 200.00	01/04/2019	\$ 26.27	\$ 26.27
Southwood Research Ltd	Monroe Capital Management Advisors LLC	\$ 170.00	03/08/2019	\$ 24.70	\$ 24.70
Franklin BioScience-Penn LLC	Jushi Holdings Inc	\$ 54.61	07/10/2019	\$ 10.20	-
Agincourt Industries LLC	Cracker Barrel Old Country Store Inc	\$ 36.00	10/11/2019	\$ 3,030.40	-
Three Limes Inc	Oisix ra daichi Inc	\$ 21.00	05/31/2019	\$ 360.90	-

A.5 Sector Consumo 2021

Objetivo	Empresa compradora	Valor (mill)	Fecha del acuerdo	Revenue (BMG)	Revenue aj.
Speedway LLC	Seven & I Holdings Co Ltd	\$ 21,000.00	05/14/2021	\$ 48,900.10	\$ 33,070.00
Paidy Inc	PayPal Holdings Inc	\$ 2,721.90	10/31/2021	\$ 17,772.00	-
Fertin Pharma AS	Philip Morris International In	\$ 812.43	09/15/2021	\$ 150.60	\$ 150.60
Lily's Sweets LLC	Hershey Co/The	\$ 425.00	06/28/2021	\$ 8,149.70	-
Green Leaf Medical LLC	Cannabist Co Holdings Inc/The	\$ 240.00	06/11/2021	\$ 179.50	\$ 160.00
Plantation Products LLC	Central Garden & Pet Co	\$ 532.00	02/16/2021	\$ 2,695.50	-
Bountiful Co/The	Nestle SA	\$ 5,750.00	08/09/2021	\$ 2,069.10	\$ 2,069.10
Billie Inc	Edgewell Personal Care Co	\$ 310.00	11/29/2021	\$ 1,949.70	-
Flex Flow Services LLC	DNOW Inc	\$ 90.00	04/05/2021	\$ 1,619.00	-
Bentley Technologies LLC	THG PLC	\$ 255.00	06/15/2021	\$ 2,071.60	\$ 77.00
Laurel Harvest Labs LLC	Cresco Labs Inc	\$ 80.00	12/10/2021	\$ 476.30	-

A.6 Sector Consumo 2025

Objetivo	Empresa compradora	Valor (mill)	Fecha del acuerdo	Revenue (BMG)	Revenue aj.
Viterra Ltd	Bunge Global SA	\$ 8,027.13	07/02/2025	\$ 53.11	\$ 34,000.00
Pharma solutions business/International Flavors & Fragrances Inc	Roquette Freres SA	\$ 2,850.00	05/01/2025	\$ 11.48	\$ 1,000.00
Alani Nutrition LLC	Celsius Holdings Inc	\$ 1,650.00	04/01/2025	\$ 1,355.60	\$ 595.00
Pasta business/Post Holdings Inc	Richardsons Holdings Ltd	\$ 375.00	12/01/2025	\$ 7,922.70	-
Care Topco Pty Ltd	Colgate-Palmolive Co	\$ 298.90	04/04/2025	\$ 20.10	-
AGV Logistica SA	Multiple acquirers	\$ 129.01	07/02/2025	\$ 111.00	\$ 111.00
Dyla LLC	Keurig Dr Pepper Inc	\$ 98.00	06/02/2025	\$ 15.35	-
Bendalls Engineering Ltd,Carr's Engineering US Inc	Cadre Holdings Inc	\$ 91.78	04/22/2025	\$ 95.50	\$ 95.50
HPGL & VRU Systems/Archrock Inc	Flowco Holdings Inc	\$ 71.00	08/04/2025	\$ 1,157.60	-
Purvala Bioscience Inc	Olaplex Holdings Inc	\$ 10.50	08/20/2025	\$ 422.70	-
Ratio Cannabis LLC	TerrAscend Corp	\$ 10.30	05/07/2025	\$ 268.10	\$ 9.00

A.7 Lista múltiples EV/SALES Damodaran

Industria	2019	2021	2025
Advertising	1.94	2.03	2.12
Aerospace/Defense	2.27	2.33	3.57
Air Transport	1.34	2.14	1.03
Apparel	1.89	1.82	1.59
Auto & Truck	1.26	4.88	3.88
Auto Parts	0.75	1.06	0.82
Bank (Money Center)	7.28	4	8.31
Banks (Regional)	5.95	3.57	4.28
Beverage (Alcoholic)	4.62	4.78	2.45
Beverage (Soft)	4.88	4.97	4.16
Broadcasting	2.72	1.85	1.4
Brokerage & Investment Banking	6.17	5.2	5.78
Building Materials	1.6	2.14	2.05
Business & Consumer Services	2.39	2.65	2.53
Cable TV	3.44	3.33	2.06
Chemical (Basic)	1.3	1.2	0.85
Chemical (Diversified)	1.35	1.33	0.84
Chemical (Specialty)	2.09	3.33	2.65
Coal & Related Energy	0.62	1.36	2.54
Computer Services	1.28	1.53	1.48
Computers/Peripherals	3.23	5.33	6.63
Construction Supplies	1.68	2.39	3.23
Diversified	2.45	2.81	3.08
Drugs (Biotechnology)	7.33	7.06	7.92
Drugs (Pharmaceutical)	5.44	5.25	6.24
Education	2.59	2.72	1.99
Electrical Equipment	2.56	3.98	4.42
Electronics (Consumer & Office)	0.91	1.55	0.91
Electronics (General)	1.99	2.88	3.21
Engineering/Construction	0.7	1.06	1.74
Entertainment	4.72	6.37	4.33
Environmental & Waste Services	3.08	3.63	3.7
Farming/Agriculture	1.08	1.26	1.34
Financial Svcs. (Non-bank & Insurance)	30.15	25.04	18.91
Food Processing	2.3	2.23	1.47
Food Wholesalers	0.6	0.52	0.46
Furn/Home Furnishings	1.11	1.25	1.33
Green & Renewable Energy	9.94	10.38	7.87
Healthcare Products	5.94	7	4.76
Healthcare Support Services	0.69	0.78	0.46
Healthcare Information and Technology	5.41	7.78	5.31
Homebuilding	1.21	1.37	1.19
Hospitals/Healthcare Facilities	1.63	1.68	1.69

Hotel/Gaming	3.78	8.87	4.33
Household Products	3.74	4.38	3.06
Information Services	9.17	8.75	2.21
Insurance (General)	1.95	2.38	4.32
Insurance (Life)	1.36	1.35	1.28
Insurance (Prop/Cas.)	1.49	1.31	1.49
Investments & Asset Management	4.58	5.42	5.49
Machinery	2.58	3.25	3.43
Metals & Mining	2.04	2.7	4.03
Office Equipment & Services	1.2	1.31	1.43
Oil/Gas (Integrated)	1.61	1.59	1.75
Oil/Gas (Production and Exploration)	2.71	3.1	2.68
Oil/Gas Distribution	4.44	3.59	4.37
Oilfield Svcs/Equip.	0.74	0.74	0.74
Packaging & Container	1.59	1.63	1.55
Paper/Forest Products	0.77	1.14	1.02
Power	4.11	4.41	4.7
Precious Metals	5.05	4.25	5.98
Publishing & Newspapers	1.07	1.31	1.7
R.E.I.T.	13.48	14.23	10.65
Real Estate (Development)	5.37	5.23	3.03
Real Estate (General/Diversified)	6.57	6.06	6.83
Real Estate (Operations & Services)	1.39	2.18	1.46
Recreation	2.35	2.73	1.94
Reinsurance	1.12	0.69	0.65
Restaurant/Dining	4.26	5.12	4.17
Retail (Automotive)	1.19	1.17	1.27
Retail (Building Supply)	2.03	2.63	2.26
Retail (Distributors)	1.4	1.85	1.89
Retail (General)	0.88	0.96	2.11
Retail (Grocery and Food)	0.49	0.45	0.49
Retail (REITs)	3.42	3.73	12.04
Retail (Special Lines)	1.19	1.11	1.63
Rubber & Tires	0.74	0.88	0.59
Semiconductor	5.38	8.69	15.7
Semiconductor Equip	4	6.08	7.61
Shipbuilding & Marine	1.98	1.69	1.74
Shoe	3.55	4.85	2.04
Software (Entertainment)	6.76	8.12	9.13
Software (Internet)	7.64	17.07	9.56
Software (System & Application)	8.77	12.84	11.41
Steel	0.7	0.88	1.17
Telecom (Wireless)	2.43	2.96	3.72
Telecom. Equipment	3.5	4.74	6.52

Telecom. Services	2.85	2.44	2.61
Tobacco	5.19	5.06	6.4
Transportation	1.35	1.52	1.64
Transportation (Railroads)	6.32	8.55	6.67
Trucking	1.93	2.59	1.74
Utility(General)	4.26	4.81	5.25
Utility(Water)	8.83	10.39	7.16
Total Market	3.16	3.76	3.97
Total Market (without financials)	2.62	3.37	3.46

Anexo B: Código del Simulador de Valuación

Se presentan los fragmentos de código correspondientes al núcleo funcional de cada bloque del simulador desarrollado en Python (Jupyter Notebook). Se omiten las secciones de visualización gráfica y las funciones auxiliares de interfaz de consola.

B.1 Bloque 1 — Simulador de Valuación

```
# pip install yfinance pandas openpyxl

import datetime
import pandas as pd
import yfinance as yf

# =====
# CONFIGURACIÓN GENERAL
# =====

ARCHIVO_CSV_DAMODARAN = "damodaran_ev_sales.csv"
ARCHIVO_HISTORIAL     = "historial_valuaciones.xlsx"

# =====
# CONSTANTES DLOM — ESTUDIOS PRE-IPO (WMA)
# Rango adoptado: 25%-40%
# Calibrador: VIX promedio 3 meses previos al cierre
#   VIX <= 20 → tramo inferior: 25.0% - 32.5%
#   VIX > 20 → tramo superior: 32.5% - 40.0%
# =====

DLOM_MIN = 0.25    # piso WMA ajustado
DLOM_MAX = 0.40    # techo WMA
DLOM_MID = 0.325   # punto de quiebre en VIX = 20
VIX_PIVOT = 20     # umbral tramo bajo / alto

def calcular_dlom(vix):
    """
    Interpola el DLOM dentro del rango WMA ajustado (25%-40%).
    VIX <= 20 → tramo inferior 25.0% - 32.5%
    VIX > 20 → tramo superior 32.5% - 40.0%
    """
    if vix <= VIX_PIVOT:
        t = max(vix, 0) / VIX_PIVOT
        dlom = DLOM_MIN + t * (DLOM_MID - DLOM_MIN)
    else:
        t = min(vix - VIX_PIVOT, VIX_PIVOT) / VIX_PIVOT
        dlom = DLOM_MID + t * (DLOM_MAX - DLOM_MID)
```

```

        return round(max(DLOM_MIN, min(DLOM_MAX, dlom)), 4)

def obtener_vix(fecha_cierre):
    """
    Descarga el VIX diario de Yahoo Finance y calcula el promedio
    de los 91 días previos a la fecha de cierre.
    """
    fecha_inicio = fecha_cierre - datetime.timedelta(days=91)
    df = yf.Ticker("^VIX").history(
        start=fecha_inicio.strftime("%Y-%m-%d"),
        end=fecha_cierre.strftime("%Y-%m-%d"),
        interval="1d", auto_adjust=False,
    )
    cierres = df["Close"].dropna().tolist()
    promedio = round(sum(cierres) / len(cierres), 2)
    return promedio

def paso4_valor(target, multiplo, industria, anio, dlom, vix):
    """
    Fórmula central:
    Valor = Ventas_Target × EV/Sales_Damodaran × (1 - DLOM)
    """
    mult_ajustado = multiplo * (1 - dlom)
    valor_final = target["ventas"] * mult_ajustado
    val_piso = target["ventas"] * multiplo * (1 - DLOM_MAX)
    val_techo = target["ventas"] * multiplo * (1 - DLOM_MIN)

    # Rango de sensibilidad
    escenarios = {
        "Optimista (DLOM piso = 25%)": val_techo,
        "Base (DLOM = VIX)": valor_final,
        "Conservador (DLOM techo = 40%)": val_piso,
    }
    for label, valor in escenarios.items():
        print(f" {label}: USD {valor:,.0f}")

    # Registro en historial
    _historial_transacciones.append({
        "Empresa Target": target["nombre"],
        "Año": anio,
        "Ventas (USD)": target["ventas"],
        "Industria": industria,
        "VIX Aplicado": round(vix, 2),
        "DLOM Aplicado (%)": round(dlom * 100, 2),
        "Valor Estimado (USD)": round(valor_final, 2),
    })
    return valor_final

def main():
    while True:
        target = paso0_target()
        multiplo, nombre_m, industria, anio = paso1_2_multiplo_damodaran()
        vix = obtener_vix(pedir_fecha("Fecha de cierre: "))
        dlom = calcular_dlom(vix)
        paso4_valor(target, multiplo, industria, anio, dlom, vix)

        if input(" ¿Otra valuación? [si/no]: ").strip().lower() not in ("s", "si",
"si"):
            break

```

```

df = pd.DataFrame(_historial_transacciones)
df.to_excel(ARCHIVO_HISTORIAL, index=False)

if __name__ == "__main__":
    main()

```

B.2 Bloque 2 — Análisis Estadístico de Error

```

# pip install pandas numpy matplotlib seaborn scipy openpyxl

import pandas as pd
import numpy as np
from scipy import stats

# =====
# CONFIGURACIÓN
# =====

ANIOS = [2019, 2021, 2025]
UMBRAL = 10 # MAPE hipótesis < 10%

COLUMNAS_NECESARIAS = [
    'Empresa Target', 'Año', 'Ventas (USD)', 'Industria',
    'VIX Aplicado', 'DLOM Aplicado (%)',
    'Valor Estimado codigo (USD)', 'Valor Bloomberg (Real)', 'Diferencia',
]

def limpiar_numero(valor):
    """Convierte valores con formato europeo/latino a float."""
    if pd.isna(valor): return np.nan
    if isinstance(valor, str):
        valor = valor.replace('$', '').replace(' ', '')
        if '.' in valor and ',' in valor:
            valor = valor.replace('.', '').replace(',', '.')
        elif ',' in valor:
            valor = valor.replace(',', '.')
    try:
        return float(valor)
    except (ValueError, TypeError):
        return np.nan

def analizar_anio(anio):
    # 1. CARGA Y LIMPIEZA
    df = pd.read_excel(f"historial_valuaciones{anio}.xlsx")
    df.columns = [' '.join(str(c).split()) for c in df.columns]
    df = df[COLUMNAS_NECESARIAS].copy()
    df.columns = [
        'Empresa Target', 'Año', 'Ventas_USD', 'Industria',
        'VIX Aplicado', 'DLOM Porcentaje',
        'Valor_Codigo', 'Valor_Real', 'Diferencia',
    ]
    for col in ['Ventas_USD', 'VIX Aplicado', 'DLOM Porcentaje', 'Valor_Codigo',
'Valor_Real']:
        df[col] = df[col].apply(limpiar_numero)
    df = df.dropna(subset=['Ventas_USD', 'Valor_Real'])
    df = df[df['Valor_Real'] != 0].copy()

```

```

df['DLOM_Decimal'] = np.where(df['DLOM_Porcentaje'] > 1,
                              df['DLOM_Porcentaje'] / 100,
                              df['DLOM_Porcentaje'])

# 2. CÁLCULOS CENTRALES
df['Multiplo_Implicito'] = df['Valor_Real'] / (df['Ventas_USD'] * (1 -
df['DLOM_Decimal']))
df['Error_Pct'] = ((df['Valor_Codigo'] - df['Valor_Real']) /
df['Valor_Real']) * 100
df['Error_Abs_Pct'] = df['Error_Pct'].abs()

# 3. FILTRO OUTLIERS - percentil 5 al 95 sobre Error_Pct
p5, p95 = df['Error_Pct'].quantile(0.05), df['Error_Pct'].quantile(0.95)
df_analisis = df[(df['Error_Pct'] >= p5) & (df['Error_Pct'] <= p95)].copy()

# 4. CORRELACIÓN DE SPEARMAN: error vs tamaño de empresa (log ventas)
log_ventas = np.log10(df_analisis['Ventas_USD'])
errores = df_analisis['Error_Abs_Pct']
sp_r, sp_p = stats.spearmanr(log_ventas, errores)

# 5. TEST DE SESGO - Wilcoxon Signed-Rank
# H0: error mediano = 0 (sin sesgo sistemático)
errores_limpios = df_analisis['Error_Pct'].dropna()
stat_w, p_w = stats.wilcoxon(errores_limpios)

# 6. MAPE
# Hipótesis: MAPE < 10%
df_mape = df_analisis[['Valor_Real',
'Valor_Codigo']].dropna().copy()
df_mape['Err_MAPE'] = (df_mape['Valor_Real'] - df_mape['Valor_Codigo']).abs() /
df_mape['Valor_Real'].abs()
MAPE = (100 / len(df_mape)) * df_mape['Err_MAPE'].sum()

# 7. RESULTADOS
return {
'anio' : anio,
'n_total' : len(df),
'n_filtrado' : len(df_analisis),
'n_excluidos' : len(df) - len(df_analisis),
'p5' : p5, 'p95': p95,
'MAPE' : round(MAPE, 2),
'error_mediana' : round(df_analisis['Error_Pct'].median(), 2),
'error_p90' : round(df_analisis['Error_Pct'].quantile(0.90), 2),
'hit_ratio_20' : round((df_analisis['Error_Abs_Pct'] < 20).mean() * 100, 1),
'hit_ratio_50' : round((df_analisis['Error_Abs_Pct'] < 50).mean() * 100, 1),
'pct_sobreestima' : round((df_analisis['Error_Pct'] > 0).mean() * 100, 1),
'spearman_r' : round(sp_r, 4),
'spearman_p' : round(sp_p, 4),
'wilcoxon_stat' : round(stat_w, 2),
'wilcoxon_p' : round(p_w, 4),
'df_analisis' : df_analisis,
}

resultados = [analizar_anio(a) for a in ANIOS]

```

B.3 Bloque 3 — Resumen Comparativo Inter-Anual

```

import pandas as pd
import numpy as np

```



```

# Requiere haber ejecutado Bloque 2 en la misma sesión (variable 'resultados')

# =====
# 1. TABLA RESUMEN DE MÉTRICAS CLAVE
# =====

df_resumen = pd.DataFrame([
    'Año' : r['anio'],
    'N total' : r['n_total'],
    'N analizado (post-filtro)' : r['n_filtrado'],
    'Outliers excluidos' : r['n_excluidos'],
    'Rango filtro' : f"{r['p5']:.1f}% - {r['p95']:.1f}%",
    'MAPE (%)' : r['MAPE'],
    'Error Mediano (%)' : r['error_mediana'],
    'Hit Ratio <20% (%)' : r['hit_ratio_20'],
    'Hit Ratio <50% (%)' : r['hit_ratio_50'],
    'Sobreestima (%)' : r['pct_sobreestima'],
    'Spearman r' : r['spearman_r'],
    'Spearman p' : r['spearman_p'],
    'Wilcoxon p' : r['wilcoxon_p'],
} for r in resultados]).set_index('Año')

print(df_resumen.to_string())

# =====
# 2. CONCLUSIÓN NARRATIVA AUTOMÁTICA
# =====

mejor_mape = min(resultados, key=lambda r: r['MAPE'])
peor_mape = max(resultados, key=lambda r: r['MAPE'])
mejor_mediana = min(resultados, key=lambda r: r['error_mediana'])
mayor_hr20 = max(resultados, key=lambda r: r['hit_ratio_20'])

print(f"""
    MAPE: Mejor año: {mejor_mape['anio']} ({mejor_mape['MAPE']:.1f}%) | Peor:
    {peor_mape['anio']} ({peor_mape['MAPE']:.1f}%)
    Mediana: Mejor año: {mejor_mediana['anio']} ({mejor_mediana['error_mediana']:.1f}%)
    Hit<20%: Mejor año: {mayor_hr20['anio']} ({mayor_hr20['hit_ratio_20']:.1f}% de
    empresas dentro del umbral)
""")

print(" HIPÓTESIS (MAPE < 10%):")
for r in resultados:
    estado = "CUMPLIDA" if r['MAPE'] < 10 else "NO CUMPLIDA"
    print(f" · {r['anio']} → {estado} (MAPE = {r['MAPE']:.1f}%)")

print("\n SESGO (Wilcoxon):")
for r in resultados:
    sesgo = "SIGNIFICATIVO" if r['wilcoxon_p'] < 0.05 else "no significativo"
    print(f" · {r['anio']} → p = {r['wilcoxon_p']:.4f} ({sesgo})")

if len(resultados) >= 2:
    mapes_ord = sorted(resultados, key=lambda r: r['anio'])
    diff = mapes_ord[-1]['MAPE'] - mapes_ord[0]['MAPE']
    tendencia = "mejoró" if diff < 0 else "empeoró"
    print(f"\n TENDENCIA: El MAPE {tendencia} {abs(diff):.1f} pp entre "
          f"{mapes_ord[0]['anio']} y {mapes_ord[-1]['anio']}.")

```

Anexo C: Resultados del Simulador

C.1 Sector Tecnología — Ventas BMG

C.1.1 Año 2019

Métrica	Resultado
Empresas analizadas (originales)	23
Empresas finales (tras filtro P5/P95)	19
MAPE	26.784,67 %
Sesgo mediano	+9.156,1 % (sobreestima)
Dirección del sesgo	100 % de los casos sobreestima
Factor BMG mediano	92,56x

C.1.2 Año 2021

Métrica	Resultado
Empresas analizadas (originales)	22
Empresas finales (tras filtro P5/P95)	18
MAPE	5.184,32 %
Sesgo mediano (Wilcoxon significativo)	+2.584,0 % (sobreestima)
Factor BMG mediano	26,84x

C.1.3 Año 2025

Métrica	Resultado
Empresas analizadas (originales)	27
Empresas finales (tras filtro P5/P95)	23
MAPE	5.255,87 %
Sesgo mediano (Wilcoxon significativo)	+2.275,5 % (sobreestima)
Hit Ratio (error < 20 %)	21,7 %
Factor BMG mediano	23,75x

C.1.4 Conjunto de los tres años (2019, 2021 y 2025)

Métrica	Resultado
Total de empresas	60
MAPE	12.051,86 %
Sesgo mediano (Wilcoxon significativo)	+2.905,7 % (sobreestima)
Factor BMG mediano	30,06x

C.2 Sector Tecnología — Ventas Ajustadas

C.2.1 Año 2019

Métrica	Resultado
Empresas analizadas (originales)	7
Empresas finales (tras filtro P5/P95)	5
MAPE	71,59 %
Sesgo mediano	-45,1 % (subestima)
Hit Ratio (error < 50 %)	40,0 %
Factor BMG mediano	0,55x

C.2.2 Año 2021

Métrica	Resultado
Empresas analizadas (originales)	4
Empresas finales (tras filtro P5/P95)	2
MAPE	118,20 %
Sesgo mediano	+118,2 % (sobreestima)
Dirección del sesgo	100 % de los casos sobreestima
Factor BMG mediano	N/D (muestra insuficiente)

C.2.3 Año 2025

Métrica	Resultado
Empresas analizadas (originales)	12
Empresas finales (tras filtro P5/P95)	10
MAPE	444,73 %
Sesgo mediano	−42,4 % (subestima)
Hit Ratio (error < 20 %)	20,0 %
Factor BMG mediano	0,40x

C.2.4 Conjunto de los tres años (2019, 2021 y 2025)

Métrica	Resultado
Total de empresas	17
MAPE	296,56 %
Sesgo mediano	−40,7 % (subestima)
Hit Ratio (error < 20 %)	11,8 %
Factor BMG mediano	0,56x

C.3 Sector Consumo Básico— Ventas BMG

C.3.1 Año 2019

Métrica	Resultado
Empresas analizadas (originales)	13
Empresas finales (tras filtro P5/P95)	11
MAPE	549,96 %
Sesgo mediano	−32,8 % (subestima)
Relación ventas–error (regresión)	Significativa: a mayor ventas, mayor error
Factor BMG mediano	0,67x

C.3.2 Año 2021

Métrica	Resultado
Empresas analizadas (originales)	11
Empresas finales (tras filtro P5/P95)	9
MAPE	1.096,46 %
Sesgo mediano (Wilcoxon significativo)	+436,9 % (sobreestima)
Factor BMG mediano	5,37x

C.3.3 Año 2025

Métrica	Resultado
Empresas analizadas (originales)	11
Empresas finales (tras filtro P5/P95)	9
MAPE	241,06 %
Sesgo mediano	+7,6 % (sobreestima leve, no significativo)
Factor BMG mediano	1,08x

C.3.4 Conjunto de los tres años (2019, 2021 y 2025)

Métrica	Resultado
Total de empresas	29
MAPE	623,70 %
Sesgo mediano (Wilcoxon significativo)	+114,2 % (sobreestima)
Factor BMG mediano	2,14x

C.4 Sector Consumo Básico— Ventas Ajustadas

C.4.1 Año 2019

Métrica	Resultado
Empresas analizadas (originales)	8
Empresas finales (tras filtro P5/P95)	6
MAPE	50,50 %
Sesgo mediano (Wilcoxon significativo)	−57,6 % (subestima)
Hit Ratio (error < 20 %)	33,3 %
Factor BMG mediano	0,42x

C.4.2 Año 2021

Métrica	Resultado
Empresas analizadas (originales)	7
Empresas finales (tras filtro P5/P95)	5
MAPE	59,39 %
Sesgo mediano	−10,0 % (subestima, no significativo)
Hit Ratio (error < 20 %)	20,0 %
Factor BMG mediano	0,90x

C.4.3 Año 2025

Métrica	Resultado
Empresas analizadas (originales)	8
Empresas finales (tras filtro P5/P95)	6
MAPE	82,08 %
Sesgo mediano	+15,5 % (sobreestima leve, no significativo)
Hit Ratio (error < 20 %)	33,3 %
Hit Ratio (error < 50 %)	66,7 %
Factor BMG mediano	1,16x

C.4.4 Conjunto de los tres años (2019, 2021 y 2025)

Métrica	Resultado
Total de empresas	17
MAPE	64,26 %
Sesgo mediano	−10,0 % (no significativo)
Hit Ratio (error < 20 %)	29,4 %
Factor BMG mediano	0,90x

C.5 Cuadro Comparativo entre Combinaciones

Combinación	n total	MAPE	Sesgo mediano	HR <20 %	Factor BMG
Tech – Ventas Corregidas	17	296,56 %	−40,7 %	11,8 %	0,56x
Tech – Ventas BMG	60	12.051,86 %	+2.905,7 %	—	30,06x
Consumo – Ventas Corregidas	17	64,26 %	−10,0 %	29,4 %	0,90x
Consumo – Ventas BMG	29	623,70 %	+114,2 %	—	2,14x

Anexo D: Librerías

Bloque	Librería	Función principal
Bloque 1	datetime	Cálculo y formateo de fechas para el período VIX
Bloque 1	pandas	Lectura del CSV Damodaran y exportación del historial Excel
Bloque 1	yfinance	Descarga automática del índice VIX desde Yahoo Finance
Bloque 2	pandas	Carga, limpieza y manipulación del historial de valuaciones
Bloque 2	numpy	Operaciones vectorizadas, manejo de NaN e infinitos
Bloque 2	matplotlib	Gráficos scatter, histogramas, barras y box plots
Bloque 2	seaborn	Visualización de distribuciones con curva KDE
Bloque 2	scipy.stats	Regresión lineal, correlación Spearman, test de Wilcoxon
Bloque 3	pandas	Consolidación inter-anual de métricas
Bloque 3	numpy	Cálculos numéricos y manejo de valores faltantes
Bloque 3	matplotlib	Gráficos comparativos entre años y box plots conjuntos

Bibliografía

- Alexandridis, G., Meng, Y., Sutton, N. (2022). *The evolution of bidder gains and acquisition discounts in M&A*. *Journal of Banking & Finance*
- Bain & Company. (2026). *Looking back at M&A in 2025: Behind the great rebound*
- Berk, J., & DeMarzo, P. (2020). *Corporate Finance (5th ed.)*
- Bhojraj Sanjeev & Lee Charles (2002), *"Who Is My Peer? A Valuation-Based Approach to the Selection of Comparable Firms"*
- Bruner (2004). *Applied Mergers and Acquisitions*
- Caselli, S. (2010). *Private Equity and Venture Capital in Europe: Markets, Techniques, and Deals*

- Cooper, I. A., & Lambertides, N. (2016). *Optimal equity valuation using multiples: The number of comparable firms*.
- Damodaran, A. (2009). *The dark side of valuation*.
- Damodaran, A.(2012). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset (3rd ed.)*
- Damodaran, A. (s.f.a). *Data Archives*. Damodaran Online, Stern School of Business, New York University. Recuperado de https://pages.stern.nyu.edu/~adamodar/New_Home_Page/dataarchived.html#multiples
- Damodaran, A. (s.f.b). *Financial ratios and measures*. Damodaran Online, Stern School of Business, New York University. Recuperado de https://pages.stern.nyu.edu/~adamodar/New_Home_Page/definitions.html
- DePamphilis (2022). *Mergers, Acquisitions, and Other Restructuring Activities: An Integrated Approach to Process, Tools, Cases, and Solutions*
- Emory, J. D. (2002). *The value of marketability as illustrated in initial public offerings of common stock (1980-2000)*. *Business Valuation Review*, 21(4), 182-186.
- Garland, P. J., & Reilly, A. L. (2004). *Update on the Willamette Management Associates pre-IPO discount for lack of marketability for the period 1998 through 2002*. *Insights*, Spring, 38-39.
- Ghosh, R. K. (2017). *Mergers and acquisitions: Strategy, valuation and integration*.
- J.P. Morgan. (2026). *Global M&A annual outlook*.
- Kaplan, S. N., & Ruback, R. S. (1995). *The valuation of cash flow forecasts: An empirical analysis*.
- Koller, T., Goedhart, M., & Wessels, D. (2020). *Valuation: Measuring and Managing the Value of Companies*
- Lewis, C. D. (1982). *Industrial and business forecasting methods*.
- Liu, J., Nissim, D., & Thomas, J. (2002). *Equity valuation using multiples*.

- Mascareñas, J (2013). *Las oleadas de las fusiones y adquisiciones de empresas*.
- Officer, M. S. (2007). *The price of corporate liquidity: Acquisition discounts for unlisted targets*.
- Patrick A. Gaughan (2017). *Mergers, Acquisitions, and Corporate Restructurings (7th Edition)*.
- Shannon P. Pratt, Robert F. Reilly, y Robert P. Schweihs (1995). *Valuing a Business: The Analysis and Appraisal of Closely Held Companies*.
- Sherman, A. J. (2012). *Mergers and acquisitions from A to Z*.
- Spearman, C. (1904). *The proof and measurement of association between two things. The American Journal of Psychology*
- Sudarsanam (2010). *Creating Value from Mergers and Acquisitions: The Challenges*
- Weston, Mitchell & Mulherin (2004). *Takeovers, Restructuring, and Corporate Governance*.
- Wilcoxon, F. (1945). *Individual comparisons by ranking methods*