



Instituto Católico de Administración y Dirección de Empresas

Análisis comparativo de rentabilidad y riesgo de las SOCIMIs españolas frente a los REITs estadounidenses: Un enfoque de Business Analytics aplicado al mercado global de la inversión inmobiliaria

Clave: 202109389

MADRID | Junio 2026

Estudiante: Ada Victoria Montesino Quesada

Director: Miguel Ángel García-Ramos Lucero

Resumen

Este trabajo desarrolla un análisis comparativo del perfil de rentabilidad y riesgo de vehículos de inversión inmobiliaria cotizada, tomando como muestra cinco REITs estadounidenses y dos SOCIMIs españolas durante el período 2017-2025. El enfoque adoptado es el de Business Analytics, integrando técnicas descriptivas, comparativas y predictivas para transformar datos financieros heterogéneos en conocimiento útil para la toma de decisiones de inversión. Se calculan indicadores de mercado como la rentabilidad anualizada, la volatilidad, la beta y el Sharpe ratio, así como ratios financieros fundamentales obtenidos de estados contables. La fase comparativa emplea el test de Mann-Whitney para contrastar las diferencias entre grupos, y la fase predictiva aplica tres modelos de complejidad creciente: ARIMA, Prophet y LSTM. El trabajo busca cubrir un vacío identificado en la literatura, consistente en la ausencia de comparativas sistemáticas entre REITs y SOCIMIs con indicadores homogéneos y herramientas de Business Analytics.

Palabras clave: REITs, SOCIMIs, rentabilidad, riesgo, Business Analytics, ARIMA, Prophet, LSTM, Deep Learning, inversión inmobiliaria cotizada.

Abstract

This paper develops a comparative analysis of the return and risk profile of listed real estate investment vehicles, using a sample of five US REITs and two Spanish SOCIMIs over the period 2017-2025. The adopted approach is Business Analytics, integrating descriptive, comparative and predictive techniques to transform heterogeneous financial data into actionable investment knowledge. Market indicators such as annualised return, volatility, beta and Sharpe ratio are calculated, along with fundamental financial ratios obtained from financial statements. The comparative phase applies the Mann-Whitney test to contrast differences between groups, and the predictive phase applies three models of increasing complexity: ARIMA, Prophet and LSTM. The paper aims to address a gap identified in the literature, namely the absence of systematic comparisons between REITs and SOCIMIs using homogeneous indicators and Business Analytics tools.

Keywords: REITs, SOCIMIs, return, risk, Business Analytics, ARIMA, Prophet, LSTM, Deep Learning, listed real estate investment.

Tabla de contenido

1. INTRODUCCIÓN.....	5
1.1. INTRODUCCIÓN Y RELEVANCIA DEL TEMA.....	5
1.2. OBJETIVOS E HIPÓTESIS DE INVESTIGACIÓN	6
1.3. ESTRUCTURA DEL TRABAJO	7
2. MARCO TEÓRICO	8
2.1. VEHÍCULOS DE INVERSIÓN INMOBILIARIA COTIZADA: DEFINICIÓN Y EVOLUCIÓN	8
2.1.1. <i>Definición</i>	<i>8</i>
2.1.2. <i>Evolución</i>	<i>9</i>
2.2. EL MODELO REIT EN EE. UU.	11
2.2.1. <i>Marco normativo y origen legal.....</i>	<i>11</i>
2.2.2. <i>Requisitos estructurales: activos, ingresos y actividad.....</i>	<i>12</i>
2.2.3. <i>Régimen fiscal especial de los REITs.....</i>	<i>13</i>
2.2.4. <i>Tipologías sectoriales de REIT y papel en el mercado de capitales.....</i>	<i>13</i>
2.3. EL MODELO SOCIMI EN ESPAÑA.....	15
2.3.1. <i>Marco normativo y origen legal.....</i>	<i>15</i>
2.3.2. <i>Requisitos estructurales y de distribución.....</i>	<i>16</i>
2.3.3. <i>Régimen fiscal especial.....</i>	<i>17</i>
2.3.4. <i>Evolución y situación actual del mercado español</i>	<i>17</i>
2.4. DIFERENCIAS ESTRUCTURALES, FISCALES Y DE MERCADO.....	18
2.5. APLICACIÓN DE BUSINESS ANALYTICS EN LAS FINANZAS E INVERSIONES	20
3. REVISIÓN DE LA LITERATURA	22
3.1. ESTUDIOS SOBRE RENTABILIDAD DE LOS REITS.....	22
3.2. EVIDENCIAS EMPÍRICAS SOBRE LAS SOCIMIS.....	24
3.3. COMPARATIVAS INTERNACIONALES Y VACÍOS DE INVESTIGACIÓN	25
4. METODOLOGÍA Y DATOS.....	27
4.1. ENFOQUE DEL ANÁLISIS	27
4.2. SELECCIÓN DE LA MUESTRA.....	28
4.3. VARIABLES UTILIZADAS Y JUSTIFICACIÓN.....	31
4.4. FUENTES DE DATOS Y HERRAMIENTAS ANALÍTICAS.....	34
4.5. ESPECIFICACIÓN DE LOS MODELOS.....	35
4.5.1. <i>Fase descriptiva.....</i>	<i>35</i>
4.5.2. <i>Fase comparativa</i>	<i>35</i>
4.5.3. <i>Fase predictiva</i>	<i>36</i>

5. ANÁLISIS CUANTITATIVO Y RESULTADOS	37
5.1. ANÁLISIS DESCRIPTIVO DE RENTABILIDAD Y RIESGO	37
5.1.1. <i>Rentabilidad</i>	37
5.1.2. <i>Riesgo</i>	38
5.2. COMPARATIVA REITS VS SOCIMIS Y PRUEBAS ESTADÍSTICAS	41
5.3. ANÁLISIS DE RATIOS FINANCIEROS FUNDAMENTALES	44
5.4. MODELOS PREDICTIVOS: ARIMA, PROPHET Y LSTM	46
5.4.1. <i>Modelo ARIMA</i>	48
5.4.2. <i>Modelo Prophet</i>	50
5.4.3. <i>Modelo LSTM</i>	52
5.4.4. <i>Comparativa de los tres modelos</i>	54
6. DISCUSIÓN DE LOS RESULTADOS	55
7. CONCLUSIÓN.....	57
BIBLIOGRAFÍA.....	59
ANEXO A – CÓDIGO PYTHON.....	63
A.1. SCRIPT DE SELECCIÓN DE MUESTRA	63
A.2. ANÁLISIS DESCRIPTIVO	68
A.3. ANÁLISIS COMPARATIVO	75
A.4. ANÁLISIS DE INDICADORES FINANCIEROS	78
A.5. MODELO ARIMA	82
A.6 MODELO PROPHET	87
A.7 MODELO LSTM	91

1. INTRODUCCIÓN

1.1. Introducción y relevancia del tema

Los vehículos de inversión inmobiliaria cotizada tienen un rol clave en los mercados financieros de hoy, pues unen liquidez, diversificación, buena rentabilidad y transparencia. Pero existen diferencias notables entre los diversos modelos que se pueden encontrar. Las SOCIMIs españolas son un vehículo bastante reciente, enfocado sobre todo a la profesionalización del sector inmobiliario del país. Por el contrario, los REITs estadounidenses tienen un camino más largo y firme, siendo un ejemplo mundial en regulación, tamaño y profundidad del mercado.

Para los inversores, ambos instrumentos son importantes para diversificar las carteras y generar ingresos sin trabajar. Sin embargo, tienen distintas sensibilidades ante factores macroeconómicos como los tipos de interés, la inflación o las fases del ciclo económico. Esto hace necesario comparar de forma práctica mercados que operan con normas diferentes, y analizar los elementos macroeconómicos que afectan a su comportamiento.

Este trabajo presenta un enfoque de Business Analytics, basado en juntar datos de varias fuentes, para crear indicadores comparables de rentabilidad y riesgo. Por medio del análisis visual y estadístico, se busca identificar patrones y diferencias entre los dos modelos de inversión, transformando los datos en conocimiento útil para tomar decisiones estratégicas y financieras.

1.2. Objetivos e hipótesis de investigación

El propósito principal de este trabajo es emplear herramientas de Business Analytics como estudio comparativo de la rentabilidad y riesgo entre las SOCIMIs españolas y los REITs estadounidenses. Con el objetivo de identificar patrones de comportamiento, correlaciones y niveles de eficiencia relativa entre ambos modelos, mediante la integración de indicadores financieros, análisis estadístico y herramientas de visualización.

Objetivos específicos:

1. Obtener y limpiar datos financieros y bursátiles de una muestra representativa de SOCIMIs y REITs, en concreto cinco REITs y dos SOCIMIs, según los criterios de liquidez y disponibilidad de datos detallados en el Capítulo 4.
2. Calcular indicadores clave de rentabilidad, como ROE, ROA o Dividend Yield, además de riesgo, como Beta, Volatilidad o Sharpe Ratio.
3. Visualizar los resultados mediante gráficos desarrollados con Python, con el objetivo de interpretar la comparativa fácilmente.
4. Identificar correlaciones y tendencias entre variables de rentabilidad, riesgo y estructura financiera, ya sea con técnicas descriptivas, analíticas y predictivas.
5. Formular conclusiones con las evidencias realizadas en los puntos anteriores, destacando las implicaciones para inversores y gestores de activos.

Hipótesis de investigación:

- Hipótesis 1: Los REITs estadounidenses presentan mayor rentabilidad ajustada al riesgo en comparación con las SOCIMIs, debido a su mayor diversificación geográfica y madurez de mercado.
- Hipótesis 2: Las SOCIMIs muestran mayor volatilidad debido a su menor liquidez y la concentración sectorial de sus activos.
- Hipótesis 3: Relación positiva entre el apalancamiento y la rentabilidad, pero está acompañada a un incremento proporcional del riesgo financiero.

1.3. Estructura del trabajo

El presente trabajo se organiza en siete capítulos.

- El Capítulo 2 desarrolla el marco teórico sobre REITs y SOCIMIs, sus regímenes normativos y los indicadores financieros empleados.
- El Capítulo 3 revisa la literatura académica existente
- El Capítulo 4 describe la metodología, la muestra y las herramientas analíticas.
- El Capítulo 5 muestra el análisis cuantitativo y los resultados, incluyendo el análisis descriptivo, la comparativa, los ratios financieras y los modelos predictivos.
- El Capítulo 6 discute los resultados en relación con las hipótesis de investigación planteadas.
- El Capítulo 7 recoge las conclusiones, las implicaciones para inversores y las líneas de investigación futuras.

2. MARCO TEÓRICO

2.1. Vehículos de inversión inmobiliaria cotizada: definición y evolución

2.1.1. Definición

El concepto de sociedad de inversión inmobiliaria cotizada, conocido internacionalmente como *Real Estate Investment Trust* (REIT), se constituyó en EEUU en 1961. Estos se caracterizan por ser un vehículo canalizador del ahorro de particulares e inversores institucionales a través de la cotización en mercados de valores (PricewaterhouseCoopers Auditores S.L., 2020), con lo cual ofrece al inversor una liquidez similar a la de las acciones. Gracias a la creación de este tipo de sociedades, los ciudadanos han podido invertir en estas como si fueran acciones o bonos de compañías (Nareit, 2025).

En cambio, este tipo de sociedades es relativamente nuevo en España, introduciéndose por primera vez con la Ley 11/2009 que regula las Sociedades Anónimas Cotizadas de Inversión (SOCIMI) dentro del mercado español. No obstante, tuvo que ser modificada por la Ley 12/2012, con el objetivo de reforzar su atractivo fiscal y equipararlos con el régimen de los REIT estadounidenses (PricewaterhouseCoopers Auditores S.L., 2020). Las SOCIMIs se han configurado como una herramienta que ha ayudado a superar la crisis inmobiliaria y económica que tuvo lugar en España durante 2008 y sus años posteriores, debido a la gran influencia económica del sector dentro del PIB del país (JLL España y BME, 2021).

Según define William Bernstein, los REIT son sociedades de inversión que gestionan y poseen carteras diversificadas de inmuebles de distintas categorías, pudiendo ser edificios comerciales, residenciales, oficinas, etc. Se caracterizan por proporcionar la mayor parte de su rentabilidad a largo plazo a través del ingreso recurrente por alquiler y del reparto de dividendos a sus accionistas (Bernstein, 2025). En este caso, un REIT está obligado a distribuir la mayoría de su renta neta imponible entre sus accionistas, restringiéndose en su actividad, estructura y base accionarial. Debido a esto, este tipo de vehículos no están

sujetos al impuesto de sociedades s,obre la renta y plusvalías, reduciendo su carga fiscal (Cohen & Steers, 2012).

La relevancia del REIT en los mercados inmobiliarios cotizados es significativa, ya que aproximadamente el 75% de las compañías que forman parte del mercado de valores inmobiliarios son de esta tipología (Cohen & Steers, 2012).

2.1.2. Evolución

Como se mencionó anteriormente, los REITs se originaron en EE. UU. en 1961 durante la presidencia de Dwight D. Eisenhower, con el objetivo de dar oportunidad al inversor a invertir y diversificar su cartera en el sector inmobiliario a través de sociedades cotizadas, teniendo en cuenta que anteriormente solo estaba al alcance de inversores institucionales. Esto originó la creación del NAREIT (National Association of Real Estate Funds), encargada de representar los intereses de la industria y realizan estudios de comportamientos dentro del sector dentro del país norteamericano. El primer REIT que salió a bolsa fue *Continental Mortgage Investors* en 1965 en la Bolsa de Nueva York (Nareit , 2025).

En la actualidad, más de 60 países alrededor han adoptado REITs, cada uno con su nombre propio. Tras su consolidación en EE. UU., a partir de la década de 1960, se extendió a otros países como Australia, Canadá o Brasil. Esto refleja que los REITs han sido una exitosa herramienta para la canalización de ahorro en el sector inmobiliario.

En Europa, los REITs han ido creciendo durante los últimos 50 años, abarcando 14 países dentro de la Unión Europea. Dentro de esta, las tres mayores economías europeas, Francia, Alemania y Reino Unido (aunque ya no forma parte de la UE), comprenden el 80% de la capitalización del mercado europeo de REITs (Op't Veld, 2023). El primer país europeo que optó por comenzar a desarrollar estas sociedades fue Países Bajos en 1969, asentando las bases en el desarrollo de este tipo de vehículos en el resto de Europa.

Se ha visto a lo largo del tiempo los beneficios de este tipo de sociedades, entrando cada vez más compañías en este mercado, gracias a una mayor transparencia, diversificación,

liquidez y disciplina financiera. Según el estudio realizado por Op't Veld en *The Impact of European REITs*, hay dos factores que han sustentado el crecimiento de los REITs en Europa a lo largo del tiempo: el primero es que todos se sustentan mediante un régimen específico y, en segundo lugar, la necesidad de resolver periodos de estrés dentro del sector inmobiliario, especialmente después de crisis financieras.

2.2. El Modelo REIT en EE. UU.

A continuación, se describen las características del modelo REIT estadounidense, referencia mundial en regulación y estructura de estos vehículos.

2.2.1. Marco normativo y origen legal

El régimen de los REITs fue promulgado en 1960 y comenzó a ser efectivo a partir de 1961. La definición legal de esta se recoge en la sección 856 de la Public Law 86 – 779, de septiembre de 1960 (*Real Estate Investment Trust Act of 1960*). En ella se comenta que los REITs se configuran como fideicomisos o asociaciones no incorporadas gestionados por uno o más fiduciarios, cuya titularidad beneficiaria está representada en acciones transferibles de participación; tributa como una sociedad anónima nacional (domestic corporation), en el caso de que no se aplique el régimen especial; no mantiene ningún activo a la venta a clientes en el curso ordinario de su actividad o negocio; y la titularidad beneficiaria tiene que estar en manos de 100 o más personas. En el caso de que una sociedad quiera ir a bolsa, no hay ninguna restricción, en el caso de EE. UU., de modo que coexisten los REITs cotizados y no cotizados (PriceWaterhouseCoopers, 2021).

No obstante, la implementación de los REITs fue gradual. El primer REIT que salió a bolsa fue en 1965 en el NYSE, es decir, cinco años después de su promulgación, y las corporaciones constituidas bajo derecho estatal no pudieron acogerse a este tipo de régimen hasta 1976 (Ashok, Kaplan, Hammell, Monti, & Berkenblit, 2021). Con lo cual, este desarrollo progresivo refleja las limitaciones iniciales de los REITs, donde al principio la forma jurídica y su capacidad solo se relacionaba con la gestión directa de los inmuebles, esto ha ido flexibilizándose a lo largo del tiempo.

La aprobación de esta acta permitió la democratización de la inversión inmobiliaria, al facilitar el acceso a pequeños inversores en vehículos cotizados inmobiliario, en un sector que anteriormente estaba reservado a inversores institucionales (Juliani Fernández de Córdoba, 2008). Posteriormente, se han realizado diversas reformas para ajustarse a las necesidades del mercado y los inversores, cómo puede ser el *Tax Reform Act* en 1986 o *REIT Modernization Act* en 1999 (Coletta & Busato, 2019).

2.2.2. Requisitos estructurales: activos, ingresos y actividad

El sistema estadounidense pide a los REITs ciertos requisitos estructurales sobre cómo se forman sus activos y de dónde sacan el dinero, buscando así asegurar que son medios básicamente inmobiliarios y, a la vez, mantener su situación fiscal especial.

En relación con la composición de los activos, según la normativa de EE UU. exige que al menos el 75% del valor total de activos del REIT estén invertidos en bienes inmuebles, efectivo, valores del gobierno estadounidense (letras del tesoro, bonos) y acciones de otras REITs. Este requisito pone un límite en invertir en activos financieros no relacionados con el sector inmobiliario y refuerza el carácter especializado de estos vehículos. Aunque esto es así, los porcentajes van variando entre países, por ejemplo, en el caso de Bélgica la normativa exige que la inversión se destine prácticamente su totalidad a activos inmobiliarios, apreciando la heterogeneidad que existe entre normativas a nivel internacional (Gogineni, Jain, & Upadhyay, 2024).

En cuanto a las fuentes de ingresos, por lo menos 75% de estos deben de venir de rentas de propiedades inmobiliarias, intereses sobre hipotecas, ganancias por venta de propiedades y dividendos de otros REITs. Además, cerca del 95% de los ingresos brutos deben ser ingresos pasivos, incluyendo los conceptos anteriores, además de otros dividendos e intereses (Congressional Research Service , 2016). De esta forma se limita la obtención de ingresos procedentes de actividades ajenas al sector inmobiliario.

Por último, existen diversas restricciones por actividad para evitar el desarrollo especulativo. En este caso, los REITs no pueden desarrollar el inmueble para su posterior venta, no pueden ser dealers inmobiliarios. La legislación remarca límites cuantitativos y temporales con relación a la venta de inmuebles mantenidos durante un tiempo reducido, así como la posibilidad de aplicar gravámenes adicionales sobre las ganancias derivadas de este tipo de operaciones (PriceWaterhouseCoopers, 2013). El objetivo principal de esto es que los REIT funcionen como vehículos orientados a la generación de rentas y no como sociedades de venta inmobiliaria, contribuyendo a la estabilidad de flujos de caja para el inversor.

2.2.3. Régimen fiscal especial de los REITs

Una de las características principales de los REITs es su régimen fiscal, debido a que el estado facilita este vehículo.

Si se compara con las sociedades anónimas ordinarias, sujetas a una doble imposición (primero tributan a nivel societario y, posteriormente, los accionistas vuelven a tributar por los dividendos recibidos), los REITs tributan bajo un sistema de único nivel, donde el REIT puede deducir su base imponible las distribuciones realizadas a sus accionistas, con lo cual, si distribuye la totalidad de su renta imponible, no tributa por el impuesto federal de sociedades. En resumen, la tributación solo recae en sede del inversor (Ashok, Kaplan, Hammell, Monti, & Berkenblit, 2021).

Debido a esto, el REIT actúa como un vehículo de transmisión de las rentas inmobiliarias hacia el inversor final. Estos vehículos actúan como un conducto fiscal, en el cual los ingresos generados por los activos inmobiliarios fluyen hacia los accionistas sin ser gravados por la sociedad, siempre que se cumplan los requisitos de distribución (Mazurczak, 2011).

La exención societaria se justifica por la obligación de distribuir el 90% de la renta imponible, que será gravada en sede del inversor (Oh & Verstein, 2024). Adicionalmente, el incumplimiento de los requisitos del régimen conlleva la pérdida del estatus de REIT y la sujeción al impuesto de sociedades ordinario, sin imposibilidad de reelección durante los cuatro siguientes ejercicios siguientes (Ashok, Kaplan, Hammell, Monti, & Berkenblit, 2021).

2.2.4. Tipologías sectoriales de REIT y papel en el mercado de capitales

Dentro del mercado de REITs en EE. UU. encontramos dos tipologías, los *equity REITs* y los *mortgage REITs*. Los primeros gestionan y poseen inmuebles con el objetivo de

generar renta, obteniendo así sus ingresos. Mientras que los segundos financian activos inmobiliarios a través de préstamos hipotecarios o mediante adquisiciones de hipotecas (Li & Orzano, 2020).

Una de las características de los *equity REITs* es su clasificación sectorial, la National Association of Real Estate Investment Trusts (NAREIT) lo segmenta en residencial, oficinas, logística, retail, hoteles, sanidad, self-storage, torres de telecomunicaciones o centros de datos (Li & Orzano, 2020). Gran parte de los *equity REITs* elige centrarse en un sector como forma de competir, entre los REITs más importantes de cada sector resaltan Prologis en logística, American Tower en infraestructuras de comunicación y Digital Realty en centros de datos.

Esta variedad sectorial presenta diferentes patrones de rentabilidad, volatilidad y sensibilidad a los factores macroeconómicos. Li y Orzano comentan en su estudio que algunos sectores tradicionales, como oficinas, industrial o residencial, presentan un nivel elevado de correlación entre sí. Pero otros sectores especializados como torres de telecomunicaciones o data centres, mantienen rentabilidades y fundamentos diferenciados. Además, los *mortgage REITs* muestran una correlación baja si se comparan con los *equity REITs*, por su tipo financiero de bienes subyacentes. En cuanto al riesgo, los REITs tienen una inestabilidad mayor que la de acciones y los bonos, lo cual implica una mayor exposición a sucesos extremos malos, como pasó en la crisis económica de 2008 con una bajada del -93.26% (Monteiro, Sebastiao, & Silva, 2025).

2.3. El modelo SOCIMI en España

Las Sociedades Anónimas Cotizadas de Inversión en el Mercado Inmobiliario (SOCIMI) es la adaptación española de los REITs. La creación de esta tuvo lugar a causa de la necesidad de impulsar el mercado del alquiler, favorecer la canalización de ahorro hacia el sector y dotar al mercado español de un vehículo cotizado con un régimen fiscal especial.

2.3.1. Marco normativo y origen legal

El marco normativo de las SOCIMIs se regula en la Ley 11/2009, aprobada en un contexto de crisis en el sector inmobiliario tras la crisis del 2008. Su objetivo era canalizar liquidez en el sector inmobiliario, profesionalizar el mercado del alquiler y facilitar el acceso del inversor retail, siguiendo el mismo modelo de los REITs internacionales (Valdés - Solís Fernández de Retana, 2022).

A pesar de esto, el régimen de la Ley 11/2009 no resultó muy atractivo para los inversores, debido a su diseño fiscal, que gravaba los beneficios en sede de la sociedad a un tipo del 18%, y por la dificultad de evitar la doble imposición para inversores no residentes (Viñuales Sanabria, 2010). A causa de esto, no se constituyó ninguna SOCIMI durante los tres primeros años desde la aprobación de esta ley.

No obstante, tuvo lugar una reforma introducida por la Ley 16/2012, permitiendo alinear a las SOCIMIs con el modelo de REITs internacional, adoptando un tipo del 0% en el impuesto en el impuesto de Sociedades con tributación efectiva en sede del accionista. Desde ese momento, comenzaron a constituirse las primeras SOCIMIs a finales del 2013, siendo un instrumento reciente en España, aunque actualmente España se sitúa como uno de los mercados de REITs más dinámicos de Europa (Grigorián & Escudero, 2025).

2.3.2. Requisitos estructurales y de distribución

Las sociedades deben de cumplir una serie de requisitos, para poder acogerse al régimen de las SOCIMIs. Estas se recogen dentro de la Ley 11/2009.

En primer lugar, en cuanto a la estructura de activos e ingresos, al menos el 80% del activo debe de estar invertido en inmuebles urbanos destinados al arrendamiento, terrenos para su promoción o participaciones en otras SOCIMIs. Además, el 80% de los ingresos del periodo impositivo debe venir de rentas de arrendamiento o de dividendos de participaciones en entidades que cumplan requisitos equivalentes. Los activos inmobiliarios que integren la cartera tienen que mantenerse en arrendamiento por lo menos durante tres años, mencionado en el artículo 3 de la Ley 11/2009. Hay que tener en cuenta, que en el diseño inicial del régimen, es decir con la Ley 11/2009, este periodo era de mínimo siete años, pero con la reforma del 2012 este plazo quedó reducido (Urquijo Moreno, 2019).

Desde el punto de vista de la sociedad, las SOCIMIs deben constituirse como sociedades anónimas con un capital social mínimo de cinco millones de euros y una única clase de acciones. Además, sus acciones deben cotizar en un mercado regulado o en un sistema multilateral de negociación (Ley 11/2009, Artículo 4), garantizando la liquidez y transparencia del vehículo frente al inversor.

A esto se le añade la obligación de distribuir una parte de sus beneficios obtenidos. Con carácter general, deben distribuir la mayor parte de las rentas procedentes de alquileres, los dividendos recibidos de otras entidades y una parte de las plusvalías derivadas de la transmisión de activos, aproximándolo al modelo de REIT internacional (García Serrano, 2018).

En resumen, estos requisitos definen la naturaleza de las SOCIMI como vehículos cotizados de inversión patrimonial en alquiler, especializados en activos inmobiliarios generadores de rentas y diseñados para ofrecer al inversor exposición al sector con mayor liquidez, transparencia y disciplina que la inversión directa en inmuebles.

2.3.3. Régimen fiscal especial

Al igual que los REITs estadounidenses, las SOCIMIs españolas se benefician de un régimen fiscal especial con el objetivo de evitar la doble imposición. Lo que destaca es la aplicación de un tipo del 0% en el Impuesto sobre Sociedades, marcado en la Ley 16/2012, además de estar recogido en el artículo 9 de la Ley 11/2009. Gracias a esto, los beneficios generados por la cartera de la SOCIMI no tributan en sede de la sociedad, si cumple con los requisitos de distribución. Con lo cual, la renta fluye hacia el accionista, que es quien soporta la carga tributaria que corresponda (Viñuales Sanabria, 2010). Este modelo es estructuralmente equivalente al mecanismo de transmisión fiscal de los REITs estadounidenses, estas diferencias en los tipos aplicables se analizan en la sección 2.5.

A pesar de esto, la ley contempla un gravamen especial del 19% para accionistas con participaciones significativas en jurisdicción de baja tributación, como se comenta en el artículo 9 de la Ley 11/2009, y un gravamen del 15% sobre los beneficios no distribuidos introducidos en 2021, como mecanismo para reforzar la obligación de reparto (Grigorián & Escudero, 2025).

2.3.4. Evolución y situación actual del mercado español

El mercado de las SOCIMIs ha experimentado un gran crecimiento desde la reforma de la ley en 2012. En 2013 solo existían 2 vehículos de esta tipología con capitalización conjunta de unos 105 millones de euros. Ya en 2019, el mercado alcanzó su máximo histórico con 82 SOCIMIs activas y una capitalización de mercado de aproximadamente 25.973 millones de euros (JLL España y BME, 2021). A pesar de esta señal de crecimiento, con la irrupción del Covid-19 en 2020, el mercado de las SOCIMIs se contrajo, que se reflejó en el cierre de 2020 con una capitalización de 22.026 millones. A finales de 2024, el número de SOCIMIs activas ascendía a 144, consolidando a España como uno de los mercados de inversión inmobiliaria cotizada más dinámicos de Europa (Grigorián & Escudero, 2025).

2.4. Diferencias estructurales, fiscales y de mercado

A pesar de que las SOCIMIs y los REITs tienen la misma lógica, es decir, son vehículos inmobiliarios cotizados, es cierto que presentan diferencias relevantes con relación a su normativa, estructura de requisitos y dimensión de mercado.

Requisitos estructurales

Los REITs exigen que al menos el 75% de los activos y de los ingresos procedan de fuentes inmobiliarias, con una doble prueba de ingresos al 75% y al 95%. En el caso de las SOCIMIs estas establecen un umbral único del 80% para activos y para ingresos cualificados (Ley 11/2009, 2009). Con relación a la permanencia de los activos en cartera, las SOCIMIs exigen un periodo mínimo de arrendamiento de tres años, esto no sucede en el caso estadounidense, a causa de que no existe este requisito. Además, las SOCIMIs establecen un capital social mínimo de cinco millones de euros (Ley 11/2009, 2009), los REITs no fija ningún umbral de capital mínimo para establecer el vehículo. (Ashok, Kaplan, Hammell, Monti, & Berkenblit, 2021).

Régimen fiscal y distribución

Ambos modelos comparten el principio de transparencia fiscal que se caracteriza en que los beneficios no tributan en sede de la sociedad sino en sede del accionista, eliminando así la doble imposición. No obstante, el umbral de distribución obligatoria diferencia la normativa entre estos dos vehículos, los REITs deben distribuir al menos el 90% de su renta imponible anual (Ashok, Kaplan, Hammell, Monti, & Berkenblit, 2021) y las SOCIMIs el 80% sobre los beneficios de arrendamientos (Ley 11/2009, 2009). Esta diferencia tiene implicaciones sobre la política de dividendos y la rentabilidad para el accionista, que serán analizadas en el Capítulo 5.

Acceso al mercado y dimensión

Otra de las diferencias es la obligatoriedad de cotización. Las SOCIMIs deben cotizar en un mercado regulado o sistema multilateral de negociación (Ley 11/2009, 2009), garantizando la liquidez y transparencia para el inversor. En cambio, en EE. UU. existen los REITs privados no cotizados, siendo esta una de las grandes diferencias con los vehículos españoles, esto marca la diferencia con relación al acceso de los inversores minoristas y su visibilidad dentro de los mercados de capitales (Fernández García, 2025). Finalmente, esta diferencia entre estos dos mercados es significativa. Por un lado, el mercado de REIT estadounidense alcanzaba una capitalización aproximada de 1,44 billones de dólares en 2025 (NAREIT, 2025). Por el otro lado, España cerró este mercado con una capitalización de más de 17.000 millones de euros en 2025, según CBRE (Armanext, 2025). Esta asimetría condiciona la inversión y la liquidez de los instrumentos como su comportamiento en cartera, que se analizarán en el Capítulo 5.

El análisis comparativo que se desarrolla en los capítulos siguientes se apoya en dos tipologías de indicadores. El primero se caracteriza por las variables de mercado como la rentabilidad media anualizada, la volatilidad, la beta respecto a su índice de referencia y el Sharpe ratio. El segundo incorpora variables financieras propias del sector como son el ROA, el ROE, el ratio de endeudamiento sobre activos (Deuda/Activos, aproximación al LTV) y el margen EBITDA, aplicados de manera homogénea en ambos vehículos.

2.5. Aplicación de Business Analytics en las finanzas e inversiones

El Business Analytics engloba el conjunto de métodos cuantitativos, estadísticos y computacionales para la exploración e interpretación de los datos con el objetivo de mejorar la toma de decisiones, en este caso dentro de entornos de inversión. Su aplicación en los mercados financieros ha transformado el sector de manera exponencial, gracias a que se ha incrementado la capacidad computacional y la disponibilidad de grandes volúmenes de datos estructurados y no estructurados. Como consecuencia, la gestión de inversiones ha evolucionado hacia enfoques cada vez más sistemáticos y cuantitativos, donde tiene mucha importancia la construcción de modelos para pronosticar el riesgo, el rendimiento y el coste de los activos (Kahn, 2019).

Hay que destacar que la transformación en el sector inmobiliario ha sido visible. La integración del big data en los procesos de negocios dentro del sector ha reforzado los procesos de toma de decisiones y la mejora de la gestión de riesgos, mediante la identificación de datos estructurados, como series históricas de transacciones o variables macroeconómicas, y datos no estructurados procedentes de redes sociales o información georreferenciada (Battisti, Shams, Sakka, & Miglietta, 2019). Asimismo, la disponibilidad de precios diarios para REITs y SOCIMIs hace posible aplicar las mismas herramientas analíticas empleadas en renta variable general, adaptándolo lo máximo posible al sector inmobiliario.

Con relación a la renta variable, la inversión cuantitativa emplea modelos factoriales, técnicas de optimización de carteras y análisis estadísticos de series temporales con el objetivo de identificar patrones de retornos y gestionar el riesgo. El modelo CAPM o el Sharpe ratio, definidos en el apartado anterior, son algunos de los conceptos sobre los que se constituyen estos enfoques que junto con la aplicación de business analytics, información es capaz de procesarse a gran escala y velocidad inalcanzables en un análisis tradicional (Kahn, 2019).

Además, durante los últimos años se ha hecho hincapié en la aplicación de algoritmos de Machine Learning en la predicción de los precios de REITs y a la optimización de carteras. Por ejemplo, Habbab, Kampouridis y Papastylianou (2025) comentan que algoritmos como regresiones lineales, K-Nearest Neighbours o redes neuronales superan

a modelos estadísticos como ARIMA en la predicción de series temporales de precios de REITs, reduciendo el error en hasta un 60%. Asimismo, en este estudio destacan que las carteras construidas con herramientas de Machine Learning obtienen Sharpe ratios superiores a las construidas con metodología tradicional (Habbab, Kampouridis, & Papastylianou, 2025).

En este trabajo, el enfoque de Business Analytics se emplea para usar herramientas analíticas para recopilar, organizar y analizar información financiera y bursátil de SOCIMIs y REITs, con el objetivo de analizar su rentabilidad y riesgo. Además de las técnicas descriptivas y comparativas, el Business Analytics también permite incorporar enfoques predictivos orientados a la anticipación de variables financieras y bursátiles, como se ha descrito en el párrafo anterior, con modelos de Machine Learning.

3. REVISIÓN DE LA LITERATURA

Para realizar el trabajo se ha debido realizar una investigación académica sobre rentabilidad y riesgo en vehículos de inversión inmobiliaria cotizada. La literatura empleada se categoriza en tres líneas diferentes: los estudios sobre rentabilidad y comportamiento de riesgo de los REITs estadounidenses, la evidencia empírica sobre las SOCIMIs en el mercado español y las comparativas internacionales entre este tipo de vehículos.

3.1. Estudios sobre rentabilidad de los REITs

La mayoría de las fuentes documentales sobre rentabilidad de los REITs tienen su punto de partida en el análisis del comportamiento como clase de activo diferenciada dentro de las carteras mixtas. Coletta y Busato (2019) realizan una revisión de la economía financiera de los REITs hasta 2018, llegando a la conclusión de que la rentabilidad total de estos vehículos ha presentado históricamente una correlación moderada con el mercado de renta variable general, posicionándolos como un instrumento de diversificación. Además, el estudio señala que la rentabilidad de los REITs responde tanto a factores del mercado inmobiliario como a condiciones macroeconómicas generales, sobre todo a los cambios de los tipos de interés, cuya variación afecta directamente al coste de financiación y, por tanto, a la capacidad distribuidora de dividendos.

Con relación a estudios sobre riesgo, destaca el estudio realizado por Alcock y Steiner (2015) sobre el riesgo sistemático, donde distinguen entre la dependencia lineal medida por la beta de CAPM, y el riesgo asimétrico, siendo la probabilidad de que los retornos de los REITs caigan de una forma desproporcionada junto al mercado en períodos de estrés. Dentro del estudio, los autores estimaron una beta de media de 0,589 para los REITs estadounidenses en el período entre 1993-2013, gracias a su característica de activo defensivo, pero advierten que este indicador no captura totalmente su estructura de dependencia con el mercado. De igual forma, identifican que el apalancamiento financiero tiene un efecto asimétrico sobre el riesgo, comentando que, aunque la beta no

aumente a corto plazo, aumentan las caídas conjuntas con el mercado en períodos de recesión.

Por otro lado, Rehman, Shahzad, Ahmad y Vo (2022) amplían el estudio financiero, estudiando las dinámicas de dependencia entre cincuenta REITs estadounidenses durante el periodo entre 2006-2020, incluyendo la crisis financiera global, la crisis de deuda soberana europea y la pandemia del COVID – 19. Sus resultados muestran que la pandemia fue un antes y un después en la estructura de dependencia entre REITs en comparación con las crisis anteriores, con unas de pérdidas superiores al 50% del valor de cotización entre febrero y julio de 2020. Esta evidencia subraya la importancia de controlar momentos de ruptura estructural en los análisis de series temporales de rentabilidad inmobiliaria cotizada.

Asimismo, el análisis se extiende con el estudio de Abdullah, Adeabah, Abakah y Lee (2023), donde examinan la transmisión de riesgos entre REITs, tokens inmobiliarios y otros activos en condiciones de mercado, ya sea alcista o bajista. Los resultados del estudio determinan que, en condiciones normales de mercado, la conectividad significativa se muestra solo entre el S&P 500 y los REITs, mientras que en condiciones extremas la conectividad se generaliza a través de todos los activos analizados. Con lo cual, la evidencia resalta la idea de que los beneficios de la diversificación que pueden ofrecer los REITs tienden a reducirse en momentos que más se necesita, es decir, en momentos de estrés de mercado.

Finalmente, en el ámbito de predicción de rentabilidades, la literatura reciente ha explorado la aplicación de modelos de Machine Learning en la predicción de precios de REITs, ya desarrollada en el marco teórico de este trabajo.

3.2. Evidencias empíricas sobre las SOCIMIs

La literatura académica con relación a las SOCIMIs es bastante limitada en comparación con los REITs, debido a su menor antigüedad dentro del mercado español y a sus limitaciones de tamaño y liquidez del mercado. Las primeras fuentes documentales académicas se centran en el análisis del marco regulatorio y las condiciones de implantación del modelo.

Fernández y Romero (2016) constituyen una de las primeras evidencias académicas donde muestran a las SOCIMIs desde un punto de vista del mercado de capitales, analizando su función como instrumento de canalización de ahorro dentro del sector inmobiliario en un contexto de tipo de interés reducido. En el estudio se comenta que la distribución del 80% de las rentas convierte a las SOCIMIs en vehículos atractivos para inversores que se orientan por el dividendo.

PwC (2020) ofrece un análisis descriptivo de la evolución del mercado de SOCIMIs entre 2013 y 2020, documentando el crecimiento en estos vehículos, la distribución por segmentos inmobiliarios y las tendencias en rentabilidad por dividendo y apalancamiento. Además, el informe señala que las SOCIMIs cotizadas en el Mercado Continuo presentan un perfil financiero distinto al de las que cotizan en el BME Growth, siendo las primeras de mayor tamaño, mayor liquidez y ratios de apalancamiento más moderados. JLL y BME (2021) complementan esta información con datos agregados para el periodo 2018-2020, incluyendo indicadores como ROA, ROE, Yield bruta, apalancamiento sobre GAV y el impacto diferenciado de la pandemia sobre los distintos segmentos del mercado.

3.3. Comparativas internacionales y vacíos de investigación

Por último, se encuentran los estudios de comparativa entre diferentes regímenes de REITs que se centran en la comparativa de estos vehículos en más de cuarenta países. Mazurczak (2011) analiza el desarrollo de los REITs europeos, documentando las diferencias estructurales entre los modelos de Francia, Alemania, Reino Unido, Italia y los Países Bajos con relación a los requisitos de distribución, restricción de inversión y tratamiento fiscal. Asimismo, concluye que la heterogeneidad regulatoria entre países dificulta la comparación directa de las rentabilidades y que los mercados con regímenes estrictos suelen presentar estructuras de riesgo más estables.

EPRA (2025) analiza el impacto sobre el modelo de REIT en los mercados europeos, comparando el comportamiento de empresas inmobiliarias que adoptaron el régimen de REIT con las que no lo hicieron. Sus resultados muestran, que con relación a la rentabilidad ajustada al riesgo, los REITs superan a las empresas inmobiliarias no convertidas con unas betas más reducidas y menor volatilidad, confirmando que la estructura regulatoria del modelo REIT contribuye a moderar el perfil de riesgo de los vehículos que lo adoptan.

Tansens, Pekdemir y Moreno (2022) examinan las dinámicas de apalancamiento y tipos de interés en el mercado de REITs cotizados, concluyendo que la subida de tipos iniciados en 2022 ha afectado a los vehículos con mayor exposición a deuda a tipo variable. Es relevante este estudio, debido a que comenta el impacto de la política monetaria sobre la valoración de los REITs, siendo uno de los factores de riesgo más relevantes del período entre 2022-2025.

Finalmente, Zhu y Lizieri (2024) introduce el concepto de la beta local como medida del riesgo sistemático con relación a la expansión geográfica de los activos subyacentes, demostrando que en el caso de los REITs con carteras que se concentran en un punto geográfico, la sensibilidad al riesgo del mercado inmobiliario local puede superar a la sensibilidad al riesgo bursátil general. Esto es importante para el desarrollo de este trabajo, dado que los REITs estadounidenses y las SOCIMIs españolas operan en mercados inmobiliarios completamente diferente con relación al ciclo, dimensión y sensibilidad macroeconómica.

Además, haciendo una revisión de la literatura, existen dos vacíos de investigación relevantes para este trabajo. En primer lugar, la mayoría de los estudios de rentabilidad y riesgo de vehículos inmobiliarios cotizados se centran en REITs estadounidenses, con escasa presencia del mercado español y nula presencia de las SOCIMIs como objeto de análisis cuantitativo. En segundo lugar, no existen hasta la fecha estudios que comparen de una manera sistemática el perfil de rentabilidad ajustada al riesgo de REITs y SOCIMIs empleando indicadores homogéneos y técnicas de Business Analytics, justificando así la contribución de este trabajo.

4. METODOLOGÍA Y DATOS

Este capítulo se centra en la descripción del diseño metodológico empleado para realizar el análisis comparativo de los REITs y SOCIMIs. Se exponen el enfoque analítico adoptado, los criterios de selección de la muestra, las variables empleadas, las fuentes de datos y las herramientas empleadas, además de la explicación de los modelos empleados.

4.1. Enfoque del análisis

El enfoque de este trabajo es cuantitativo y comparativo, incluyendo una dimensión predictiva de la aplicación de técnicas de Business Analytics. Esto responde a la comparación de rentabilidades y riesgos entre SOCIMIs y REITS, en donde se emplearan series temporales de datos financieros y bursátiles, así como la aplicación de indicadores estandarizados para una comparativa de cómo actúan estos vehículos en sus respectivos mercados.

El estudio combina una fase descriptiva y comparativa, que analiza rentabilidad y riesgo mediante indicadores estandarizados, y una fase predictiva, que aplica modelos ARIMA, Prophet y LSTM para proyectar la evolución de los precios.

El periodo empleado para este estudio comprende los años 2017-2025, cubriendo un ciclo económico completo en un entorno de tipos de interés reducidos y elevada liquidez hasta 2021, el shock inflacionario y el ciclo de subidas de tipos de 2022-2023. Además, incorpora el periodo del COVID – 19 en 2020, que constituye una ruptura estructural relevante para los mercados inmobiliarios cotizados. La ruptura estructural de 2020 será reconocida en el análisis estadístico mediante el control de variables dummy para no distorsionar la interpretación de los resultados.

El análisis se realizará en Python, utilizando las librerías de *yfinance* (Yahoo Finance) para la obtención de datos de mercado, *pandas* y *numpy* para el tratamiento y cálculo de indicadores, modelos estadísticos para la realización de los modelos estadísticos, y *matplotlib* y *seaborn* para la visualización de resultados. La elección de Python se debe a su capacidad para poder automatizar el procesamiento de datos, además de su compatibilidad con las fuentes empleadas en este trabajo.

4.2. Selección de la muestra

La selección de la muestra se realizó en Python, con el objetivo de garantizar que los vehículos incluidos en el análisis cumplieran los criterios de liquidez, representabilidad y disponibilidad de datos para el período completo 2017 – 2025 para poder realizar de manera efectiva el trabajo.

Universo candidato

Para la selección de los REITs estadounidenses, se construyó a partir del listado oficial de REITs cotizados publicado por NAREIT en reit.com. Se seleccionaron veinte REITs con una capitalización relevante, además de escoger vehículos especializadas por sector y diversificadas, cubriendo sectores como el logístico e industrial, infraestructuras de telecomunicaciones, centros de datos, salud, almacenamiento y retail.

Para las SOCIMIs españolas, el universo candidato se construyó a partir de SOCIMIs pertenecientes del Mercado Continuo (IBEX35), BME Growth y BME Saleup, seleccionando catorce candidatos con distintos perfiles de tamaño y segmento inmobiliario.

Descarga y procesamiento de datos en Python

Para realizar el script de Python y realizar el análisis de las empresas, se empleó la librería *yfinance*, que ofrece datos financieros de Yahoo Finance. Para cada ticker candidato, a través de esta librería, se extrajeron los siguientes datos:

- Disponibilidad de datos, siendo el % de sesiones con precio disponible sobre el total de sesiones bursátiles esperadas en el periodo, en este caso estimada en 2.016 sesiones (252 días por 8 años)
- Capitalización bursátil aproximada
- Volumen medio diario de negociación
- Rentabilidad media anualizada

- Volatilidad anualizada
- Sharpe ratio aproximado, calculado como la diferencia entre la rentabilidad media anualizada y la tasa libre de riesgo del 2%, dividida entre la volatilidad anualizada

Criterios de selección aplicados

Se estableció un criterio de inclusión mínimo de datos disponibles, teniendo que ser este porcentaje igual o superior al 80% del período analizado con el objetivo de excluir empresas con datos incompletos. A partir del filtrado por el criterio anterior, la selección final se ordenó por capitalización bursátil de forma descendente, priorizando el volumen medio diario (indicador de liquidez efectiva).

Para los REITs, veinte de los quince candidatos superaron este umbral con una disponibilidad del 99.8%. La siguiente tabla, muestra los cinco vehículos seleccionados:

Tabla 1. Muestra seleccionada de REITs estadounidenses (2017 – 2025)

► MUESTRA SELECCIONADA (Top 5 por capitalización):									
Nombre	Ticker	Inicio datos	% Datos	Cap. (B)	Vol. Diario (M)	Ret. Anual (%)	Volat. Anual (%)	Sharpe aprox.	
Welltower	WELL	2017-01	99.8	147.5	2.43	17.78	33.88	0.466	
Prologis	PLD	2017-01	99.8	135.2	3.05	15.21	27.46	0.481	
Equinix	EQIX	2017-01	99.8	108.9	0.49	17.78	27.55	0.573	
American Tower	AMT	2017-01	99.8	84.7	2.03	12.79	26.65	0.405	
Simon Property Group	SPG	2017-01	99.8	79.0	2.33	12.62	39.88	0.266	

Fuente: Elaboración propia a partir de yfinance y NAREIT

Para las SOCIMIs, al realizar este proceso fue evidente la limitación estructural en el mercado español. De los catorce vehículos seleccionados, únicamente dos SOCIMIs superaron el umbral de disponibilidad y el criterio de liquidez mínima, debido a que la librería *yfinance* no disponía de datos completos en la mayoría de SOCIMIs de BME Growth y BME Scale Up. Las empresas seleccionadas:

Tabla 2. Muestra seleccionada de SOCIMIs españolas (2017 – 2025)

► MUESTRA SELECCIONADA (Top 5 por capitalización):									
Nombre	Ticker	Inicio datos	% Datos	Cap. (B)	Vol. Diario (M)	Ret. Anual (%)	Volat. Anual (%)	Sharpe aprox.	
Merlin Properties	MRL.MC	2017-01	101.5	9.4	1.13	8.12	26.82	0.228	
Colonial	COL.MC	2017-01	101.5	3.4	1.02	3.90	28.66	0.066	
GMP Property SOCIMI	YGMP.MC	2017-01	101.5	1.2	0.00	6.23	7.85	0.539	
Quonia SOCIMI	YQUO.MC	2017-10	91.9	N/D	0.00	2.17	6.83	0.025	

Fuente: elaboración propia a partir de yfinance, BME e Ibex35

A pesar de las limitaciones que se encuentran dentro de las SOCIMIs, con el objetivo de ampliar la muestra de estas, se realizó un análisis complementario de capitalización bursátil sobre el universo completo de SOCIMIs conizadas dentro del BCE, consultando directamente en su plataforma. El resultado confirmó que las SOCIMIs con mayor capitalización dentro del mercado alternativo presentan volúmenes de negociación diaria extremadamente reducidos, incompatibles con un análisis de series temporales riguroso. Por ejemplo, GMP Property registró solamente 76 acciones negociadas en una sesión, Testa Residential una única acción o Zambal Spain ninguna transacción, frente al volumen superior de un millón de acciones diarias de Merlin Properties.

Finalmente, para hacer un buen estudio, se seleccionaron 2 SOCIMIs (Merlin y Colonial), siendo los únicos con información completa en la librería *yfinance*, y 5 REITs (Welltower, Prologis, Equinix, American Tower y Simon Property Group). El mercado estadounidense presenta una dimensión, liquidez y profundidad superior al mercado español. Por ello, se ha optado por priorizar la consistencia temporal y la calidad de los datos frente a una ampliación de la muestra con otros datos externos que puede causar inconsistencia en el estudio.

4.3. Variables utilizadas y justificación

Las variables empleadas para realizar el análisis se dividen en dos bloques:

- Variables de mercado, obtenidas a partir de las series históricas de precios.
- Variables fundamentales, procedentes de los estados financieros y memorias anuales.

En este apartado se justifica la selección de estos indicadores para el análisis comparativo, especificando las decisiones operativas para su cálculo.

Variables de mercado

Con relación al conjunto de indicadores de rentabilidad y riesgo, se han seleccionado para el análisis la rentabilidad media anualizada, la volatilidad anualizada, la beta respecto al índice de referencia, el Sharpe ratio y la rentabilidad por dividendo. Estos indicadores cubren información sobre el rendimiento bruto, el riesgo total, el riesgo sistemático, la rentabilidad ajustada al riesgo, el componente de renta y la rentabilidad acumulada para el accionista, respectivamente.

En cuanto a las decisiones operativas, los retornos se calculan en forma de logaritmo en vez de aritmética con el objetivo de analizar series financieras por sus propiedades de aditivita temporal, facilitando la agregación de retornos en horizontes más amplios y siendo más favorable estadísticamente para su análisis (Tsay, 2010):

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$$

Donde P_t es el precio de cierre ajustado al día t y P_{t-1} el precio del día anterior. Para la anualización de la rentabilidad y la volatilidad se emplean 252 sesiones bursátiles, aplicada para homogeneizar las sesiones entre los REITs y las SOCIMIs.

Para el cálculo del Sharpe ratio se emplea una tasa libre de riesgo del 2% anualizada como referencia constante para el período entre 2017 – 2025. Se aplica esta tasa para simplificar la heterogeneidad temporal de los tipos de interés, donde encontramos tipos negativos

hasta 2021 y un ciclo de subidas de hasta el 4.5% en 2023. Esto simplifica la distorsión en las ratios calculadas para distintos subperiodos. Además, esta aplicación de una tasa constante facilita la comparabilidad entre estos vehículos a lo largo del tiempo.

Para la estimación de la beta se emplean el modelo de CAPM mediante una regresión de mínimos cuadrados ordinarios:

$$\beta_i = \frac{Cov(r_i, r_m)}{Var(r_m)}$$

donde r_i son los retornos del un vehículo i y r_m son los retornos del índice de referencia. Se emplean índices de referencia diferenciados por mercado, el S&P 500 para los REITs estadounidenses y el IBEX 35 para las SOCIMIs. Utilizar un único índice global para los dos vehículos introduce un sesgo sistemático dado que ambos mercados tienen estructuras sectoriales, ciclos económicos y marcos institucionales diferentes.

El Sharpe ratio se calcula como:

$$S_i = \frac{\bar{R}_i - R_f}{\sigma_i}$$

donde \bar{R}_i es la rentabilidad media anualizada, R_f la tasa libre de riesgo y σ_i la volatilidad anualizada. En este trabajo se va a usar la tasa libre de riesgo del 2% anualizado y constante para todo el periodo 2017 – 2025, aunque es cierto que no se recoge la variación de los tipos durante el ciclo analizado, teniendo en cuenta el período alcista de 2022 – 2023.

Todas las variables de mercado se obtienen a partir de la librería *yfinance* mediante los precios de cierre ajustados diarios para garantizar la homogeneidad de la fuente para todos los vehículos.

VARIABLES FINANCIERAS FUNDAMENTALES

Se han seleccionado para realizar el análisis el ROA, el ROE, como medidas de rentabilidad sobre activos y fondos propios. El ratio Deuda/Activos para medir el

apalancamiento y aproximación al LTV. Y el margen EBITDA, como indicador de eficiencia operativa. Estos indicadores proporcionan información sobre la eficiencia operativa (ROA y ROE), la estructura de capital y el apalancamiento (Deuda/Activos y LTV), y la capacidad distribuidora ajustada a la naturaleza del negocio (margen EBITDA). Cabe destacar que el FFO no es un indicador obligatorio en el mercado español. En su lugar, se utiliza el EBITDA, ya que excluye las amortizaciones y los gastos financieros del resultado operativo, proporcionando una estimación más precisa de la capacidad de caja de explotación del vehículo (JLL España y BME, 2021).

Los indicadores para calcular los indicadores financieros se obtienen de la plataforma TIKR Terminal, que agrega y estandariza la información financiera de los informes anuales de las compañías ante sus respectivos reguladores (SEC en el caso de EEUU y CNMV en España). Estas variables muestran una frecuencia anual del período 2017-2025.

4.4. Fuentes de datos y herramientas analíticas

Las variables de mercado se obtienen a través de Yahoo Finance con la librería *yfinance* en Python, permitiendo la descarga automatizada de series históricas de cierre ajustados y volúmenes de negociación para todos los vehículos de muestra. Además, ese precio incorpora ajustes por splits, ampliaciones de capital y distribución de dividendos, así se puede comparar series temporales sin distorsiones por operaciones corporativas.

Para el cálculo de beta se descargan adicionalmente las series del S&P 500 (GSPC) y del IBEX 35 (IBEX), ambos con la misma frecuencia diaria y para el mismo período que las series de los vehículos seleccionados. Las variables financieras fundamentales, como se ha comentado en el apartado anterior, se extraen de TIKR Terminal, que estandariza la información contable de los vehículos presentados en este trabajo.

Todo el análisis empírico se realiza a través de Python, lenguaje de referencia dentro del Business Analytics financiero. Las librerías empleadas han sido *yfinance* y *pandas* para obtención y gestión de datos, *numpy* para cálculo de indicadores, *scipy* para contrastes estadísticos, *statsmodels* para ARIMA, Prophet y *tensorflow* para los modelos predictivos, además de *matplotlib* y *seaborn* para visualización. El código completo realizado se recoge en el Anexo A.

4.5. Especificación de los modelos

En análisis del trabajo se organiza en 3 fases: una fase descriptiva, una fase comparativa y una fase predictiva. Cada una de ellas responden a un objetivo distinto y emplea herramientas metodológicas específicas.

4.5.1. Fase descriptiva

Esta fase tiene como objetivo definir el perfil de rentabilidad y riesgo de cada vehículo de la muestra durante el período 2017 – 2025. Para cada vehículo se calculan los estadísticos de las variables de mercado, es decir, media, mediana, desviación típica, mínimo, máximo, coeficiente de asimetría y curtosis de la distribución de retornos. Además, se analiza la evolución temporal de precios y retornos mediante visualizaciones gráficas que permiten identificar momentos de impacto, como pudieron ser el COVID – 19 en 2020 o el ciclo de subidas de tipo en 2022 – 2023. Para poder evaluar el grado de co – movimiento entre REITs y SOCIMIs, se construye una matriz de correlaciones entre los retornos de ambos vehículos.

4.5.2. Fase comparativa

La fase comparativa es el núcleo del análisis comparativo, donde se comparan los indicadores de rentabilidad y riesgo entre REITs y SOCIMIs. Primero se realiza una comparación entre las medias y medianas de cada indicador entre grupos mediante tablas resumen y visualizaciones. En segundo lugar, se aplica el test de Mann – Whitney, siendo un contraste estadístico formal de diferencia de distribuciones entre ambos grupos. Este test es adecuado para muestras pequeñas que no asumen normalidad en la distribución de los datos, es una alternativa a un test de t de Student dado el tamaño reducido de la muestra. Estos resultados son complementarios a la fase descriptiva, reconociendo que la potencia estadística es limitada por la muestra de solo siete empresas. Los indicadores comparados incluyen la rentabilidad media anualizada, la volatilidad, la beta, el Sharpe ration, la rentabilidad por dividendo, el TSR, el ROA, el ROE y el LTV.

4.5.3. Fase predictiva

La última fase aplica un modelo ARIMA a las series de los retornos diarios de cada una de las muestras, con el objetivo de modelizar la dinámica temporal de sus datos y evaluar la capacidad predictiva del modelo fuera de la muestra. Se va a emplear un modelo ARIMA (p, d, q). Su especificación general es:

$$\Delta^d r_t = c + \sum_{i=1}^p \phi_i \Delta^d r_{t-1} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

donde r_t es el retorno logarítmico del vehículo en un período t , ϕ_i son los parámetros autorregresivos, θ_j los parámetros de media móvil, c una constante y ε_t el término de error, en este caso ruido blanco.

Los órdenes se seleccionan mediante el método de Box-Jenkins, con la cual se contrasta la estacionariedad con el test ADF, se identifican p y q a través de las funciones ACF y PACF, y se minimiza el AIC. La calidad del ajuste se verifica comprobando que los residuos se comportan como ruido blanco (Tsay, 2010).

Adicionalmente, se aplica un modelo Prophet, que descompone el precio en tendencia y estacionalidad, y una red neuronal LSTM, que aprende patrones no lineales sobre ventanas de 60 días. Esto se desarrollará a más profundidad en la Sección 5.4.

La división de los datos va a seguir una división temporal 80/20, utilizando el 80% para la estimación del modelo y el 20% para la evaluación fuera de la muestra. Las métricas de evaluación empleadas son el error absoluto medio (MAE) y la raíz del error cuadrático medio (RMSE) sobre el período de test de cada vehículo de la muestra.

5. ANÁLISIS CUANTITATIVO Y RESULTADOS

5.1. Análisis descriptivo de rentabilidad y riesgo

El análisis descriptivo se realiza mediante estadísticos calculados a partir de series de retornos logarítmicos diarios para el período 2017-2025, complementando con el dividend yield medio anualizado obtenido a partir de los datos de distribuciones de cada vehículo.

5.1.1. Rentabilidad

Con relación al retorno anualizado por apreciación del precio, los REITs de la muestra presentan un rango comprendido entre el 4,38% de Simon Property Group y el 13,58% de Equinix, frente al 5,34% de Merlin Properties y el 0,49% de Colonial, como se aprecia en la Tabla 3.

Tabla 3. Estadísticos descriptivos – Retornos diarios (2017-2025)

ESTADÍSTICOS DESCRIPTIVOS – RETORNOS DIARIOS (2017-2025)										
Vehículo	Tipo	Ret. Anual (%)	Volat. Anual (%)	Beta	Sharpe	Asimetría	Curtosis	Mín. diario (%)	Máx. diario (%)	
Welltower	REIT	12.96	33.97	0.943	0.323	-0.914	32.418	-27.97	20.85	
Prologis	REIT	12.95	27.67	0.975	0.396	-0.685	11.476	-18.96	11.16	
Equinix	REIT	13.58	27.55	0.825	0.420	0.002	5.866	-13.54	10.98	
American Tower	REIT	9.31	26.72	0.754	0.274	-0.124	9.095	-16.44	11.53	
Simon Property	REIT	4.83	40.00	1.182	0.071	-1.050	31.575	-31.08	24.58	
Merlin Properties	SOCIMI	5.34	26.83	0.827	0.125	0.345	9.806	-12.69	15.71	
Colonial	SOCIMI	0.49	28.55	0.881	-0.053	0.064	12.999	-16.99	17.90	

Fuente: elaboración propia en Python

Esta diferencia es relevante, debido a que los retornos calculados sobre la serie de precio ajustado capturan la componente de apreciación de capital, sin incluir la rentabilidad por dividendo. En la Tabla 4 se aprecia la incorporación de este segundo componente, el perfil de rentabilidad total se matiza de forma relevante.

Tabla 4. Dividend yield medio anualizado (2017-2025)

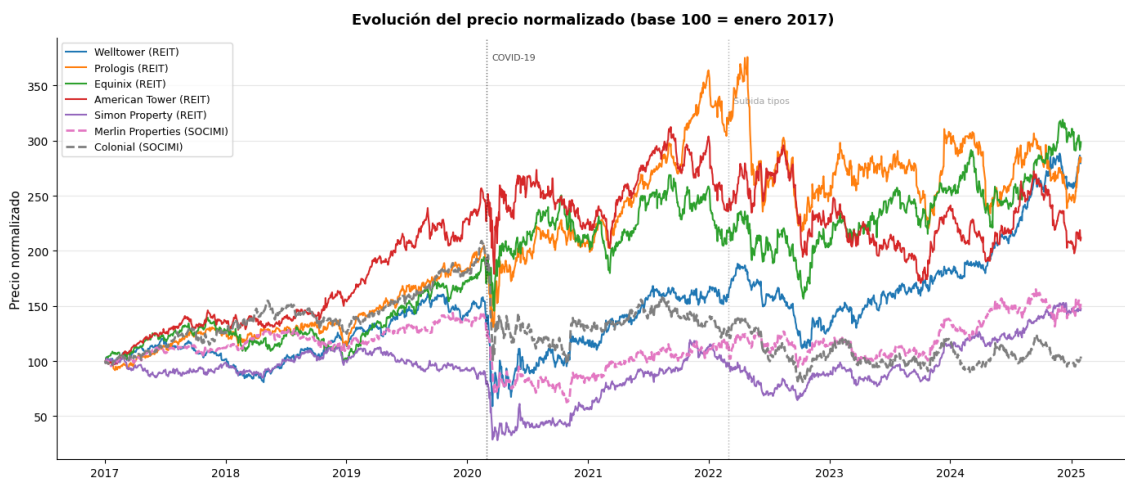
DIVIDEND YIELD MEDIO ANUALIZADO (2017-2025)

Welltower (WELL): 4.24%
 Prologis (PLD): 3.05%
 Equinix (EQIX): 2.02%
 American Tower (AMT): 2.73%
 Simon Property (SPG): 6.95%
 Merlin Properties (MRL.MC): 6.55%
 Colonial (COL.MC): 3.42%

Fuente: elaboración propia en Python

Merlin alcanza un retorno aproximado del 11,89% (5,39% de retorno de precio más 6,55% de dividendo), cifra que se puede comparar a la de Welltower (17,20%) o Prologis (16,00%). Colonia, por su parte, obtiene una rentabilidad total de 3,91% al sumar estos dos componentes. Gracias a estos resultados se ilustra que la rentabilidad para el accionista de este tipo de vehículos no puede considerarse evaluando solo la apreciación de capital, sino que también hay que tener en cuenta el rendimiento por dividendo. Las diferencias se pueden apreciar mejor en la Figura 1.

Figura 1. Evolución del precio normalizado (2017-2025)



Fuente: elaboración propia en Python


Los REITs especializados en infraestructuras digitales (American Tower, Equinix) y logística (Prologis) registraron las revalorizaciones más altas hasta 2022, año donde tuvo lugar correcciones de los tipos causadas por la bajada durante los años anteriores por la pandemia del COVID - 19. Las SOCIMIs mantuvieron una trayectoria más conservadora, situándose en el cierre de este período entre los 100 y 155 sobre base 100.

5.1.2. Riesgo

Con relación al riesgo, los resultados no confirman de forma segunda la segunda hipótesis del trabajo. Simon Property Group muestra la volatilidad más elevada dentro de la muestra con una cifra de 40,00%, mientras que las SOCIMIs muestran valores de 26,83%, en el caso de Merlin, y 28,55%, en el caso de Colonial. No obstante, estas volatilidades de las SOCIMIs son comparables a los de de Prologis (27,67%), Equinix (27,55%) o

American Tower (26,72%). La dispersión intrasectorial en los REITs es igual o superior a la diferencia entre grupos. La Figura 2 muestra como el impacto del COVID-19 en 2020 causó un pico de volatilidad más notable que en otros períodos, destacando Simon Property con volatilidades superiores al 90% anualizado. En cambio, las SOCIMIs registraron unos datos más moderados que refleja un menor nivel de liquidez del mercado español.

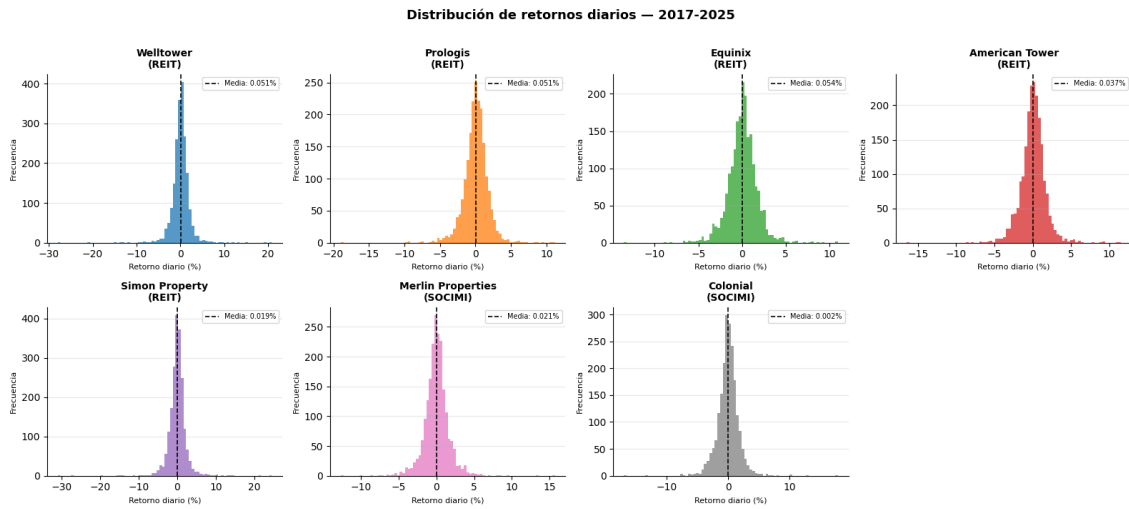
Figura 2. Volatilidad anualizada (ventana 252 días)



Fuente: elaboración propia en Python

Por otro lado, se ha realizado un análisis de la distribución de retornos diarios, recogido en la Figura 3. Se aprecia que todos los vehículos presentan distribuciones leptocúrticas (curva concentrada, elevada alrededor de la media y con grado de apuntamiento elevado). Analizando los valores de curtosis más elevados, Welltower (32,42) y Simon Property Group (31,58), presentan los niveles más altos con una colas más pesadas y una concentración de eventos extremos superior a esperada, teniendo en cuenta su previa normalización. Esto refleja que la volatilidad estándar subestima el riesgo real en períodos de estrés, como comentan Alcock y Steiner (2015).

Figura 3. Distribución de retornos diarios (2017 – 2025)



Fuente: elaboración propia en Python

Finalmente, analizando la Tabla 3 de estadísticos, el Sharpe ratio tiene unos valores más altos de media en los REITs, siendo sinónimo a una mayor rentabilidad ajustada al riesgo. Equinix (0,420) y Prologis (0,396) lideran la muestra, mientras Colonial registra el valor más bajo (-0,053). A pesar de esta diferencia, es importante tener en cuenta que la alta heterogeneidad dentro de los REITs limita la generalización de esta conclusión, explicación que se va a desarrollar en la sección 5.2.

5.2. Comparativa REITs vs SOCIMIs y pruebas estadísticas

La fase comparativa tiene como objetivo analizar las diferencias de rentabilidad y riesgos entre los REITs y las SOCIMIs. Para ello, se comparan las medias de las principales variables financieras y se aplica el test de Mann-Whitney. Además, se estudia la matriz de correlaciones de retornos diarios para poder identificar los posibles patrones de comportamientos conjunto entre estos vehículos.

Tabla 5. Medias por grupo

MEDIAS POR GRUPO				
Grupo	Ret. Anual (%)	Volat. Anual (%)	Beta	Sharpe
REIT	10.727	31.180	0.936	0.297
SOCIMI	2.918	27.687	0.854	0.036

Fuente: elaboración propia en Python

A partir de la Tabla 5, se aprecia que, dentro de la muestra, los REITs presentan una rentabilidad media anualizada del 10,73%, frente al 2,92% de las SOCIMIs, lo que representa una diferencia de casi ocho puntos porcentuales, siendo sinónimo de un mejor comportamiento relativo con relación a la rentabilidad.

Con relación al riesgo, se aprecia que la volatilidad media anual también es superior en los REITs con un 31,18%, respecto a las SOCIMIs con un 27,69%. Este resultado, como se explicó en la sección anterior, se contradice con la segunda hipótesis del trabajo. La beta media también es elevada en los REITs (0,936) que en las SOCIMIs (0,854), no obstante, ambos valores muestran que existe una sensibilidad moderada al mercado.

A pesar de las métricas anteriores, la diferencia más relevante desde el punto de vista de la hipótesis 1 se aprecia en el Sharpe ratio medio, para los REITs es un 0,297 y para las SOCIMIs un 0,036, lo que muestra una rentabilidad ajustada al riesgo notablemente superior en los vehículos estadounidenses.


Tabla 6. Medias por grupo

TEST DE MANN-WHITNEY (REITs vs SOCIMIs)			
Ret. Anual (%)	U=9.0	p=0.1905	n.s.
Volat. Anual (%)	U=6.0	p=0.8571	n.s.
Beta	U=6.0	p=0.8571	n.s.
Sharpe	U=9.0	p=0.1905	n.s.

Fuente: elaboración propia en Python

No obstante, los resultados del test de Mann-Whitney, recogidos en la Tabla 6, no permiten rechazar la hipótesis nula de igualdad de distribuciones en ninguna de las variables analizadas. Los p-valores son de 0,1905 para la rentabilidad y el Sharpe ratio, y 0,8571 para la volatilidad y la beta, estando todas estas cifras por encima del umbral de significación que es del 5%. A pesar de este resultado, hay que tener prudencia, ya que solo se está analizando una muestra de siete vehículos, limitando la potencia estadística de contraste. Este límite estructural se reconoce dentro del diseño metodológico en el Capítulo 4.

Figura 4. Matriz de correlaciones - retornos diarios (2017 – 2025)



Fuente: elaboración propia en Python

Finalmente, el análisis de la matriz de correlaciones entre retornos diarios, que se aprecia en la figura 4, muestra que las correlaciones entre los vehículos REITs oscilan entre 0,26 y 0,69, esto muestra que hay una cohesión moderada entre ellas, y lo mismo sucede entre SOCIMIs que alcanza 0,69. En cambio, las correlaciones cruzadas entre REITs y SOCIMIs son más bajas, situándose entre 0,16 y 0,41. Este patrón plantea que ambos mercados responden en mayor medida a unas dinámicas locales que a factores comunes. Este argumento también se expresa dentro del estudio de Zhu y Lizieri (2024), comentado en la Sección 3.3., sobre la relevancia del riesgo inmobiliario local frente al riesgo bursátil general. Si se mira desde un punto de vista de cartera, la baja correlación entre REITs y SOCIMIs puede ser una oportunidad de diversificación geográfica que puede ser interesante para inversores con exposición a ambos mercados.

5.3. Análisis de ratios financieros fundamentales

Se ha realizado el análisis de ratios fundamentales con el objetivo de complementar la perspectiva bursátil de las secciones anteriores mediante una visión contable de la eficiencia operativa y la estructura financiera de los vehículos. Como se ha comentado en el Capítulo 4, el cálculo de ratios financieros (ROA, ROE, Deuda/Activos y margen de EBITD) se obtienen de TIKR terminal, plataforma donde se agrega información financiera regulada por la SEC de EE. UU. y el CNMV de España. Los resultados se presentan en la Tabla 6.

Tabla 5. Ratios fundamentales

RATIOS FUNDAMENTALES (Fuente: TIKR) – media 2017-2024					
Ticker	Grupo	ROA	ROE	Debt_Assets	EBITDA_Margin
WELL	REIT	1.91	3.87	40.83	37.59
PLD	REIT	4.31	7.67	30.80	97.03
EQIX	REIT	2.10	5.59	54.06	40.96
AMT	REIT	3.60	36.40	70.21	61.19
SPG	REIT	6.36	65.83	77.13	84.48
MRL	SOCIMI	3.57	7.31	40.30	77.72
COL	SOCIMI	2.16	5.94	40.62	44.70
MEDIAS POR GRUPO:					
		ROA	ROE	Debt_Assets	EBITDA_Margin
Grupo					
REIT		3.66	23.87	54.61	64.25
SOCIMI		2.86	6.62	40.46	61.21

Fuente: TIKR

Los REITs presentan de media una ROA más grande que las SOCIMIs, 3,66% y 2,86%, respectivamente. Esto indica que hay una mayor eficiencia dentro de la generación de beneficio por unidad de activo en los vehículos del país norteamericano. Simon Property presenta el ROA más grande con 6,36%, resultado común con su modelo de centros comerciales premium de alto rendimiento. En cambio, Welltower destaca por tener el ROA más pequeño dentro de los REITs, a causa de su alto coste operativo inherente del sector sanitario en el que opera, especialmente residencias y centros médico. Haciendo una comparación entre Merlin y Colonial, la primera tiene un ROA más alto, debido a que tiene más diversificación dentro de su cartera, apostando por centros de datos, oficinas, logísticas y centros comerciales.

Esta diferencia también se aprecia dentro del cálculo del ROE, la media de los REITs alcanza el 23,87% muy por encima del 6,62% de las SOCIMIs. A pesar de este resultado,

hay que estudiar estos resultados con precaución, debido a que valores como los de Simon Property Group (65,83%) y American Towel (36,40%) están influidos por un patrimonio neto reducido en relación con sus beneficios, esto hace que se eleve el ratio de una forma que no es equivalente a una mayor rentabilidad estructural. American Tower, que destaca por ser un vehículo especializado en torres de telecomunicaciones, opera con un modelo intensivo en capital y deuda, esto hace que se comprime su patrimonio neto y el ROE se dispare. A causa de esta particularidad, si se excluyen estas dos compañías, la media de ROE de los REITs es moderado y comparable con las SOCIMIs.

Con relación al apalancamiento, los REITs tienen una ratio de Deuda/Activos de media de 54,61% frente al 40,46% de las SOCIMIs. A pesar de esto, dentro del grupo de los REITs hay diferencias de apalancamiento, las ya mencionadas Simon Property (77,13%) y American Tower (70,21%) concentran mayor apalancamiento, a causa de su modelo de negocio que requiere financiación masiva. En cambio, Prologis presenta el ratio más bajo dentro de su grupo con un 30,80%, esto refleja la solidez financiera de su modelo de logística global y su capacidad de generación de caja sin necesidad de tener que apalancarse demasiado. Las dos SOCIMIs tienen unos niveles de apalancamiento muy parecidos, Merlin (40,30%) y Colonial (40,62%), y destacan por ser inferiores a la media de los REITs, sugiere que hay una política financiera más conservadora dentro del mercado español. Este mayor apalancamiento dentro del grupo de los REITs que coexiste con una rentabilidad superior, en comparación con las SOCIMIs, confirma la hipótesis 3 del trabajo. Otros estudios como el de Tansens, Pekdemir y Moreno (2022), documentan que los REITs con mayor exposición a deuda, presentan unas rentabilidades más altas en entornos de tipos bajos, aunque también mayor vulnerabilidad en ciclos alcistas de tipos.

El margen de EBITDA en las SOCIMIs tiene una media de 61,21%, que es casi equivalente al 64,25% de los REITs, esto sugiere una eficiencia operativa similar en ambos grupos, ya descontadas las amortizaciones. Dentro del grupo de REITs vemos grandes diferencias entre Prologis (97,03%) y Welltower (37,59%), la primera responde a su naturaleza de modelo logístico con ingresos por arrendamiento industrial creciente, y la segunda por sus elevados costes operativos dentro del sector sanitario. También encontramos diferencias entre Merlin (77,72%) y Colonial (44,70%), con relación a su margen de EBITDA por la creciente diversificación sectorial de la cartera de Merlin.

5.4. Modelos predictivos: ARIMA, Prophet y LSTM

La fase predictiva aplica tres modelos complementarios a las series temporales de los vehículos de la muestra, para poder evaluar y comparar su capacidad predictiva desde diferentes enfoques metodológicos de Business Analytics. Primero, se va a realizar un modelo ARIMA, referencia de estadística clásica de series temporales. El segundo va a ser un modelo Prophet, desarrollado por Meta Platforms con el objetivo de capturar tendencia y estacionalidad en series financieras. El tercero es una red neuronal recurrente LSTM (Long Short-Term Memory), modelo de Deep Learning creado para aprender patrones no lineales y dependencias a largo plazo. En los tres casos se aplica una división temporal 80/20, durante el período 2017-2023 para el entrenamiento y 2023-2025 para la evaluación fuera de la muestra.

Previamente a la realización de los modelos, se ha analizado la estructura de las series mediante la descomposición Prophet, Figura 5, separando la serie en cuatro componentes: tendencia, efecto de eventos especiales, estacionalidad semanal y estacionalidad anual.

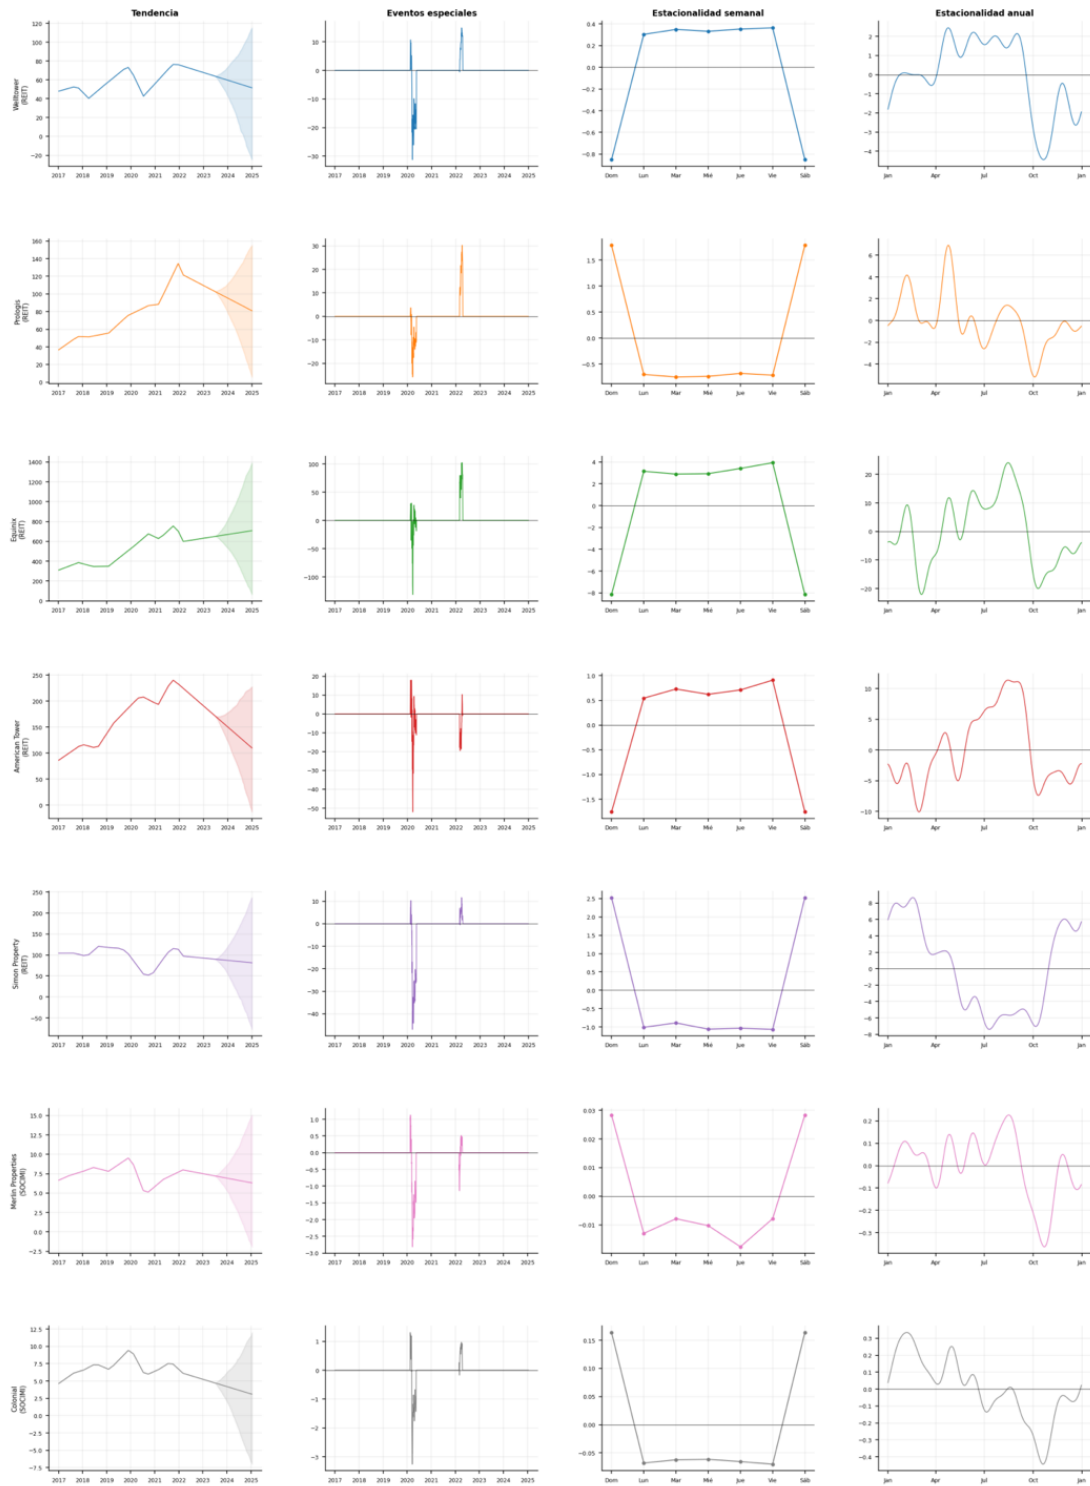
Con relación a la tendencia, todos los vehículos muestran una trayectoria alcista en el período 2017-2022, con dos cambios abruptos, la primera en marzo 2020 (COVID-19) y la segunda a partir de 2022 durante el inicio de ciclo de subidas de tipos, esto provocó una interrupción de la tendencia alcista.

La estacionalidad semanal es homogénea en todos los vehículos, los precios tienen a estar más altos a inicios de semana y más bajos al cierre, siendo este un patrón común en el comportamiento de los mercados de renta variable cotizados. Colonial es la excepción más notable, con una estacionalidad semanal plana (0,03 puntos), debido a su menor liquidez y menor volumen de negociación diario.

La estacionalidad anual muestra patrones diferentes dependiendo del sector. En el caso de Welltower, muestra un mínimo en octubre-noviembre y un máximo en febrero-marzo, mientras que Simon Property tiene su máximo estacional en verano (julio-septiembre), coincidiendo con la temporada alta del retail. Equinix muestra su pico en mayo, y American Tower en agosto-septiembre. Las SOCIMIs presentan sus máximos en los

primeros meses del año y los mínimos en verano, siendo un patrón inverso a los REITs de retail, reflejando las diferencias entre el mercado español y el estadounidense.

Figura 4. Descomposición Prophet – REITs y SOCIMIs (2017 – 2025)



Fuente: elaboración propia en Python

5.4.1. Modelo ARIMA

El test de Dickey-Fuller aumentado (ADF) confirma la estacionariedad de las series de retornos algorítmicos de la muestra con un p-valor menos a 0,01, con un orden de integración $d=0$ en todos los casos. Los órdenes p y q se seleccionaron minimizando el criterio de información de Akaike (AIC). Como resultado, se han mostrado modelos con órdenes reducidos, oscilando entre el ARIMA (0,0,0) de Colonial, siendo equivalente a ruido blanco puro, y el ARIMA (3,0,1) de Prologis, como se aprecia en la Tabla 6.

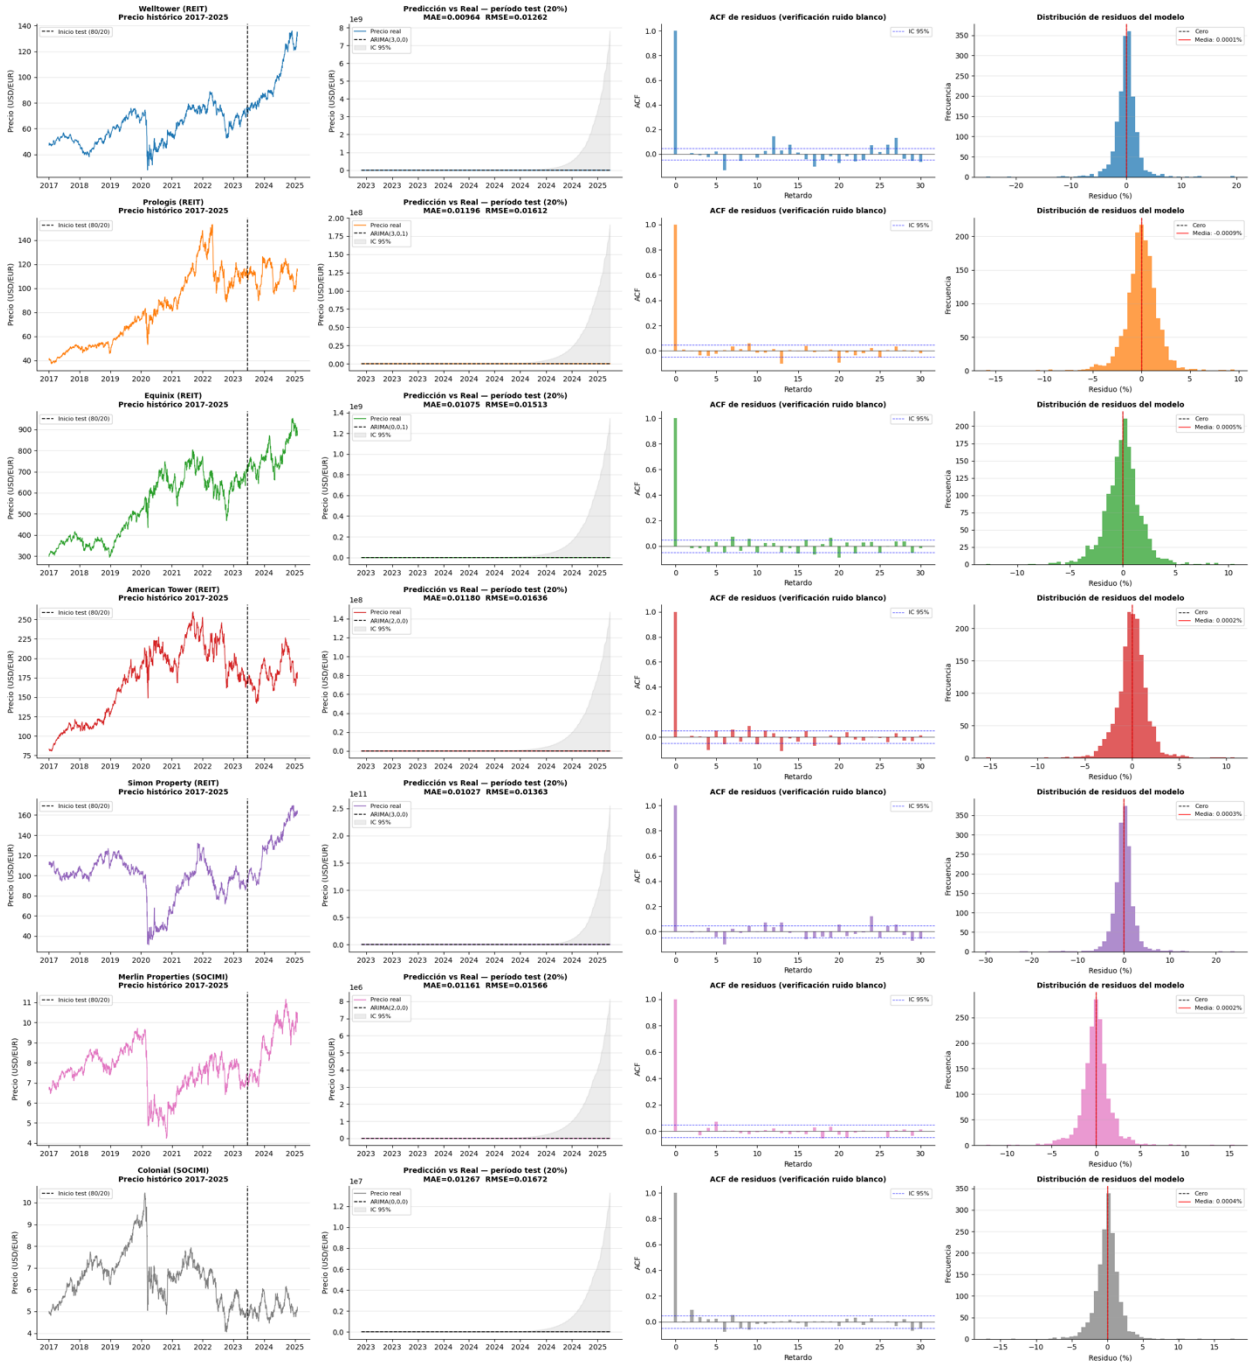
Tabla 6. Resultados ARIMA – Retornos diarios (2017-2025)

RESULTADOS ARIMA – RETORNOS DIARIOS (2017-2025)								
Vehículo	Grupo	ADF	p-valor	Orden	(p,d,q)	AIC	MAE	RMSE
Welltower	REIT	0.0		(3,0,0)	-7662.7	0.00964	0.01262	
Prologis	REIT	0.0		(3,0,1)	-8537.9	0.01196	0.01612	
Equinix	REIT	0.0		(0,0,1)	-8467.9	0.01075	0.01513	
American Tower	REIT	0.0		(2,0,0)	-8644.0	0.01180	0.01636	
Simon Property	REIT	0.0		(3,0,0)	-7105.8	0.01027	0.01363	
Merlin Properties	SOCIMI	0.0		(2,0,0)	-8742.5	0.01161	0.01566	
Colonial	SOCIMI	0.0		(0,0,0)	-8530.0	0.01267	0.01672	

Fuente: Elaboración propia en Python

Se ha verificado los residuos mediante la función ACF, como se muestran en la Figura 5, donde se muestra los resultados ARIMA de cada vehículo. La función ACF confirma que los modelos se comportan como ruido blanco en casi todos los retardos, indicando que los modelos están correctamente especificados. No obstante, como comenta Tsay (2010), los pronósticos de ARIMA convergen hacia la media incondicional de la serie, limitando su utilidad predictiva en horizontes largos.

Figura 5. Modelo ARIMA (2017 – 2025)



Fuente: elaboración propia en Python

5.4.2. Modelo Prophet

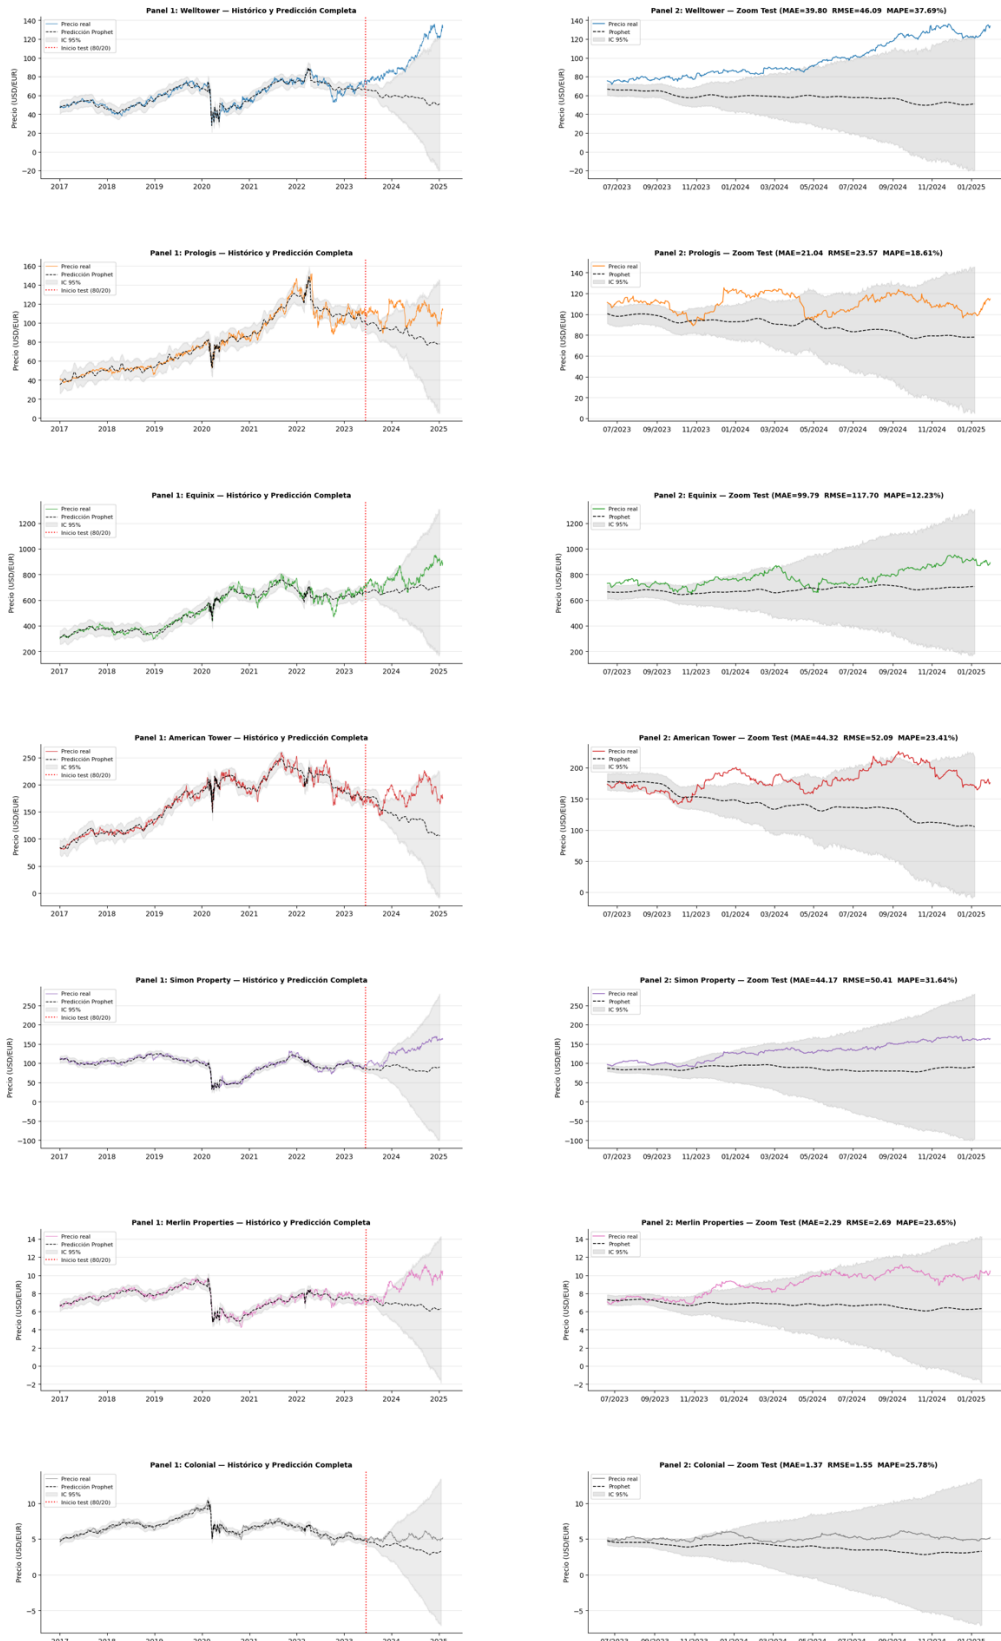
El modelo Prophet realiza una modelización de los precios incorporando componentes de tendencia, estacionalidad y efectos de eventos especiales, como se pudo apreciar en la descomposición realizada en la introducción de esta sección. Los resultados, recogidos en la Tabla 7 y la Figura 6, muestran que el modelo obtiene correctamente la tendencia histórica desarrollado durante el período de entrenamiento, ajustándose a los cambios sucedidos entre 2017 y 2023. No obstante, el período de test, 2023-2025, Prophet proyecta una tendencia que no captura los cambios bruscos de dirección que se produjeron en los mercados durante ese período. Esta es la razón por la cual se capturan más errores en vehículos que experimentaron recuperaciones intensas e inesperadas, como sucedió con Welltower (MAPE 37,82%) y Simon Property (MAPE 33,04%), en cambio Equinix (MAPE 12,11%) y Prologis (17,86%) experimentaron unas trayectorias más estables con mejores resultados. Por parte de las SOCIMIs, estas tienen un MAPE en torno al 24-26%, debido a la mayor dificultad de predecir series con menor liquidez y mayor sensibilidad a factores locales.

Tabla 7. Resultados Prophet – Predicción de precios (2017-2025)

RESULTADOS PROPHET – PREDICCIÓN DE PRECIO (2017-2025)				
Vehículo	Grupo	MAE	RMSE	MAPE (%)
Welltower	REIT	39.930	46.235	37.82
Prologis	REIT	20.360	22.889	17.86
Equinix	REIT	98.818	116.759	12.11
American Tower	REIT	43.685	51.318	23.07
Simon Property	REIT	46.056	52.385	33.04
Merlin Properties	SOCIMI	2.285	2.688	23.62
Colonial	SOCIMI	1.363	1.542	25.73

Fuente: Elaboración propia en Python

Figura 6. Modelo Prophet (2017 – 2025)



Fuente: elaboración propia en Python

5.4.3. Modelo LSTM

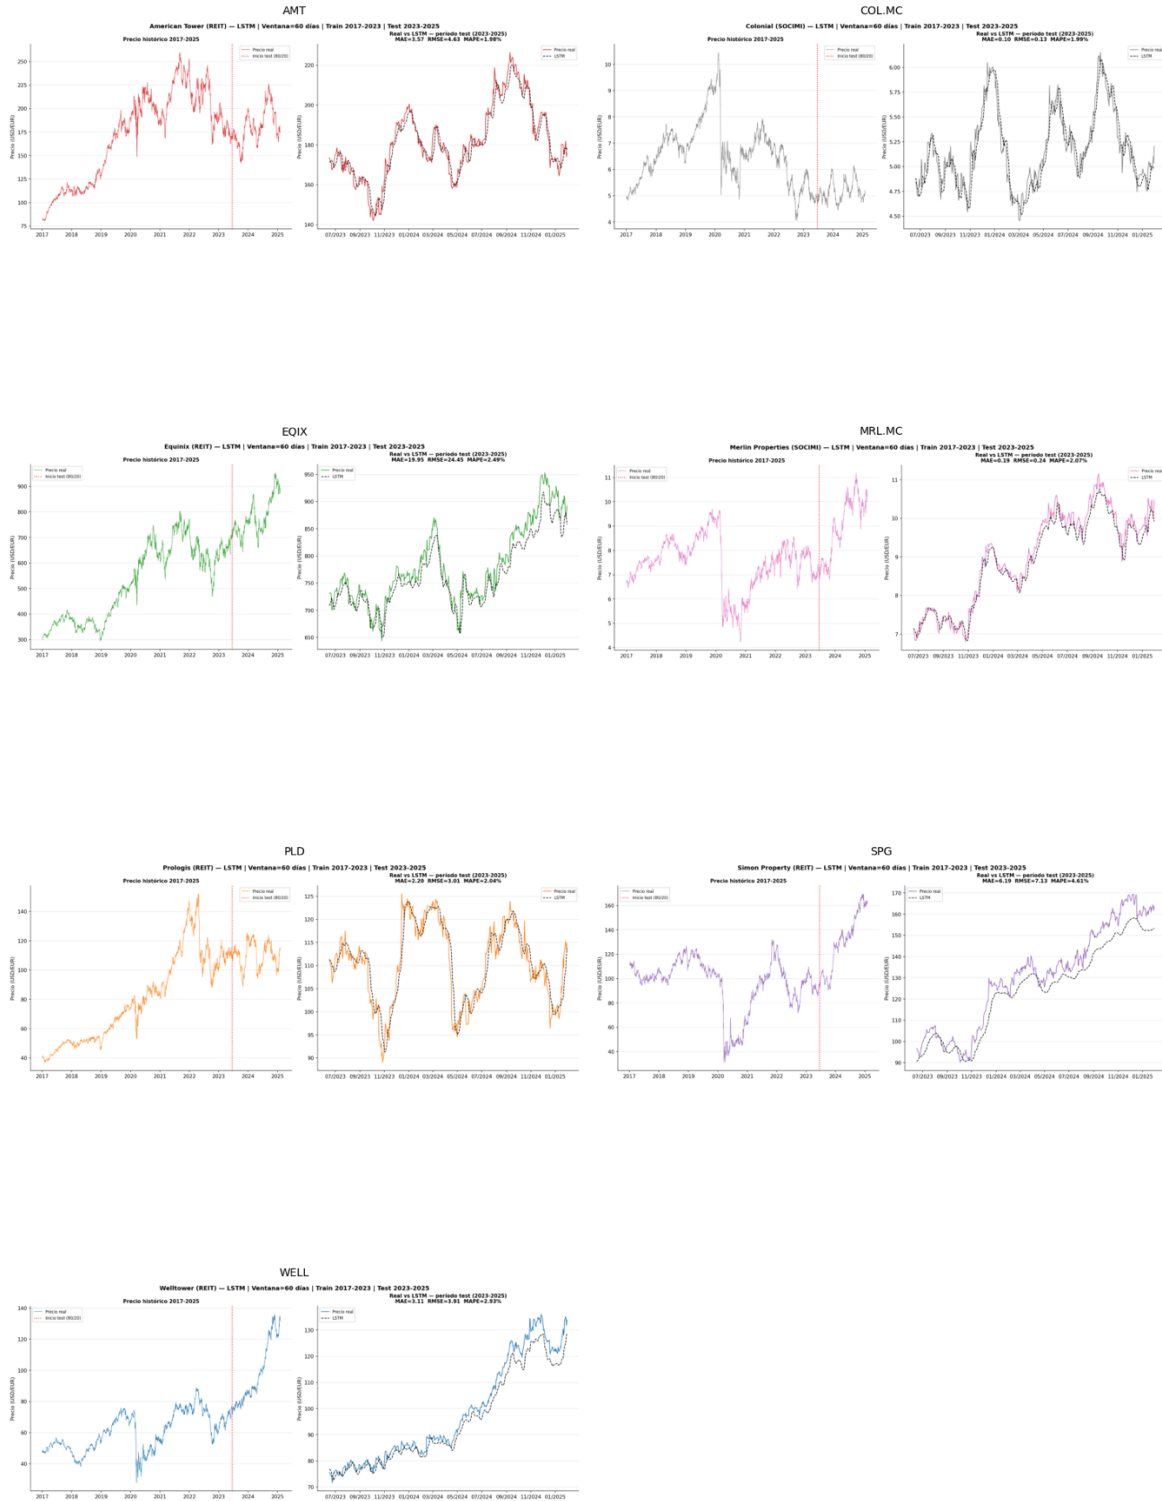
Finalmente, se ha realizado una red neuronal LSTM, la cual se entrena sobre 60 días consecutivos de precio normalizado para predecir el precio del día siguiente, acumulando estas predicciones con el objetivo de construir la trayectoria completa del período test. Esta arquitectura consta de dos capas LSTM, de 64 y 32 neuronas, con Dropout del 20% para evitar un sobreajuste, y un mecanismo de Early Stopping que detiene el entrenamiento cuando la pérdida sobre el conjunto de validaciones deja de mejorar. Los resultados se muestran en la Tabla 8 y Figura 7, en ella se puede apreciar una capacidad predictiva superior a los dos modelos anteriores. El MAPE de Colonial es de 1,99% y el de Equinix de 2,49%, además, la media total de los siete vehículos es de 2,59%. Los gráficos del período test muestran que la predicción realizada con LSTM sigue de forma ajustada una trayectoria real del precio de los vehículos, capturando tendencias generales y movimientos de menor escala.

Tabla 8. Resultados LSTM – Predicción de precios (2017-2025)

RESULTADOS LSTM – PREDICCIÓN DE PRECIO (2017-2025)				
Vehículo	Grupo	MAE	RMSE	MAPE (%)
Welltower	REIT	3.107	3.911	2.93
Prologis	REIT	2.202	3.014	2.04
Equinix	REIT	19.953	24.447	2.49
American Tower	REIT	3.568	4.627	1.98
Simon Property	REIT	6.186	7.129	4.61
Merlin Properties	SOCIMI	0.191	0.239	2.07
Colonial	SOCIMI	0.103	0.130	1.99

Fuente: Elaboración propia en Python

Figura 7. Modelo LSTM (2017 – 2025)



Fuente: elaboración propia en Python

5.4.4. Comparativa de los tres modelos

Los resultados confirman una superioridad progresiva de complejidad a precisión. ARIMA es valioso para caracterizar la dinámica temporal de los retornos, en cambio su capacidad predictiva sobre precios es limitada por la convergencia hacia la media incondicional (Tsay, 2010). Prophet mejora la interpretabilidad del modelo, interpretando el precio con componentes de tendencia y estacionalidad, aunque su MAPE medio, 24,75%, representa esas dificultades para poder capturar cambios bruscos de dirección en el período test. La LSTM obtiene el mejor resultado con un MAPE medio de 2,59%, confirmando la superioridad de los modelos de Deep Learning, en comparación con los estadísticos clásicos, en la predicción de precios de vehículos inmobiliarios cotizados, esto sigue también la tesis del estudio realizado por Habbab, Kampouridis y Papastylianou. A pesar de esto, este rendimiento debe contextualizarse como predicción one-step ahead, esto limita su extrapolación a predicciones a más largo plazo.

Tabla 9. Comparativa de modelos predictivos

COMPARATIVA DE MODELOS PREDICTIVOS				
Vehículo	Grupo	ARIMA (RMSE)	Prophet MAPE (%)	LSTM MAPE (%)
Welltower	REIT	0.01262	37.82	2.93
Prologis	REIT	0.01612	17.86	2.04
Equinix	REIT	0.01513	12.11	2.49
American Tower	REIT	0.01636	23.07	1.98
Simon Property	REIT	0.01363	33.04	4.61
Merlin Properties	SOCIMI	0.01566	23.62	2.07
Colonial	SOCIMI	0.01672	25.73	1.99
MEDIAS POR GRUPO:				
			Prophet MAPE (%)	LSTM MAPE (%)
Grupo				
REIT			24.78	2.81
SOCIMI			24.68	2.03

Fuente: Elaboración propia en Python

6. DISCUSIÓN DE LOS RESULTADOS

Los resultados obtenidos permiten comentar las tres hipótesis planteadas y contextualizar su relación con la literatura existente, integrando tanto la dimensión descriptiva como la predictiva.

La primera hipótesis plantea que existe una mayor rentabilidad ajustada al riesgo en los REITs, donde se confirma a nivel descriptivo. El Sharpe ratio medio de los REITs (0,297) es mayor al de las SOCIMIs (0,026), y la rentabilidad media anualizada corresponde a las REITs un 10,73%, mientras en el caso de las SOCIMIs es solo un 2,92%. Este resultado se evidencia con el estudio de Coletta y Busato (2019), en donde se comenta que en el caso de las REITs existe esta superioridad, a causa de su madurez dentro del mercado, su diversificación sectorial y profundidad de capital. No obstante, esta conclusión debe matizarse por varios motivos. El primero, es que el test de Mann-Whitney no permite rechazar la hipótesis nula de igualdad de distribuciones en ninguna variable, encontramos p-valores de 0,1905 para rentabilidad y Sharpe, esto hace que se limite la significación estadística dentro de la muestra por su reducido tamaño ($n=7$). El segundo motivo, es que existe una alta heterogeneidad entre vehículos dentro de las REITs, y se puede apreciar que hay empresas con Sharpe ratios muy diferentes, como sucede con Equinix (0,402) y Simon Property (0,071).

La segunda hipótesis, que anticipa una mayor volatilidad en las SOCIMIs, no se confirma. La volatilidad media de los REITs (31,18%) supera al de las SOCIMIs (27,69%). Esto contradice la hipótesis inicial, pero tiene relación con lo que comentan Alcock y Steiner (2015), que la volatilidad estándar subestima el riesgo real en períodos de estrés y que la dispersión intrasectorial puede superar las diferencias entre los mercados.

La tercera, y última, hipótesis se confirma. Los REITs operan con un mayor apalancamiento (56,61%) frente a las SOCIMIs (40,46%) y obtienen más rentabilidad, esto sugiere una relación positiva que es defendida por Tansens, Pekdemir y Moreno (2022). Además, como se comentó en el párrafo anterior, estos REITs también presentan niveles de volatilidad más altos, existiendo una relación apalancamiento y riesgo.

Finalmente, la dimensión predictiva aporta una conclusión metodológica relevante. La LSTM supera los modelos de Prophet y ARIMA con un MAPE medio menor en combinación de los REITs y SOCIMIs. Además, es importante tener en cuenta que LSTM es más precisa en las SOCIMIs (2,03%) que en los REITs (2,81%) y esto debe deberse a la mayor regularidad dentro de las series españolas derivadas de su menor liquidez. Pero, a pesar del rendimiento de este modelo, se debe interpretar las predicciones en un marco de one-step ahead, ya que sus ventajas se reducen en horizontes a largo plazo.

7. CONCLUSIÓN

Este trabajo ha permitido mostrar que el un enfoque en Business Analytics permite comparar de forma sistemática y rigurosa dos vehículos de inversión inmobiliaria cotizada diferentes con relación a sus estructuras, mercados y normativa, transformando datos financieros heterogéneos en conocimiento comparable y accionable.

El análisis empírico muestra que los REITs y las SOCIMIs responden altamente a las dinámicas locales que, a factores comunes, como refleja su baja correlación cruzada (0,16-0,41). Esta discrepancia es una oportunidad real con relación a la diversificación geográfica para inversores con exposición a ambos mercados, en concreto en períodos de estrés donde los beneficios de diversificación dentro de cada grupo tienden a reducirse.

Por otra parte, desde un punto de vista metodológico, este trabajo contribuye a cubrir un vacío identificado en la literatura, que se relaciona con la ausencia de comparativas sistemáticas entre REITs y SOCIMIs con indicadores homogéneos y técnicas de Business Analytics. Asimismo, la aplicación de tres modelos predictivos de diferentes complejidades, han demostrado que las herramientas de Deep Learning ofrecen una mayor capacidad predictiva a los modelos estadísticos clásicos en series de precios.

A pesar de todo lo anterior, existen limitaciones, como ha sido el pequeño tamaño muestral de solo siete vehículos, debido a la falta de información y volumen de datos, en específico en el caso de los vehículos españoles. Como líneas futuras se propone la ampliación de la muestra a más SOCIMIs europeas, la incorporación de variables macroeconómicas exógenas en un modelo LSTM multivariante, y el análisis de subperíodos diferenciados por ciclo de tipos.

En conjunto, los resultados reflejan que los REITs presentan un comportamiento más favorable en términos de rentabilidad y rentabilidad ajustada al riesgo dentro de la muestra analizada. En cambio, las SOCIMIs muestran un perfil más limitado con relación a la liquidez y disponibilidad de datos, condicionando la comparación empírica. Por ello, la principal aportación de este trabajo es mostrar cómo las herramientas de Business Analytics permiten estructurar, comparar y visualizar diferencias relevantes entre vehículos inmobiliarios cotizados en mercados con distinto grado de madurez.

Bibliografía

- Abdullah, M., Adeabah, D., Abakah, E., & Lee, C. (2023). Extreme return and volatility connectedness among real estate tokens, REITs, and other assets: The role of global factors and portfolio implications. *Finance Research Letters*, 55, 103979.
- Alcock, J., & Steiner, E. (2015). What determines the systematic risk of REITs? University of Birmingham.
- Armanext. (2025). X Estudio SOCIMI 2025: Datos, análisis y perspectivas de un sector en crecimiento. Armanext.
- Ashok, A., Kaplan, D. H., Hammell, B. E., Monti, L. A., & Berkenblit, H. E. (2021). Real Estate Investment Trust - USA. Sullivan & Worcester LLP. Lexology GTDT.
- Battisti, E., Shams, R., Sakka, G., & Miglietta, N. (2019). Big data and risk management in business processes: Implications for corporate real estate. *Business Process Management Journal*, 26(5), 1141-1155.
- Bernstein, W. (2025). Los cuatro pilares de la inversión. Deusto.
- Cohen & Steers. (2012). Introduction to real estate securities. Cohen & Steers.
- Coletta, C. M., & Busato, F. (2019). U.S. REITs: A financial economics review as of 2018. *Real Estate Management and Valuation*, 27(2), 20-32.
- Congressional Research Service. (2016). Real estate investment trusts (REITs) and the Foreign Investment in Real Property Tax Act (FIRPTA): Overview and recent tax revisions. CRS.
- EPRA. (2023). The impact of European REITs. European Public Real Estate Association.
- Fernández García, L. (2025). Las SOCIMI: una herramienta para consolidar el alquiler residencial en España. *La fiscalidad de la vivienda en España: Una propuesta de mejora*, 216-226.

- Fernández, N., & Romero, M. (2016). Las SOCIMI y el mercado inmobiliario. Cuadernos de Información Económica, 253, 61-66.
- García Serrano, M. G. (2018). Las SOCIMI como instrumento de inversión: Estudio de su marco normativo con especial referencia al ámbito tributario [Trabajo de fin de grado]. Universidad Miguel Hernández.
- Geltner, D. M., Miller, N. G., Clayton, J., & Eichholtz, P. (2001). Commercial real estate: Analysis and investments. LEAP Publishing Services.
- Gogineni, S., Jain, P., & Upadhyay, A. (2024). Global REIT regulations and valuation. International Review of Economics and Finance, 93, 152-166.
- Grigorián, L., & Escudero, M. (2025). SOCIMIs: Regulación, mercado y estrategia para liderar el nuevo ciclo inmobiliario. Revista La Notaria, 1, 95-99.
- Habbab, F. Z., Kampouridis, M., & Papastylianou, T. (2025). Improving real estate investment trusts (REITs) time-series prediction accuracy using machine learning and technical analysis indicators. Artificial Intelligence Review, 58, 70.
- Jackson, L. A. (2007). Lodging REIT performance and comparison with other equity REIT returns [Tesis doctoral]. Oklahoma State University.
- JLL España y BME. (2021). SOCIMIs: Un futuro sostenible. Jones Lang LaSalle IP.
- Juliani Fernández de Córdoba, I. (2008). El mercado inmobiliario: Instituciones de inversión colectiva, entidades dedicadas al arrendamiento de viviendas y una aproximación a los REIT. Crónica Tributaria, 128, 147-167.
- Kahn, R. N. (2019). El futuro de la gestión de inversiones. CFA Institute Research Foundation.
- KPMG International Cooperative. (2013). Taxation of real estate investment trusts. KPMG.
- Ley 11/2009, de 26 de octubre, por la que se regulan las Sociedades Anónimas Cotizadas de Inversión en el Mercado Inmobiliario. Boletín Oficial del Estado,

259, de 27 de octubre de 2009. <https://www.boe.es/buscar/pdf/2009/BOE-A-2009-17000-consolidado.pdf>

Li, Q., & Orzano, M. (2020). Understanding REIT sectors. S&P Global. <https://www.spglobal.com/en/research-insights/market-insights/understanding-reit-sectors>

Mazurczak, A. (2011). Development of real estate investment trust (REIT) regime in Europe. *Journal of International Studies*, 4(1), 115-123.

Monteiro, A. S., Sebastiao, H., & Silva, N. (2025). Prediction and allocation of stocks, bonds, and REITs in the US market. *Computational Economics*, 65, 1191-1230.

Nareit. (2025). The history of REITs. <https://www.reit.com/what-reit/history-reits>

Nareit. (2025). U.S. REIT industry equity market cap. <https://www.reit.com/data-research/reit-market-data/report/us-reit-industry-equity-market-cap>

Oh, J. S., & Verstein, A. (2024). A theory of the REIT. *The Yale Law Journal*, 133, 755-838.

PricewaterhouseCoopers. (2013). Compare and contrast: Worldwide real estate investment trust (REIT) regimes. PwC.

PricewaterhouseCoopers. (2021). Worldwide real estate investment trust (REIT) regime: Compare and contrast. PwC.

PricewaterhouseCoopers Auditores S.L. (2020). Las SOCIMI en el mercado inmobiliario español. PwC.

Rehman, M. U., Shahzad, S. J., Ahmad, N., & Vo, X. V. (2022). Dependence dynamics of US REITs. *International Review of Financial Analysis*, 81, 102070.

Tansens, P. R., Pekdemir, D., & Moreno, D. (2022). Interest rates and inflation: What are the challenges for listed real estate? European Public Real Estate Association.

- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37-45.
- TIKR Terminal. (2025). Financial data platform. <https://www.tikr.com>
- Tsay, R. S. (2010). *Analysis of financial time series* (3.^a ed.). Wiley.
- Urquijo Moreno, T. (2019). *Las SOCIMI: Normativa y evolución* [Trabajo de fin de grado]. Universidad Pontificia Comillas.
- Valdés-Solís Fernández de Retana, R. (2022). *Estudio sobre su régimen jurídico y comparativa con otros vehículos de inversión inmobiliaria* [Trabajo de fin de grado]. Universidad del País Vasco.
- Viñuales Sanabria, L. M. (2010). SOCIMI: ¿El REIT de nueva generación? Un estudio comparado. *Crónica Tributaria*, 135, 247-266.
- Zhu, B., & Lizieri, C. (2024). Local beta: Has local real estate market risk been priced in REIT returns? *The Journal of Real Estate Finance and Economics*, 69(4), 682-718.

ANEXO A – Código Python

A.1. Script de selección de muestra

```
import yfinance as yf
import pandas as pd
import numpy as np
import warnings
warnings.filterwarnings('ignore')

# Parámetros globales

START = "2017-01-01"
END   = "2025-01-01"
SESIONES_ESPERADAS = 252 * 8 # 8 años x 252 sesiones/año
RF     = 0.02                # tasa libre de riesgo anualizada
(2%)

# Universo candidato REITs estadounidenses (fuente: NAREIT)

reits_candidatos = {
    "Prologis": "PLD",
    "American Tower": "AMT",
    "Equinix": "EQIX",
    "Public Storage": "PSA",
    "Simon Property Group": "SPG",
    "Welltower": "WELL",
    "Digital Realty": "DLR",
    "Crown Castle": "CCI",
    "Realty Income": "O",
    "AvalonBay Communities": "AVB",
    "Extra Space Storage": "EXR",
    "Iron Mountain": "IRM",
    "VICI Properties": "VICI",
    "Alexandria Real Est.": "ARE",
    "SBA Communications": "SBAC",
    "Broadstone Net Lease": "BNL",
    "COPT Defense Properties": "CDP",
    "Americold Realty Trust": "COLD",
    "Four Corners Property Trust": "FCPT",
    "NNN Reit": "NNN",
    "Postal Realty Trust": "PSTL",
}
```

```

# Universo candidato SOCIMIs españolas (fuente: BME)

socimis_candidatas = {
    "Merlin Properties": "MRL.MC",
    "Colonial": "COL.MC",
    "Árima Real Estate": "ARIM.MC",
    "Quonia SOCIMI": "YQUO.MC",
    "MICISO Real Estate": "YMCS.MC",
    "VBARE Iberian Prop.": "SCVBA.MC",
    "ALFIL Patrimonial": "SCALF.MC",
    "PSN Gestión SOCIMI": "YPSN.MC",
    "Castellana Properties": "YCPS.MC",
    "GMP Property": "YGMP.MC",
    "Emperador Properties": "YEPSA.MC",
    "Vivenio Residencial": "YVIV.MC",
    "Zambal Spain": "YZAM.MC",
    "Atom Hoteles": "YAOT.MC",
    "Fidere Patrimonio": "YFID.MC",
    "Testa Residencial": "YTST.MC",
    "Vitruvio Real Estate": "YVTR.MC",
    "Témpore Properties": "YTMP.MC",
    "Silicius Real Estate": "YSIL.MC",
    "General de Galerías": "YGGC.MC",
}

def analizar(ticker, nombre):
    """Descarga datos y calcula indicadores para un ticker."""
    try:
        datos = yf.download(
            ticker, start=START, end=END,
            auto_adjust=True, progress=False, timeout=15
        )
        if datos.empty:
            return None

        # Aplanar MultiIndex si existe
        if isinstance(datos.columns, pd.MultiIndex):
            datos.columns = datos.columns.get_level_values(0)

        close = datos["Close"].dropna()
        volume = datos["Volume"].dropna()

        if len(close) < 50:
            return None

        # Disponibilidad de datos

```

```

1) pct_datos = round(len(close) / SESIONES_ESPERADAS * 100,

# Volumen medio diario en millones
vol_medio = round(volume.mean() / 1e6, 2)

# Capitalización bursátil aproximada en miles de
millones
try:
    mkt_cap =
round(yf.Ticker(ticker).fast_info.market_cap / 1e9, 1)
except Exception:
    mkt_cap = None

# Retornos logarítmicos diarios
ret = np.log(close / close.shift(1)).dropna()

ret_anual = round(float(ret.mean()) * 252 * 100, 2)
vol_anual = round(float(ret.std()) * np.sqrt(252) *
100, 2)
sharpe = round((ret_anual - RF * 100) / vol_anual, 3)
\
    if vol_anual > 0 else None

return {
    "Nombre": nombre,
    "Ticker": ticker,
    "Inicio datos": close.index[0].strftime("%Y-
%m"),
    "Obs.": len(close),
    "% Datos": pct_datos,
    "Cap. (B)": mkt_cap if mkt_cap else "N/D",
    "Vol. Diario (M)": vol_medio,
    "Ret. Anual (%)": ret_anual,
    "Volat. Anual (%)": vol_anual,
    "Sharpe aprox.": sharpe,
}

except Exception as e:
    print(f" ERROR {ticker}: {e}")
    return None

def ejecutar_analisis(universo, titulo, n_seleccion=5):
    """Ejecuta el análisis de selección sobre un universo de
tickers."""
    print("\n" + "=" * 72)

```

```

print(f" {titulo}")
print(f" Período: {START} → {END} | Selección: Top
{n_seleccion}")
print("=" * 72)

resultados = []
for nombre, ticker in universo.items():
    r = analizar(ticker, nombre)
    print(f" {'✓' if r else 'X'} {nombre} ({ticker}")
    if r:
        resultados.append(r)

if not resultados:
    print(" Sin datos disponibles.")
    return None

df = pd.DataFrame(resultados)

# Filtro: mínimo 80% de datos disponibles
df = df[df["% Datos"] >= 80.0].copy()
print(f"\n Candidatos con ≥ 80% datos: {len(df)}")

# Ordenar por capitalización (desc.) y luego por volumen
df["_cap"] = pd.to_numeric(
    df["Cap. (B)"].replace("N/D", 0), errors="coerce"
).fillna(0)
df = df.sort_values(["_cap", "Vol. Diario (M)"],
ascending=False).drop(columns="_cap")

cols = [
    "Nombre", "Ticker", "Inicio datos", "% Datos",
    "Cap. (B)", "Vol. Diario (M)",
    "Ret. Anual (%)", "Volat. Anual (%)", "Sharpe aprox."
]

print("\n CANDIDATOS CON DATOS SUFICIENTES:")
print(df[cols].to_string(index=False))

print(f"\n MUESTRA SELECCIONADA (Top {n_seleccion}):")
print(df.head(n_seleccion)[cols].to_string(index=False))

return df

```

```

# Ejecución

df_reits = ejecutar_analisis(reits_candidatos,
                             "REITs ESTADOUNIDENSES (NAREIT)",
                             n_seleccion=5)

df_socimis = ejecutar_analisis(socimis_candidatas,
                                "SOCIMIs ESPAÑOLAS (BME)",
                                n_seleccion=2)

# Tabla final conjunta

df_reits["Mercado"] = "REIT (EE.UU.)"
df_socimis["Mercado"] = "SOCIMI (España)"

muestra_final = pd.concat(
    [df_reits.head(5), df_socimis.head(2)],
    ignore_index=True
)

cols_final = [
    "Mercado", "Nombre", "Ticker", "Cap. (B)",
    "Vol. Diario (M)", "Ret. Anual (%)", "Volat. Anual (%)",
    "Sharpe aprox."
]

print("\n\nMUESTRA FINAL – 5 REITs + 2 SOCIMIs")
print("=" * 72)
print(muestra_final[cols_final].to_string(index=False))
print("\nFuente: elaboración propia a partir de yfinance, NAREIT
y BME (2025).")

```

A.2. Análisis descriptivo

```
##ANÁLISIS DESCRIPTIVO

import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.dates as mdates
import seaborn as sns
import warnings
warnings.filterwarnings('ignore')

# Parámetros globales

START = "2017-01-01"
END   = "2025-01-31"
RF    = 0.02

# Muestra final seleccionada

tickers = {
    "Welltower":      "WELL",
    "Prologis":       "PLD",
    "Equinix":        "EQIX",
    "American Tower": "AMT",
    "Simon Property": "SPG",
    "Merlin Properties": "MRL.MC",
    "Colonial":       "COL.MC",
}

grupo = {
    "WELL": "REIT",
    "PLD": "REIT",
    "EQIX": "REIT",
    "AMT": "REIT",
    "SPG": "REIT",
    "MRL.MC": "SOCIMI",
    "COL.MC": "SOCIMI",
}

colores = {
    "WELL": "#1f77b4",
    "PLD": "#ff7f0e",
    "EQIX": "#2ca02c",
    "AMT": "#d62728",
    "SPG": "#9467bd",
    "MRL.MC": "#e377c2",
}
```

```

        "COL.MC": "#7f7f7f",
    }

# Descarga de datos

print("Descargando datos...")
precios = {}
for nombre, ticker in tickers.items():
    datos = yf.download(ticker, start=START, end=END,
                        auto_adjust=True, progress=False)
    if isinstance(datos.columns, pd.MultiIndex):
        datos.columns = datos.columns.get_level_values(0)
    precios[ticker] = datos["Close"].dropna()
    print(f"  ✓ {nombre} ({ticker}): {len(precios[ticker])}
sesiones")

# Índices de referencia

sp500 = yf.download("^GSPC", start=START, end=END,
                    auto_adjust=True,
                    progress=False)["Close"].dropna()
ibex = yf.download("^IBEX", start=START, end=END,
                   auto_adjust=True,
                   progress=False)["Close"].dropna()

# Cálculo de retornos logarítmicos

retornos = {}
for ticker, precio in precios.items():
    retornos[ticker] = np.log(precio / precio.shift(1)).dropna()

df_ret = pd.DataFrame(retornos)

# ESTADÍSTICOS DESCRIPTIVOS

print("\n" + "=" * 70)
print("  ESTADÍSTICOS DESCRIPTIVOS – RETORNOS DIARIOS (2017-
2025)")
print("=" * 70)

filas = []
for nombre, ticker in tickers.items():
    r = retornos[ticker]

    # Beta respecto al índice correspondiente
    if grupo[ticker] == "REIT":
        idx = np.log(sp500 / sp500.shift(1)).dropna()

```

```

else:
    idx = np.log(ibex / ibex.shift(1)).dropna()

alineado = pd.concat([r, idx], axis=1).dropna()
alineado.columns = ["activo", "indice"]
cov = np.cov(alineado["activo"], alineado["indice"])
beta = cov[0, 1] / cov[1, 1]

ret_anual = r.mean() * 252 * 100
vol_anual = r.std() * np.sqrt(252) * 100
sharpe = (ret_anual - RF * 100) / vol_anual

filas.append({
    "Vehículo": nombre,
    "Tipo": grupo[ticker],
    "Ret. Anual (%)": round(ret_anual, 2),
    "Volat. Anual (%)": round(vol_anual, 2),
    "Beta": round(beta, 3),
    "Sharpe": round(sharpe, 3),
    "Asimetría": round(float(r.skew()), 3),
    "Curtosis": round(float(r.kurt()), 3),
    "Mín. diario (%)": round(float(r.min()) * 100, 2),
    "Máx. diario (%)": round(float(r.max()) * 100, 2),
})

df_stats = pd.DataFrame(filas)
print(df_stats.to_string(index=False))

# Dividend Yield

print("\n DIVIDEND YIELD MEDIO ANUALIZADO (2017-2025)")
print("-" * 50)

for nombre, ticker in tickers.items():
    try:
        info = yf.Ticker(ticker)
        dividendos = info.dividends
        precio_medio = precios[ticker].mean()

        if len(dividendos) > 0:
            # Filtrar dividendos del período
            div_perodo = dividendos[
                (dividendos.index >= START) &
                (dividendos.index <= END)
            ]
            # Dividendo anual medio

```

```

        div_anual = div_periodo.sum() / 8
        div_yield = round((div_anual / precio_medio) * 100,
2)
        print(f" {nombre} ({ticker}): {div_yield}%")
    else:
        print(f" {nombre} ({ticker}): Sin datos")
except Exception as e:
    print(f" {nombre} ({ticker}): Error - {e}")

# GRÁFICO 1: Evolución precios normalizados (base 100)

fig, ax = plt.subplots(figsize=(14, 6))

for nombre, ticker in tickers.items():
    precio = precios[ticker]
    normalizado = precio / precio.iloc[0] * 100
    ls = "-" if grupo[ticker] == "REIT" else "--"
    lw = 1.5 if grupo[ticker] == "REIT" else 2.0
    ax.plot(normalizado.index, normalizado,
            label=f"{nombre} ({'REIT' if grupo[ticker]=='REIT'
else 'SOCIMI'})",
            color=colores[ticker], linestyle=ls, linewidth=lw)

# Marcar eventos relevantes
ax.axvline(pd.Timestamp("2020-03-01"), color="black",
           linestyle=":", alpha=0.6, linewidth=1)
ax.text(pd.Timestamp("2020-03-15"), ax.get_ylim()[1] * 0.95,
        "COVID-19", fontsize=8, color="black", alpha=0.7)

ax.axvline(pd.Timestamp("2022-03-01"), color="gray",
           linestyle=":", alpha=0.6, linewidth=1)
ax.text(pd.Timestamp("2022-03-15"), ax.get_ylim()[1] * 0.85,
        "Subida tipos", fontsize=8, color="gray", alpha=0.7)

ax.set_title("Evolución del precio normalizado (base 100 = enero
2017)",
           fontsize=13, fontweight="bold", pad=12)
ax.set_ylabel("Precio normalizado", fontsize=11)
ax.set_xlabel("")
ax.legend(loc="upper left", fontsize=9, framealpha=0.8)
ax.xaxis.set_major_formatter(mdates.DateFormatter("%Y"))
ax.xaxis.set_major_locator(mdates.YearLocator())
ax.grid(axis="y", alpha=0.3)
sns.despine()
plt.tight_layout()

```

```

plt.savefig("grafico1_precios_normalizados.png", dpi=150,
bbox_inches="tight")
plt.show()
print("  ✓ Gráfico 1 guardado")

# GRÁFICO 2: Distribución de retornos diarios (histogramas)

fig, axes = plt.subplots(2, 4, figsize=(16, 7))
axes = axes.flatten()

for i, (nombre, ticker) in enumerate(tickers.items()):
    r = retornos[ticker] * 100
    ax = axes[i]
    ax.hist(r, bins=80, color=colores[ticker], alpha=0.75,
edgecolor="none")
    ax.axvline(r.mean(), color="black", linestyle="--",
linewidth=1.2,
                label=f"Media: {r.mean():.3f}%")
    ax.set_title(f"{nombre}\n({'REIT' if grupo[ticker]=='REIT'
else 'SOCIMI'})",
                fontsize=10, fontweight="bold")
    ax.set_xlabel("Retorno diario (%)", fontsize=8)
    ax.set_ylabel("Frecuencia", fontsize=8)
    ax.legend(fontsize=7)
    ax.grid(axis="y", alpha=0.3)
    sns.despine(ax=ax)

# Ocultar el subplot sobrante
axes[-1].set_visible(False)

plt.suptitle("Distribución de retornos diarios – 2017-2025",
            fontsize=13, fontweight="bold", y=1.01)
plt.tight_layout()
plt.savefig("grafico2_distribucion_retornos.png", dpi=150,
bbox_inches="tight")
plt.show()
print("  ✓ Gráfico 2 guardado")

# GRÁFICO 3: Matriz de correlaciones

nombres_cortos = {v: k.split()[0] for k, v in tickers.items()}
df_corr = df_ret.rename(columns=nombres_cortos).corr()

fig, ax = plt.subplots(figsize=(9, 7))
mask = np.triu(np.ones_like(df_corr, dtype=bool), k=1)
sns.heatmap(df_corr, annot=True, fmt=".2f", cmap="RdYlGn",
            center=0, vmin=-1, vmax=1,

```

```

        linewidths=0.5, linecolor="white",
        annot_kws={"size": 10}, ax=ax)
ax.set_title("Matriz de correlaciones – retornos diarios (2017-
2025)",
            fontsize=12, fontweight="bold", pad=12)
plt.tight_layout()
plt.savefig("grafico3_correlaciones.png", dpi=150,
bbox_inches="tight")
plt.show()
print("  ✓ Gráfico 3 guardado")

# GRÁFICO 4: Volatilidad rolling (252 días)

fig, ax = plt.subplots(figsize=(14, 6))

for nombre, ticker in tickers.items():
    vol_rolling = retornos[ticker].rolling(252).std() *
np.sqrt(252) * 100
    ls = "-" if grupo[ticker] == "REIT" else "--"
    ax.plot(vol_rolling.index, vol_rolling,
            label=nombre, color=colores[ticker],
            linestyle=ls, linewidth=1.5)

ax.axvline(pd.Timestamp("2020-03-01"), color="black",
            linestyle=":", alpha=0.5, linewidth=1)
ax.axvline(pd.Timestamp("2022-03-01"), color="gray",
            linestyle=":", alpha=0.5, linewidth=1)
ax.set_title("Volatilidad anualizada rolling (ventana 252
días)",
            fontsize=13, fontweight="bold", pad=12)
ax.set_ylabel("Volatilidad anualizada (%)", fontsize=11)
ax.legend(loc="upper right", fontsize=9, framealpha=0.8)
ax.xaxis.set_major_formatter(mdates.DateFormatter("%Y"))
ax.xaxis.set_major_locator(mdates.YearLocator())
ax.grid(axis="y", alpha=0.3)
sns.despine()
plt.tight_layout()
plt.savefig("grafico4_volatilidad_rolling.png", dpi=150,
bbox_inches="tight")
plt.show()
print("  ✓ Gráfico 4 guardado")

print("\n" + "=" * 70)
print("  ANÁLISIS DESCRIPTIVO COMPLETADO")
print("  Archivos generados:")
print("  - grafico1_precios_normalizados.png")
print("  - grafico2_distribucion_retornos.png")

```

```
print(" - grafico3_correlaciones.png")  
print(" - grafico4_volatilidad_rolling.png")  
print("=" * 70)
```

A.3. Análisis comparativo

```
import yfinance as yf
import pandas as pd
import numpy as np
from scipy import stats
import warnings
warnings.filterwarnings('ignore')

# Parámetros

START = "2017-01-01"
END   = "2025-01-31"
RF    = 0.02

tickers = {
    "Welltower":      "WELL",
    "Prologis":       "PLD",
    "Equinix":        "EQIX",
    "American Tower": "AMT",
    "Simon Property": "SPG",
    "Merlin Properties": "MRL.MC",
    "Colonial":       "COL.MC",
}

grupo = {
    "WELL": "REIT", "PLD": "REIT", "EQIX": "REIT",
    "AMT": "REIT", "SPG": "REIT",
    "MRL.MC": "SOCIMI", "COL.MC": "SOCIMI",
}

# Descarga

precios = {}
for nombre, ticker in tickers.items():
    datos = yf.download(ticker, start=START, end=END,
                        auto_adjust=True, progress=False)
    if isinstance(datos.columns, pd.MultiIndex):
        datos.columns = datos.columns.get_level_values(0)
    precios[ticker] = datos["Close"].dropna()

sp500 = yf.download("^GSPC", start=START, end=END,
                    auto_adjust=True,
                    progress=False)["Close"].dropna()
ibex = yf.download("^IBEX", start=START, end=END,
                  auto_adjust=True,
                  progress=False)["Close"].dropna()
```

```

# Indicadores por vehículo

filas = []
for nombre, ticker in tickers.items():
    r = np.log(precios[ticker] /
precios[ticker].shift(1)).dropna()

    if grupo[ticker] == "REIT":
        idx = np.log(sp500 / sp500.shift(1)).dropna()
    else:
        idx = np.log(ibex / ibex.shift(1)).dropna()

    alineado = pd.concat([r, idx], axis=1).dropna()
    alineado.columns = ["activo", "indice"]
    cov = np.cov(alineado["activo"], alineado["indice"])
    beta = cov[0, 1] / cov[1, 1]

    ret_anual = r.mean() * 252 * 100
    vol_anual = r.std() * np.sqrt(252) * 100
    sharpe = (ret_anual - RF * 100) / vol_anual

    filas.append({
        "Vehículo": nombre,
        "Grupo": grupo[ticker],
        "Ret. Anual (%)": round(ret_anual, 3),
        "Volat. Anual (%)": round(vol_anual, 3),
        "Beta": round(beta, 3),
        "Sharpe": round(sharpe, 3),
    })

df = pd.DataFrame(filas)

# Medias por grupo

print("=" * 60)
print(" MEDIAS POR GRUPO")
print("=" * 60)
print(df.groupby("Grupo")[["Ret. Anual (%)", "Volat. Anual (%)",
"Beta", "Sharpe"]].mean().round(3))

# Test de Mann-Whitney

print("\n" + "=" * 60)
print(" TEST DE MANN-WHITNEY (REITs vs SOCIMIs)")
print("=" * 60)

reits = df[df["Grupo"] == "REIT"]

```

```

socimis = df[df["Grupo"] == "SOCIMI"]

for var in ["Ret. Anual (%)", "Volat. Anual (%)", "Beta",
"Sharpe"]:
    stat, p = stats.mannwhitneyu(
        reits[var].values,
        socimis[var].values,
        alternative="two-sided"
    )
    sig = "* p<0.10" if p < 0.10 else " n.s."
    if p < 0.05: sig = "** p<0.05"
    if p < 0.01: sig = "*** p<0.01"
    print(f" {var:<22} U={stat:.1f} p={p:.4f} {sig}")

# Correlaciones

print("\n" + "=" * 60)
print(" MATRIZ DE CORRELACIONES (retornos diarios)")
print("=" * 60)

retornos = {}
for nombre, ticker in tickers.items():
    retornos[ticker] = np.log(
        precios[ticker] / precios[ticker].shift(1)
    ).dropna()

nombres_cortos = {v: k.split()[0] for k, v in tickers.items()}
df_ret = pd.DataFrame(retornos).rename(columns=nombres_cortos)
df_corr = df_ret.corr().round(2)
print(df_corr.to_string())

```

A.4. Análisis de indicadores financieros

```
import os
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns

CARPETA = "/content/drive/MyDrive/TFG_Ratios"

EMPRESAS = {
    "WELL": "REIT", "PLD": "REIT", "EQIX": "REIT",
    "AMT": "REIT", "SPG": "REIT",
    "MRL": "SOCIMI", "COL": "SOCIMI",
}

ANIOS = ["31/12/17", "31/12/18", "31/12/19", "31/12/20",
         "31/12/21", "31/12/22", "31/12/23", "31/12/24"]

INDICADORES = {
    "ROA": "Return on Assets %",
    "ROE": "Return On Equity %",
    "Debt_Assets": "Debt / Assets",
    "EBITDA_Margin": "EBITDA Margin %",
}

def limpiar_valor(x):
    """Convierte '3,6 %' o '0.036' o '3.6' a float en %."""
    if pd.isna(x):
        return np.nan
    s = str(x).strip()
    if s in ("-", "", "-", "N/A", "nan"):
        return np.nan
    # Quitar símbolo % y espacios
    es_pct = "%" in s
    s = s.replace("%", "").replace(" ", "")
    # Coma como decimal (formato europeo "3,6")
    # Solo si hay una coma y no hay punto → es decimal europeo
    if "," in s and "." not in s:
        s = s.replace(",", ".")
    # Si hay punto Y coma → coma es miles, punto es decimal
    elif "." in s and "," in s:
        s = s.replace(".", ",")
    try:
        val = float(s)
    except ValueError:
        return np.nan
```

```

# Si viene como decimal puro (ej 0.036) convertir a %
if not es_pct and abs(val) < 2:
    val = val * 100
return val

def cargar_ratios(ticker):
    nombre = f"TIKR - {ticker} - Ratios - (31.12.17 -
31.12.25).xlsx"
    ruta = os.path.join(CARPETA, nombre)
    df = pd.read_excel(ruta, header=0)
    df = df.rename(columns={df.columns[0]: "Partida"})
    df["Partida"] =
df["Partida"].astype(str).str.replace('\xa0', '', regex=False).str
.strip()
    df = df.set_index("Partida")
    df.columns = [str(c).strip() for c in df.columns]
    return df

filas = []

for ticker, grupo in EMPRESAS.items():
    try:
        df = cargar_ratios(ticker)
    except FileNotFoundError:
        print(f" ⚠ No encontrado: {ticker}")
        continue

    fila_emp = {"Ticker": ticker, "Grupo": grupo}

    for clave, nombre_tikr in INDICADORES.items():
        if nombre_tikr not in df.index:
            print(f" X {ticker}: no encontrado
'{nombre_tikr}'")
            fila_emp[clave] = np.nan
            continue

        s = df.loc[nombre_tikr]
        if isinstance(s, pd.DataFrame):
            s = s.iloc[0]

        # Aplicar limpieza a cada valor
        cols = [c for c in ANIOS if c in s.index]
        valores = pd.Series({c: limpiar_valor(s[c]) for c in
cols})
        fila_emp[clave] = round(valores.mean(), 2)

    filas.append(fila_emp)

```

```

df_ratios = pd.DataFrame(filas)

print("="*70)
print("  RATIOS FUNDAMENTALES (Fuente: TIKR) – media 2017-2024")
print("="*70)
print(df_ratios.to_string(index=False))
print("\n MEDIAS POR GRUPO:")
print(df_ratios.groupby("Grupo")[list(INDICADORES.keys())]
      .mean().round(2).to_string())

colores_grupo = {"REIT": "#1f77b4", "SOCIMI": "#e377c2"}
etiquetas = {
    "ROA":          "ROA (%)",
    "ROE":          "ROE (%)",
    "Debt_Assets": "Deuda / Activos (%)",
    "EBITDA_Margin": "Margen EBITDA (%)"
}

fig, axes = plt.subplots(2, 2, figsize=(14, 10))
axes = axes.flatten()

for i, (clave, label) in enumerate(etiquetas.items()):
    ax = axes[i]
    colores_barras = [colores_grupo[g] for g in
df_ratios["Grupo"]]
    bars = ax.bar(df_ratios["Ticker"], df_ratios[clave],
                  color=colores_barras, edgecolor="white",
linewidth=0.5)

    media_reit =
df_ratios[df_ratios["Grupo"]=="REIT"][clave].mean()
    media_socimi =
df_ratios[df_ratios["Grupo"]=="SOCIMI"][clave].mean()
    ax.axhline(media_reit, color="#1f77b4", linestyle="--",
linewidth=1.2, label=f"Media REIT:
{media_reit:.1f}%")
    ax.axhline(media_socimi, color="#e377c2", linestyle="--",
linewidth=1.2, label=f"Media SOCIMI:
{media_socimi:.1f}%")

    for bar, val in zip(bars, df_ratios[clave]):
        if not pd.isna(val):
            ax.text(bar.get_x() + bar.get_width()/2,
                    bar.get_height() + 0.3,
                    f"{val:.1f}%", ha="center", va="bottom",
fontsize=8)

```

```

ax.set_title(label, fontsize=11, fontweight="bold")
ax.set_ylabel("%", fontsize=9)
ax.legend(fontsize=8)
ax.grid(axis="y", alpha=0.3)
sns.despine(ax=ax)

from matplotlib.patches import Patch
leyenda = [Patch(color="#1f77b4", label="REIT"),
           Patch(color="#e377c2", label="SOCIMI")]
fig.legend(handles=leyenda, loc="upper center", ncol=2,
           fontsize=10, framealpha=0.8)

plt.suptitle("Ratios fundamentales – REITs vs SOCIMIs (media
2017-2024)",
            fontsize=13, fontweight="bold", y=1.01)
plt.tight_layout()
plt.savefig("grafico5_ratios_fundamentales.png", dpi=150,
bbox_inches="tight")
plt.show()
print(" ✓ Gráfico guardado")

```

A.5. Modelo ARIMA

```
import yfinance as yf
import pandas as pd
import numpy as np
from statsmodels.tsa.arima.model import ARIMA
from statsmodels.tsa.stattools import adfuller, acf
from sklearn.metrics import mean_absolute_error,
mean_squared_error
import matplotlib.pyplot as plt
import matplotlib.dates as mdates
import seaborn as sns
import warnings
warnings.filterwarnings('ignore')
from pmdarima import auto_arima

START = "2017-01-01"
END = "2025-01-31"

tickers = {
    "Welltower": "WELL", "Prologis": "PLD", "Equinix": "EQIX",
    "American Tower": "AMT", "Simon Property": "SPG",
    "Merlin Properties": "MRL.MC", "Colonial": "COL.MC",
}
grupo = {
    "WELL": "REIT", "PLD": "REIT", "EQIX": "REIT", "AMT": "REIT", "SPG": "REI
T",
    "MRL.MC": "SOCIMI", "COL.MC": "SOCIMI",
}
colores = {
    "WELL": "#1f77b4", "PLD": "#ff7f0e", "EQIX": "#2ca02c",
    "AMT": "#d62728", "SPG": "#9467bd",
    "MRL.MC": "#e377c2", "COL.MC": "#7f7f7f",
}

resultados = []

for nombre, ticker in tickers.items():
    print(f"Procesando {nombre}...")

    datos = yf.download(ticker, start=START, end=END,
                        auto_adjust=True, progress=False)
    if isinstance(datos.columns, pd.MultiIndex):
        datos.columns = datos.columns.get_level_values(0)
    precio = datos["Close"].dropna()
    ret = np.log(precio / precio.shift(1)).dropna()
```

```

n = len(ret)
corte = int(n * 0.8)
train_ret = ret.iloc[:corte]
test_ret = ret.iloc[corte:]
fecha_corte = ret.index[corte]
precio_test = precio.loc[fecha_corte:]

adf_p = adfuller(train_ret)[1]

modelo_auto = auto_arima(
    train_ret, start_p=0, start_q=0, max_p=3, max_q=3, d=0,
    seasonal=False, stepwise=True, suppress_warnings=True,
    error_action="ignore", information_criterion="aic"
)
p, d, q = modelo_auto.order
print(f" ARIMA({p},{d},{q})")

modelo = ARIMA(train_ret, order=(p, d, q)).fit()
residuos = modelo.resid

fc = modelo.get_forecast(steps=len(test_ret))
pred_ret = pd.Series(fc.predicted_mean.values,
index=test_ret.index)
conf_int = fc.conf_int(alpha=0.05)
ic_lower = pd.Series(conf_int.iloc[:, 0].values,
index=test_ret.index)
ic_upper = pd.Series(conf_int.iloc[:, 1].values,
index=test_ret.index)

precio_base =
float(precio.loc[precio.loc[:fecha_corte].index[-1]])

precio_pred = [precio_base]
for r in pred_ret:
    precio_pred.append(precio_pred[-1] * np.exp(float(r)))
precio_pred = pd.Series(precio_pred[1:],
index=test_ret.index)

precio_ic_low = [precio_base]
for r in ic_lower:
    precio_ic_low.append(precio_ic_low[-1] *
np.exp(float(r)))
precio_ic_low = pd.Series(precio_ic_low[1:],
index=test_ret.index)

precio_ic_up = [precio_base]
for r in ic_upper:

```

```

        precio_ic_up.append(precio_ic_up[-1] * np.exp(float(r)))
    precio_ic_up = pd.Series(precio_ic_up[1:],
index=test_ret.index)

    mae = mean_absolute_error(test_ret, pred_ret)
    rmse = np.sqrt(mean_squared_error(test_ret, pred_ret))

    resultados.append({
        "Vehículo": nombre, "Grupo": grupo[ticker],
        "ADF p-valor": round(adf_p, 4),
        "Orden (p,d,q)": f"({p},{d},{q})",
        "AIC": round(modelo.aic, 1),
        "MAE": round(mae, 5), "RMSE": round(rmse, 5),
    })

    color = colores[ticker]
    fig, axes = plt.subplots(2, 2, figsize=(14, 9))

    # Panel 1: Precio histórico completo
    ax1 = axes[0, 0]
    ax1.plot(precio.index, precio, color=color, linewidth=1.0)
    ax1.axvline(fecha_corte, color="black", linestyle="--",
                linewidth=1.2, label="Inicio test (80/20)")
    ax1.set_title("Precio histórico 2017-2025", fontsize=10,
fontweight="bold")
    ax1.set_ylabel("Precio (USD/EUR)")
    ax1.legend(fontsize=8)
    ax1.grid(axis="y", alpha=0.3)
    ax1.xaxis.set_major_formatter(mdates.DateFormatter("%Y"))
    sns.despine(ax=ax1)

    # Panel 2: Predicción vs Real en precios
    ax2 = axes[0, 1]
    ax2.plot(precio_test.index, precio_test,
            color=color, linewidth=1.2, label="Precio real")
    ax2.plot(precio_pred.index, precio_pred,
            color="black", linewidth=1.2, linestyle="--",
            label=f"ARIMA({p},{d},{q})")
    ax2.fill_between(precio_pred.index,
                    precio_ic_low, precio_ic_up,
                    alpha=0.15, color="gray", label="IC 95%")
    ax2.set_title(f"Predicción vs Real – período test
(20%) \nMAE={mae:.5f} RMSE={rmse:.5f}",
                fontsize=10, fontweight="bold")
    ax2.set_ylabel("Precio (USD/EUR)")
    ax2.legend(fontsize=8)
    ax2.grid(axis="y", alpha=0.3)

```

```

ax2.xaxis.set_major_formatter(mdates.DateFormatter("%Y"))
sns.despine(ax=ax2)

# Panel 3: ACF de residuos
ax3 = axes[1, 0]
nlags = 30
acf_vals = acf(residuos, nlags=nlags, fft=True)
lags_arr = np.arange(len(acf_vals))
conf_band = 1.96 / np.sqrt(len(residuos))
ax3.bar(lags_arr, acf_vals, color=color, alpha=0.7,
width=0.4)
ax3.axhline( conf_band, color="blue", linestyle="--",
            linewidth=0.8, alpha=0.7, label="IC 95%")
ax3.axhline(-conf_band, color="blue", linestyle="--",
            linewidth=0.8, alpha=0.7)
ax3.axhline(0, color="black", linewidth=0.5)
ax3.set_title("ACF de residuos (verificación ruido blanco)",
            fontsize=10, fontweight="bold")
ax3.set_xlabel("Retardo")
ax3.set_ylabel("ACF")
ax3.legend(fontsize=8)
sns.despine(ax=ax3)

# Panel 4: Distribución de residuos
ax4 = axes[1, 1]
ax4.hist(residuos * 100, bins=60, color=color,
            alpha=0.75, edgecolor="none")
ax4.axvline(0, color="black", linestyle="--",
            linewidth=1, label="Cero")
ax4.axvline(residuos.mean() * 100, color="red", linestyle="-",
            linewidth=1, label=f"Media:
{residuos.mean()*100:.4f}%")
ax4.set_title("Distribución de residuos del modelo",
            fontsize=10, fontweight="bold")
ax4.set_xlabel("Residuo (%)")
ax4.set_ylabel("Frecuencia")
ax4.legend(fontsize=8)
ax4.grid(axis="y", alpha=0.3)
sns.despine(ax=ax4)

plt.suptitle(
    f"{nombre} ({grupo[ticker]}) - ARIMA({p},{d},{q}) |
AIC={modelo.aic:.1f}",
    fontsize=12, fontweight="bold", y=1.01
)
plt.tight_layout()

```

```
fname = f"arima_{ticker.replace('.', '_')}.png"
plt.savefig(fname, dpi=150, bbox_inches="tight")
plt.show()
print(f" ✓ {nombre} completado")

df_arima = pd.DataFrame(resultados)
print("\n" + "="*80)
print(" RESULTADOS ARIMA – RETORNOS DIARIOS (2017-2025)")
print("="*80)
print(df_arima.to_string(index=False))
```

A.6 Modelo Prophet

```
pip install prophet
from prophet import Prophet
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.dates as mdates
import seaborn as sns
from sklearn.metrics import mean_absolute_error,
mean_squared_error
import warnings
warnings.filterwarnings('ignore')

START = "2017-01-01"
END   = "2025-01-31"

tickers = {
    "Welltower": "WELL", "Prologis": "PLD", "Equinix": "EQIX",
    "American Tower": "AMT", "Simon Property": "SPG",
    "Merlin Properties": "MRL.MC", "Colonial": "COL.MC",
}
grupo = {

"WELL": "REIT", "PLD": "REIT", "EQIX": "REIT", "AMT": "REIT", "SPG": "REI
T",
    "MRL.MC": "SOCIMI", "COL.MC": "SOCIMI",
}
colores = {
    "WELL": "#1f77b4", "PLD": "#ff7f0e", "EQIX": "#2ca02c",
    "AMT": "#d62728", "SPG": "#9467bd",
    "MRL.MC": "#e377c2", "COL.MC": "#7f7f7f",
}

resultados = []

for nombre, ticker in tickers.items():
    print(f"Procesando {nombre}...")

    datos = yf.download(ticker, start=START, end=END,
                        auto_adjust=True, progress=False)
    if isinstance(datos.columns, pd.MultiIndex):
        datos.columns = datos.columns.get_level_values(0)
    precio = datos["Close"].dropna().reset_index()
    precio.columns = ["ds", "y"]
    precio["ds"] =
pd.to_datetime(precio["ds"]).dt.tz_localize(None)
```

```

n = len(precio)
corte = int(n * 0.8)
train = precio.iloc[:corte]
test = precio.iloc[corte:]
fecha_corte = train["ds"].iloc[-1]
# — Descomposición Prophet (tendencia + estacionalidad)

fig_descomp = modelo.plot_components(forecast)
fig_descomp.suptitle(
    f"{nombre} ({grupo[ticker]}) – Descomposición Prophet",
    fontsize=12, fontweight="bold", y=1.01
)
fig_descomp.savefig(
    f"descomp_{ticker.replace('.', '_')}.png",
    dpi=150, bbox_inches="tight"
)
plt.show()
print(f" ✓ Descomposición guardada")

modelo = Prophet(
    yearly_seasonality=True,
    weekly_seasonality=True,
    daily_seasonality=False,
    changepoint_prior_scale=0.05, # flexibilidad de la
tendencia
    interval_width=0.95          # intervalo de confianza
95%
)

# Añadir eventos relevantes como holidays
eventos = pd.DataFrame({
    "holiday": ["COVID-19", "Subida tipos Fed"],
    "ds": pd.to_datetime(["2020-03-16", "2022-03-16"]),
    "lower_window": [-30, -15],
    "upper_window": [60, 30],
})
modelo = Prophet(
    yearly_seasonality=True,
    weekly_seasonality=True,
    daily_seasonality=False,
    changepoint_prior_scale=0.05,
    interval_width=0.95,
    holidays=eventos
)

modelo.fit(train)

```

```

futuro = modelo.make_future_dataframe(
    periods=len(test), freq="B" # B = días hábiles
)
forecast = modelo.predict(futuro)

# Filtrar solo el período test
forecast_test = forecast[forecast["ds"] >
fecha_corte].copy()
forecast_test = forecast_test.iloc[:len(test)]

y_real = test["y"].values[:len(forecast_test)]
y_pred = forecast_test["yhat"].values

mae = mean_absolute_error(y_real, y_pred)
rmse = np.sqrt(mean_squared_error(y_real, y_pred))
mape = np.mean(np.abs((y_real - y_pred) / y_real)) * 100

resultados.append({
    "Vehículo": nombre,
    "Grupo": grupo[ticker],
    "MAE": round(mae, 3),
    "RMSE": round(rmse, 3),
    "MAPE (%)": round(mape, 2),
})

print(f" √ MAE={mae:.3f} RMSE={rmse:.3f}
MAPE={mape:.2f}%")

color = colores[ticker]
fig, axes = plt.subplots(1, 2, figsize=(16, 6))

# Panel 1: Precio histórico + predicción completa
ax1 = axes[0]
ax1.plot(precio["ds"], precio["y"],
        color=color, linewidth=0.8, label="Precio real",
alpha=0.9)
ax1.plot(forecast["ds"], forecast["yhat"],
        color="black", linewidth=1.0, linestyle="--",
        label="Predicción Prophet")
ax1.fill_between(forecast["ds"],
                forecast["yhat_lower"],
                forecast["yhat_upper"],
                alpha=0.15, color="gray", label="IC 95%")
ax1.axvline(fecha_corte, color="red", linestyle=":",
            linewidth=1.5, label="Inicio test (80/20)")

```

```

ax1.set_title("Precio histórico y predicción Prophet (2017-
2025)",
              fontsize=10, fontweight="bold")
ax1.set_ylabel("Precio (USD/EUR)")
ax1.legend(fontsize=8)
ax1.grid(axis="y", alpha=0.3)
ax1.xaxis.set_major_formatter(mdates.DateFormatter("%Y"))
sns.despine(ax=ax1)

# Panel 2: Zoom en el período test (predicción vs real)
ax2 = axes[1]
ax2.plot(test["ds"], test["y"],
         color=color, linewidth=1.2, label="Precio real")
ax2.plot(forecast_test["ds"], forecast_test["yhat"],
         color="black", linewidth=1.2, linestyle="--",
         label="Prophet")
ax2.fill_between(forecast_test["ds"],
                forecast_test["yhat_lower"],
                forecast_test["yhat_upper"],
                alpha=0.20, color="gray", label="IC 95%")

ax2.set_title(
    f"Zoom período test (2023-2025)\nMAE={mae:.2f}
    RMSE={rmse:.2f} MAPE={mape:.2f}%",
    fontsize=10, fontweight="bold")
ax2.set_ylabel("Precio (USD/EUR)")
ax2.legend(fontsize=8)
ax2.grid(axis="y", alpha=0.3)
ax2.xaxis.set_major_formatter(mdates.DateFormatter("%m/%Y"))
sns.despine(ax=ax2)

plt.suptitle(
    f"{nombre} ({grupo[ticker]}) – Prophet | Entrenamiento
    2017-2023 | Test 2023-2025",
    fontsize=12, fontweight="bold", y=1.01
)
plt.tight_layout()
fname = f"prophet_{ticker.replace('.', '_')}.png"
plt.savefig(fname, dpi=150, bbox_inches="tight")
plt.show()
print(f" ✓ Guardado: {fname}")

df_prophet = pd.DataFrame(resultados)
print("\n" + "="*70)
print(" RESULTADOS PROPHET – PREDICCIÓN DE PRECIO (2017-2025)")
print("="*70)
print(df_prophet.to_string(index=False))

```

A.7 Modelo LSTM

```
!pip install tensorflow

import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.dates as mdates
import seaborn as sns
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_absolute_error,
mean_squared_error
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
from tensorflow.keras.callbacks import EarlyStopping
import warnings
warnings.filterwarnings('ignore')

START = "2017-01-01"
END   = "2025-01-31"
WINDOW = 60 # ventana de 60 días para aprender patrones

tickers = {
    "Welltower": "WELL", "Prologis": "PLD", "Equinix": "EQIX",
    "American Tower": "AMT", "Simon Property": "SPG",
    "Merlin Properties": "MRL.MC", "Colonial": "COL.MC",
}
grupo = {

"WELL": "REIT", "PLD": "REIT", "EQIX": "REIT", "AMT": "REIT", "SPG": "REI
T",
    "MRL.MC": "SOCIMI", "COL.MC": "SOCIMI",
}
colores = {
    "WELL": "#1f77b4", "PLD": "#ff7f0e", "EQIX": "#2ca02c",
    "AMT": "#d62728", "SPG": "#9467bd",
    "MRL.MC": "#e377c2", "COL.MC": "#7f7f7f",
}

resultados = []

for nombre, ticker in tickers.items():
    print(f"\nProcesando {nombre}...")

    # Datos
    datos = yf.download(ticker, start=START, end=END,
                        auto_adjust=True, progress=False)
```

```

if isinstance(datos.columns, pd.MultiIndex):
    datos.columns = datos.columns.get_level_values(0)
precio = datos["Close"].dropna()
fechas = precio.index

# Normalización (LSTM requiere datos entre 0 y 1)

scaler = MinMaxScaler(feature_range=(0, 1))
precio_scaled = scaler.fit_transform(precio.values.reshape(-
1, 1))

# División 80/20

n = len(precio_scaled)
corte = int(n * 0.8)

# Crear secuencias de 60 días

def crear_secuencias(data, window):
    X, y = [], []
    for i in range(window, len(data)):
        X.append(data[i-window:i, 0])
        y.append(data[i, 0])
    return np.array(X), np.array(y)

X_all, y_all = crear_secuencias(precio_scaled, WINDOW)

# Ajustar corte para las secuencias
corte_seq = corte - WINDOW
X_train = X_all[:corte_seq]
y_train = y_all[:corte_seq]
X_test = X_all[corte_seq:]
y_test = y_all[corte_seq:]
fechas_test = fechas[corte:]

# Reshape para LSTM: (muestras, pasos_tiempo, features)
X_train = X_train.reshape((X_train.shape[0],
X_train.shape[1], 1))
X_test = X_test.reshape((X_test.shape[0], X_test.shape[1],
1))

# Arquitectura LSTM

modelo = Sequential([
    LSTM(64, return_sequences=True,
        input_shape=(WINDOW, 1)),
    Dropout(0.2),

```

```

        LSTM(32, return_sequences=False),
        Dropout(0.2),
        Dense(16, activation="relu"),
        Dense(1)
    ])

modelo.compile(optimizer="adam", loss="mean_squared_error")

early_stop = EarlyStopping(
    monitor="val_loss", patience=10,
    restore_best_weights=True
)

print(" Entrenando LSTM...")
historia_entrenamiento = modelo.fit(
    X_train, y_train,
    epochs=50,
    batch_size=32,
    validation_split=0.1,
    callbacks=[early_stop],
    verbose=0
)
print(f" Épocas ejecutadas:
{len(historia_entrenamiento.history['loss'])}")

# Predicción

pred_scaled = modelo.predict(X_test, verbose=0)
pred_precio =
scaler.inverse_transform(pred_scaled).flatten()
real_precio = scaler.inverse_transform(
    y_test.reshape(-1, 1)).flatten()

# Alinear fechas
fechas_pred = fechas_test[:len(pred_precio)]

# Métricas

mae = mean_absolute_error(real_precio, pred_precio)
rmse = np.sqrt(mean_squared_error(real_precio, pred_precio))
mape = np.mean(np.abs(
    (real_precio - pred_precio) / real_precio)) * 100

resultados.append({
    "Vehículo": nombre,
    "Grupo": grupo[ticker],
    "MAE": round(mae, 3),

```

```

        "RMSE": round(rmse, 3),
        "MAPE (%)": round(mape, 2),
    })

    print(f" √ MAE={mae:.3f} RMSE={rmse:.3f}
    MAPE={mape:.2f}%")

    # GRÁFICO

    color = colores[ticker]
    fig, axes = plt.subplots(1, 2, figsize=(16, 6))

    # Panel 1: Serie completa con corte train/test
    ax1 = axes[0]
    ax1.plot(fechas, precio.values,
            color=color, linewidth=0.8,
            label="Precio real", alpha=0.9)
    ax1.axvline(fechas[corte], color="red", linestyle=":",
            linewidth=1.5, label="Inicio test (80/20)")
    ax1.set_title("Precio histórico 2017-2025",
            fontsize=10, fontweight="bold")
    ax1.set_ylabel("Precio (USD/EUR)")
    ax1.legend(fontsize=8)
    ax1.grid(axis="y", alpha=0.3)
    ax1.xaxis.set_major_formatter(mdates.DateFormatter("%Y"))
    sns.despine(ax=ax1)

    # Panel 2: Real vs LSTM en período test
    ax2 = axes[1]
    ax2.plot(fechas_pred, real_precio,
            color=color, linewidth=1.2,
            label="Precio real")
    ax2.plot(fechas_pred, pred_precio,
            color="black", linewidth=1.2,
            linestyle="--", label="LSTM")
    ax2.set_title(
        f"Real vs LSTM – período test (2023-2025)\n"
        f"MAE={mae:.2f} RMSE={rmse:.2f} MAPE={mape:.2f}%",
        fontsize=10, fontweight="bold")
    ax2.set_ylabel("Precio (USD/EUR)")
    ax2.legend(fontsize=8)
    ax2.grid(axis="y", alpha=0.3)
    ax2.xaxis.set_major_formatter(mdates.DateFormatter("%m/%Y"))
    sns.despine(ax=ax2)

    # Pérdida durante entrenamiento
    plt.tight_layout()

```

```

plt.suptitle(
    f"{nombre} ({grupo[ticker]}) - LSTM | "
    f"Ventana={WINDOW} días | Train 2017-2023 | Test 2023-
2025",
    fontsize=12, fontweight="bold", y=1.01
)
fname = f"lstm_{ticker.replace('.', '_')}.png"
plt.savefig(fname, dpi=150, bbox_inches="tight")
plt.show()
print(f" ✓ Guardado: {fname}")

# Tabla resumen

df_lstm = pd.DataFrame(resultados)
print("\n" + "="*70)
print(" RESULTADOS LSTM - PREDICCIÓN DE PRECIO (2017-2025)")
print("="*70)
print(df_lstm.to_string(index=False))

```

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

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

Por la presente, yo, Ada Victoria Montesino Quesada, estudiante de E6 Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " Análisis comparativo de rentabilidad y riesgo de las SOCIMIs españolas frente a los REITs estadounidenses: Un enfoque de Business Analytics aplicado al mercado global de la inversión inmobiliaria", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
2. **Interpretador de código:** Para realizar análisis de datos preliminares.
3. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
4. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
5. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
6. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
7. **Traductor:** Para traducir textos de un lenguaje a otro.

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

Fecha: 17/06/2026

Firma: