

**MODELO MULTIFACTORIAL DE NUEVE FACTORES PARA LA EXPLICACIÓN
DEL RENDIMIENTO ACCIONARIO: EXTENSIÓN EMPÍRICA ESCALONADA DEL
MODELO DE CINCO FACTORES DE FAMA-FRENCH EN EL MERCADO
ACCIONARIO ESTADOUNIDENSE (201407-202512)**

AUTOR

PABLO FELIPE LÓPEZ VELÁSQUEZ



**PONTIFICIA UNIVERSIDAD JAVERIANA
FACULTAD DE CIENCIAS ECONÓMICAS Y ADMINISTRATIVAS
MAESTRÍA EN FINANZAS
SANTIAGO DE CALI**

2026

**MODELO MULTIFACTORIAL DE NUEVE FACTORES PARA LA EXPLICACIÓN
DEL RENDIMIENTO ACCIONARIO: EXTENSIÓN EMPÍRICA ESCALONADA DEL
MODELO DE CINCO FACTORES DE FAMA-FRENCH EN EL MERCADO
ACCIONARIO ESTADOUNIDENSE (201407-202512)**

AUTOR

PABLO FELIPE LÓPEZ VELÁSQUEZ

**Trabajo de grado presentado como requisito parcial para optar por el título
de Magíster en Finanzas**

Director del trabajo de grado: Víctor Alberto Peña Vargas

Profesión: Docente

**PONTIFICIA UNIVERSIDAD JAVERIANA
FACULTAD DE CIENCIAS ECONÓMICAS Y ADMINISTRATIVAS
MAESTRÍA EN FINANZAS
SANTIAGO DE CALI**

2026


Santiago de Cali, 8 de Mayo de 2026

Doctor
Fabián Fernando Osorio Tinoco
Decano
Facultad de Ciencias Económicas y Administrativas
Pontificia Universidad Javeriana
Cali

Por medio de la presente se entrega a usted el Trabajo de Grado cuyo título es "Modelo multifactorial de nueve factores para la explicación del rendimiento accionario: extensión empírica escalonada del modelo de cinco factores de Fama-French en el mercado accionario estadounidense (201407-202512)"

Se espera que este Trabajo cumpla con los requisitos académicos exigidos y que alcance el propósito para el cual fue elaborado.

Atentamente,



PABLO FELIPE LÓPEZ VELÁSQUEZ
1143840549

Santiago de Cali, 21 de Mayo de 2026

Doctor
Fabian Fernando Osorio Tinoco
Decano
Facultad de Ciencias Económicas y Administrativas
Pontificia Universidad Javeriana

La Ciudad

Por medio de la presente me permito comunicarle, que en mi calidad de director de trabajo de grado he leído detenidamente el informe final del estudio titulado “**MODELO MULTIFACTORIAL DE NUEVE FACTORES PARA LA EXPLICACIÓN DEL RENDIMIENTO ACCIONARIO: EXTENSIÓN EMPÍRICA ESCALONADA DEL MODELO DE CINCO FACTORES DE FAMA-FRENCH EN EL MERCADO ACCIONARIO ESTADOUNIDENSE (201407-202512)**”. Realizado por el estudiante de Maestría en Finanzas de la Facultad de Ciencias Económicas y Administrativas de la Universidad Javeriana nombres: **PABLO FELIPE LÓPEZ VELÁSQUEZ C.C 1143840549**, y considero que cumple con todos los requisitos requeridos para ser presentada a evaluación.

Atentamente

Victor Alberto Peña Vargas
Firmado digitalmente por
Victor Alberto Peña Vargas
Fecha: 2026.05.21 15:36:00
-05'00'

Víctor Alberto Peña Vargas PhD.
Director del Trabajo de Grado

ARTÍCULO 23 DE LA RESOLUCIÓN N.º 13 DE JULIO 6 DE 1946**ARTÍCULO 23 de la Resolución N.º 13 de julio 6 de 1946**

“La Universidad no se hace responsable por los conceptos emitidos por sus alumnos en sus trabajos de Tesis. Sólo velará porque no se publique nada contrario al dogma y a la moral católica y porque la Tesis no contenga ataques o polémicas puramente personales; antes bien, se vea en ellas el anhelo de buscar la Verdad y la Justicia”.


PÁGINA DE ACEPTACIÓN

“MODELO MULTIFACTORIAL DE NUEVE FACTORES PARA LA EXPLICACIÓN DEL RENDIMIENTO ACCIONARIO: EXTENSIÓN EMPÍRICA ESCALONADA DEL MODELO DE CINCO FACTORES DE FAMA-FRENCH EN EL MERCADO ACCIONARIO ESTADOUNIDENSE (201407-202512)”. Aprobado por el Comité de Trabajos de Grado en cumplimiento de los requisitos exigidos por la Pontificia Universidad Javeriana para optar por el título de Magíster en Finanzas.



Fabian Fernando Osorio Tinoco
Decano


Facultad de Ciencias Económicas y Administrativas



Juan Fernando Garrido Navia
Director de Maestría en Finanzas



Jesús Ancizar Gómez Daza
Jurado



Víctor Alberto Peña Vargas
Director del Trabajo de Grado

Santiago de Cali, 24 de julio del 2026.

Contenido

Título	Pág.
Introducción	14
Capítulo 1. Planteamiento de la investigación.....	17
1.1 Contexto y antecedentes del problema	17
1.2 Planteamiento del problema	18
1.3 Justificación y motivaciones de la investigación.....	19
1.4 Pregunta central de investigación.....	20
1.5 Alcance y delimitaciones.....	20
1.6 Objetivos del proyecto	21
Capítulo 2. Marco teórico y revisión de literatura.....	23
2.1 Fundamentos de valoración de activos.....	23
2.2 CAPM y teoría moderna de portafolio	24
2.3 Modelo de tres factores de Fama–French.....	25
2.4 Modelo de cinco factores de Fama–French.....	27
2.5 Momentum y anomalías persistentes	29
2.6 Factor Zoo y proliferación de factores	30
2.7 Intangibles, innovación y limitaciones contables	31
2.8 Free Cash Flow Yield y valoración fundamental	33
2.9 Low Volatility anomaly	35
2.10 Síntesis del marco teórico e hipótesis de investigación.....	37
Capítulo 3. Metodología.....	38
3.1 Diseño empírico de la investigación	38
3.2 Ventana temporal, frecuencia y muestra de estimación.....	39
3.3 Fuentes de datos financieros y de mercado	40
3.3.1 Kenneth R. French Data Library	41
3.3.2 Refinitiv Workspace.....	45
3.4 Universo muestral y criterios de depuración	46
3.5 Construcción de señales factoriales.....	48
3.5.1 Señal Low Volatility.....	48
3.5.2 Señal FCF/EV	50
3.5.3 Señal de Intangible Intensity	53
3.6 Control de sesgo de anticipación y consistencia temporal	55
3.7 Formación de portafolios y construcción de factores propios	56
3.7.1 Formación de grupos por tamaño y por señal	57
3.7.2 Cálculo de los retornos ponderados por valor	58
3.7.3 Construcción del factor LVOL	59
3.7.4 Construcción del factor FCFEV	60
3.7.5 Construcción del factor INT.....	61
3.7.6 Temporalidad de los factores y frecuencia final de las series.....	63
3.7.7 Consideraciones sobre datos faltantes y cobertura	63
3.7.8 Síntesis metodológica.....	64
3.8 Factor Zoo Screening y prueba de redundancia factorial	65
3.9 Especificación econométrica de los modelos FF3–FF9	67
3.9.1 Modelo FF3.....	68
3.9.2 Modelo FF5.....	68
3.9.3 Modelo FF6.....	68
3.9.4 Modelo FF7.....	69
3.9.5 Modelo FF8.....	69
3.9.6 Modelo FF9 completo.....	69
3.10 Evaluación del desempeño del modelo	69
3.10.1 Análisis de alfas	69
3.10.2 R^2 y R^2 ajustado.....	71

3.10.3 Prueba GRS	71
3.10.4 Análisis complementario de exposiciones factoriales del modelo FF9	72
3.11 Estimación de precios de riesgo mediante Fama–MacBeth	73
3.12 Corrección de Shanken.....	74
3.13 Diagnósticos de robustez y validación empírica	75
3.13.1 Multicolinealidad y VIF	75
3.13.2 Tratamiento de valores extremos y decisión de no winsorización	75
3.13.3 Potencia estadística y MDE.....	76
3.13.4 Criterio de significancia reforzada bajo el umbral de Harvey	77
3.13.5 Validación out-of-sample	79
3.14 Implementación tecnológica.....	80
3.15 Alcance metodológico de los resultados.....	82
Capítulo 4. Resultados empíricos	83
4.1 Estadística descriptiva de los factores	83
4.2 Diagnóstico de correlación factorial y multicolinealidad	86
4.2.1 Matriz de correlación entre factores.....	86
4.2.2 Diagnóstico de multicolinealidad mediante Variance Inflation Factor — VIF	88
4.2.3 Implicaciones para la especificación de un modelo con 9 factores	89
4.3 Resultados de regresiones time-series FF3–FF9	90
4.3.1 Propósito del análisis time-series	90
4.3.2 Alfas, errores de pricing, prueba GRS y cambios incrementales frente al modelo anterior y al benchmark FF5.....	91
4.3.3 Betas promedio y sensibilidad factorial de los portafolios bajo FF9	94
4.4. Prueba de redundancia factorial	97
4.5. MDE y potencia estadística en la detección de alfas	99
4.6 Resultados Fama-MacBeth y precios de riesgo.....	100
4.6.1 Corrección de Shanken	101
4.6.2 Umbral de Harvey $ t > 3$	103
4.6.3 MDE y potencia estadística en la detección de lambdas	104
4.7 Validación out-of-sample	105
4.8 Evaluación incremental y comparación escalonada de modelos FF3–FF9	107
4.8.1 Síntesis de selección del modelo	110
Capítulo 5. Discusión, conclusiones y recomendaciones	111
5.1 Discusión de resultados	111
5.1.1 Lectura económica de la reducción de errores de pricing	114
5.1.2 Lectura económica de las lambdas	116
5.2 Contribución teórica y empírica	120
5.3 Implicaciones para asset pricing y gestión de portafolios	123
5.4 Limitaciones de la investigación	127
5.5 Recomendaciones para futuras investigaciones	130
5.6 Conclusiones	132
Referencias	136
Anexos.....	141

Lista de tablas

Tabla	Pág.
Tabla 3.1. Especificaciones evaluadas en la estrategia empírica	38
Tabla 3.2. Componentes de datos provenientes de Kenneth R. French Data Library.....	41
Tabla 3.3. Factores Fama-French utilizados como benchmark.....	42
Tabla 3.4. Incorporación de Momentum en las especificaciones FF5 y FF6.....	43
Tabla 3.5. Estructura de los 25 portafolios Size x Book-to-Market.....	44
Tabla 3.6. Rezago contable aplicado al Free Cash Flow	52
Tabla 3.7. Reglas de información utilizadas para evitar sesgo de anticipación	55
Tabla 3.8. Señales utilizadas para la construcción de factores propios.....	56
Tabla 3.9. Estructura general de formación de portafolios por tamaño y señal	58
Tabla 3.10. Factores de control en las pruebas de redundancia factorial	67
Tabla 4.1. Cobertura temporal de factores y definición de muestra común.....	84
Tabla 4.2. Estadísticas descriptivas de los factores	84
Tabla 4.3. Portafolios 5x5: media y volatilidad mensual.....	85
Tabla 4.4. Correlaciones factoriales más relevantes.....	87
Tabla 4.5. Diagnóstico VIF de los factores FF9	88
Tabla 4.6. Resultados agregados de regresiones time-series	91
Tabla 4.7. Cambios incrementales frente al modelo anterior y frente al benchmark FF5.....	92
Tabla 4.8. Exposiciones promedio estimadas en FF9.....	94
Tabla 4.9. Pruebas de spanning para factores adicionales	98
Tabla 4.10. MDE para alfas time-series por modelo	99
Tabla 4.11. Primas de riesgo Fama-MacBeth del modelo FF9 con corrección de Shanken	101
Tabla 4.12. Evaluación del umbral Harvey $ t > 3$	103
Tabla 4.13. MDE de lambdas para factores candidatos.....	104
Tabla 4.14. Validación out-of-sample de los modelos FF3-FF9	105
Tabla 4.15. Comparación escalonada de modelos FF3-FF9 frente al benchmark FF5	107
Tabla 4.16. Evidencia del segundo piso y factores añadidos.....	108
Tabla 5.1. Síntesis interpretativa de los resultados principales.....	114
Tabla 5.2. Potencia observada aproximada en la detección de primas de riesgo	119
Tabla 5.3. Implicaciones prácticas por tipo de usuario del modelo	127
Tabla A.1. RMSE/MAE promedio por modelo - muestra común 201407-202512.....	141

Lista de figuras

Figura	Pág.
Figura 4.1. Distribución y datos atípicos de los factores	86
Figura 4.2. Mapa de calor de correlaciones entre factores	87

Lista de anexos

Anexo	Pág.
Anexo A. RMSE/MAE promedio por modelo - muestra común 201407-202512.....	141

Resumen

La investigación evalúa empíricamente una extensión escalonada del modelo de cinco factores de Fama-French hacia una especificación de nueve factores para explicar los retornos accionarios en el mercado estadounidense durante el periodo 201407-202512. El estudio incorpora progresivamente Momentum, Low Volatility, FCF/EV e Intangible Intensity al modelo FF5, con el propósito de determinar si una arquitectura multifactorial ampliada reduce errores de *pricing* y aporta capacidad explicativa incremental. La metodología combina regresiones time-series, prueba GRS, Fama-MacBeth con corrección de Shanken, pruebas de redundancia factorial, diagnóstico VIF, análisis MDE, criterio conservador de Harvey $|t| > 3$ y validación out-of-sample. Los resultados muestran que FF9 reduce el alfa absoluto promedio frente a FF5, mejora el R^2 ajustado y obtiene el p-valor GRS más favorable entre las especificaciones evaluadas. Dentro de esta arquitectura, Intangible Intensity presenta la evidencia empírica más consistente entre los factores adicionales, aunque su magnitud estimada y el hecho de que no supere el umbral conservador de Harvey sugieren una interpretación prudente. Se concluye que FF9 mejora la especificación del modelo frente a FF5 en la muestra analizada; sin embargo, la validación de nuevas primas de riesgo requiere futuras pruebas de robustez, ventanas más amplias, test assets alternativos y proxies complementarios de intangibles.

Palabras clave: Valoración de activos financieros; Modelos Fama-French; Modelos multifactoriales; Anomalías financieras; Factor Zoo.

Abstract

This research empirically evaluates a stepwise extension of the Fama-French five-factor model into a nine-factor specification to explain stock returns in the U.S. equity market over 201407-202512. The study progressively adds Momentum, Low Volatility, FCF/EV, and Intangible Intensity to FF5 to assess whether an expanded multifactor architecture reduces pricing errors and provides incremental explanatory power. The methodology combines time-series regressions, the GRS test, Fama-MacBeth regressions with Shanken correction, factor redundancy tests, VIF diagnostics, MDE analysis, Harvey's conservative $|t| > 3$ threshold, and out-of-sample validation. The results show that FF9 reduces the average absolute alpha relative to FF5, improves adjusted R^2 , and obtains the most favorable GRS p-value among the specifications evaluated. Within this architecture, Intangible Intensity provides the most consistent empirical evidence among the additional factors; however, its estimated magnitude and failure to pass Harvey's conservative threshold call for a cautious interpretation. The thesis concludes that FF9 improves model specification relative to FF5 in the sample analyzed; nevertheless, the validation of newly introduced risk premia requires further robustness analysis, longer estimation windows, alternative test assets, and complementary proxies for intangibles.

Keywords: Asset pricing; Fama–French models; Multifactor models; Financial anomalies; Factor Zoo.

Introducción

La explicación de los retornos accionarios constituye uno de los problemas centrales de la teoría financiera moderna. Desde la formulación de la teoría moderna de portafolio y del Capital Asset Pricing Model, la literatura ha buscado identificar qué riesgos sistemáticos o características empresariales son compensados por el mercado. Sin embargo, la evidencia empírica ha mostrado que el factor de mercado por sí solo no explica completamente la sección transversal de retornos, lo que impulsó el desarrollo de modelos multifactoriales como el modelo de tres factores y el modelo de cinco factores de Fama-French.

Esta tesis se ubica en esa tradición empírica de asset pricing. Su propósito es evaluar si una extensión escalonada del modelo de cinco factores de Fama-French hacia una especificación de nueve factores mejora la explicación de los retornos accionarios en el mercado estadounidense durante el periodo 201407-202512. La propuesta incorpora cuatro dimensiones adicionales: Momentum, Low Volatility, FCF/EV e Intangible Intensity. La pregunta central no es solo si un modelo con más factores ajusta mejor, sino si dichos factores reducen errores de pricing, aportan información incremental y mantienen coherencia económica bajo pruebas de robustez.

El punto de partida es el modelo FF5, integrado por mercado, tamaño, value, rentabilidad operativa e inversión. A partir de este benchmark se construye una secuencia de modelos anidados: FF6 incorpora Momentum; FF7 añade Low Volatility; FF8 incorpora FCF/EV; y FF9 agrega Intangible Intensity. Esta estructura escalonada permite analizar el aporte marginal de cada factor y evita presentar la ampliación factorial como una acumulación mecánica de variables.

La investigación combina factores benchmark de la Kenneth R. French Data Library con factores propios contruidos a partir de información de Refinitiv Workspace. Los factores propios se forman mediante señales firm-level, ordenamientos transversales, portafolios ponderados por capitalización bursátil y diferenciales long-short consistentes con la tradición metodológica de Fama y French. El análisis utiliza como activos de prueba los 25 portafolios Size x Book-to-Market, con frecuencia mensual y una ventana común de 138 observaciones.

Metodológicamente, el estudio se estructura en dos pisos. El primer piso corresponde a regresiones time-series, análisis de alfas, R^2 ajustado y prueba GRS. El segundo piso estima precios de riesgo mediante regresiones Fama-MacBeth con corrección de Shanken. De forma complementaria, se incorporan diagnósticos de correlación, VIF, pruebas de redundancia factorial, criterio reforzado de Harvey $|t| > 3$, análisis de potencia estadística mediante MDE y validación out-of-sample.

Los resultados muestran que FF9 es la especificación con mejor desempeño agregado en el bloque time-series: reduce el alfa absoluto promedio frente a FF5, mejora el R^2 ajustado y obtiene el p-valor GRS más alto entre las especificaciones evaluadas. No obstante, la evidencia también revela que no todos los factores adicionales aportan de la misma forma. INT emerge como el factor con mayor respaldo empírico dentro del diseño aplicado, al mostrar evidencia de prima positiva y significativa bajo inferencia convencional con corrección de Shanken. Sin embargo, ningún factor supera el estándar conservador de Harvey $|t| > 3$, por lo que la interpretación debe mantenerse prudente.

El documento se organiza en cinco capítulos. El primer capítulo presenta el planteamiento de la investigación, el problema, la justificación, la pregunta central, el alcance y los objetivos. El segundo capítulo desarrolla el marco teórico y la revisión de literatura sobre

valoración de activos, modelos Fama-French, Momentum, Factor Zoo, intangibles, FCF/EV y Low Volatility. El tercer capítulo expone la metodología empírica, la construcción de señales y factores, las especificaciones econométricas y los diagnósticos de robustez. El cuarto capítulo presenta los resultados empíricos. Finalmente, el quinto capítulo desarrolla la discusión, conclusiones, limitaciones y recomendaciones de investigación futura.

Capítulo 1. Planteamiento de la investigación

1.1 Contexto y antecedentes del problema

La explicación de los retornos accionarios ha sido una preocupación central de la teoría financiera moderna, porque permite comprender cómo los mercados valoran el riesgo, la información y las características económicas de las empresas. La teoría moderna de portafolio formalizó la relación entre retorno esperado, riesgo y diversificación, mostrando que el riesgo de un portafolio depende no solo de la volatilidad individual de sus activos, sino también de las covarianzas entre ellos (Markowitz, 1952). Sobre esta base, el CAPM propuso que el retorno esperado de un activo debía estar asociado a su sensibilidad frente al portafolio de mercado (Sharpe, 1964; Lintner, 1965; Mossin, 1966).

No obstante, la evidencia empírica posterior mostró que la beta de mercado no era suficiente para explicar la sección transversal de retornos accionarios. Fama y French (1992, 1993) documentaron que variables como tamaño y book-to-market capturaban patrones sistemáticos de retorno no explicados por el CAPM, dando lugar al modelo de tres factores. Posteriormente, Fama y French (2015) incorporaron rentabilidad operativa e inversión, proponiendo el modelo de cinco factores. Este último mejora el desempeño del FF3, pero no elimina completamente los errores de pricing, especialmente en ciertos portafolios de empresas pequeñas con baja rentabilidad y alta inversión.

La literatura contemporánea ha ampliado el campo de análisis mediante factores asociados a Momentum, baja volatilidad, flujos de caja, calidad, liquidez e intangibles. Sin embargo, esta expansión produjo un problema adicional: la proliferación de factores o Factor Zoo. Harvey et al. (2016) advierten que, en un entorno donde se prueban muchas hipótesis, los umbrales tradicionales de significancia pueden generar falsos descubrimientos. Por tanto, una

extensión factorial no debe evaluarse únicamente por su ajuste dentro de muestra, sino por su aporte incremental, coherencia económica, robustez estadística y capacidad de reducir errores de valoración.

En este contexto, la presente investigación propone una extensión empírica escalonada del modelo FF5 hacia una especificación FF9. La ampliación incorpora Momentum, Low Volatility, FCF/EV e Intangible Intensity, factores que representan dimensiones relevantes de la literatura financiera contemporánea. La estructura escalonada permite evaluar de manera ordenada si cada incorporación contribuye a explicar los retornos accionarios, sin confundir mejora de ajuste con validación definitiva de nuevas primas de riesgo.

1.2 Planteamiento del problema

El problema de investigación se ubica en la tensión entre dos hechos documentados en la literatura de asset pricing. Por un lado, el modelo FF5 constituye una especificación ampliamente aceptada y empíricamente superior al FF3 en varios contextos. Por otro lado, persisten errores de pricing y anomalías que sugieren que algunas dimensiones de los retornos esperados podrían no estar plenamente capturadas por mercado, tamaño, value, rentabilidad e inversión.

Agregar factores adicionales parece una respuesta natural a este problema, pero también introduce riesgos metodológicos. Un modelo con más factores puede mejorar el ajuste dentro de muestra de forma mecánica, capturar ruido estadístico o incorporar variables redundantes. Además, la literatura del Factor Zoo muestra que muchas anomalías pierden robustez cuando se evalúan con criterios más estrictos de replicabilidad, significancia y validación fuera de muestra (Cochrane, 2011; Harvey et al., 2016; Hou et al., 2020).

Por tanto, el problema no consiste únicamente en construir un modelo con nueve factores, sino en determinar si una extensión escalonada del FF5 mejora efectivamente la explicación de

retornos accionarios. Esta evaluación exige contrastar varias dimensiones: reducción de alfas, mejora del R^2 ajustado, desempeño de la prueba GRS, evidencia de precios de riesgo en Fama-MacBeth, ausencia de redundancia factorial severa, potencia estadística suficiente y estabilidad fuera de muestra.

1.3 Justificación y motivaciones de la investigación

La investigación se justifica por razones teóricas, empíricas y metodológicas. En el plano teórico, permite conectar la tradición Fama-French con dimensiones contemporáneas de valoración asociadas a Momentum, defensividad, generación de caja e intangibles. En particular, la creciente relevancia de activos intangibles, software, datos, conocimiento organizacional e innovación plantea desafíos para modelos basados exclusivamente en variables contables tradicionales (Lev, 2001; Lev y Gu, 2016; Peters y Taylor, 2017).

En el plano empírico, la tesis evalúa si factores contruidos sobre Low Volatility, FCF/EV e Intangible Intensity aportan información adicional frente a los factores benchmark de Kenneth R. French Data Library. Este punto es relevante porque las estrategias multifactoriales son usadas en gestión de portafolios, atribución de desempeño y análisis sistemático de exposiciones; sin embargo, su utilidad depende de que los factores tengan significado económico y no sean simples duplicaciones de factores existentes (Ang, 2014; Ilmanen, 2011).

En el plano metodológico, el trabajo evita una lectura ingenua de “más factores es mejor”. Para ello combina regresiones time-series, prueba GRS, Fama-MacBeth, corrección de Shanken, análisis de multicolinealidad, pruebas de redundancia, criterio de Harvey, MDE y validación out-of-sample. Esta arquitectura permite separar tres niveles de evidencia: mejora de especificación, existencia de precios de riesgo y robustez inferencial.

En este sentido, la contribución central de la investigación se entiende como la evaluación empírica, escalonada y robusta de una arquitectura FF9 frente al benchmark FF5, más que como la validación aislada de un único factor. Esta aproximación permite analizar si la combinación progresiva de factores adicionales mejora la especificación del modelo, reduce errores de pricing y mantiene una interpretación prudente frente al debate del Factor Zoo.

1.4 Pregunta central de investigación

¿En qué medida una extensión empírica escalonada del modelo de cinco factores de Fama-French hacia una especificación multifactorial de nueve factores mejora la capacidad explicativa de los retornos accionarios en el mercado accionario estadounidense durante 201407-202512?

1.5 Alcance y delimitaciones

El alcance de la investigación se limita a la evaluación empírica de especificaciones multifactoriales en el mercado accionario estadounidense, utilizando frecuencia mensual y una ventana común principal comprendida entre julio de 2014 y diciembre de 2025. El análisis toma como activos de prueba los 25 portafolios Size x Book-to-Market de Kenneth R. French Data Library, lo cual permite evaluar errores de pricing sobre un conjunto estandarizado y ampliamente utilizado en la literatura.

Los factores benchmark se toman de la Kenneth R. French Data Library. Los factores propios se construyen a partir de una muestra depurada de 400 acciones estadounidenses extraídas de Refinitiv Workspace, bajo criterios de disponibilidad de información, continuidad de precios, liquidez mínima y comparabilidad financiera. En consecuencia, los resultados deben

interpretarse dentro del universo muestral, periodo, frecuencia, test assets y metodología definidos.

La investigación no busca validar de manera universal todos los factores propuestos como primas de riesgo independientes. Su objetivo es evaluar si la incorporación escalonada de Momentum, Low Volatility, FCF/EV e Intangible Intensity mejora la capacidad explicativa del FF5 bajo una batería de pruebas econométricas. Por tanto, las conclusiones no deben extrapolarse sin validación adicional a otros mercados, frecuencias, universos de acciones o periodos muestrales.

1.6 Objetivos del proyecto

Objetivo general

Evaluar empíricamente una extensión escalonada del modelo de cinco factores de Fama-French hacia una especificación multifactorial de nueve factores, con el fin de determinar si la incorporación de Momentum, Intangible Intensity, FCF/EV y Low Volatility mejora la explicación de los retornos accionarios en el mercado accionario estadounidense durante el período 201407-202512.

Objetivos específicos

Analizar los fundamentos teóricos y empíricos del modelo de cinco factores de Fama-French y de la literatura multifactorial contemporánea, con el propósito de justificar la incorporación escalonada de Momentum, Intangible Intensity, FCF/EV y Low Volatility como factores adicionales de explicación del rendimiento accionario.

Definir, formalizar y operacionalizar la especificación multifactorial de nueve factores, precisando la fuente, medición y construcción de cada factor, en particular de los factores propios

Intangible Intensity, FCF/EV y Low Volatility, bajo criterios consistentes con la literatura y con la disponibilidad de información en Refinitiv Workspace y Kenneth R. French Data Library.

Construir los factores Intangible Intensity, FCF/EV y Low Volatility a partir de una muestra de 400 acciones del mercado estadounidense, articulándolos con los factores benchmark y los test assets estandarizados de Kenneth R. French Data Library, asegurando coherencia temporal, trazabilidad metodológica y compatibilidad con un diseño empírico mensual para el período 201407-202512.

Estimar de manera escalonada las especificaciones FF5, FF6, FF7, FF8 y FF9 mediante un enfoque econométrico de dos pisos, que combine regresiones de series de tiempo y regresiones cross-section tipo Fama-MacBeth sobre portafolios de prueba estandarizados, con el fin de evaluar la significancia económica y estadística de los factores incorporados.

Comparar de manera escalonada el desempeño empírico de las especificaciones FF5, FF6, FF7, FF8 y FF9, con el fin de determinar si la incorporación secuencial de Momentum, Intangible Intensity, FCF/EV y Low Volatility mejora la capacidad explicativa del modelo en términos de reducción de alfas residuales, mejora del ajuste, estimación de precios de riesgo y aporte incremental sin redundancia factorial excesiva ni fragilidad econométrica.

Capítulo 2. Marco teórico y revisión de literatura

2.1 Fundamentos de valoración de activos

La valoración de activos financieros busca explicar por qué ciertos activos ofrecen mayores retornos esperados que otros y qué fuentes de riesgo o características económicas justifican dichas diferencias. En términos generales, la teoría de *asset pricing* parte de la premisa de que los inversionistas exigen compensación por asumir riesgos que no pueden ser eliminados mediante diversificación. Bajo esta lógica, los retornos esperados no dependen únicamente del comportamiento individual de una acción, sino de su exposición a fuentes sistemáticas de riesgo o a características persistentes asociadas con primas de retorno.

La literatura moderna de valoración de activos ha evolucionado desde modelos de un solo factor, como el CAPM, hacia modelos multifactoriales que incorporan dimensiones adicionales relacionadas con tamaño, valor, rentabilidad, inversión, momentum, baja volatilidad, liquidez, calidad, intangibles y otras características firm-level. Esta evolución responde a la evidencia empírica de que el factor de mercado, aunque central, no logra explicar completamente la sección transversal de los retornos accionarios.

En este contexto, los modelos multifactoriales cumplen una doble función. Primero, permiten evaluar si los retornos promedio de los activos pueden explicarse mediante exposiciones a factores sistemáticos. Segundo, ofrecen una herramienta práctica para descomponer el riesgo y retorno de portafolios, distinguiendo entre retorno atribuible a exposición factorial y retorno anormal o alfa. Esta distinción resulta fundamental para la presente investigación, dado que el objetivo no es únicamente estimar un modelo con mayor número de factores, sino evaluar si la incorporación escalonada de factores adicionales reduce errores

de *pricing* y aporta capacidad explicativa incremental frente al modelo de cinco factores de Fama-French.

Bajo la lógica empírica de *asset pricing*, una especificación factorial adecuada debería producir alfas cercanos a cero y estadísticamente no significativos en los activos de prueba. Esto significa que, una vez controladas las exposiciones a los factores del modelo, no deberían quedar retornos anormales sistemáticos no explicados. Por ello, el análisis de alfas, la prueba GRS, las regresiones Fama–MacBeth, la corrección de Shanken y las pruebas de robustez constituyen herramientas fundamentales para evaluar la validez empírica de un modelo multifactorial.

2.2 CAPM y teoría moderna de portafolio

La teoría moderna de portafolio tiene su punto de partida en el trabajo de Markowitz (1952), quien formalizó el problema de selección de portafolios bajo un enfoque media-varianza. Su contribución central fue demostrar que el riesgo de un portafolio no depende únicamente del riesgo individual de los activos que lo componen, sino también de la covarianza entre ellos. En consecuencia, la diversificación permite reducir el riesgo específico o idiosincrático, pero no elimina necesariamente el riesgo sistemático asociado al comportamiento conjunto del mercado.

Este marco conceptual sentó las bases para el desarrollo del Capital Asset Pricing Model —CAPM— propuesto por Sharpe (1964), Lintner (1965) y Mossin (1966). El CAPM establece que el retorno esperado de un activo depende linealmente de su sensibilidad al portafolio de mercado, medida por la beta. En su forma más conocida, el modelo puede expresarse como:

$$E(R_i) = R_f + \beta_i [E(R_m) - R_f]$$

donde $E(R_i)$ representa el retorno esperado del activo i , R_f la tasa libre de riesgo, $E(R_m)$ el retorno esperado del mercado y β_i la sensibilidad del activo frente al mercado. La interpretación económica es directa: los inversionistas solo deberían ser compensados por asumir riesgo sistemático, dado que el riesgo idiosincrático puede ser diversificado. Sharpe (1964) desarrolla este marco como una teoría de equilibrio bajo condiciones de riesgo, en la cual los precios se ajustan de forma que los retornos esperados sean consistentes con la exposición al riesgo de mercado.

A pesar de su importancia teórica, la evidencia empírica mostró que el CAPM no lograba explicar completamente la sección transversal de retornos accionarios. Diversos estudios documentaron anomalías asociadas a tamaño, value, momentum, rentabilidad, inversión y otras características empresariales. Estas anomalías sugirieron que el mercado no remuneraba únicamente la beta de mercado o que esta no capturaba todas las dimensiones relevantes de riesgo y retorno. Esta limitación abrió el camino hacia modelos multifactoriales, en los cuales los retornos esperados se explican a partir de múltiples fuentes sistemáticas de variación.

Para la presente tesis, el CAPM cumple una función fundacional. No se utiliza como especificación principal, pero provee la lógica central de la exposición factorial: un activo o portafolio obtiene retorno esperado en función de su sensibilidad a factores sistemáticos. La investigación extiende esta lógica hacia un marco multifactorial escalonado que parte del FF5 y evalúa la incorporación progresiva de Momentum, Low Volatility, FCF/EV e Intangible Intensity.

2.3 Modelo de tres factores de Fama-French

El modelo de tres factores de Fama y French (1993) representa uno de los avances más influyentes en la literatura empírica de *asset pricing*. A partir de evidencia previa sobre anomalías de tamaño y valor, los autores propusieron extender el CAPM incorporando dos

factores adicionales: SMB —Small Minus Big— y HML —High Minus Low—. El modelo puede expresarse como:

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,\text{MKT}}(\text{MKT-RF})_t + \beta_{i,\text{SMB}}\text{SMB}_t + \beta_{i,\text{HML}}\text{HML}_t + \varepsilon_{i,t}$$

En esta especificación, MKT–RF representa el exceso de retorno del mercado sobre la tasa libre de riesgo, SMB captura la prima asociada a compañías pequeñas frente a compañías grandes, y HML captura la prima value, asociada a compañías con alto book-to-market frente a compañías con bajo book-to-market. Fama y French (1993) documentan que estos factores comunes ayudan a explicar patrones de retornos en acciones y bonos, y establecen una arquitectura empírica que posteriormente se convertiría en referencia central para la construcción de modelos multifactoriales.

La interpretación económica del factor SMB se asocia con la observación de que las compañías de menor capitalización han tendido, en ciertos períodos, a generar retornos promedio superiores a los de compañías grandes. Esta prima puede interpretarse como compensación por riesgos asociados a menor liquidez, mayor incertidumbre, menor cobertura de analistas, restricciones financieras o sensibilidad a condiciones macroeconómicas. Por su parte, HML captura la diferencia entre compañías value y growth. Las compañías con alto book-to-market suelen interpretarse como firmas relativamente baratas respecto a su valor contable, posiblemente más expuestas a dificultades financieras o a riesgos de reversión. Las compañías con bajo book-to-market, en cambio, suelen asociarse con expectativas de crecimiento más elevadas.

El FF3 es relevante para esta tesis por dos razones. Primero, constituye el benchmark histórico fundamental frente al cual se desarrollan los modelos multifactoriales posteriores. Segundo, provee la estructura metodológica de construcción de factores a partir de portafolios

long-short formados sobre características firm-level. Aunque el eje principal de esta investigación es la extensión escalonada del FF5 hacia FF9, el FF3 se incluye como referencia histórica complementaria para contextualizar la mejora progresiva de las especificaciones evaluadas.

No obstante, el FF3 también presenta limitaciones. La evidencia posterior mostró que factores relacionados con rentabilidad operativa e inversión capturaban dimensiones relevantes no plenamente explicadas por mercado, tamaño y value. Esto llevó al desarrollo del modelo de cinco factores de Fama-French, que constituye la especificación base principal de esta investigación.

2.4 Modelo de cinco factores de Fama-French

Fama y French (2015) proponen el modelo de cinco factores como una extensión del FF3, incorporando dos dimensiones adicionales: RMW —Robust Minus Weak— y CMA —Conservative Minus Aggressive—. El modelo queda definido como:

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,MKT}(MKT-RF)_t + \beta_{i,SMB}SMB_t + \beta_{i,HML}HML_t \\ + \beta_{i,RMW}RMW_t + \beta_{i,CMA}CMA_t + \varepsilon_{i,t}$$

El factor RMW captura el diferencial de retorno entre compañías con rentabilidad operativa robusta y compañías con rentabilidad operativa débil. La intuición económica proviene de modelos de valoración en los cuales, manteniendo constantes otras variables, compañías más rentables deberían tener mayores retornos esperados. El factor CMA, por su parte, captura el diferencial entre compañías con políticas de inversión conservadoras y compañías con inversión agresiva. La lógica subyacente es que, dado un nivel de rentabilidad, las compañías que invierten agresivamente pueden tener menores retornos esperados si el mercado ya capitaliza sus

oportunidades de crecimiento o si dichas inversiones reducen flujos disponibles para los accionistas.

El modelo FF5 se apoya en la relación entre rentabilidad, inversión y valoración. En términos generales, el valor de una empresa puede entenderse como el valor presente de sus flujos de caja esperados. Bajo este enfoque, la rentabilidad esperada y la política de inversión contienen información relevante sobre retornos futuros. Fama y French (2015) muestran que el FF5 mejora el desempeño empírico frente al FF3, especialmente al capturar patrones relacionados con rentabilidad e inversión. No obstante, también encuentran que el modelo no elimina completamente todos los errores de *pricing* y que su principal dificultad se concentra en acciones pequeñas con baja rentabilidad y alta inversión. Además, al incorporar RMW y CMA, el factor HML pierde parte de su relevancia incremental y puede volverse redundante para describir retornos promedio en la muestra evaluada.

Este hallazgo es central para la presente tesis. El FF5 constituye una especificación más completa que el FF3, pero no representa una solución definitiva al problema de explicar la sección transversal de retornos accionarios. Su mejora frente al FF3, junto con sus limitaciones, justifica evaluar si factores adicionales —Momentum, Low Volatility, FCF/EV e Intangible Intensity— pueden aportar capacidad explicativa incremental. Al mismo tiempo, la posible redundancia de HML dentro del FF5 ilustra un problema fundamental de los modelos multifactoriales: agregar factores no garantiza necesariamente independencia, robustez o contribución incremental. Por esta razón, la tesis incorpora pruebas de redundancia factorial, VIF, Shanken, Harvey y MDE como parte de su arquitectura metodológica.

2.5 Momentum y anomalías persistentes

El factor Momentum se fundamenta en la evidencia de que los activos con mejor desempeño reciente tienden a continuar superando a los activos con peor desempeño reciente durante ciertos horizontes intermedios. Jegadeesh y Titman (1993) documentan que estrategias que compran acciones ganadoras y venden acciones perdedoras generan retornos significativos, lo cual plantea desafíos para la hipótesis de mercados eficientes en su forma más estricta.

En términos empíricos, Momentum se interpreta como una anomalía persistente porque captura patrones de continuación de retornos que no son plenamente explicados por los factores clásicos de mercado, tamaño y value. Diversas explicaciones han sido propuestas para esta anomalía. Algunas se apoyan en sesgos conductuales, como subreacción inicial a nueva información, sobreconfianza de inversionistas o comportamiento de seguimiento de tendencias. Otras interpretaciones enfatizan fricciones de mercado, límites al arbitraje, retrasos en la incorporación de información o exposición a riesgos macroeconómicos no capturados por modelos tradicionales.

La relevancia de Momentum para esta tesis es doble. Primero, se trata de una de las anomalías más documentadas y utilizadas en la literatura empírica. Segundo, su incorporación como FF6 permite evaluar si la persistencia de retornos pasados aporta capacidad explicativa adicional después de controlar por mercado, tamaño, value, rentabilidad e inversión. Esto es metodológicamente importante porque Momentum no se deriva directamente del modelo FF5, pero sí representa un factor ampliamente reconocido en la literatura multifactorial. Carhart (1997) incorporó Momentum en un modelo de cuatro factores para estudiar la persistencia del desempeño de fondos, mientras que Jegadeesh y Titman (2001) evaluaron explicaciones alternativas para la rentabilidad de estas estrategias.

En el diseño de esta investigación, Momentum se toma directamente de la Kenneth R. French Data Library, lo que permite mantener consistencia metodológica con una fuente académica estandarizada. Su rol dentro del modelo escalonado es servir como primera extensión del FF5, antes de incorporar los factores propios contruidos desde Refinitiv. De esta manera, la tesis evalúa primero una anomalía ampliamente aceptada antes de introducir dimensiones adicionales asociadas a baja volatilidad, generación de caja e intensidad intangible.

2.6 Factor Zoo y proliferación de factores

La expansión de la literatura multifactorial ha dado lugar a lo que se conoce como el Factor Zoo, término utilizado para describir la proliferación de factores y anomalías propuestas para explicar la sección transversal de retornos esperados. Esta proliferación plantea un problema metodológico relevante: no todos los factores documentados son necesariamente robustos, independientes, replicables o económicamente interpretables.

Harvey et al. (2016) argumentan que, dado el elevado número de factores probados en la literatura, los criterios tradicionales de significancia estadística pueden resultar insuficientes. En particular, advierten que un umbral convencional cercano a $|t| > 2$ puede aumentar el riesgo de falsos descubrimientos cuando múltiples hipótesis han sido evaluadas. Por ello, proponen estándares más exigentes, entre ellos un umbral aproximado de $|t| > 3$, para validar nuevos factores en un entorno de pruebas múltiples y potencial *data mining*.

Cochrane (2011) también destaca que uno de los grandes desafíos de la literatura de *asset pricing* consiste en organizar una gran cantidad de variables predictivas, factores y patrones de retorno dentro de un marco económico coherente. En la misma línea, Hou et al. (2020) muestran que muchas anomalías pierden robustez cuando son sometidas a procedimientos de replicación más estrictos. Esta evidencia refuerza la necesidad de evaluar cuidadosamente cualquier

extensión factorial, evitando que la investigación se convierta en una acumulación mecánica de variables.

Para esta tesis, la discusión del Factor Zoo es particularmente importante. El modelo propuesto incorpora factores adicionales al FF5, pero lo hace bajo una lógica escalonada, fundamentada y sujeta a pruebas de robustez. La investigación no busca validar indiscriminadamente cualquier factor, sino evaluar si Momentum, Low Volatility, FCF/EV e Intangible Intensity aportan información incremental, reducen errores de *pricing* y presentan evidencia empírica suficiente para justificar su incorporación. Por ello, la metodología incluye pruebas de redundancia factorial, análisis de correlación, VIF, corrección de Shanken, MDE y umbral de Harvey.

En este sentido, el aporte de la tesis no se limita a proponer un modelo FF9. Su contribución consiste en evaluar una extensión multifactorial de manera disciplinada, distinguiendo entre factores con fundamento económico, factores empíricamente útiles y factores que podrían ser redundantes o estadísticamente frágiles. Esta distinción es esencial para una investigación rigurosa en el contexto contemporáneo de *asset pricing*.

2.7 Intangibles, innovación y limitaciones contables

El crecimiento de la economía basada en conocimiento, tecnología, software, datos, propiedad intelectual e innovación ha incrementado la importancia de los activos intangibles en la creación de valor empresarial. Sin embargo, la contabilidad financiera tradicional no siempre refleja plenamente esta realidad económica. En muchos casos, inversiones en investigación y desarrollo, software interno, capacidades organizacionales, marcas, datos o capital humano son reconocidas como gasto del período, en lugar de ser capitalizadas como activos. Esto puede generar una brecha entre el valor económico de una firma y su representación contable.

Esta limitación resulta especialmente relevante para empresas growth, tecnológicas, farmacéuticas, de software, biotecnología, plataformas digitales y compañías intensivas en investigación y desarrollo. En estos casos, métricas tradicionales como book-to-market pueden no capturar completamente la acumulación de capital intangible generado internamente. Peters y Taylor (2017) proponen una medición de capital intangible y muestran que incorporar intangibles mejora la relación entre inversión y Tobin's q , sugiriendo que los activos intangibles contienen información relevante para entender oportunidades de inversión y valoración empresarial. Lev (2001), Lev y Gu (2016) y Eisfeldt y Papanikolaou (2013) refuerzan esta discusión al mostrar que los intangibles, el conocimiento organizacional y la innovación pueden no quedar reflejados plenamente en la contabilidad tradicional.

La literatura reciente también ha avanzado hacia la construcción explícita de factores asociados a la intensidad intangible. En particular, Bongaerts et al. (2025) proponen un factor INT vinculado con la intensidad de activos intangibles y muestran que su incorporación puede mejorar el desempeño de modelos multifactoriales tradicionales. Esta investigación reconoce dicho antecedente y se inserta en esa línea de discusión; sin embargo, su propósito no es aislar el factor INT como contribución única, sino evaluarlo dentro de una arquitectura multifactorial escalonada más amplia, en la cual la intensidad intangible se incorpora junto con Momentum, Low Volatility y FCF/EV como extensiones progresivas del modelo FF5. De esta manera, el aporte de la tesis radica en analizar si una especificación FF9, construida de forma secuencial y sometida a pruebas de robustez, mejora la capacidad explicativa del modelo base sin asumir que la inclusión de nuevos factores implica automáticamente la validación definitiva de nuevas primas de riesgo.

La señal Intangible Intensity utilizada en esta tesis se construye como:

$$\text{Intangible Intensity}_{j,y} = \frac{\text{R\&D}_{j,y}}{\text{Revenue}_{j,y}}$$

Esta medida busca capturar la intensidad relativa con la que una compañía invierte en investigación y desarrollo frente a su escala de ingresos. No se interpreta como una medición completa de todos los activos intangibles de la firma, sino como una proxy empírica observable y replicable de intensidad innovadora. Su relevancia radica en que una empresa con alto R&D/Revenue puede estar destinando una proporción significativa de sus ingresos a desarrollar conocimiento, tecnología, productos, patentes o capacidades futuras.

Sin embargo, la inclusión de esta señal no implica asumir que las empresas intensivas en investigación y desarrollo carecen de valor contable o activos tangibles significativos. Más bien, el ratio R&D/Revenue busca medir la intensidad relativa con la que una compañía destina recursos a innovación frente a su escala de ingresos. Por tanto, esta variable puede aportar información complementaria a factores tradicionales como HML, RMW y CMA, especialmente en empresas donde la innovación, el conocimiento o el desarrollo tecnológico constituyen elementos centrales del modelo de negocio.

En la estructura escalonada de la tesis, Intangible Intensity se incorpora como el último factor, dando lugar a la especificación FF9. Esta decisión permite evaluar si la intensidad intangible aporta información incremental después de controlar por mercado, tamaño, value, rentabilidad, inversión, momentum, baja volatilidad y generación de caja relativa.

2.8 Free Cash Flow Yield y valoración fundamental

El flujo de caja libre constituye una medida fundamental en valoración corporativa, dado que aproxima la capacidad de una empresa para generar caja después de cubrir sus necesidades

de inversión de capital. Desde una perspectiva de valoración, el valor de una firma está vinculado con la generación esperada de flujos de caja futuros y con el riesgo asociado a dichos flujos. Por ello, indicadores basados en flujo de caja pueden aportar información complementaria a métricas contables tradicionales de rentabilidad o valor en libros.

En esta tesis, la señal FCF/EV se interpreta como una medida de free cash flow yield, es decir, como la generación de flujo de caja libre relativa al valor empresarial de la compañía:

$$FCFEV_{j,t} = \frac{FCF_{j,y}^{available}}{EV_{j,t-1}}$$

Desde la lógica de valoración fundamental, una empresa con mayor FCF/EV genera más caja libre por unidad de valor empresarial. Esto puede interpretarse como una señal de valoración atractiva, eficiencia en la asignación de capital, disciplina financiera o calidad de generación de caja. En contraste, una empresa con bajo o negativo FCF/EV puede reflejar menor conversión de caja, valoración elevada respecto a su flujo disponible, inversión intensiva o condiciones transitorias de deterioro financiero.

La literatura de Fama y French (2006) relaciona rentabilidad, inversión y retornos promedio, reforzando la idea de que variables fundamentales contienen información relevante para explicar diferencias transversales en retornos esperados. De forma complementaria, Dai (2019) analiza el net cash flow yield como una variable relacionada con la sección transversal de retornos, lo que respalda la pertinencia de estudiar medidas de rendimiento de caja dentro de modelos multifactoriales. Fama y French (2015), al incorporar rentabilidad e inversión, también refuerzan la importancia de variables fundamentales en la explicación de retornos promedio. Sloan (1996) y Dechow et al. (2008) también muestran que los componentes de caja contienen información diferenciada frente a las utilidades contables.

La contribución de FCF/EV frente a los factores tradicionales radica en que no se limita a la rentabilidad contable ni al book-to-market. Mientras HML se apoya en la relación entre valor contable y valor de mercado, y RMW captura rentabilidad operativa, FCF/EV introduce una dimensión más cercana a la generación efectiva de caja frente al valor total de la firma. Esta perspectiva puede ser particularmente relevante para inversionistas institucionales, gestores de portafolio y estrategias sistemáticas que buscan identificar compañías con capacidad real de generación de caja, no solo con altos niveles de utilidad contable.

No obstante, el uso de FCF/EV también exige cautela metodológica. Los ratios de flujo de caja pueden presentar valores extremos debido a flujos negativos, denominadores bajos, eventos corporativos o cambios abruptos en deuda neta. Por ello, en esta investigación su construcción se realiza con reglas explícitas de disponibilidad temporal, rezagos contables y Enterprise Value observado al cierre del mes anterior. De esta forma, el factor se incorpora bajo una lógica consistente con la prevención de *look-ahead bias*.

2.9 Low Volatility anomaly

La anomalía de baja volatilidad se refiere a la evidencia empírica de que acciones con menor volatilidad histórica o menor beta pueden generar retornos ajustados por riesgo superiores, o al menos no proporcionalmente inferiores, a los de acciones de mayor riesgo. Este patrón contradice parcialmente la predicción tradicional de una relación positiva entre riesgo y retorno esperado bajo modelos simples como el CAPM.

Blitz y van Vliet (2007) documentan que portafolios de baja volatilidad presentan retornos ajustados por riesgo atractivos en mercados desarrollados. Baker et al. (2011) argumentan que restricciones institucionales, benchmarks y límites al arbitraje pueden contribuir a que las acciones de alta beta o alta volatilidad sean sobrevaloradas, generando retornos futuros

relativamente bajos. Frazzini y Pedersen (2014) desarrollan el factor Betting Against Beta, mostrando que una estrategia larga en activos de bajo beta apalancados y corta en activos de alto beta produce retornos ajustados por riesgo positivos, y vinculan esta anomalía con restricciones de apalancamiento y preferencias de inversionistas por activos de mayor beta. La evidencia temprana de Haugen y Heins (1975), junto con los resultados de Ang et al. (2006, 2009), respalda la importancia de evaluar la relación empírica entre volatilidad y retornos esperados.

La relevancia de Low Volatility para esta tesis es tanto teórica como práctica. Desde la perspectiva teórica, permite evaluar si una dimensión de riesgo realizado, no capturada plenamente por mercado, tamaño, value, rentabilidad e inversión, aporta capacidad explicativa adicional. Desde la perspectiva práctica, Low Volatility es ampliamente utilizado en estrategias defensivas, gestión de riesgo, construcción de portafolios orientados a menor drawdown y asignación táctica en entornos de incertidumbre.

En esta investigación, la señal de baja volatilidad se calcula como la desviación estándar de los retornos mensuales de cada acción durante los 12 meses previos. El factor se define como una estrategia Low Volatility minus High Volatility, de modo que una prima positiva indicaría que las acciones de menor volatilidad superaron a las de mayor volatilidad durante el período correspondiente. Esta definición mantiene coherencia con la interpretación económica del factor y con la evidencia documentada en la literatura.

Dentro del modelo escalonado, Low Volatility se incorpora después de Momentum, dando lugar a la especificación FF7. Esta decisión permite evaluar si la dimensión defensiva de baja volatilidad aporta información incremental antes de incorporar factores fundamentales adicionales como FCF/EV e Intangible Intensity.

2.10 Síntesis del marco teórico e hipótesis de investigación

La revisión de literatura permite establecer la lógica conceptual que sustenta la presente investigación. En primer lugar, la teoría moderna de portafolio y el CAPM proporcionan la base para entender la relación entre riesgo sistemático y retorno esperado. En segundo lugar, el modelo de tres factores de Fama-French amplía esta lógica al incorporar tamaño y value como dimensiones relevantes para explicar retornos. En tercer lugar, el modelo de cinco factores introduce rentabilidad e inversión, mejorando la capacidad explicativa del FF3, aunque sin eliminar completamente los errores de *pricing*.

A partir de esta evolución, la literatura contemporánea plantea dos desafíos simultáneos. Por un lado, existen factores adicionales documentados —Momentum, Low Volatility, cash-flow yield, intangibles— que podrían capturar dimensiones relevantes no plenamente absorbidas por el FF5. Por otro lado, la proliferación del Factor Zoo obliga a evaluar cualquier extensión de manera rigurosa, evitando la acumulación indiscriminada de factores y controlando problemas de redundancia, *data mining*, baja robustez estadística y sobreajuste.

La tesis se ubica precisamente en esta intersección. Su propuesta no consiste en agregar factores de forma mecánica, sino en evaluar una extensión escalonada del FF5 hacia FF9, incorporando factores con fundamento económico y relevancia empírica contemporánea. En particular, Momentum captura persistencia de retornos; Low Volatility captura una dimensión defensiva o de riesgo realizado; FCF/EV incorpora generación de caja relativa al valor empresarial; e Intangible Intensity introduce una proxy de inversión en innovación y activos intangibles generados internamente.

Capítulo 3. Metodología

3.1 Diseño empírico de la investigación

La presente investigación adopta un enfoque cuantitativo, empírico y explicativo, orientado a evaluar la capacidad de distintos modelos multifactoriales para explicar los retornos accionarios en el mercado estadounidense. El estudio parte del modelo de cinco factores de Fama y French como especificación base principal y propone una extensión escalonada hacia un modelo de nueve factores mediante la incorporación progresiva de **Momentum**, **Low Volatility**, **FCF/EV** e **Intangible Intensity**.

El objetivo metodológico central consiste en determinar si la adición secuencial de estos factores mejora la capacidad explicativa del modelo, medida a través de la reducción de alfas residuales, mejora del ajuste estadístico, significancia de los precios de riesgo y robustez econométrica. La investigación no busca simplemente incrementar el número de factores, sino evaluar si cada incorporación aporta información incremental, coherencia económica y capacidad explicativa adicional frente a las especificaciones previas.

La estrategia empírica se estructura en torno a seis especificaciones:

Tabla 3.1. Especificaciones evaluadas en la estrategia empírica

Modelo	Especificación
FF3	MKT-RF, SMB, HML
FF5	MKT-RF, SMB, HML, RMW, CMA
FF6	FF5 + Momentum
FF7	FF6 + Low Volatility
FF8	FF7 + FCF/EV
FF9	FF8 + Intangible Intensity

Nota. La tabla resume la incorporación escalonada de factores desde FF3 hasta FF9.

Aunque el eje central de la investigación es la extensión escalonada del modelo FF5 hacia FF9, se incluye también el modelo FF3 como referencia histórica complementaria, dada su relevancia en la literatura de valoración de activos. En consecuencia, el FF3 no constituye el punto central de la propuesta, sino un benchmark adicional que permite contextualizar la evolución desde modelos multifactoriales clásicos hacia especificaciones más amplias.

La metodología se desarrolla en varias etapas: definición de la ventana temporal, selección de fuentes de información, delimitación del universo muestral, construcción de señales factoriales, formación de portafolios long–short, prueba de redundancia factorial, estimación de regresiones de series de tiempo, aplicación de la prueba GRS, estimación de precios de riesgo mediante Fama–MacBeth, corrección de Shanken y pruebas complementarias de robustez.

3.2 Ventana temporal, frecuencia y muestra de estimación

La comparación principal entre especificaciones se realiza sobre una ventana común estricta comprendida entre julio de 2014 y diciembre de 2025. Esta decisión metodológica responde al objetivo central de evaluar si la incorporación incremental de factores mejora la capacidad explicativa del modelo manteniendo constante el período muestral. Al utilizar una misma ventana temporal para las especificaciones FF3, FF5, FF6, FF7, FF8 y FF9, se evita atribuir a la inclusión de nuevos factores diferencias que podrían estar explicadas por cambios en las condiciones de mercado, regímenes macrofinancieros o disponibilidad de información en períodos distintos.

La ventana principal 201407–202512 contiene aproximadamente 138 observaciones mensuales. Esta frecuencia mensual es consistente con la literatura empírica de modelos

multifactoriales y permite reducir el ruido asociado a datos de alta frecuencia, manteniendo al mismo tiempo un número suficiente de observaciones para la estimación econométrica.

La utilización de una ventana común es particularmente relevante en una investigación de asset pricing, dado que métricas como los alfas, el R^2 ajustado, la prueba GRS y los precios de riesgo estimados mediante Fama–MacBeth son sensibles tanto a la estructura factorial del modelo como al período muestral utilizado. En la literatura empírica de valoración de activos, la comparabilidad entre especificaciones requiere que los modelos sean evaluados bajo condiciones muestrales homogéneas, de forma que las diferencias observadas en errores de pricing, significancia de factores o ajuste estadístico puedan atribuirse a la estructura del modelo y no a cambios en la ventana temporal de estimación. Esta lógica es consistente con el enfoque de Fama y MacBeth (1973), quienes estiman precios de riesgo a partir de regresiones transversales en períodos definidos; con Gibbons et al. (1989), cuya prueba conjunta de alfas requiere una matriz común de retornos y factores; y con Fama y French (1993, 2015), quienes evalúan modelos multifactoriales sobre muestras claramente delimitadas y comparables. Asimismo, Cochrane (2005) destaca que la evaluación empírica de modelos de asset pricing depende críticamente de la especificación del conjunto de activos, factores y período de estimación. En consecuencia, la ventana 201407–202512 constituye la base principal para la comparación incremental entre modelos y para la evaluación de la contribución explicativa de los factores adicionales.

3.3 Fuentes de datos financieros y de mercado

La investigación utiliza dos fuentes principales de información: la Kenneth R. French Data Library y Refinitiv Workspace.

3.3.1 Kenneth R. French Data Library

Los factores benchmark del modelo Fama-French, la tasa libre de riesgo y los portafolios de prueba estandarizados se obtienen de la Kenneth R. French Data Library. Esta fuente es ampliamente utilizada en la literatura empírica de *asset pricing* y provee series históricas construidas bajo metodologías estandarizadas, lo cual facilita la comparación de los resultados de esta investigación con modelos y pruebas ampliamente aceptados en la literatura financiera.

En particular, la investigación utiliza la información proveniente de esta fuente para tres propósitos principales:

Tabla 3.2. Componentes de datos provenientes de Kenneth R. French Data Library

Componente	Uso en la tesis	Descripción
Factores Fama–French	Variables explicativas benchmark	MKT-RF, SMB, HML, RMW y CMA
Momentum	Factor adicional en FF6	Factor de persistencia de retornos pasados
25 portafolios Size $\times$ Book-to-Market	Activos de prueba / variable dependiente	Portafolios usados para evaluar errores de pricing

Nota. La tabla resume los principales usos de la información estandarizada empleada en la tesis.

La utilización de estos datos permite que la estimación de las especificaciones FF3, FF5, FF6, FF7, FF8 y FF9 se realice sobre factores y activos de prueba reconocidos y comparables con la literatura académica.

a) Factores Fama-French

Los factores Fama-French se utilizan como base para las especificaciones FF3 y FF5. El modelo FF3 incorpora los factores de mercado, tamaño y value, mientras que el FF5 amplía esta estructura con los factores de rentabilidad operativa e inversión.

Tabla 3.3. Factores Fama-French utilizados como benchmark

Factor	Nombre	Interpretación
MKT-RF	Market excess return	Exceso de retorno del mercado sobre la tasa libre de riesgo
SMB	Small Minus Big	Prima asociada a compañías pequeñas frente a compañías grandes
HML	High Minus Low	Prima value, asociada a alto book-to-market frente a bajo book-to-market
RMW	Robust Minus Weak	Prima asociada a rentabilidad operativa robusta frente a débil
CMA	Conservative Minus Aggressive	Prima asociada a inversión conservadora frente a inversión agresiva

Nota. La tabla presenta los factores benchmark empleados en las especificaciones FF3 y FF5.

De acuerdo con la documentación metodológica de la Kenneth R. French Data Library, los factores del modelo de cinco factores se construyen a partir de portafolios formados mediante la combinación de dos criterios: tamaño de la compañía y una característica financiera específica. Para ello, las acciones se clasifican primero en dos grupos por tamaño —Small y Big— y luego en tres grupos según la característica correspondiente: book-to-market, rentabilidad operativa o nivel de inversión.

Esta metodología genera portafolios 2×3 , es decir, seis portafolios para cada combinación de tamaño y característica: Small-Low, Small-Neutral, Small-High, Big-Low, Big-Neutral y Big-High. Posteriormente, a partir de los retornos ponderados por valor de estos portafolios se calculan los factores del modelo: SMB, HML, RMW y CMA. Por su parte, MKT-RF representa el exceso de retorno del mercado sobre la tasa libre de riesgo (French, s.f.-a; Fama & French, 1993, 2015).

Esta metodología es relevante para la presente investigación porque provee factores benchmark contruidos bajo reglas estandarizadas, lo que permite evaluar si los factores propios propuestos aportan capacidad explicativa incremental frente a una base ampliamente aceptada en la literatura de *asset pricing*.

b) Factor Momentum

El factor **Momentum** se incorpora en la especificación **FF6**, como primera extensión del modelo FF5. Su inclusión responde a la evidencia empírica de que los activos con mejor desempeño reciente pueden continuar presentando retornos relativos superiores en horizontes posteriores, fenómeno ampliamente documentado en la literatura de anomalías de mercado.

En esta investigación, el factor Momentum se toma directamente de la Kenneth R. French Data Library, con el fin de mantener consistencia con una fuente estandarizada y evitar diferencias metodológicas derivadas de una construcción propia. Este factor permite evaluar si la persistencia de retornos pasados aporta capacidad explicativa adicional después de controlar por mercado, tamaño, value, rentabilidad e inversión.

La serie empleada corresponde a la documentación específica del factor Momentum de la Kenneth R. French Data Library (French, s.f.-c), lo que refuerza la consistencia entre las variables benchmark y los factores adicionales descargados de dicha fuente.

Tabla 3.4. Incorporación de Momentum en las especificaciones FF5 y FF6

Modelo	Incorporación de Momentum
FF5	No incluye Momentum
FF6	FF5 + Momentum

Nota. La tabla resume la incorporación de Momentum como primera extensión del benchmark FF5.

c) Portafolios de prueba: 25 Size × Book-to-Market

Los **25 portafolios Size × Book-to-Market** se utilizan como activos de prueba o variable dependiente en las regresiones de series de tiempo. Estos portafolios permiten evaluar si las

distintas especificaciones factoriales reducen los errores de pricing sobre un conjunto de activos ampliamente utilizado en la literatura empírica de valoración de activos.

De acuerdo con la documentación de Kenneth French, estos portafolios se construyen al final de cada junio como la intersección de cinco portafolios formados por tamaño y cinco portafolios formados por book-to-market. El tamaño se mide mediante capitalización de mercado, mientras que la razón book-to-market se calcula utilizando el book equity del último cierre fiscal disponible en $t-1$, dividido por el market equity de diciembre de $t-1$. Los puntos de corte se basan en quintiles de NYSE, lo que permite una clasificación estandarizada de las acciones según tamaño y value (French, s.f.-b).

La estructura de estos portafolios puede representarse como una matriz 5×5 :

Tabla 3.5. Estructura de los 25 portafolios Size x Book-to-Market

	BM1 Low	BM2	BM3	BM4	BM5 High
Size 1 Small	S1/BM1	S1/BM2	S1/BM3	S1/BM4	S1/BM5
Size 2	S2/BM1	S2/BM2	S2/BM3	S2/BM4	S2/BM5
Size 3	S3/BM1	S3/BM2	S3/BM3	S3/BM4	S3/BM5
Size 4	S4/BM1	S4/BM2	S4/BM3	S4/BM4	S4/BM5
Size 5 Big	S5/BM1	S5/BM2	S5/BM3	S5/BM4	S5/BM5

Nota. La matriz muestra la intersección entre quintiles de tamaño y book-to-market utilizada como activos de prueba.

En esta investigación, cada uno de estos 25 portafolios constituye una serie de retornos dependiente. Para cada portafolio i , se estima el exceso de retorno mensual frente a los factores correspondientes a cada modelo:

$$R_{i,t}^e = R_{i,t} - R_{f,t}$$

El uso de estos portafolios como activos de prueba permite evaluar si las especificaciones **FF3, FF5, FF6, FF7, FF8 y FF9** reducen los alfas y errores de pricing de manera incremental. Asimismo, al utilizar factores benchmark y test assets provenientes de una misma fuente metodológica, se preserva consistencia en la definición de retornos, tasa libre de riesgo y construcción de portafolios.

Esta estructura permite combinar factores benchmark reconocidos con factores propios contruidos a partir de Refinitiv, manteniendo una separación clara entre los datos estandarizados usados como referencia académica y las señales propias propuestas por la investigación.

3.3.2 Refinitiv Workspace

Para la construcción de los factores propios —Low Volatility, FCF/EV e Intangible Intensity— se utiliza información financiera y de mercado obtenida de Refinitiv Workspace. Esta fuente permite extraer datos contables, métricas de valoración, retornos históricos, precios y capitalización bursátil de las acciones incluidas en el universo muestral.

Las principales variables utilizadas son:

- Retornos mensuales por acción.
- Capitalización bursátil.
- Enterprise Value.
- Free Cash Flow.
- Gasto en investigación y desarrollo.
- Ingresos.

- Información sectorial y de clasificación corporativa.

En particular, la investigación utiliza definiciones consistentes para los factores propios. El factor Low Volatility se construye a partir de la volatilidad histórica de retornos; el factor FCF/EV utiliza flujo de caja libre sobre Enterprise Value; y el factor Intangible Intensity se construye a partir del gasto en investigación y desarrollo sobre ingresos.

3.4 Universo muestral y criterios de depuración

Para la construcción de los factores propios se utilizó un universo muestral de 400 acciones estadounidenses, definido a partir de criterios de disponibilidad de datos, continuidad de series de precios, liquidez mínima y comparabilidad financiera. Esta delimitación busca asegurar que las señales factoriales —volatilidad histórica, FCFEV y R&D/Revenue— puedan estimarse de manera consistente y replicable.

Asimismo, se procuró excluir microcapitalizaciones, acciones con baja negociabilidad, compañías de Real Estate/REITs y entidades financieras tradicionales, dado que estos segmentos presentan características contables, regulatorias y operativas que pueden afectar la comparabilidad de los factores construidos. Por tanto, los resultados asociados a los factores propios deben interpretarse en el marco de un universo muestral depurado y no como una caracterización exhaustiva del mercado accionario estadounidense en su totalidad.

Esta delimitación metodológica responde a la necesidad de construir factores propios con información suficientemente robusta, series de retornos continuas y condiciones mínimas de negociabilidad. En particular, la literatura de *asset pricing* y microestructura de mercado ha documentado que los activos de baja liquidez pueden presentar problemas asociados a spreads amplios, menor profundidad de mercado, costos de transacción más altos, precios discontinuos y mayor ruido de microestructura, lo que puede afectar la estimación de retornos y primas

esperadas (Amihud & Mendelson, 1986; Pástor & Stambaugh, 2003). Por esta razón, la exclusión de microcapitalizaciones y acciones con baja negociabilidad busca reducir distorsiones empíricas que podrían afectar la construcción e interpretación de los factores propios.

Esta decisión también es consistente con evidencia clásica sobre iliquidez y retornos esperados, según la cual activos menos líquidos pueden exigir compensaciones de retorno y presentar mayor ruido empírico en la estimación de primas (Amihud, 2002).

Asimismo, las compañías de Real Estate y los REITs presentan características contables, fiscales y operativas particulares que dificultan su comparabilidad con compañías corporativas tradicionales. En este segmento, métricas como el resultado contable, el flujo de caja libre o ciertos múltiplos basados en valor empresarial pueden no reflejar adecuadamente el desempeño operativo recurrente, razón por la cual la industria suele utilizar medidas específicas como Funds From Operations (FFO) y Adjusted Funds From Operations (AFFO) para evaluar la generación de caja y desempeño de REITs (Nareit, s.f.). En consecuencia, la exclusión de compañías de Real Estate/REITs busca evitar que diferencias estructurales en la medición de desempeño distorsionen señales como FCFEV, , rentabilidad operativa o generación de caja relativa.

De manera similar, las entidades financieras tradicionales presentan estructuras de balance, apalancamiento, regulación de capital e ingresos sustancialmente distintas a las de compañías no financieras. Fama y French (1992) excluyen firmas financieras en su análisis empírico debido a que el alto apalancamiento, que para empresas no financieras puede indicar dificultades financieras, tiene una interpretación diferente en firmas financieras. Bajo esta lógica, la exclusión de bancos, aseguradoras y entidades financieras tradicionales permite mejorar la comparabilidad de métricas como Enterprise Value, Free Cash Flow, rentabilidad operativa e intensidad de inversión. En consecuencia, el universo muestral fue diseñado para favorecer la

consistencia empírica de los factores propios, manteniendo una base de compañías con información disponible, liquidez mínima y características financieras razonablemente comparables.

3.5 Construcción de señales factoriales

La investigación propone tres señales propias: **Low Volatility**, **FCF/EV** e **Intangible Intensity**. Estas señales se calculan a nivel de acción y permiten clasificar las compañías en portafolios con alta y baja exposición a cada característica.

La lógica general consiste en ordenar transversalmente las acciones de la muestra en cada fecha de formación, formar portafolios extremos y calcular el retorno diferencial entre ellos. Esta aproximación es consistente con la literatura de factores, en la cual las características observables de las firmas se utilizan para formar portafolios long–short que capturan primas o anomalías específicas.

El orden de incorporación de los factores propios en el modelo escalonado responde a la estructura empírica definida para la investigación: primero se incorpora Momentum al FF5 para formar FF6; posteriormente se incorpora Low Volatility para formar FF7; luego se incorpora FCF/EV para formar FF8; y finalmente se incorpora Intangible Intensity para formar FF9.

3.5.1 Señal Low Volatility

La señal **Low Volatility** busca capturar la exposición de las acciones a la anomalía de baja volatilidad. Esta anomalía se asocia con la evidencia empírica de que las acciones con menor volatilidad histórica o menor beta pueden generar retornos ajustados por riesgo superiores, o al menos no proporcionalmente inferiores, a los de acciones de mayor riesgo, en contraste con la predicción tradicional de una relación positiva entre riesgo y retorno esperado.

Blitz y van Vliet (2007) documentan que los portafolios de baja volatilidad presentan altos retornos ajustados por riesgo en mercados desarrollados, mientras que Baker et al. (2011) muestran que las acciones de alta volatilidad y alta beta han tendido a subdesempeñar frente a acciones de baja volatilidad y baja beta en el mercado estadounidense. De forma complementaria, Frazzini y Pedersen (2014) desarrollan el factor Betting Against Beta, argumentando que restricciones de apalancamiento y preferencias por activos de mayor beta pueden contribuir a que los activos de bajo beta ofrezcan retornos ajustados por riesgo atractivos. En consecuencia, la inclusión de Low Volatility permite evaluar si una dimensión de riesgo realizado, no capturada plenamente por los factores tradicionales de Fama-French, aporta capacidad explicativa incremental dentro del modelo multifactorial propuesto.

Para cada acción j y mes t , la señal de volatilidad se calcula como la desviación estándar de sus retornos mensuales durante los 12 meses previos:

$$VOL_{j,t} = sd(R_{j,t-12}, \dots, R_{j,t-1})$$

Esta definición utiliza únicamente información histórica disponible antes de la formación del portafolio. En consecuencia, el retorno del mes t no se incorpora en el cálculo de la señal, lo cual evita sesgo de anticipación.

A diferencia de las señales contables, Low Volatility se construye con información de mercado observada en los retornos históricos de la acción. Por esta razón, puede actualizarse con frecuencia mensual. En cada mes, las acciones se ordenan de menor a mayor volatilidad histórica. Posteriormente, se forman portafolios de baja y alta volatilidad.

El factor se construye como la diferencia entre el retorno del portafolio de baja volatilidad y el retorno del portafolio de alta volatilidad:

$$LVOL_t = R_{LowVol,t} - R_{HighVol,t}$$

Esta definición es consistente con la interpretación económica del factor: una prima positiva indica que las acciones de baja volatilidad superaron en retorno a las acciones de alta volatilidad durante el período correspondiente.

En la estructura escalonada de la investigación, **Low Volatility** se incorpora después de Momentum, dando lugar a la especificación **FF7**.

3.5.2 Señal FCF/EV

La señal **FCF/EV** busca capturar la relación entre la generación de flujo de caja libre y el valor empresarial de la compañía. En esta investigación, el factor se construye utilizando definiciones específicas de Refinitiv Workspace, con el fin de asegurar consistencia, trazabilidad y replicabilidad en la medición empírica.

En particular, el Free Cash Flow se obtiene a partir del campo TR.FCFActValue, definido por Refinitiv como *Free Cash Flow – Actual*. Esta métrica corresponde, en términos generales, al flujo de caja operativo menos los gastos de capital, es decir:

$$FCF_j \approx \text{Operating Cash Flow}_j - \text{Capital Expenditures}_j$$

Por su parte, el Enterprise Value se obtiene a partir del campo TR.F.EV, definido por Refinitiv como el valor empresarial de la firma. Conceptualmente, el Enterprise Value aproxima el valor total de la compañía para los proveedores de capital y se calcula como:

$$EV_j = \text{MarketCap}_j + \text{Debt}_j + \text{PrefEq}_j + \text{MinInt}_j - \text{CashSTI}_j$$

Bajo estas definiciones, la señal se calcula como:

$$FCFEV_{j,t} = \frac{FCF_{j,y}^{\text{available}}}{EV_{j,t-1}}$$

donde el numerador corresponde al flujo de caja libre más reciente disponible bajo el rezago contable definido, y el denominador corresponde al Enterprise Value observado al cierre del mes anterior a la formación del portafolio.

Desde una perspectiva de valoración, esta relación permite evaluar cuánto flujo de caja libre genera una compañía en proporción a su valor empresarial. En consecuencia, FCFEV puede interpretarse como una medida de free cash flow yield o rendimiento de caja relativo al valor de la firma. Un mayor FCFEV puede asociarse con mayor generación de caja relativa, disciplina financiera, eficiencia en la asignación de capital o una valoración fundamental más atractiva.

Esta lógica es consistente con la literatura de valoración corporativa, que vincula el valor de la firma con la generación esperada de flujos de caja libres, y con la literatura de *asset pricing*, que relaciona variables de rentabilidad, inversión y rendimiento de caja con diferencias transversales en retornos esperados (Damodaran, 2012; Fama & French, 2006; Dai, 2019). Asimismo, desde la perspectiva de Jensen (1986), la generación de flujo de caja libre también puede estar asociada a decisiones de asignación de capital y disciplina corporativa, aunque su efecto sobre retornos esperados debe evaluarse empíricamente dentro del modelo multifactorial propuesto.

Dado que el numerador del ratio proviene de información contable anual, se aplica un rezago temporal para evitar el uso de información futura y mitigar el riesgo de look-ahead bias. Para los meses de enero a junio del año calendario y , se utiliza el Free Cash Flow correspondiente al año fiscal $y - 2$. Para los meses de julio a diciembre del año calendario y , se utiliza el Free Cash Flow correspondiente al año fiscal $y - 1$.

Tabla 3.6. Rezago contable aplicado al Free Cash Flow

Meses de formación	Free Cash Flow utilizado
Enero–junio del año Y	Año fiscal $Y - 2$
Julio–diciembre del año Y	Año fiscal $Y - 1$

Nota. La tabla resume la regla de disponibilidad temporal usada para mitigar el sesgo de anticipación.

El denominador, Enterprise Value, se toma al cierre del mes anterior a la formación del portafolio. Esta decisión evita utilizar información de mercado observada al final del mismo mes cuyo retorno será evaluado, preservando la consistencia temporal del análisis. Por ejemplo, para formar portafolios en enero de 2020, se utiliza el Free Cash Flow del año fiscal 2018 y el Enterprise Value observado al cierre de diciembre de 2019; para julio de 2020, se utiliza el Free Cash Flow del año fiscal 2019 y el Enterprise Value observado al cierre de junio de 2020.

Una vez calculado el ratio para cada acción, las compañías se ordenan transversalmente de acuerdo con su nivel de FCFEV. Posteriormente, se forman portafolios de alta y baja exposición a la señal. El factor FCFEV se define como la diferencia entre el retorno del portafolio de alta FCFEV y el retorno del portafolio de baja FCFEV:

$$FCFEV_t = R_{\text{High FCFEV},t} - R_{\text{Low FCFEV},t}$$

Una prima positiva del factor indicaría que, durante el período correspondiente, las compañías con mayor generación de flujo de caja libre relativo a su valor empresarial obtuvieron retornos superiores a las compañías con menor FCFEV. Por el contrario, un valor negativo indicaría el patrón opuesto.

En la estructura escalonada de la investigación, **FCF/EV** se incorpora después de **Momentum** y **Low Volatility**, dando lugar a la especificación **FF8**. Esta decisión permite

evaluar si la generación de caja relativa al valor empresarial aporta capacidad explicativa incremental después de controlar por mercado, tamaño, value, rentabilidad, inversión, momentum y baja volatilidad.

3.5.3 Señal de Intangible Intensity

La señal de **Intangible Intensity** busca capturar la intensidad relativa de inversión en activos intangibles generados internamente. Se calcula como el gasto en investigación y desarrollo dividido entre los ingresos de la compañía:

$$INT_{j,y} = \frac{R\&D_{j,y}}{Revenue_{j,y}}$$

donde $R\&D_{j,y}$ representa el gasto en investigación y desarrollo de la compañía j durante el año fiscal y , y $Revenue_{j,y}$ corresponde a sus ingresos durante el mismo período.

La elección de $R\&D/Revenue$ responde a criterios de parsimonia, trazabilidad y disponibilidad homogénea de información en Refinitiv Workspace para el universo muestral definido. Además, esta medida se encuentra alineada con literatura reciente que emplea la intensidad de investigación y desarrollo como proxy observable de intensidad intangible en modelos multifactoriales (Bongaerts et al., 2025). Si bien medidas ampliadas de intensidad intangible podrían incorporar componentes adicionales, como $SG\&A$, su implementación requiere una cobertura consistente y comparable a través del tiempo para evitar pérdidas significativas de observaciones o cambios no deseados en la composición de la muestra. En este sentido, el uso de $R\&D/Revenue$ permite construir una señal observable, replicable y alineada con la literatura reciente, manteniendo coherencia temporal y reduciendo el riesgo de sesgos asociados a información incompleta o heterogénea.

La relevancia de esta señal radica en que una parte significativa de la creación de valor en empresas modernas puede provenir de innovación, software, propiedad intelectual, datos, plataformas tecnológicas, conocimiento organizacional y capacidades de desarrollo. En muchos casos, estas inversiones pueden ser reconocidas contablemente como gasto del período, en lugar de ser capitalizadas como activo, lo que puede limitar la capacidad de métricas tradicionales para capturar plenamente su valor económico.

Sin embargo, la inclusión de esta señal no implica asumir que las empresas intensivas en investigación y desarrollo carecen de valor contable o activos tangibles significativos. Más bien, el ratio $R\&D/Revenue$ busca medir la intensidad relativa con la que una compañía destina recursos a innovación frente a su escala de ingresos. Por tanto, esta variable puede aportar información complementaria a factores tradicionales como HML, RMW y CMA, especialmente en empresas donde la innovación, el conocimiento o el desarrollo tecnológico constituyen elementos centrales del modelo de negocio.

Para evitar sesgo de anticipación, la señal se construye anualmente y se aplica bajo una convención de actualización julio–junio. En particular, la información contable del año fiscal $y - 1$ se utiliza para formar portafolios desde julio del año y hasta junio del año $y + 1$:

$$INT_{j,t} = \frac{R\&D_{j,y-1}}{Revenue_{j,y-1}}, \quad t \in \{\text{Jul } (y), \dots, \text{Jun } (y + 1)\}$$

Por ejemplo, la señal aplicada entre julio de 2014 y junio de 2015 se construye con información correspondiente al año fiscal 2013. Esta regla introduce un rezago conservador entre el cierre fiscal y el uso de la información en la formación de portafolios.

Una vez calculada la señal para cada acción, las compañías se ordenan según su intensidad intangible. El factor se define como la diferencia entre el retorno del portafolio con alta intensidad intangible y el retorno del portafolio con baja intensidad intangible:

$$INT_t = R_{\text{High INT},t} - R_{\text{Low INT},t}$$

En la estructura escalonada de la investigación, **Intangible Intensity** se incorpora como el último factor adicional, dando lugar a la especificación **FF9**. Esta decisión permite evaluar si la intensidad intangible aporta capacidad explicativa incremental después de controlar por mercado, tamaño, value, rentabilidad, inversión, momentum, baja volatilidad y generación de caja relativa.

3.6 Control de sesgo de anticipación y consistencia temporal

Un elemento central de la metodología es evitar el **look-ahead bias**, entendido como el uso de información futura para construir portafolios en períodos pasados. Para mitigar este riesgo, las señales factoriales se construyen utilizando exclusivamente información disponible antes del período de inversión.

El principio rector es el siguiente: para cada mes t , las señales y clasificaciones deben construirse con información disponible hasta $t-1$ o con información contable rezagada; el retorno del mes t se utiliza únicamente para medir el desempeño posterior del portafolio.

Tabla 3.7. Reglas de información utilizadas para evitar sesgo de anticipación

Elemento	Información utilizada
Momentum	Factor mensual obtenido de Kenneth French
Low Volatility	Volatilidad de los retornos históricos desde $t - 12$ hasta $t - 1$
FCF/EV	Free Cash Flow fiscal rezagado y EV al cierre de $t - 1$
Intangible Intensity	Información fiscal rezagada bajo convención julio–junio

Elemento	Información utilizada
Pesos value-weighted	Capitalización bursátil al cierre de $t - 1$
Retorno del portafolio	Retorno realizado durante el mes t

Nota. La tabla sintetiza las reglas temporales aplicadas a señales, variables de mercado y retornos evaluados.

En el caso de Intangible Intensity y FCF/EV, se aplican rezagos contables conservadores debido a que la información financiera anual no está disponible inmediatamente al cierre del período fiscal. En el caso de Low Volatility, la señal se calcula exclusivamente con retornos históricos previos al mes de formación. Esta estructura permite simular de forma más realista la información que habría estado disponible para un inversionista al momento de formar los portafolios.

3.7 Formación de portafolios y construcción de factores propios

Una vez definidas las señales correspondientes a **Low Volatility**, **FCF/EV** e **Intangible Intensity**, el siguiente paso metodológico consiste en transformarlas en factores de retorno comparables con la lógica de construcción de factores de Fama y French. Para ello, la investigación adopta una estructura de formación de portafolios inspirada en el esquema 2×3 utilizado en la Kenneth R. French Data Library, en el cual las acciones se clasifican mediante la intersección de dos grupos de tamaño y tres grupos de una característica financiera específica.

En esta investigación, las señales utilizadas para la construcción de factores propios son:

Tabla 3.8. Señales utilizadas para la construcción de factores propios

Factor propio	Señal utilizada	Frecuencia de actualización de la señal	Definición del factor
LVOL	$LVOL_{signal}$	Mensual	Low Volatility minus High Volatility

Factor propio	Señal utilizada	Frecuencia de actualización de la señal	Definición del factor
FCFEV	$FCFEV_{signal}$	Señal contable con aplicación mensual	High FCF/EV minus Low FCF/EV
INT	INT_{signal}	Señal contable anual con aplicación julio –junio	High Intangible Intensity minus Low Intangible Intensity

Nota. La tabla resume las señales firm-level usadas para formar los factores propios del modelo.

La finalidad de esta etapa es construir series mensuales de factores propios que puedan integrarse con los factores benchmark de Kenneth French y utilizarse posteriormente en las especificaciones FF7, FF8 y FF9. Aunque los factores propios capturan dimensiones económicas distintas a los factores clásicos, su construcción mantiene una lógica metodológica comparable: clasificación transversal de acciones, formación de portafolios, cálculo de retornos ponderados por valor y construcción de un diferencial entre portafolios extremos.

3.7.1 Formación de grupos por tamaño y por señal

Para cada fecha de formación, el universo elegible de acciones se clasifica primero en dos grupos por tamaño: **Small** y **Big**. La clasificación se realiza con base en la capitalización bursátil disponible antes del período de retorno que será evaluado. En la metodología original de Fama y French, el punto de corte de tamaño se calcula utilizando la mediana del *market equity* del universo NYSE. Sin embargo, dado que esta investigación trabaja con un universo muestral específico de 400 acciones estadounidenses y no con el universo completo NYSE/AMEX/NASDAQ, el punto de corte se calcula sobre el universo elegible del estudio en cada fecha de formación. Esta decisión constituye una adaptación necesaria para mantener la lógica del método 2×3 dentro del universo efectivamente disponible.

Posteriormente, las acciones se clasifican en tres grupos según la señal correspondiente: **Low**, **Neutral** y **High**. Para ello, se utilizan los percentiles 30 y 70 como puntos de corte de la

distribución transversal de cada señal. Así, las acciones ubicadas por debajo o en el percentil 30 se asignan al grupo **Low**; aquellas ubicadas entre los percentiles 30 y 70 se asignan al grupo **Neutral**; y las acciones ubicadas por encima o en el percentil 70 se asignan al grupo **High**.

Esta regla permite contrastar los extremos de la distribución sin descartar una zona intermedia, lo cual contribuye a estabilizar la clasificación transversal de las compañías. La intersección entre los dos grupos de tamaño y los tres grupos de señal produce seis portafolios en cada fecha de formación:

$$\{SL, SN, SH, BL, BN, BH\}$$

donde S representa Small, B representa Big, L representa Low, N representa Neutral y H representa High.

De esta forma, la estructura general de formación de portafolios puede resumirse así:

Tabla 3.9. Estructura general de formación de portafolios por tamaño y señal

Tamaño / Señal	Low	Neutral	High
Small	S_L	S_N	S_H
Big	B_L	B_N	B_H

Nota. La tabla resume la clasificación 2 x 3 empleada para construir los portafolios factoriales.

Esta arquitectura permite controlar de manera básica por tamaño al momento de construir cada factor, dado que el diferencial final promedia entre empresas pequeñas y grandes antes de comparar las carteras con señales extremas.

3.7.2 Cálculo de los retornos ponderados por valor

Una vez definidos los seis portafolios, se calculan sus retornos mensuales utilizando una metodología value-weighted, es decir, ponderada por capitalización bursátil. Bajo esta aproximación, las acciones con mayor valor de mercado tienen mayor peso dentro del retorno del

portafolio, mientras que las empresas de menor tamaño tienen una participación proporcionalmente menor.

Formalmente, si en el mes t una cartera P contiene N_P acciones, su retorno ponderado se calcula como:

$$R_{P,t} = \sum_{j=1}^{N_P} w_{j,t-1} r_{j,t}$$

donde $r_{\{j,t\}}$ representa el retorno de la acción j durante el mes t , y $w_{\{j,t-1\}}$ corresponde al peso relativo de esa acción dentro del portafolio, calculado a partir de su capitalización bursátil disponible antes del retorno del mes t . El uso de pesos rezagados evita incorporar información contemporánea del mismo mes en la construcción del retorno del portafolio.

El peso de cada acción se define como:

$$w_{j,t-1} = \frac{\text{MarketCap}_{j,t-1}}{\sum_{\ell=1}^{N_P} \text{MarketCap}_{\ell,t-1}}$$

Esta decisión metodológica busca mantener consistencia con la tradición Fama-French, cuyos factores se construyen a partir de portafolios ponderados por valor de mercado. Asimismo, la ponderación por capitalización bursátil reduce la influencia excesiva de compañías pequeñas o menos líquidas, mejorando la implementabilidad y estabilidad de los factores propios.

3.7.3 Construcción del factor LVOL

El factor LVOL se construye a partir de la señal $\text{VOL}_{\{j,t\}}$, definida como la volatilidad histórica de los retornos mensuales observados entre $t-12$ y $t-1$. A diferencia de las señales

contables, esta señal se actualiza mensualmente, dado que se basa en información de mercado disponible antes del mes de formación.

En cada mes t , las acciones se clasifican en grupos Small y Big con base en la capitalización bursátil rezagada, y en grupos Low, Neutral y High con base en la señal de volatilidad histórica. A partir de la intersección de estos grupos se forman las seis carteras 2×3 :

$$\{SL, SN, SH, BL, BN, BH\}$$

Dado que el interés económico del factor es capturar el desempeño relativo de las acciones de baja volatilidad frente a las de alta volatilidad, el factor se define como una estrategia **Low minus High**:

$$LVOL_t = \frac{1}{2}(R_{SL,t} + R_{BL,t}) - \frac{1}{2}(R_{SH,t} + R_{BH,t})$$

Bajo esta definición, el factor **LVOL** será positivo en aquellos meses en los que las acciones de menor volatilidad histórica superen, en promedio, a las acciones de mayor volatilidad histórica, después de controlar de manera básica por tamaño mediante la estructura 2×3 .

En la estructura escalonada de la investigación, **LVOL** se incorpora después de Momentum, dando lugar a la especificación **FF7**.

3.7.4 Construcción del factor FCFEV

El factor FCFEV se construye a partir de la señal FCFEV, definida como la razón entre Free Cash Flow y Enterprise Value. Como se explicó en la sección de construcción de señales, el numerador corresponde al Free Cash Flow disponible bajo el rezago contable definido, mientras que el denominador corresponde al Enterprise Value observado al cierre del mes anterior a la formación del portafolio.

A diferencia de LVOL, cuya señal se actualiza mensualmente por depender de retornos históricos, FCFEV se basa en información contable y de valoración que debe ser tratada con especial atención temporal para evitar sesgo de anticipación. En particular, el Free Cash Flow se incorpora bajo la regla de disponibilidad definida previamente: para enero–junio del año y , se utiliza información fiscal de $y-2$; y para julio–diciembre del año y , se utiliza información fiscal de $y-1$. El Enterprise Value se mide al cierre del mes anterior.

Una vez calculada la señal, las acciones se ordenan según su nivel de FCFEV, y se forman los seis portafolios 2×3 cruzando grupos de tamaño con grupos de señal. Posteriormente, el factor se define como una estrategia High minus Low:

$$FCFEV_t = \frac{1}{2}(R_{SH,t} + R_{BH,t}) - \frac{1}{2}(R_{SL,t} + R_{BL,t})$$

Bajo esta definición, el factor FCFEV será positivo cuando, en promedio, las compañías con mayor generación de flujo de caja libre relativo a su valor empresarial superen a las compañías con menor FCFEV. Esta forma funcional es coherente con la lógica de factores de valoración, en los cuales el retorno del factor se obtiene contrastando portafolios con señales extremas de la característica de interés.

En la estructura escalonada de la investigación, **FCFEV** se incorpora después de Momentum y Low Volatility, dando lugar a la especificación **FF8**.

3.7.5 Construcción del factor INT

El factor INT se construye a partir de la señal INTSIG, definida como la razón entre gasto en investigación y desarrollo e ingresos:

$$INT_{j,y} = \frac{R\&D_{j,y}}{Revenue_{j,y}}$$

Esta señal se calcula con información contable anual y se aplica bajo la convención julio–junio. En particular, la información fiscal del año $y - 1$ se utiliza para formar portafolios desde julio del año y hasta junio del año $y + 1$, respetando el rezago temporal definido para evitar look-ahead bias.

En cada fecha de formación anual, las empresas se clasifican en grupos **Small** y **Big** según tamaño, y en grupos **Low**, **Neutral** y **High** según la señal de intensidad intangible disponible para el ciclo correspondiente. A partir de esta clasificación se forman las seis carteras 2×3 y se calculan sus retornos mensuales ponderados por capitalización bursátil.

El factor **INT** se define como una estrategia **High minus Low**, es decir, como la diferencia entre el promedio de las carteras con alta intensidad intangible y el promedio de las carteras con baja intensidad intangible:

$$INT_t = \frac{1}{2}(R_{SH,t} + R_{BH,t}) - \frac{1}{2}(R_{SL,t} + R_{BL,t})$$

La interpretación económica es directa: el factor será positivo en aquellos meses en los que las empresas con alta intensidad intangible obtengan un mejor desempeño que las empresas con baja intensidad intangible, una vez controlado de manera básica el tamaño mediante la estructura 2×3 .

En la estructura escalonada de la investigación, **INT** se incorpora como el último factor adicional, dando lugar a la especificación **FF9**. Esta decisión permite evaluar si la intensidad intangible aporta capacidad explicativa incremental después de controlar por mercado, tamaño, value, rentabilidad, inversión, momentum, baja volatilidad y generación de caja relativa.

3.7.6 Temporalidad de los factores y frecuencia final de las series

La temporalidad de la construcción de los factores responde a la naturaleza de las señales utilizadas. En el caso de INT, al tratarse de una señal contable anual, la clasificación de las acciones se realiza una vez al año, al final de junio, y la composición de las carteras se mantiene vigente desde julio del año y hasta junio del año $y+1$. En el caso de FCFEV, aunque el componente contable del Free Cash Flow se actualiza con rezago fiscal, el ratio incorpora Enterprise Value rezagado mensualmente; por tanto, su señal puede reflejar variaciones mensuales derivadas del cambio en el valor empresarial, manteniendo siempre la regla de disponibilidad de información definida previamente. En el caso de LVOL, al tratarse de una señal de mercado basada en retornos históricos, la clasificación se actualiza mensualmente.

Estas diferencias no constituyen una inconsistencia metodológica. Por el contrario, reflejan que la frecuencia de actualización de cada factor debe ser coherente con la frecuencia y disponibilidad de la información que le da origen. Lo importante es que, en todos los casos, las señales utilizadas para formar portafolios respetan la información disponible antes del retorno que se pretende evaluar.

Todos los factores se expresan finalmente como series mensuales en formato `yyyymm`, de modo que puedan integrarse con los factores benchmark de Kenneth French y con los portafolios de prueba utilizados en la etapa de modelación. En otras palabras, la frecuencia mensual del dataset final no implica que todas las clasificaciones se formen mensualmente, sino que todos los factores quedan representados en el mismo calendario mensual de análisis.

3.7.7 Consideraciones sobre datos faltantes y cobertura

La construcción de factores depende de la disponibilidad simultánea de varias piezas de información. Para que una acción pueda entrar en una cartera en una fecha determinada, debe

contar con señal observable, medida de tamaño disponible y retorno mensual utilizable. En consecuencia, los valores faltantes reducen el número de empresas elegibles y pueden afectar tanto la estabilidad de los puntos de corte como la composición de las carteras extremas.

Este punto es especialmente relevante en señales contables como **INT** y **FCFEV**, donde la cobertura puede verse limitada por la ausencia de alguna variable fundamental para ciertas empresas o años. También puede afectar a **LVOL**, cuando la serie histórica de retornos no permite completar la ventana requerida de 12 meses para calcular la volatilidad rezagada. Por ello, el número de empresas elegibles en cada fecha de formación se interpreta como una condición relevante de calidad del factor: una cobertura baja puede traducirse en carteras menos diversificadas y, por tanto, en factores más sensibles a observaciones individuales.

Para preservar la consistencia metodológica, no se imputan señales faltantes de manera discrecional. Las compañías que no cuentan con la información requerida para una señal determinada en una fecha de formación específica no son incluidas en la construcción del factor correspondiente para ese período. Esta decisión evita introducir supuestos no observados en la formación de portafolios y mantiene la trazabilidad de la información utilizada.

3.7.8 Síntesis metodológica

En síntesis, la construcción de los factores propios sigue una secuencia clara. Primero, se parte de señales definidas de manera consistente con su naturaleza económica y temporal. Segundo, se clasifican las empresas en grupos **Small/Big** y **Low/Neutral/High** utilizando una estructura 2×3 inspirada en la metodología de Fama y French. Tercero, se calculan los retornos de las seis carteras mediante ponderación por capitalización bursátil. Finalmente, se obtiene cada factor como una diferencia entre carteras extremas: **Low minus High** para **LVOL**, y **High minus Low** para **FCFEV** e **INT**.

Esta estrategia permite que los factores propuestos conserven una lógica comparable a la de los factores clásicos de Fama y French, aun cuando su contenido económico sea distinto. En lugar de construir factores *ad hoc*, la metodología busca que cada uno de ellos pueda interpretarse como una extensión razonada de la arquitectura original de formación de portafolios 2×3 , manteniendo disciplina temporal, consistencia en los puntos de corte, uso de retornos ponderados por capitalización bursátil y control básico por tamaño.

3.8 Factor Zoo Screening y prueba de redundancia factorial

La literatura contemporánea de *asset pricing* ha documentado una amplia proliferación de factores y anomalías destinados a explicar la sección transversal de retornos esperados, fenómeno comúnmente asociado con el concepto de Factor Zoo. Sin embargo, no todos los factores documentados son necesariamente robustos, independientes o económicamente interpretables. Harvey et al. (2016) advierten que el elevado número de factores probados en la literatura incrementa el riesgo de *data mining* y exige criterios de validación más estrictos que los niveles tradicionales de significancia estadística. De manera similar, Hou et al. (2020) muestran que muchas anomalías pierden robustez al ser evaluadas bajo procedimientos empíricos más exigentes.

Por esta razón, la investigación incorpora una etapa de Factor Zoo Screening, entendida como un proceso de revisión y depuración de los factores candidatos antes de su incorporación al modelo escalonado. Esta etapa busca reducir el riesgo de selección arbitraria de factores y evaluar si cada candidato cuenta con fundamento económico, respaldo empírico, disponibilidad de datos, posibilidad de construcción replicable y potencial de aportar información incremental frente a las especificaciones existentes.

Como complemento a esta revisión conceptual y empírica, se aplica una prueba de redundancia factorial para determinar si cada factor candidato se encuentra *spanned* por los factores previamente incluidos.

Un factor se considera *spanned* cuando sus retornos pueden ser explicados por una combinación lineal de factores existentes, sin dejar un componente incremental estadísticamente significativo.

La prueba de redundancia factorial se interpreta a partir del alfa estimado en la regresión del factor candidato sobre los factores previamente incorporados. La regresión general de redundancia se define como:

$$F_{c,t} = \alpha_c + \sum_{k \in K_m} \gamma_{c,k} F_{k,t} + \varepsilon_{c,t}$$

donde $F_{c,t}$ es el factor candidato y $F_{k,t}$ representa cada uno de los factores ya incluidos en la especificación previa.

La hipótesis nula es:

$$H_0: \alpha_c = 0$$

Si el alfa no es estadísticamente distinto de cero, no existe evidencia suficiente de que el factor candidato aporte una prima incremental frente al conjunto de factores de control; por tanto, puede considerarse potencialmente redundante o *spanned* en términos de *pricing*. Esta conclusión no implica que el factor sea replicado perfectamente por los factores existentes, sino que su retorno promedio ajustado por dichas exposiciones no presenta un componente anormal significativo. Por el contrario, si el alfa es estadísticamente distinto de cero, el factor candidato presenta evidencia de una prima no explicada por los factores existentes y puede considerarse potencialmente *non-spanned*.

La prueba se aplica de manera escalonada, respetando el orden incremental definido para la investigación:

Tabla 3.10. Factores de control en las pruebas de redundancia factorial

Factor candidato	Factores de control
Momentum	FF5
Low Volatility	FF5 + Momentum
FCF/EV	FF5 + Momentum + Low Volatility
Intangible Intensity	FF5 + Momentum + Low Volatility + FCF/EV

Nota. La tabla indica los factores de control utilizados para evaluar el aporte incremental de cada factor candidato.

Esta etapa permite evaluar si los factores adicionales aportan información nueva antes de incorporarlos formalmente al modelo escalonado. No obstante, la decisión final de inclusión no se basa únicamente en la significancia estadística del alfa, sino también en la coherencia económica, estabilidad, correlación con otros factores y contribución posterior a la reducción de errores de pricing.

3.9 Especificación econométrica de los modelos FF3–FF9

La evaluación empírica se realiza mediante regresiones de series de tiempo aplicadas a los 25 portafolios Size $\times$ Book-to-Market. Para cada portafolio i , se estima una regresión del exceso de retorno mensual sobre los factores correspondientes a cada especificación.

El modelo general se define como:

$$R_{i,t} - R_{f,t} = \alpha_i + \sum_{k \in K_m} \beta_{i,k} F_{k,t} + \varepsilon_{i,t}$$

donde:

- $R_{i,t}$ es el retorno del portafolio i en el mes t .
- $R_{f,t}$ es la tasa libre de riesgo en el mes t .

$$R_{i,t}^e = R_{i,t} - R_{f,t}$$

- α_i es el intercepto o retorno anormal no explicado del portafolio i .
- $\beta_{i,k}$ mide la exposición del portafolio i al factor k .
- $F_{k,t}$ representa el factor k en el mes t , con k perteneciente al conjunto K_m

de factores incluidos en el modelo m .

- $\varepsilon_{i,t}$ es el término de error.

3.9.1 Modelo FF3

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,\text{MKT}}(\text{MKT-RF})_t + \beta_{i,\text{SMB}}\text{SMB}_t + \beta_{i,\text{HML}}\text{HML}_t + \varepsilon_{i,t}$$

3.9.2 Modelo FF5

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,\text{MKT}}(\text{MKT-RF})_t + \beta_{i,\text{SMB}}\text{SMB}_t + \beta_{i,\text{HML}}\text{HML}_t + \beta_{i,\text{RMW}}\text{RMW}_t \\ + \beta_{i,\text{CMA}}\text{CMA}_t + \varepsilon_{i,t}$$

3.9.3 Modelo FF6

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,\text{MKT}}(\text{MKT-RF})_t + \beta_{i,\text{SMB}}\text{SMB}_t + \beta_{i,\text{HML}}\text{HML}_t + \beta_{i,\text{RMW}}\text{RMW}_t \\ + \beta_{i,\text{CMA}}\text{CMA}_t + \beta_{i,\text{MOM}}\text{MOM}_t + \varepsilon_{i,t}$$

3.9.4 Modelo FF7

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,MKT}(MKT-RF)_t + \beta_{i,SMB}SMB_t + \beta_{i,HML}HML_t + \beta_{i,RMW}RMW_t \\ + \beta_{i,CMA}CMA_t + \beta_{i,MOM}MOM_t + \beta_{i,LVOL}LVOL_t + \varepsilon_{i,t}$$

3.9.5 Modelo FF8

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,MKT}(MKT-RF)_t + \beta_{i,SMB}SMB_t + \beta_{i,HML}HML_t + \beta_{i,RMW}RMW_t \\ + \beta_{i,CMA}CMA_t + \beta_{i,MOM}MOM_t + \beta_{i,LVOL}LVOL_t + \beta_{i,FCFEV}FCFEV_t + \varepsilon_{i,t}$$

3.9.6 Modelo FF9 completo

$$R_{i,t} - R_{f,t} = \alpha_i + \beta_{i,MKT}(MKT-RF)_t + \beta_{i,SMB}SMB_t + \beta_{i,HML}HML_t + \beta_{i,RMW}RMW_t \\ + \beta_{i,CMA}CMA_t + \beta_{i,MOM}MOM_t + \beta_{i,LVOL}LVOL_t + \beta_{i,FCFEV}FCFEV_t \\ + \beta_{i,INT}INT_t + \varepsilon_{i,t}$$

Esta estructura escalonada permite evaluar la contribución marginal de cada factor adicional en el siguiente orden: Momentum, Low Volatility, FCF/EV e Intangible Intensity.

3.10 Evaluación del desempeño del modelo

La comparación entre modelos se realiza utilizando un conjunto de métricas complementarias. El objetivo es evaluar no solo el ajuste estadístico, sino también la reducción de errores de pricing, la significancia económica de los factores y la robustez de la especificación.

3.10.1 Análisis de alfas

El alfa representa la porción del retorno promedio de un activo o portafolio que no es explicada por las exposiciones sistemáticas incluidas en el modelo. En el contexto de modelos de *asset pricing*, el alfa puede interpretarse como un error de pricing o retorno anormal ajustado por

riesgo. Por tanto, una especificación empíricamente adecuada debería producir alfas cercanos a cero y estadísticamente no significativos, indicando que los factores incluidos capturan de manera suficiente las fuentes sistemáticas de variación en los retornos esperados. Esta lógica se encuentra en la tradición de evaluación de desempeño iniciada por Jensen (1968), en la que el intercepto de la regresión mide el desempeño anormal ajustado por riesgo, y se extiende a la evaluación conjunta de modelos multifactoriales en trabajos como Fama y French (1993, 2015) y Gibbons et al. (1989), donde la significancia de los alfas constituye una prueba central de la capacidad explicativa del modelo.

En consecuencia, la investigación evalúa si la incorporación escalonada de factores adicionales reduce la magnitud y significancia de los alfas estimados para los portafolios de prueba. Una reducción sistemática de los alfas absolutos, junto con una menor proporción de alfas estadísticamente significativos, se interpreta como evidencia de mejora en la capacidad explicativa del modelo.

La investigación evalúa:

- alfa promedio;
- alfa absoluto promedio;
- número de alfas estadísticamente significativos;
- reducción de alfas al pasar de FF3/FF5 hacia FF9.

Una reducción sistemática de alfas al incorporar factores adicionales se interpreta como evidencia de mejora en la capacidad explicativa del modelo.

3.10.2 R^2 y R^2 ajustado

El R^2 mide la proporción de variación de los retornos explicada por los factores. Sin embargo, dado que la incorporación de factores adicionales puede aumentar mecánicamente el R^2 , la investigación presta especial atención al R^2 ajustado, el cual penaliza la inclusión de variables adicionales.

Una mejora en el R^2 ajustado sugiere que los factores adicionales aportan capacidad explicativa neta, más allá del efecto mecánico de aumentar el número de regresores.

3.10.3 Prueba GRS

La prueba de Gibbons et al. (1989) se utiliza para evaluar si los alfas de los portafolios de prueba son conjuntamente iguales a cero.

La hipótesis nula se define como:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_N = 0$$

donde N corresponde al número de portafolios de prueba.

La hipótesis alternativa de la prueba GRS establece que al menos uno de los alfas es estadísticamente distinto de cero; por tanto, un menor estadístico GRS y un mayor p-value sugieren una mejor capacidad del modelo para explicar los retornos de los portafolios de prueba. En este sentido, no rechazar H_0 implica que no existe evidencia estadística suficiente para afirmar que los alfas sean conjuntamente distintos de cero, lo que indica que el modelo no deja errores de pricing significativos en conjunto. En consecuencia, si el modelo FF9 presenta un menor estadístico GRS y un mayor p-value que el FF5 —especialmente si no se rechaza H_0 —, ello constituiría evidencia a favor de que los factores adicionales mejoran la capacidad

explicativa del modelo. Así, la prueba GRS es especialmente relevante porque evalúa el desempeño conjunto del modelo, no únicamente la significancia individual de cada alfa.

3.10.4 Análisis complementario de exposiciones factoriales del modelo FF9

Como complemento al análisis time-series, se examinan las exposiciones factoriales promedio estimadas para el modelo FF9. Este análisis no se plantea como un criterio adicional de selección entre modelos, sino como una herramienta interpretativa para caracterizar la estructura económica de la especificación ampliada. Dado que FF9 incorpora la totalidad de los factores considerados en el estudio, incluyendo los factores tradicionales de Fama-French, momentum y los factores adicionales construidos en esta investigación, su análisis permite observar qué dimensiones de riesgo o comportamiento sistemático presentan mayor incidencia promedio sobre los 25 portafolios evaluados.

Para ello, se calculan las betas promedio de cada factor a partir de las 25 regresiones time-series estimadas bajo la especificación FF9. Adicionalmente, se reporta el porcentaje de portafolios con betas positivas y el porcentaje de portafolios en los que dichas betas son estadísticamente significativas al 5%. Esta lectura permite complementar los resultados de alfas, R^2 ajustado y prueba GRS, al mostrar no solo si el modelo reduce errores de pricing, sino también qué factores concentran las exposiciones más relevantes dentro de la especificación final.

El análisis se restringe al modelo FF9 dado que los modelos evaluados son especificaciones anidadas o progresivas, una revisión detallada de betas para cada uno de ellos podría generar una lectura redundante y excesivamente extensa. En cambio, concentrar la interpretación en FF9 permite caracterizar la estructura factorial completa del modelo más amplio, que es justamente el espacio donde se observa el aporte conjunto de los factores

adicionales. No obstante, esta interpretación no sustituye la evaluación de primas de riesgo, la cual se desarrolla posteriormente mediante el segundo piso Fama-MacBeth.

3.11 Estimación de precios de riesgo mediante Fama–MacBeth

Además de las regresiones de series de tiempo, la investigación utiliza regresiones cross-section tipo Fama–MacBeth para estimar los precios de riesgo asociados a los factores.

En la primera etapa, se estiman las betas de cada portafolio frente a los factores del modelo. En la segunda etapa, estas betas se utilizan para explicar los retornos promedio o retornos mensuales transversales de los portafolios.

La regresión cross-section mensual se define como:

$$R_{i,t} - R_{f,t} = \lambda_{0,t} + \sum_{k=1}^K \lambda_{k,t} \hat{\beta}_{i,k} + u_{i,t}$$

Posteriormente, las lambdas se promedian en el tiempo:

$$\bar{\lambda}_k = \frac{1}{T} \sum_{t=1}^T \lambda_{k,t}$$

Las lambdas estimadas representan los precios de riesgo de los factores. Una lambda estadísticamente significativa indica que la exposición a dicho factor está asociada con una prima de retorno en la sección transversal de activos.

La interpretación de las lambdas se realiza considerando tanto su significancia estadística como su magnitud económica y coherencia con la teoría financiera.

3.12 Corrección de Shanken

La corrección de Shanken se incorpora como ajuste de robustez para la inferencia de las lambdas estimadas mediante el procedimiento Fama–MacBeth. Su importancia radica en que las betas utilizadas en la segunda etapa no son variables observadas directamente, sino coeficientes estimados previamente en las regresiones de series de tiempo. Por tanto, estas betas contienen error de estimación, el cual puede afectar los errores estándar de los precios de riesgo y conducir a una sobreestimación de su significancia estadística. Este ajuste se fundamenta en Shanken (1992), quien muestra que la inferencia en modelos beta-pricing debe reconocer que las betas utilizadas en la segunda etapa son parámetros estimados y, por tanto, incorporan una fuente adicional de incertidumbre.

Operativamente, esta investigación aplicará la corrección de Shanken ajustando los errores estándar de las lambdas estimadas en la segunda etapa, con el fin de incorporar la incertidumbre derivada del uso de betas estimadas como regresores. Este ajuste permite obtener una inferencia más conservadora sobre los precios de riesgo y reduce el riesgo de interpretar como estadísticamente significativas primas que podrían estar afectadas por error de medición en las exposiciones factoriales.

En consecuencia, la significancia estadística de las lambdas se evaluará directamente con errores estándar corregidos por Shanken. Una lambda se interpretará como más robusta cuando mantenga significancia estadística bajo esta corrección, presente una magnitud económica razonable y sea coherente con la interpretación teórica del factor correspondiente.

3.13 Diagnósticos de robustez y validación empírica

La investigación incorpora varias pruebas complementarias de robustez con el fin de evaluar la estabilidad y confiabilidad de los resultados.

3.13.1 Multicolinealidad y VIF

Dado que el modelo FF9 incorpora nueve factores, existe el riesgo de que algunos factores capturen información similar o estén altamente correlacionados. Para evaluar este riesgo, se analiza la matriz de correlación entre factores y se calcula el Variance Inflation Factor o VIF.

El VIF permite identificar si la varianza estimada de un coeficiente se encuentra inflada por la correlación con otros regresores. Valores elevados de VIF pueden indicar redundancia factorial o dificultad para interpretar de forma aislada la contribución de cada factor.

3.13.2 Tratamiento de valores extremos y decisión de no winsorización

En la especificación principal de la investigación no se aplica winsorización a las señales utilizadas para la formación de los factores propios. Esta decisión responde a dos criterios metodológicos. En primer lugar, la construcción de factores bajo una lógica cercana a la tradición de Fama-French se fundamenta principalmente en reglas de elegibilidad, ordenamiento transversal, breakpoints y formación de portafolios ponderados por valor, más que en la truncación sistemática de valores extremos de las señales. En segundo lugar, los valores extremos observados en variables contables o financieras pueden reflejar heterogeneidad económica genuina entre compañías, y no necesariamente errores de medición; por tanto,

recortarlos *ex ante* podría alterar artificialmente la asignación de firmas entre portafolios y modificar el contenido económico del factor construido.

Esta decisión es especialmente relevante en el contexto de factores como **FCF/EV** e **Intangible Intensity**, donde valores elevados o negativos pueden capturar situaciones económicas significativas, tales como alta generación relativa de caja, deterioro financiero, modelos de negocio intensivos en innovación, ciclos de inversión o diferencias estructurales entre compañías. En consecuencia, eliminar o truncar sistemáticamente estas observaciones podría reducir la capacidad del factor para capturar justamente la heterogeneidad que busca representar.

3.13.3 Potencia estadística y MDE

La investigación incorpora una aproximación al Minimum Detectable Effect —MDE— con el fin de evaluar la potencia estadística del diseño empírico en dos dimensiones centrales: la detección de errores de *pricing* agregados por especificación factorial, asociados a los alfas del modelo, y la detección de lambdas o precios de riesgo estimados mediante Fama–MacBeth. Este enfoque responde a que ambos parámetros están directamente vinculados con el aporte principal de la tesis: evaluar si las especificaciones factoriales reducen errores de valoración y si los factores incorporados presentan evidencia de primas de riesgo en la sección transversal.

En el primer nivel, el MDE se aplica a los alfas a nivel de modelo, con el propósito de estimar qué tan grande tendría que ser el error de *pricing* agregado para ser detectado estadísticamente bajo cada especificación factorial. Este análisis complementa la interpretación de los alfas y de la prueba GRS, al aportar una medida adicional de la capacidad inferencial de cada modelo para identificar errores de valoración económicamente relevantes.

En el segundo nivel, el MDE se aplica a las lambdas estimadas en la etapa *cross-section* de Fama–MacBeth. Esta evaluación permite estimar qué tan grande tendría que ser una prima de riesgo mensual para ser detectada estadísticamente bajo el diseño empírico utilizado. Así, una lambda no significativa no implica necesariamente ausencia de efecto económico; también puede indicar que la prima estimada se encuentra por debajo del umbral detectable dada la muestra, el número de portafolios, los grados de libertad disponibles y la variabilidad de las estimaciones.

En consecuencia, el análisis de potencia estadística y MDE se utiliza como una herramienta complementaria para interpretar con mayor cautela los resultados no significativos. En particular, permite evitar conclusiones excesivamente fuertes sobre la irrelevancia de una especificación o de un factor cuando el alfa agregado del modelo o la lambda estimada se ubican por debajo del tamaño mínimo detectable. De esta manera, la investigación diferencia entre ausencia de evidencia estadística suficiente y ausencia económica del efecto, fortaleciendo la interpretación de los resultados en las especificaciones FF3, FF5, FF6, FF7, FF8 y FF9.

3.13.4 Criterio de significancia reforzada bajo el umbral de Harvey $|t| > 3$

Como criterio adicional de robustez, la investigación incorpora el umbral de significancia reforzada propuesto por Harvey et al. (2016), según el cual, en el contexto del denominado *Factor Zoo*, los factores candidatos deberían superar un umbral aproximado de $|t| > 3$ para ser considerados estadísticamente robustos frente al riesgo de selección múltiple, *data mining* y proliferación de pruebas empíricas.

La motivación de este criterio surge de una preocupación central en la literatura contemporánea de *asset pricing*: el elevado número de factores y anomalías documentadas incrementa la probabilidad de encontrar resultados estadísticamente significativos por azar. Bajo este contexto, los niveles tradicionales de significancia, usualmente asociados a valores cercanos

a $|t| > 2$, pueden resultar insuficientes para validar nuevos factores cuando existe un amplio universo de hipótesis potencialmente evaluadas. Harvey et al. (2016) argumentan que, ante la proliferación de factores, se requieren estándares de significancia más exigentes para reducir el riesgo de falsos descubrimientos. Esta preocupación es consistente con la discusión del *Factor Zoo* y con estudios posteriores que documentan que muchas anomalías pierden robustez cuando son sometidas a filtros empíricos más estrictos (Cochrane, 2011; Hou et al., 2020).

En esta investigación, el criterio $|t| > 3$ no reemplaza las pruebas principales del modelo ni la interpretación económica de los factores, sino que se utiliza como un filtro complementario de robustez. En particular, se aplica para evaluar la fortaleza estadística de los resultados obtenidos en las pruebas de redundancia factorial y en la estimación de precios de riesgo mediante Fama–MacBeth. De esta manera, los coeficientes que superen el umbral de $|t| > 3$ se interpretan como evidencia estadística fuerte bajo un criterio conservador, mientras que aquellos con valores de $|t|$ entre 2 y 3 se consideran evidencia sugerente o significativa bajo criterios tradicionales, pero no necesariamente robusta frente al estándar reforzado de Harvey et al. (2016).

La incorporación de este umbral permite fortalecer la evaluación empírica de los factores propuestos, especialmente porque la tesis se inscribe en una literatura donde la selección de factores puede estar expuesta a problemas de redundancia, múltiples pruebas y sensibilidad muestral. Por tanto, este criterio contribuye a distinguir entre resultados estadísticamente fuertes, resultados moderados y evidencia no concluyente, evitando sobreinterpretar la significancia de factores que podrían responder a patrones específicos de la muestra.

3.13.5 Validación out-of-sample

Como prueba adicional de robustez, la investigación incorpora una validación fuera de muestra —out-of-sample— con el propósito de evaluar la estabilidad temporal y la capacidad de generalización de las especificaciones factoriales. Para ello, la ventana común principal, comprendida entre julio de 2014 y diciembre de 2025, se divide en dos subperíodos: un tramo in-sample entre julio de 2014 y diciembre de 2017, utilizado como período inicial de estimación, y un tramo out-of-sample entre enero de 2018 y diciembre de 2025, utilizado para evaluar el desempeño posterior de los modelos.

Esta división permite analizar si la mejora observada en las especificaciones ampliadas se mantiene en un período posterior al tramo inicial de estimación. La validación out-of-sample es especialmente relevante en modelos multifactoriales, dado que ayuda a mitigar el riesgo de sobreajuste. En este contexto, el sobreajuste se entiende como la posibilidad de que un modelo con mayor número de factores mejore su desempeño dentro de la muestra al capturar patrones particulares o ruido estadístico, sin que ello implique necesariamente una mejora genuina en su capacidad explicativa.

El ejercicio fuera de muestra no reemplaza la comparación principal realizada sobre la ventana común completa 201407–202512. Más bien, funciona como una prueba complementaria de robustez, orientada a verificar si las especificaciones con más factores conservan un desempeño relativo favorable cuando son evaluadas en un período posterior. Esta distinción es importante porque la evaluación principal permite comparar todos los modelos bajo una misma muestra homogénea, mientras que la validación out-of-sample aporta evidencia adicional sobre estabilidad temporal.

La selección del período 2018–2025 como muestra fuera de estimación ofrece, además, una prueba exigente desde el punto de vista económico y de mercado. Este tramo incluye episodios de alta volatilidad, shocks asociados a la pandemia de COVID-19, presiones inflacionarias, ajustes relevantes en tasas de interés, cambios en las condiciones monetarias y rotaciones entre estilos de inversión. Por tanto, si una especificación mantiene un desempeño relativo favorable en este período, ello fortalece su interpretación como un modelo con mayor capacidad de generalización y utilidad práctica para el análisis de portafolios.

La evaluación out-of-sample se realiza mediante métricas complementarias de desempeño, con énfasis en la reducción de alfas fuera de muestra, el alfa absoluto promedio, el R^2 ajustado fuera de muestra y la prueba GRS aplicada al tramo posterior. Asimismo, se compara el desempeño relativo de las especificaciones ampliadas frente al modelo FF5, que constituye el benchmark principal de la investigación. En particular, se presta especial atención a la comparación entre FF5 y FF9, dado que esta última representa la especificación completa propuesta por el estudio.

3.14 Implementación tecnológica

La implementación empírica del estudio se desarrolló principalmente en Python, usando una estructura reproducible basada en notebooks de ejecución secuencial y funciones reutilizables. El archivo de configuración centraliza las rutas de entrada, procesamiento y salida, lo que facilita la replicación del flujo en otro entorno de trabajo si se requiere. Se organiza el proceso por etapas: diagnóstico inicial de bases, construcción de señales propias, construcción de factores, modelación principal.

Las fuentes de datos se dividen en dos grupos. Por un lado, la información de Refinitiv Workspace se almacena como insumo bruto, que contiene los datos del universo de acciones,

retornos mensuales, capitalización bursátil mensual, enterprise value mensual, ingresos anuales, gasto en investigación y desarrollo anual, y flujo de caja libre anual. Por otro lado, desde la Kenneth R. French Data Library se utilizan los 25 portafolios $\text{Size} \times \text{Book-to-Market}$, los factores Fama-French de cinco factores, Momentum y la tasa libre de riesgo. Estas fuentes se integran posteriormente en Python para construir la base final de estimación.

En la etapa de diagnóstico se verifica la estructura, cobertura temporal, tipos de variables, faltantes y consistencia de los archivos base. Posteriormente, la información proveniente de Refinitiv se transforma desde estructuras anchas hacia paneles largos a nivel acción-mes. A partir de este panel se construyen las señales utilizadas para los factores propios: LVOL, FCF/EV e INT. La construcción de estas señales incorpora reglas temporales para evitar sesgo de anticipación. En particular, las señales contables se construyen con información fiscal rezagada y se utilizan para ordenar las acciones antes de observar los retornos de los meses posteriores. De esta manera, los retornos asignados a cada portafolio reflejan una decisión de formación basada únicamente en información disponible ex ante. Por su parte, LVOL se calcula con retornos históricos previos al mes de formación, evitando incorporar información contemporánea o futura.

Luego, para cada mes t , se realiza un ordenamiento transversal de las acciones con base en la señal factorial disponible antes de la formación del portafolio. A partir de este ordenamiento se conforman portafolios de alta y baja exposición a cada señal, se calculan sus retornos mensuales ponderados por capitalización bursátil y se construyen las series temporales de los factores propios. Posteriormente, estas series se integran con los factores benchmark y con los 25 portafolios $\text{Size} \times \text{Book-to-Market}$ de Kenneth French para generar la base final de estimación, almacenada en formatos reproducibles. Esta organización permite conservar los datos brutos,

documentar los productos intermedios y finales, y mantener trazabilidad entre fuentes, transformaciones y resultados.

Para la modelación, se utiliza la base final de datos para ejecutar las especificaciones FF3, FF5, FF6, FF7, FF8 y FF9. En esta etapa se calculan estadísticas descriptivas, diagnósticos de cobertura, correlación y multicolinealidad, regresiones time-series, prueba GRS, estimaciones Fama–MacBeth con corrección de Shanken, pruebas de redundancia factorial, validación out-of-sample, medidas de potencia estadística y métricas complementarias de robustez. Los resultados se exportan automáticamente, garantizando que las tablas y gráficos usados en el documento puedan ser reproducidos.

Este diseño permite separar claramente las responsabilidades del proyecto: los archivos Excel y CSV funcionan como insumos brutos; los notebooks orquestan cada etapa analítica; y los módulos de funciones concentran la lógica reutilizable. Con ello, el estudio mantiene trazabilidad, evita cálculos manuales dispersos, reduce el riesgo de errores por manipulación directa de datos y facilita que la construcción de señales, factores y modelos econométricos sea auditable y reproducible.

3.15 Alcance metodológico de los resultados

Los resultados de la investigación deben interpretarse dentro del alcance definido por la metodología. En primer lugar, la comparación principal entre modelos se basa en una ventana común estricta, lo que permite evaluar de manera homogénea la contribución incremental de los factores. En segundo lugar, los factores propios se construyen a partir de un universo muestral depurado de acciones estadounidenses con información financiera suficiente, continuidad de precios y liquidez mínima. Por tanto, los resultados asociados a estos factores no deben

interpretarse como una caracterización exhaustiva de todo el mercado accionario estadounidense, sino como evidencia empírica dentro del universo definido.

Asimismo, la incorporación de factores adicionales se evalúa bajo criterios de parsimonia, incrementalidad y robustez. Una mejora en el ajuste estadístico no será interpretada automáticamente como evidencia de superioridad del modelo; deberá estar acompañada de reducción de alfas, mejora en pruebas conjuntas, significancia económica de las lambdas, ausencia de redundancia excesiva y estabilidad bajo pruebas complementarias.

De esta manera, la metodología busca construir una evaluación integral del modelo propuesto, combinando fundamentos teóricos, construcción rigurosa de factores, control temporal de información, pruebas econométricas y análisis de robustez. El objetivo final es determinar si la extensión escalonada hacia FF9 mejora la explicación de retornos accionarios frente al modelo FF5, sin incurrir en acumulación indiscriminada de factores ni fragilidad econométrica.

Capítulo 4. Resultados empíricos

4.1 Estadística descriptiva de los factores

El análisis descriptivo se realiza sobre la muestra común usada en la modelación principal, comprendida entre 201407 y 202512, con **138** observaciones mensuales. Esta ventana garantiza que los 25 portafolios dependientes y los nueve factores explicativos estén disponibles simultáneamente, evitando que la comparación entre modelos se vea afectada por diferencias de cobertura temporal.

Tabla 4.1. Cobertura temporal de factores y definición de muestra común

Bloque	Variables	Cobertura histórica	Faltantes históricos	Uso en ventana común
Factores FF + momentum	MKT_RF, SMB, HML, RMW, CMA, MOM	196307–202601	0.0%	Completo
LVOL	LVOL	200603–202512	68.3%	Completo
FCFEV	FCFEV	201207–202512	78.4%	Completo
INT	INT	201407–202512	81.6%	Completo
Ventana común final	25 portafolios + 9 factores	201407–202512	0.0% en la muestra	138 meses

Nota. La tabla resume la disponibilidad temporal de los factores y la ventana común empleada en la estimación principal.

La restricción principal de la muestra proviene de los factores propios añadidos al modelo, especialmente INT, cuya disponibilidad inicia en 201407. Por esta razón, aunque los factores tradicionales de Fama-French y momentum tienen una historia mucho más extensa, la muestra principal se fija desde 201407 para asegurar una comparación homogénea entre FF3, FF5, FF6, FF7, FF8 y FF9.

Tabla 4.2. Estadísticas descriptivas de los factores

Factor	Media mensual (%)	Desv. est. mensual (%)	P5	P95	Atípicos IQR (%)
MKT_RF	0.99	4.41	-7.03	7.64	4.35
SMB	-0.23	2.95	-4.37	4.78	4.35
HML	-0.15	3.66	-4.80	6.80	4.35
RMW	0.27	2.10	-2.85	3.36	3.62
CMA	-0.11	2.32	-3.14	3.75	3.62
MOM	0.18	3.85	-6.00	5.46	1.45
LVOL	-0.67	4.08	-7.04	5.41	4.35
FCFEV	0.00	2.47	-3.93	3.37	1.45

Factor	Media mensual (%)	Desv. est. mensual (%)	P5	P95	Atípicos IQR (%)
INT	0.93	3.64	-5.50	6.50	3.62

Nota. Los estadísticos se reportan en porcentaje mensual para la muestra común 201407-202512.

Los factores con mayor media mensual en la muestra son mkt_rf e INT, ambos cercanos a 1% mensual. En contraste, LVOL tiene media negativa de -0.67% mensual y una volatilidad elevada, lo que anticipa que su aporte debe evaluarse con cuidado en la etapa econométrica. Los factores más volátiles son mkt_rf, LVOL y mom, coherente con el hecho de que capturan dimensiones de riesgo o anomalías con mayor dispersión mensual.


Tabla 4.3. Portafolios 5x5: media y volatilidad mensual

	Low	2	3	4	High
Small	0.49 / 7.97	0.70 / 6.72	0.66 / 6.34	0.58 / 6.14	1.05 / 7.28
2	0.78 / 7.00	0.93 / 6.12	0.78 / 6.09	0.71 / 6.10	0.74 / 7.09
3	0.75 / 6.05	0.78 / 5.44	0.66 / 5.43	0.67 / 6.09	0.72 / 7.20
4	0.85 / 5.23	0.85 / 5.11	0.84 / 5.18	0.78 / 5.91	0.67 / 6.64
Big	1.32 / 4.75	0.92 / 4.07	0.73 / 4.34	0.68 / 4.92	1.19 / 6.64

Nota. Cada celda reporta media mensual (%) / desviación estándar mensual (%).

Los portafolios muestran heterogeneidad tanto en retorno promedio como en volatilidad. El portafolio Big–Low registra la mayor media mensual, 1.32%, mientras que Small–Low presenta la menor media, 0.49%, y además la mayor volatilidad, 7.97%. En general, los portafolios de menor tamaño tienden a exhibir mayor dispersión, lo que confirma que la dimensión Size sigue siendo relevante para caracterizar el comportamiento de los retornos.

Figura 4.1. Distribución y datos atípicos de los factores



Nota. Figura generada en Python a partir de los retornos mensuales de los factores del modelo. Los valores atípicos se conservan por corresponder a realizaciones efectivas del mercado.

Como se observa en la Figura 4.1, los factores presentan episodios extremos, especialmente en `mkt_rf`, `LVOL`, `hml` y `mom`. Sin embargo, estos valores no se eliminan ni se winsorizan, porque corresponden a realizaciones mensuales efectivas de los factores y pueden reflejar periodos de estrés o cambios relevantes en el mercado. Por tanto, los atípicos se documentan como parte del diagnóstico descriptivo, pero se conservan para la modelación econométrica posterior.


4.2 Diagnóstico de correlación factorial y multicolinealidad

4.2.1 Matriz de correlación entre factores

Para evaluar si los factores incluidos capturan dimensiones suficientemente diferenciadas, se estimó la matriz de correlaciones entre los nueve factores: `mkt_rf`, `smb`, `hml`, `rmw`, `cma`, `mom`, `LVOL`, `FCFEV` e `INT`. El diagnóstico se realiza

sobre la muestra común 201407–202512, que corresponde a la ventana en la cual todos los factores están disponibles simultáneamente.

Figura 4.2. Mapa de calor de correlaciones entre factores



Nota. Figura generada en Python a partir de la matriz de correlaciones de los factores del modelo. Las asociaciones identifican relaciones lineales relevantes sin evidenciar dependencia extrema entre factores.

Tabla 4.4. Correlaciones factoriales más relevantes

Par de factores	Correlación
HML – CMA	0.630
MKT_RF – LVOL	-0.628
HML – INT	-0.558
CMA – INT	-0.531
MOM – LVOL	0.489
HML – FCFEV	0.484
SMB – LVOL	-0.449
LVOL – INT	-0.443
SMB – MOM	-0.418
CMA – FCFEV	0.402

Nota. La tabla muestra los pares de factores con las correlaciones más relevantes para el diagnóstico de redundancia.

Las correlaciones (Figura 4.2) no evidencian una dependencia extrema entre factores, aunque sí aparecen asociaciones económicamente relevantes. La mayor correlación positiva se observa entre hml y cma con 0.630, lo cual es razonable porque ambos factores pueden capturar dimensiones relacionadas con empresas de valor, inversión conservadora y características contables. También se observa una correlación negativa importante entre mkt_rf y LVOL de -0.628, lo que sugiere que el factor de baja volatilidad tiende a comportarse de forma defensiva frente al mercado.

En cuanto a los factores propuestos, INT presenta correlaciones (Tabla 4.4) negativas con HML (-0.558), CMA (-0.531), LVOL (-0.443) y FCFEV (-0.394). Esto indica que INT no parece ser una simple réplica lineal de los factores existentes, aunque sí comparte parte de la variación con dimensiones de valor, inversión y baja volatilidad. Por su parte, FCFEV tiene correlaciones moderadas con hml y cma, lo cual es consistente con su naturaleza de señal fundamental basada en flujo de caja libre frente al valor de la empresa.

4.2.2 Diagnóstico de multicolinealidad mediante Variance Inflation Factor — VIF

Además de revisar correlaciones bivariadas, se estimó el Variance Inflation Factor — VIF para cada factor. El VIF mide cuánto aumenta la varianza estimada de un coeficiente como consecuencia de su relación lineal con los demás regresores. Valores cercanos a 1 indican baja colinealidad; valores superiores a 5 suelen considerarse una señal de alerta moderada y valores superiores a 10 indican multicolinealidad severa.

Tabla 4.5. Diagnóstico VIF de los factores FF9

Factor	VIF
MKT_RF	1.826
SMB	1.825

Factor	VIF
HML	2.574
RMW	1.597
CMA	2.063
MOM	1.744
LVOL	3.245
FCFEV	1.377
INT	2.213

Nota. Valores VIF inferiores a 5 sugieren ausencia de multicolinealidad severa bajo el criterio aplicado.

Los resultados del VIF no muestran evidencia de multicolinealidad severa. Todos los factores tienen VIF inferiores a 5, y el valor máximo corresponde a LVOL, con 3.245. Esto implica que, aunque LVOL presenta correlaciones moderadas con otros factores, especialmente con mkt_rf, mom e INT, su inclusión no genera un problema crítico de redundancia lineal dentro de la especificación FF9.

4.2.3 Implicaciones para la especificación de un modelo con 9 factores

El diagnóstico conjunto de correlaciones y VIF sugiere que la especificación FF9 es estadísticamente viable. Aunque existen relaciones moderadas entre algunos factores, especialmente entre hml–cma, mkt_rf–LVOL, hml–INT y cma–INT, estas asociaciones no alcanzan niveles que invaliden la estimación conjunta del modelo.

La ausencia de alertas por VIF indica que los nueve factores pueden incorporarse simultáneamente sin generar un problema severo de identificación de coeficientes. Esto es importante para el objetivo del trabajo, porque permite evaluar si los factores adicionales — LVOL, FCFEV e INT— aportan información incremental frente a las especificaciones tradicionales de Fama-French y momentum.

El diagnóstico previo no recomienda excluir factores por multicolinealidad. Por tanto, la especificación FF9 puede avanzar a la etapa de estimación econométrica manteniendo los nueve factores definidos.

4.3 Resultados de regresiones time-series FF3–FF9

4.3.1 Propósito del análisis time-series

La evaluación empírica se realiza mediante regresiones de series de tiempo aplicadas a los 25 portafolios Size $\times$ Book-to-Market. Para cada portafolio i , se estima una regresión del exceso de retorno mensual sobre los factores correspondientes a cada especificación.

$$R_{i,t} - R_{f,t} = \alpha_i + \sum_{k \in K_m} \beta_{i,k} F_{k,t} + \varepsilon_{i,t}$$

donde el exceso de retorno se define como:

$$R_{i,t}^e = R_{i,t} - R_{f,t}$$

En esta expresión, $R_{i,t}$ representa el retorno mensual del portafolio i en el mes t , $R_{f,t}$ corresponde a la tasa libre de riesgo del mismo periodo y $R_{i,t}^e$ es el retorno del portafolio por encima de dicha tasa libre de riesgo. A su vez, $F_{k,t}$ representa cada factor incluido en la especificación evaluada, α_i mide el retorno anormal promedio del portafolio que no es explicado por los factores, $\beta_{i,k}$ captura la exposición del portafolio i al factor k , y $\varepsilon_{i,t}$ corresponde al término de error.

En este contexto, un modelo factorial más adecuado debería reducir la magnitud de los alfas, aumentar el poder explicativo de las regresiones y no rechazar la hipótesis conjunta de que todos los alfas son iguales a cero mediante la prueba GRS.

4.3.2 Alfas, errores de pricing, prueba GRS y cambios incrementales frente al modelo anterior y al benchmark FF5

Tabla 4.6. Resultados agregados de regresiones time-series

Modelo	Alfa abs. promedio	Alfas sig. 5%	R ² promedio	R ² ajustado prom.	GRS	p-valor GRS
FF3	0.113	8.0%	0.918	0.916	1.251	0.214
FF5	0.121	12.0%	0.926	0.923	1.291	0.185
FF6	0.118	12.0%	0.926	0.923	1.264	0.204
FF7	0.112	8.0%	0.929	0.925	1.184	0.271
FF8	0.113	8.0%	0.931	0.927	1.246	0.219
FF9	0.094	8.0%	0.934	0.929	1.046	0.418

Nota. Los alfas están expresados en porcentaje mensual; el porcentaje de alfas significativos se calcula sobre los 25 portafolios.

Los resultados muestran que todos los modelos presentan una alta capacidad explicativa en las regresiones time-series, con R² promedio superior a 0.91 en todos los casos. Esto indica que las especificaciones factoriales explican una proporción elevada de la variación mensual de los retornos de los portafolios.

La especificación FF9 presenta el mejor desempeño agregado dentro del conjunto evaluado. Este modelo registra el menor alfa absoluto promedio, con 0.094% mensual, y el mayor R² promedio, con 0.934. También obtiene el mayor R² ajustado promedio, 0.929, lo cual es importante porque esta métrica penaliza la inclusión de factores adicionales. Por tanto, la mejora de FF9 no se explica únicamente por agregar más regresores, sino que se mantiene incluso después de ajustar por complejidad del modelo.

La prueba GRS tampoco rechaza la hipótesis conjunta de alfas iguales a cero en ninguna especificación, dado que todos los p-valores son superiores a 0.05. No obstante, el resultado más

favorable corresponde nuevamente a FF9, con un p-valor GRS de 0.418, el más alto entre los modelos comparados. Esto no prueba que FF9 sea el modelo verdadero, pero sí indica que, dentro de esta muestra, es la especificación con menor evidencia estadística en contra de la hipótesis de ausencia de errores de valoración conjunta.

Un resultado puntual a destacar es que, en esta muestra, el alfa absoluto promedio de FF3 es ligeramente inferior al de FF5. Este patrón no invalida la especificación FF5, sino que evidencia que la incorporación de factores adicionales no reduce mecánicamente los errores de pricing en todas las ventanas muestrales. Para el período 201407-202512 y los portafolios evaluados, RMW y CMA no generan por sí solos una mejora inmediata en alfa absoluto promedio, lo que refuerza la pertinencia de evaluar las especificaciones de manera escalonada y empírica.

Tabla 4.7. Cambios incrementales frente al modelo anterior y frente al benchmark FF5

Modelo	Delta alfa abs. vs. modelo anterior	Delta R ² ajustado vs. modelo anterior	Delta alfa abs. vs. FF5	Delta R ² ajustado vs. FF5	Reducción alfa vs. FF5
FF5	—	—	0.000	0.000	0.0%
FF6	-0.002	-0.000	-0.002	-0.000	1.7%
FF7	-0.007	0.002	-0.009	0.002	7.2%
FF8	0.001	0.001	-0.008	0.004	6.4%
FF9	-0.019	0.002	-0.027	0.006	22.2%

Nota. Los cambios se calculan sobre la misma ventana común 201407-202512 para preservar comparabilidad.

La comparación incremental se realiza tomando como referencia el modelo **FF5**, que constituye el benchmark principal del estudio. La métrica central de esta evaluación es el **alfa**

absoluto promedio, dado que en un modelo de valoración de activos el objetivo principal es reducir los errores de pricing no explicados por los factores. En este sentido, un modelo más adecuado debería producir alfas más cercanos a cero, manteniendo una especificación estadísticamente defendible.

Los resultados muestran que la incorporación de factores adicionales no genera una mejora mecánica ni uniforme. Al pasar de **FF5 a FF6**, la inclusión de momentum reduce marginalmente el alfa absoluto promedio, pero la mejora es pequeña. La incorporación de **LVOL** en FF7 produce una reducción adicional de los errores de pricing, mientras que **FCFEV**, al incorporarse en FF8, no mejora el alfa frente al modelo inmediatamente anterior, aunque la especificación sigue mostrando un alfa promedio inferior al benchmark FF5.

El cambio más relevante ocurre con la inclusión de **INT** en FF9. Frente a FF8, el alfa absoluto promedio se reduce en **0.019 puntos porcentuales mensuales**. Más importante aún, frente al benchmark **FF5**, FF9 reduce el alfa absoluto promedio en aproximadamente **22.2%**. Esta es la mejora económicamente más relevante del bloque time-series, porque indica que la especificación de nueve factores deja una menor proporción de retorno promedio sin explicar en los 25 portafolios evaluados.

El R^2 ajustado se usa como criterio complementario, dado que penaliza la inclusión de factores adicionales. En este caso, FF9 también mejora frente a FF5, lo que sugiere que la reducción de alfas no se obtiene a costa de una pérdida de ajuste penalizado. Sin embargo, la conclusión principal no descansa en el aumento del R^2 , sino en la reducción de errores de pricing y en que la prueba GRS no rechaza la hipótesis conjunta de alfas iguales a cero.

En conjunto, los resultados del primer piso indican que **FF9 es la especificación más favorable frente al benchmark FF5**, principalmente porque reduce de manera más clara los

errores de valoración promedio. Esta evidencia respalda la pertinencia de mantener los factores adicionales en la evaluación posterior, aunque la confirmación de si estos factores están asociados a primas de riesgo significativas corresponde al segundo piso mediante Fama-MacBeth.

4.3.3 Betas promedio y sensibilidad factorial de los portafolios bajo FF9

Tabla 4.8. Exposiciones promedio estimadas en FF9

Factor	β promedio	β positivas	β sig. 5%
MKT-RF	1.001	100.0%	100.0%
SMB	0.607	80.0%	92.0%
HML	0.177	64.0%	84.0%
RMW	-0.131	36.0%	48.0%
CMA	-0.029	32.0%	28.0%
MOM	0.000	48.0%	12.0%
LVOL	-0.017	48.0%	24.0%
FCFEV	0.059	72.0%	24.0%
INT	-0.045	32.0%	44.0%

Nota. Las betas corresponden al promedio transversal de las exposiciones estimadas sobre los 25 portafolios.

Las betas reportadas en la Tabla 4.8 corresponden al promedio transversal de las exposiciones estimadas en las 25 regresiones time-series del modelo FF9. Es decir, para cada factor se estima una beta individual por portafolio y luego se calcula el promedio de esas 25 betas. Por tanto, la beta promedio resume la sensibilidad media de los portafolios ante variaciones mensuales de cada factor. Una beta positiva indica que, en promedio, los portafolios se mueven en la misma dirección del factor; una beta negativa indica una relación inversa. La

columna de significancia muestra el porcentaje de portafolios en los que dicha exposición es estadísticamente distinta de cero al 5%.

El factor **MKT-RF** presenta una beta promedio de 1.001 y es significativo en el 100% de los portafolios. Esto confirma que el riesgo de mercado es la principal fuente común de variación de los excesos de retorno. En términos económicos, un aumento de 1 punto porcentual mensual en el exceso de retorno del mercado se asocia, en promedio, con un aumento cercano a 1 punto porcentual en el exceso de retorno de los portafolios. La magnitud cercana a uno y la significancia universal validan que los activos de prueba tienen una exposición sistemática fuerte al mercado.

El factor SMB tiene una beta promedio de 0.607 y es significativo en el 92% de los portafolios. La magnitud positiva indica que, en promedio, los portafolios tienen una exposición importante al factor tamaño. Esto es coherente con la construcción de los activos de prueba, dado que los portafolios están ordenados por tamaño y book-to-market. La alta proporción de significancia muestra que la dimensión Size no es marginal, sino una fuente estructural de variación en los retornos.

El factor HML presenta una beta promedio de 0.177 y significancia en el 84% de los portafolios. Aunque su magnitud es menor que la de MKT-RF y SMB, su alta frecuencia de significancia indica que la dimensión valor conserva poder explicativo dentro de la especificación FF9. En promedio, los portafolios tienden a estar positivamente expuestos al factor value, lo cual es consistente con el uso de portafolios formados por book-to-market.

El factor RMW muestra una beta promedio de -0.131 y es significativo en el 48% de los portafolios. El signo negativo sugiere que, en promedio, los portafolios analizados se relacionan inversamente con el factor de rentabilidad operativa robusta. La significancia cercana a la mitad

de los portafolios indica que su efecto no es uniforme, pero sí aparece en una fracción relevante de los activos de prueba. Por tanto, RMW aporta información, aunque con una incidencia transversal menos generalizada que MKT-RF, SMB o HML.

El factor CMA tiene una beta promedio de -0.029 y significancia en el 28% de los portafolios. Su magnitud promedio es reducida, lo que indica que la exposición media a la dimensión inversión es limitada dentro de esta muestra. Además, el bajo porcentaje de significancia sugiere que su influencia se concentra en un subconjunto específico de portafolios y no constituye una exposición dominante en el conjunto total de activos.

El factor MOM presenta una beta promedio prácticamente nula, 0.000, y solo es significativo en el 12% de los portafolios. Esto indica que, dentro de la especificación FF9 y en esta ventana temporal, momentum no genera una exposición promedio sistemática en los portafolios evaluados. Su efecto puede existir en portafolios particulares, pero no aparece como una dimensión transversal dominante en las regresiones time-series.

El factor LVOL muestra una beta promedio de -0.017 y significancia en el 24% de los portafolios. La magnitud promedio es pequeña y el signo negativo sugiere una relación inversa débil con los retornos de los portafolios. La baja proporción de significancia indica que la exposición a baja volatilidad no se manifiesta de forma generalizada en los 25 portafolios, aunque puede ser relevante para segmentos específicos.

El factor FCFEV presenta una beta promedio de 0.059 y es significativo en el 24% de los portafolios. El signo positivo indica que, en promedio, los portafolios tienden a moverse en la misma dirección que el factor de flujo de caja libre sobre valor de empresa. Sin embargo, la magnitud moderada y la baja proporción de significancia muestran que su efecto no es

transversalmente amplio. Esto sugiere que FCFEV puede capturar información fundamental específica, pero no constituye una exposición dominante para todos los portafolios.

Finalmente, el factor INT registra una beta promedio de -0.045 y significancia en el 44% de los portafolios. Aunque la magnitud promedio no es alta, el porcentaje de significancia es relevante frente a otros factores añadidos como LVOL y FCFEV. El signo negativo indica que, en promedio, los portafolios tienen una relación inversa con el factor de intensidad. Esto sugiere que INT captura una dimensión diferenciada que no afecta de manera homogénea a todos los portafolios, pero sí tiene incidencia estadística en una parte importante de ellos.

Las betas promedio muestran que la estructura de exposición del modelo FF9 sigue dominada por los factores tradicionales MKT-RF, SMB y HML. Sin embargo, los factores adicionales no son irrelevantes: especialmente INT, y en menor medida FCFEV y LVOL, capturan variaciones específicas que contribuyen a reducir errores de pricing en el primer piso. La lectura correcta no es que todos los factores deban tener betas grandes y significativas en todos los portafolios, sino que algunos factores pueden aportar información incremental al mejorar la capacidad del modelo para explicar los retornos y reducir alfas residuales.

4.4. Prueba de redundancia factorial

La prueba de redundancia factorial, o spanning test, evalúa si un factor nuevo contiene información incremental frente a los factores ya existentes. Para ello, cada factor agregado se regresa sobre el conjunto de factores previamente incluidos. La hipótesis relevante se interpreta a partir del intercepto α : si el intercepto no es estadísticamente distinto de cero, el factor puede considerarse explicado por los factores existentes; si el intercepto es significativo, el factor no está completamente cubierto por ellos.

Tabla 4.9. Pruebas de spanning para factores adicionales

Factor	α	$t(\alpha)$	p-valor	R ²	¿Redundante?
MOM	0.363	1.468	0.142	0.320	Sí
LVOL	-0.474	-2.376	0.017	0.640	No
FCFEV	0.094	0.683	0.495	0.267	Sí
INT	0.576	2.390	0.017	0.548	No

Nota. La prueba evalúa si cada factor candidato conserva información incremental frente a los factores de control.

Los resultados indican que mom y FCFEV no presentan interceptos estadísticamente significativos en sus pruebas de spanning. Esto sugiere que, en esta muestra, estos factores pueden ser explicados en buena medida por las combinaciones de factores previamente incluidas. Por esta razón, se clasifican como factores redundantes desde el punto de vista del spanning test.

En contraste, LVOL e INT presentan interceptos estadísticamente significativos. Esto implica que dichos factores no quedan completamente explicados por los factores existentes y, por tanto, contienen información incremental en su serie de retornos factoriales.

El resultado de INT es particularmente importante porque su prueba de spanning se realiza frente al conjunto más exigente de factores existentes: mkt_rf, smb, hml, rmw, cma, mom, LVOL y FCFEV. Es decir, INT no se evalúa únicamente frente al modelo base FF5, sino frente a una especificación ya ampliada de ocho factores. Aun en ese contexto, el intercepto de INT es positivo y estadísticamente significativo, con $\alpha = 0.576$, $t(\alpha) = 2.390$ y p-valor de 0.017. Esto indica que INT no queda absorbido por los factores tradicionales ni por los factores adicionales previamente incorporados.

Por tanto, la inclusión de INT en la especificación FF9 tiene sustento empírico desde la prueba de redundancia factorial: el factor aporta una dimensión de variación que no está completamente replicada por los otros ocho factores. Esta evidencia es relevante para el trabajo

porque muestra que INT no se comporta simplemente como una combinación lineal de factores ya conocidos, sino como una señal factorial con contenido incremental. En consecuencia, su incorporación en FF9 está justificada para evaluar si dicha información adicional contribuye a reducir errores de pricing y mejorar la capacidad explicativa del modelo.

4.5. MDE y potencia estadística en la detección de alfas

Para complementar la lectura de los alfas time-series, se calcula el minimum detectable effect (MDE). Esta métrica indica el tamaño mínimo de alfa mensual que el estudio puede detectar con un nivel determinado de potencia estadística. En este caso, se reportan umbrales para 80% y 90% de potencia, usando la aproximación:

$$MDE_{\alpha} = (z_{1-\alpha/2} + z_{1-\beta}) \times SE(\hat{\alpha})$$

Tabla 4.10. MDE para alfas time-series por modelo

Modelo	Alfa abs. promedio	MDE alfa 80% promedio	MDE alfa 90% promedio
FF3	0.113	0.375	0.433
FF5	0.121	0.358	0.415
FF6	0.118	0.356	0.412
FF7	0.112	0.352	0.407
FF8	0.113	0.351	0.406
FF9	0.094	0.337	0.390

Nota. Los valores MDE se expresan como alfa mensual mínimo detectable bajo los niveles de potencia reportados.

La tabla muestra que los alfas absolutos promedio son considerablemente menores que los MDE promedio. Por ejemplo, en FF9 el alfa absoluto promedio es 0.094% mensual, mientras que el MDE promedio para 80% de potencia es 0.337% mensual y para 90% de potencia es 0.390% mensual. Esto significa que, con la muestra disponible, el estudio tiene mayor capacidad para detectar alfas mensuales relativamente grandes, pero menor potencia para detectar errores de pricing pequeños.

Este resultado es relevante para evitar una interpretación excesiva de la no significancia individual de algunos alfas. Que un alfa no sea estadísticamente significativo no implica necesariamente que sea exactamente cero; puede ser que su magnitud esté por debajo del umbral que la muestra permite detectar con alta potencia. Por eso, el MDE funciona como una medida de sensibilidad inferencial: indica qué tan grandes tendrían que ser los errores de pricing para que el diseño empírico los detecte de forma confiable.

Desde el punto de vista comparativo, FF9 presenta el menor alfa absoluto promedio y también el menor MDE promedio para alfas, lo cual es favorable. La lectura conjunta es que FF9 no solo reduce los errores de pricing promedio, sino que también mantiene una sensibilidad estadística ligeramente mejor para detectar alfas frente a las especificaciones anteriores.

4.6 Resultados Fama-MacBeth y precios de riesgo

En el segundo piso se estiman las primas de riesgo λ_k mediante el procedimiento Fama-MacBeth. A diferencia del primer piso, donde las regresiones time-series evalúan si los factores explican los retornos de los portafolios, el segundo piso evalúa si las exposiciones estimadas a dichos factores son remuneradas en el corte transversal.

En este contexto, λ_k representa el precio de riesgo asociado al factor k . Dado que las series están expresadas en porcentaje mensual, los lambdas también se interpretan como

porcentaje mensual. Un λ_k positivo indica que, en promedio, una mayor exposición al factor se asocia con mayor retorno esperado; un λ_k negativo indica lo contrario.

4.6.1 Corrección de Shanken

La estimación Fama-MacBeth utiliza betas estimadas en el primer piso como regresores en el segundo piso. Por esta razón, los errores estándar convencionales pueden subestimar la incertidumbre, ya que no incorporan completamente el error de medición asociado a las betas. Para corregir este problema, se reportan errores estándar con corrección de Shanken, lo que produce una inferencia más conservadora sobre las primas de riesgo.

Tabla 4.11. Primas de riesgo Fama-MacBeth del modelo FF9 con corrección de Shanken

Factor	λ mensual (%)	SE(λ) Shanken	t(λ)	p – valor	Sig. 5%
MKT-RF	0.312	0.561	0.556	0.579	No
SMB	-0.284	0.269	-1.053	0.294	No
HML	-0.135	0.425	-0.319	0.750	No
RMW	0.201	0.309	0.649	0.518	No
CMA	0.004	0.297	0.012	0.990	No
MOM	0.262	0.655	0.400	0.690	No
LVOL	-0.270	0.558	-0.484	0.629	No
FCFEV	0.232	0.524	0.443	0.658	No
INT	1.090	0.489	2.228	0.028	Sí

Nota. Los lambdas se expresan en porcentaje mensual y los errores estándar incorporan la corrección de Shanken.

Los resultados del modelo FF9 muestran que la única prima de riesgo estadísticamente significativa al 5% bajo corrección de Shanken es INT. Su λ estimado es 1.090% mensual, con $t = 2.228$ y p-valor de 0.028. Esto indica que, dentro de la especificación completa de nueve

factores, una mayor exposición al factor INT se asocia con una prima positiva en el corte transversal de retornos.

El resto de factores no presenta significancia estadística al 5% en el segundo piso. Esto no significa que sean irrelevantes para explicar retornos en el primer piso, sino que sus exposiciones no se traducen en primas de riesgo estadísticamente distinguibles de cero en esta muestra.

La distinción entre ambos pisos de estimación es fundamental. En el primer piso, el aporte del modelo se evalúa por su capacidad para reducir errores de pricing, es decir, por la disminución de los alfas time-series. En este sentido, FF9 presenta una mejora relevante frente al benchmark FF5. El segundo piso Fama-MacBeth, en cambio, responde una pregunta diferente: si las exposiciones a los factores son remuneradas mediante primas de riesgo en el corte transversal. Por ello, un factor puede contribuir a reducir alfas en las regresiones time-series y, aun así, no presentar una lambda estadísticamente robusta.

Esta diferencia no contradice el aporte de la investigación; por el contrario, delimita su alcance e invita a complementar la interpretación de los lambdas con pruebas adicionales de robustez. En particular, que una prima de riesgo no resulte estadísticamente significativa no implica necesariamente que carezca de relevancia económica. Puede ocurrir que la magnitud estimada sea económicamente coherente, pero que la muestra disponible no tenga suficiente potencia para detectarla con precisión estadística. Por tanto, una evaluación concluyente sobre la robustez de dichas primas requeriría ejercicios adicionales, como análisis de potencia, ampliación de muestra o contrastes alternativos, los cuales pueden considerarse una línea de profundización más allá del alcance principal de esta investigación.

4.6.2 Umbral de Harvey $|t| > 3$

Además del criterio convencional de significancia, se aplica el umbral de Harvey $|t| > 3$, que es más exigente y se utiliza como filtro para reducir el riesgo de falsos positivos en contextos donde se evalúan múltiples factores.

Tabla 4.12. Evaluación del umbral Harvey $|t| > 3$

Modelo	Factor con mayor $ t(\lambda) $	λ mensual (%)	$ t(\lambda) $	p-valor	¿Supera $ t > 3$?
FF3	MKT-RF	0.397	0.874	0.384	No
FF5	MKT-RF	0.742	1.355	0.178	No
FF6	MOM	1.215	1.860	0.065	No
FF7	MOM	1.172	1.813	0.072	No
FF8	MOM	1.079	1.664	0.098	No
FF9	INT	1.090	2.228	0.028	No

Nota. El umbral se usa como criterio conservador para evaluar robustez frente a múltiples pruebas factoriales.

Ningún factor supera el umbral conservador de Harvey $|t| > 3$. El resultado más cercano se encuentra en el modelo FF9, donde INT alcanza $t = 2.228$. Bajo el criterio tradicional del 5%, INT es significativo; sin embargo, bajo el estándar más exigente de Harvey no alcanza el umbral requerido.

El resultado de INT constituye evidencia favorable bajo inferencia convencional con corrección de Shanken, pero no debe interpretarse como una prima plenamente robusta frente a criterios estrictos de factor zoo. Por tanto, la conclusión adecuada es que INT muestra una prima positiva y estadísticamente significativa al 5%, aunque no supera el filtro conservador $|t| > 3$.

4.6.3 MDE y potencia estadística en la detección de lambdas

Para contextualizar la inferencia sobre las primas de riesgo, se calcula el minimum detectable effect (MDE) para los lambdas. Esta medida indica qué tamaño mínimo debería tener una prima mensual para ser detectada con un nivel determinado de potencia estadística.

La fórmula utilizada es:

$$MDE_{\lambda_k} = (z_{1-\alpha/2} + z_{1-\beta}) \times SE(\hat{\lambda}_k)$$

En este caso, se reportan MDE para 80% y 90% de potencia, usando los errores estándar con corrección de Shanken.

Tabla 4.13. MDE de lambdas para factores candidatos

Factor	Modelo	λ mensual (%)	SE Shanken	MDE 80%	MDE 90%	$ \lambda /\text{MDE 80\%}$
MOM	FF6	1.215	0.653	1.830	2.117	0.664
LVOL	FF7	-0.265	0.500	1.400	1.620	0.189
FCFEV	FF8	0.198	0.528	1.478	1.710	0.134
INT	FF9	1.090	0.489	1.371	1.587	0.795

Nota. Los MDE se calculan usando errores estándar con corrección de Shanken y se reportan en porcentaje mensual.

El análisis MDE muestra que la muestra disponible tiene capacidad limitada para detectar primas pequeñas. Por ejemplo, en el caso de INT, la prima estimada es 1.090% mensual, mientras que el MDE para 80% de potencia es 1.371% mensual. Esto significa que, aunque INT resulta significativo al 5%, su magnitud está por debajo del tamaño que el estudio detectaría con 80% de potencia.

Este resultado no invalida la significancia de INT, pero sí exige una lectura prudente. La evidencia sugiere que INT tiene una prima positiva en el segundo piso, pero la potencia estadística para detectar lambdas de esa magnitud no es alta. Por tanto, el resultado debe interpretarse como evidencia empírica relevante, aunque no definitiva bajo estándares estrictos de potencia y factor zoo.

En los demás factores candidatos, la distancia frente al MDE es mayor. MOM presenta una prima positiva relativamente alta, pero no alcanza significancia al 5% ni supera el MDE de 80%. LVOL y FCFEV tienen lambdas de menor magnitud en relación con sus errores estándar, lo que explica su baja evidencia estadística en Fama-MacBeth.

4.7 Validación out-of-sample

Con el propósito de evaluar si los resultados del modelo se mantienen fuera del periodo inicial de estimación, se realiza una validación **out-of-sample**. La muestra común cubre el periodo **201407-202512**, con **138 observaciones mensuales**. Esta ventana se divide en dos bloques: una muestra **in-sample** entre **201407** y **201712**, con **42 meses**, y una muestra **out-of-sample** entre **201801** y **202512**, con **96 meses**. El corte se fija en **2017-12**, de modo que la evaluación fuera de muestra se concentre en la capacidad de los modelos para mantener bajo control los errores de pricing en un periodo posterior.

Tabla 4.14. Validación out-of-sample de los modelos FF3-FF9

Modelo	Meses OOS	Alfa abs. in-sample	Alfa abs. out-of-sample	Reducción alfa OOS vs. FF5	R ² ajustado OOS	Δ R ² ajustado OOS vs. FF5	p-valor GRS OOS
FF3	96	0.170	0.135	-0.2%	0.920	-0.007	0.396
FF5	96	0.151	0.135	0.0%	0.927	0.000	0.372
FF6	96	0.153	0.129	4.2%	0.927	0.000	0.352
FF7	96	0.158	0.105	21.7%	0.930	0.003	0.571

Modelo	Meses OOS	Alfa abs. in-sample	Alfa abs. out-of-sample	Reducción alfa OOS vs. FF5	R ² ajustado OOS	Δ R ² ajustado OOS vs. FF5	p-valor GRS OOS
FF8	96	0.157	0.103	23.2%	0.930	0.003	0.377
FF9	96	0.148	0.099	26.6%	0.932	0.005	0.512

Nota. Los alfas están expresados en porcentaje mensual. La reducción del alfa out-of-sample se calcula frente al benchmark FF5. El R² ajustado se usa en lugar del R² simple porque penaliza la inclusión de factores adicionales.

La métrica central de esta validación es el **alfa absoluto promedio fuera de muestra**, porque resume el tamaño de los errores de pricing que permanecen después de estimar cada especificación factorial. En este criterio, **FF9 presenta el mejor resultado**, con un alfa absoluto promedio out-of-sample de **0.099% mensual**, inferior al benchmark FF5, que registra **0.135% mensual**. Esto equivale a una reducción aproximada de **26.6%** en los errores de pricing fuera de muestra frente al modelo benchmark.

El R² ajustado confirma que esta mejora no se obtiene únicamente por agregar más factores. FF9 alcanza un R² ajustado out-of-sample de **0.932**, superior al **0.927** de FF5. Aunque la diferencia es moderada, es favorable porque el R² ajustado penaliza la complejidad del modelo. Por tanto, la evidencia principal sigue siendo la **reducción de alfas**, mientras que el R² ajustado funciona como respaldo complementario de que el modelo mantiene capacidad explicativa fuera del periodo inicial.

Esta validación es especialmente relevante desde el punto de vista económico y de mercado porque el periodo out-of-sample **201801-202512** incluye episodios de alta inestabilidad, como la pandemia de COVID-19, los ajustes de tasas de interés, presiones inflacionarias y cambios importantes en las condiciones financieras globales. Que **FF9 mantenga menores errores de pricing** durante este bloque posterior sugiere que la especificación no solo ajusta bien

una muestra histórica, sino que conserva capacidad explicativa en un entorno con shocks económicos relevantes.

4.8 Evaluación incremental y comparación escalonada de modelos FF3–FF9

La evaluación final compara de manera escalonada las especificaciones FF3, FF5, FF6, FF7, FF8 y FF9 sobre la misma ventana común 201407-202512, con 138 observaciones mensuales. El modelo FF5 se toma como benchmark principal, dado que corresponde a la especificación de referencia de Fama y French con cinco factores. La comparación se centra en la capacidad de cada modelo para reducir errores de pricing, medidos mediante el alfa absoluto promedio, y se complementa con el R^2 ajustado, la prueba GRS, la validación out-of-sample y la evidencia de precios de riesgo estimados mediante Fama-MacBeth.

Tabla 4.15. Comparación escalonada de modelos FF3-FF9 frente al benchmark FF5

Modelo	Factores	Meses	Alfa abs. prom.	Reducción alfa vs. FF5	Alfas sig. 5%	R^2 ajustado prom.	ΔR^2 ajustado vs. FF5	p-valor GRS	Periodos FM	Factores Harvey $ t >3$
FF3	3	138	0.113	6.2%	8.0%	0.916	-0.007	0.214	138	0
FF5	5	138	0.121	0.0%	12.0%	0.923	0.000	0.185	138	0
FF6	6	138	0.118	1.7%	12.0%	0.923	0.000	0.204	138	0
FF7	7	138	0.112	7.2%	8.0%	0.925	0.002	0.271	138	0
FF8	8	138	0.113	6.4%	8.0%	0.927	0.004	0.219	138	0
FF9	9	138	0.094	22.2%	8.0%	0.929	0.006	0.418	138	0

Nota. El alfa absoluto promedio está expresado en porcentaje mensual. La reducción del alfa se calcula frente al benchmark FF5 como $(\text{alfa FF5} - \text{alfa media}) / \text{alfa FF5}$.

La comparación muestra que FF9 es la especificación que supera con mayor claridad al benchmark FF5. Su principal mejora está en la reducción de errores de pricing: el alfa absoluto promedio cae de 0.121% mensual en FF5 a 0.094% mensual en FF9, equivalente a una reducción de 22.2%. Esta es la métrica más importante de la tabla, porque en un modelo de valoración de

activos el objetivo central no es maximizar mecánicamente el ajuste, sino reducir el componente de retorno promedio que queda sin explicar por los factores.

La superioridad de FF9 no depende únicamente de agregar más variables. El R^2 ajustado promedio también mejora frente al benchmark, pasando de 0.923 en FF5 a 0.929 en FF9. Esto es relevante porque el R^2 ajustado penaliza la complejidad del modelo. Por tanto, la especificación FF9 no solo reduce alfas, sino que mantiene una mejora en capacidad explicativa aun después de considerar el mayor número de factores.

La prueba GRS refuerza esta lectura. Ningún modelo rechaza la hipótesis conjunta de alfas iguales a cero al 5%, adicionalmente el modelo FF9 obtiene el p-valor GRS más alto, con 0.418. Esto indica que, dentro del conjunto de modelos evaluados, FF9 es el que presenta menor evidencia estadística contra la hipótesis de ausencia de errores de valoración conjuntos. Además, FF9 mantiene el porcentaje de alfas significativos en 8%, por debajo del 12% observado en FF5.

La lectura anterior se mantiene en la validación out-of-sample. En el bloque posterior 201801-202512, FF9 registra el menor alfa absoluto promedio fuera de muestra, con 0.099% mensual, frente a 0.135% mensual en FF5. Esto equivale a una reducción de 26.6% en los errores de pricing fuera de muestra. Además, FF9 conserva el mayor R^2 ajustado out-of-sample entre las especificaciones evaluadas. Este resultado es relevante porque el periodo fuera de muestra incluye shocks económicos y financieros importantes, por lo que la mejora de FF9 no parece limitarse a un ajuste dentro de la muestra completa.

Tabla 4.16. Evidencia del segundo piso y factores añadidos

Factor	Modelo de entrada	λ mensual (%)	$t(\lambda)$	p-valor	MDE 80%	¿Supera Harvey $t >3$?	¿Redundante en spanning?
MOM	FF6	1.215	1.860	0.065	1.830	No	Sí
LVOL	FF7	-0.265	-	0.597	1.400	No	No

Factor	Modelo de entrada	λ mensual (%)	$t(\lambda)$	p-valor	MDE 80%	¿Supera Harvey $ t > 3$?	¿Redundante en spanning?
			0.529				
FCFEV	FF8	0.198	0.376	0.708	1.478	No	Sí
INT	FF9	1.090	2.228	0.028	1.371	No	No

Nota. Los λ s y el MDE están expresados en porcentaje mensual. Los errores estándar usados para el MDE corresponden a la corrección de Shanken. La columna de redundancia proviene de las pruebas de spanning.

La segunda etapa del análisis permite precisar mejor la elección del modelo. En Fama-MacBeth con corrección de Shanken, el único factor añadido que presenta una prima de riesgo significativa al 5% es INT, con $\lambda = 1.090\%$ mensual, $t = 2.228$ y p-valor de 0.028. Este resultado diferencia a FF9 de las especificaciones anteriores: MOM aparece solo como marginal en FF6-FF8, LVOL no presenta prima significativa y FCFEV tampoco muestra evidencia estadística en el segundo piso.

Además, INT no es redundante en la prueba de spanning frente a los ocho factores previos. Esto es importante porque su incorporación en FF9 no se justifica únicamente por mejorar métricas agregadas de ajuste, sino porque el factor aporta información que no queda completamente absorbida por mkt_rf, smb, hml, rmw, cma, mom, LVOL y FCFEV. En cambio, MOM y FCFEV aparecen como redundantes bajo el spanning test, y LVOL, aunque no redundante, no muestra una prima de riesgo significativa en Fama-MacBeth.

No obstante, la conclusión debe ser prudente. Ningún factor supera el umbral conservador de Harvey $|t| > 3$, e INT tampoco alcanza el MDE de 80% de potencia, dado que su prima estimada de 1.090% mensual es inferior al MDE 80% de 1.371% mensual. Por tanto, la evidencia sobre INT no debe presentarse como una prueba definitiva de una nueva prima robusta bajo criterios estrictos de factor zoo. La lectura adecuada es que INT ofrece evidencia favorable

bajo inferencia convencional con corrección de Shanken, pero requiere validación adicional bajo muestras más amplias o ejercicios complementarios.

4.8.1 Síntesis de selección del modelo

En conjunto, el modelo elegido es FF9. Frente al benchmark FF5, FF9 presenta la mayor reducción de errores de pricing en muestra completa, el mejor desempeño fuera de muestra, el mayor R^2 ajustado promedio y el p-valor GRS más favorable. Además, es la única especificación que incorpora un factor adicional, INT, con evidencia positiva en el segundo piso y sin redundancia factorial frente a los ocho factores previos. Por estas razones, FF9 se selecciona como la especificación empíricamente más favorable del estudio, aunque la interpretación de la prima de INT se mantiene en términos de evidencia moderada y no como confirmación definitiva bajo criterios estrictos de factor zoo.

Capítulo 5. Discusión, conclusiones y recomendaciones

Este capítulo discute los principales resultados de la investigación, precisa su contribución teórica y empírica, examina sus implicaciones para asset pricing y gestión de portafolios, reconoce las principales limitaciones del diseño empírico y formula recomendaciones para futuras investigaciones. La lectura se organiza alrededor de una distinción central: el primer piso de estimación evalúa la capacidad de las especificaciones FF5-FF9 para reducir errores de pricing en regresiones time-series, mientras que el segundo piso Fama-MacBeth evalúa si las exposiciones estimadas a los factores son remuneradas mediante lambdas o precios de riesgo en el corte transversal de retornos.

Esta distinción es fundamental para evitar una interpretación excesivamente simple de los resultados. Un modelo puede mejorar la explicación time-series de los retornos y reducir alfas residuales sin que todos sus factores presenten lambdas estadísticamente significativas. A su vez, una lambda no significativa no implica necesariamente que el factor sea económicamente irrelevante; también puede reflejar baja potencia estadística, alta incertidumbre de estimación, colinealidad parcial con otros factores o una ventana muestral insuficiente para detectar efectos moderados. Bajo esta lógica, el capítulo no presenta la especificación FF9 como una prueba definitiva de un nuevo modelo universal, sino como la especificación empíricamente más favorable dentro del diseño propuesto y de la muestra 201407-202512.

5.1 Discusión de resultados

Los resultados empíricos muestran que la extensión escalonada del modelo de cinco factores de Fama-French hacia una especificación de nueve factores mejora la capacidad explicativa del modelo, especialmente cuando se evalúa la reducción de alfas absolutos promedio. La especificación FF9, que incorpora Momentum, Low Volatility, FCF/EV e

Intangible Intensity sobre la base FF5, obtiene el menor alfa absoluto promedio, el mayor R^2 ajustado promedio y el p-valor GRS más alto entre las especificaciones evaluadas. En términos sustantivos, esto indica que FF9 deja una menor porción del retorno promedio mensual de los 25 portafolios Size x Book-to-Market sin explicar.

El resultado más relevante del primer piso es la reducción del alfa absoluto promedio frente al benchmark FF5. El alfa absoluto promedio pasa de 0.121% mensual en FF5 a 0.094% mensual en FF9, lo que representa una disminución aproximada de 22.2% en los errores de pricing promedio. Esta mejora no ocurre de manera perfectamente lineal en todos los modelos intermedios, lo cual es importante desde el punto de vista metodológico: la evidencia no sugiere que agregar factores mejore mecánicamente todos los indicadores, sino que la combinación completa de factores alcanza la mejor lectura agregada en la muestra analizada.

El R^2 ajustado también favorece a FF9. Esta métrica es relevante porque penaliza la complejidad del modelo, de modo que una mejora en R^2 ajustado tiene más valor interpretativo que una mejora en R^2 simple cuando se comparan modelos anidados o progresivamente ampliados. En el estudio, FF9 alcanza un R^2 ajustado promedio de 0.929, superior al 0.923 de FF5. La diferencia no es enorme en magnitud absoluta, pero sí es consistente con la reducción de alfas y con el desempeño fuera de muestra. En asset pricing, la métrica principal no es maximizar el ajuste mecánico, sino reducir errores de valoración sin sacrificar parsimonia ni robustez.

La prueba GRS aporta una lectura conjunta de los alfas. Ninguna especificación rechaza la hipótesis de alfas conjuntamente iguales a cero al 5%, pero FF9 obtiene el p-valor GRS más alto, con 0.418. Esta evidencia no permite afirmar que FF9 sea el modelo verdadero, pero sí indica que, dentro del conjunto de modelos comparados, es la especificación con menor evidencia estadística en contra de la ausencia de errores de pricing conjuntos. Por tanto, el primer

piso respalda la elección de FF9 como el modelo con mejor desempeño agregado frente al benchmark FF5.

La validación out-of-sample refuerza esta lectura. En el periodo 201801-202512, FF9 registra un alfa absoluto promedio fuera de muestra de 0.099% mensual, frente a 0.135% mensual en FF5. Esto equivale a una reducción aproximada de 26.6% en los errores de pricing fuera de muestra. Este resultado es especialmente relevante porque el bloque posterior incluye episodios de alta inestabilidad financiera y macroeconómica, como la pandemia de COVID-19, cambios abruptos en tasas de interés, presiones inflacionarias y reacomodos en condiciones de liquidez global. Que FF9 mantenga una reducción de alfas en este contexto sugiere que su mejora no se limita al ajuste dentro de la muestra completa.

Sin embargo, la evidencia del segundo piso exige una interpretación más precisa. Las regresiones Fama-MacBeth con corrección de Shanken muestran que, dentro de la especificación FF9, el único factor con lambda significativa al 5% es INT. Su lambda estimada es 1.090% mensual, con error estándar Shanken de 0.489, estadístico t de 2.228 y p-valor de 0.028. En cambio, los demás factores no presentan primas de riesgo estadísticamente distinguibles de cero en la especificación completa. Esta diferencia entre el primer piso y el segundo piso no constituye una contradicción; representa dos preguntas empíricas distintas.

El primer piso pregunta si los factores ayudan a explicar la variación temporal de los retornos de los portafolios y si reducen el componente anormal promedio no explicado. El segundo piso pregunta si las exposiciones a esos factores están asociadas con diferencias sistemáticas en retornos esperados entre portafolios. Por tanto, un factor puede contribuir a mejorar el ajuste time-series o a reducir alfas sin que su lambda sea estadísticamente significativa. Esta separación es central para la discusión del aporte de la tesis, porque permite

afirmar que FF9 mejora la especificación empírica del modelo, pero que la evidencia sobre primas de riesgo se concentra principalmente en INT y debe interpretarse con cautela.

Tabla 5.1. Síntesis interpretativa de los resultados principales

Dimensión	Resultado principal	Interpretación	Alcance de la evidencia
Regresiones time-series	FF9 registra menor alfa absoluto promedio y mayor R^2 ajustado.	La especificación ampliada reduce errores de pricing y mantiene buen ajuste penalizado.	Evidencia favorable para capacidad explicativa.
Comparación con FF5	Alfa absoluto promedio: 0.121% en FF5 y 0.094% en FF9.	Reducción aproximada de 22.2% en errores de pricing promedio.	Aporte central del primer piso.
Validación out-of-sample	FF9 reduce el alfa OOS frente a FF5 en 26.6%.	La mejora se mantiene en el bloque posterior 201801-202512.	Robustez empírica moderada.
Spanning test	INT y LVOL no aparecen como redundantes; MOM y FCFEV sí.	INT contiene información incremental frente a los factores previos.	Justifica evaluar FF9.
Fama-MacBeth	INT es el único lambda significativo al 5% bajo Shanken.	La prima asociada a intensidad intangible tiene respaldo estadístico convencional.	Evidencia económica prometedora, no definitiva.
Criterio Harvey y potencia	Ningún factor supera $ t > 3$; INT tiene potencia observada de 60.6%.	La evidencia no alcanza el estándar más conservador de factor zoo.	Conclusión prudente y abierta a validación futura.

Nota. La tabla resume la interpretación conjunta de los resultados empíricos reportados en el capítulo 4. Los alfas están expresados en porcentaje mensual.

5.1.1 Lectura económica de la reducción de errores de pricing

La reducción de errores de pricing tiene una interpretación económica directa. En un modelo multifactorial, el alfa representa la parte del retorno promedio que no queda explicada por las exposiciones sistemáticas incluidas. Si un modelo reduce los alfas absolutos promedio, está capturando mejor las fuentes comunes de variación de los retornos y deja menos retorno anormal residual. En esta investigación, FF9 reduce los alfas de manera más clara que FF5, lo

cual sugiere que los factores adicionales contienen información útil para explicar el comportamiento de los 25 portafolios de prueba.

Desde una perspectiva de asset pricing, esta mejora importa porque el objetivo de un modelo factorial no es solo producir regresiones con alto ajuste, sino explicar por qué diferentes activos o portafolios obtienen retornos distintos. La evidencia indica que las dimensiones capturadas por Momentum, Low Volatility, FCF/EV e Intangible Intensity ayudan a organizar mejor los retornos realizados de los portafolios, aunque no todas se traduzcan en primas de riesgo estadísticamente significativas. En particular, INT aparece como el componente más relevante de la ampliación, tanto por su aporte al modelo completo como por la evidencia obtenida en el segundo piso.

El resultado también tiene una lectura práctica: una reducción de alfa absoluto promedio de 22.2% frente a FF5 implica que el modelo FF9 mejora la descomposición del retorno ajustado por riesgo. Para un evaluador de desempeño, esto significa que una parte del retorno que podría interpretarse como anomalía o error residual bajo FF5 puede ser explicada por exposiciones a factores adicionales bajo FF9. Por tanto, la especificación ampliada puede generar una atribución de desempeño más exigente y menos propensa a confundir exposición factorial con retorno anormal.

No obstante, la magnitud de los alfas debe interpretarse junto con el análisis MDE. En la comparación escalonada, la incorporación progresiva de factores no solo redujo los errores de pricing promedio, sino que también estuvo acompañada por una disminución gradual de los umbrales mínimos detectables. Esto significa que, a medida que el modelo avanzó hacia especificaciones más amplias, especialmente hacia FF9, los alfas residuales tendieron a ser menores y el diseño empírico mostró una capacidad ligeramente mayor para detectar errores de

pricing de menor magnitud. En FF9, el alfa absoluto promedio alcanza 0.094% mensual, mientras que el MDE promedio para detectar alfas con 80% de potencia se ubica en 0.337% mensual, el valor más bajo entre las especificaciones evaluadas. Por tanto, FF9 no solo reduce la magnitud promedio de los alfas frente al benchmark FF5, sino que también mejora marginalmente la sensibilidad inferencial del modelo. Aun así, como el alfa promedio permanece por debajo del MDE de 80%, la ausencia de alfas significativos no debe interpretarse como prueba de que todos los alfas sean exactamente cero; más bien, debe entenderse como ausencia de evidencia estadística suficiente para detectar errores de pricing grandes bajo la muestra disponible.

5.1.2 Lectura económica de las lambdas

Las lambdas representan precios de riesgo. En el contexto Fama-MacBeth, una lambda positiva indica que los portafolios con mayor exposición a un factor tienden a recibir mayor retorno esperado, manteniendo constante la estructura del modelo. Una lambda negativa indica que una mayor exposición al factor se asocia con menor retorno esperado. Por tanto, la lambda no es simplemente el promedio histórico del factor ni una señal automática de inversión; es una estimación del precio transversal asociado a la exposición al factor.

Esta precisión es relevante para interpretar INT. La lambda de INT en FF9 es 1.090% mensual. En términos económicos, esto sugiere que una mayor exposición al factor de intensidad intangible está asociada con una prima positiva en la sección transversal de retornos durante la muestra analizada. La lectura sustantiva es que el mercado parece remunerar, bajo esta especificación, la exposición a una dimensión vinculada con inversión en investigación y desarrollo respecto a ingresos, no plenamente capturadas por los factores tradicionales.

La magnitud estimada para INT, equivalente a 1.090% mensual, corresponde aproximadamente a 13.08% anual en términos simples y a 13.89% efectivo anual si se capitaliza mensualmente. Esta magnitud es económicamente elevada cuando se compara con primas factoriales consolidadas documentadas en la literatura de modelos multifactoriales, como las asociadas a mercado, tamaño, value, profitability, investment y momentum (Fama & French, 1993, 2015; Carhart, 1997; Ilmanen, 2011). Esta prima puede reflejar características particulares del período 201407–202512, marcado por una alta relevancia de empresas intensivas en innovación, tecnología, software, datos y modelos de negocio basados en activos intangibles, en línea con la literatura que documenta la creciente importancia económica de los intangibles y sus limitaciones de medición contable (Eisfeldt & Papanikolaou, 2013; Lev & Gu, 2016; Peters & Taylor, 2017; Bongaerts et al., 2025). No obstante, precisamente por su magnitud, el resultado debe interpretarse con cautela: constituye evidencia económicamente relevante y consistente con la tesis de mayor importancia de los intangibles, pero no una validación definitiva de una prima estructural permanente.

El sentido económico de esta prima puede entenderse desde varias vías complementarias. Primero, las empresas intensivas en intangibles suelen tener mayor incertidumbre sobre la conversión futura de inversión en innovación en flujos de caja observables. Segundo, parte de la inversión en intangibles puede registrarse contablemente como gasto, lo que dificulta que medidas tradicionales como book-to-market capturen su valor económico. Tercero, la creación de valor asociada a conocimiento, datos, software o investigación puede depender de horizontes largos, competencia tecnológica, obsolescencia y escalabilidad del modelo de negocio. Si los inversionistas exigen compensación por asumir estas fuentes de incertidumbre, una λ

positiva de INT puede interpretarse como evidencia de una prima asociada a exposición intangible.

Sin embargo, esta conclusión debe formularse con precisión. El resultado no prueba que todas las empresas con alta intensidad intangible generen retornos superiores ni que INT sea una estrategia de inversión directamente explotable. Lo que muestra es que, dentro de la especificación FF9, las exposiciones estimadas al factor INT se asocian con retornos esperados mayores en el corte transversal de los 25 portafolios evaluados. La evidencia es estadísticamente significativa al 5% bajo corrección de Shanken, pero no supera el umbral conservador de Harvey $|t| > 3$. Por tanto, la prima de INT debe presentarse como evidencia favorable y económicamente relevante, pero no como confirmación definitiva de una nueva prima robusta bajo estándares estrictos de factor zoo.

El caso de MOM permite reforzar esta lectura. MOM presenta una lambda positiva relativamente alta en FF6, de 1.215% mensual, pero no alcanza significancia al 5%. Además, su potencia observada es de 46.0%, lo cual indica una capacidad intermedia para detectar una prima de la magnitud estimada. Económicamente, esto impide descartar momentum como irrelevante, pero también impide sostener una conclusión fuerte sobre su precio de riesgo en esta muestra. La evidencia sobre MOM es sugerente, pero menos robusta que la de INT.

LVOL y FCFEV muestran una situación distinta. Sus lambdas son pequeñas respecto a sus errores estándar y sus potencias observadas son muy bajas, 8.3% y 6.6%, respectivamente. En estos casos, la ausencia de significancia se explica por una combinación de magnitud estimada débil e incertidumbre relativa alta. Para LVOL, además, la media negativa del factor en la muestra y su correlación negativa con el mercado sugieren que su comportamiento defensivo no necesariamente se tradujo en una prima positiva en el periodo evaluado. Para FCFEV, la baja

evidencia puede reflejar solapamiento con dimensiones de valor, rentabilidad o inversión, o una capacidad limitada de los 25 portafolios Size x Book-to-Market para capturar esta característica fundamental específica.

Tabla 5.2. Potencia observada aproximada en la detección de primas de riesgo

Factor	Modelo	Lambda	SE	MDE 80%	MDE 90%	Potencia observada
MOM	FF6	1.215	0.653	1.830	2.117	46.0%
LVOL	FF7	-0.265	0.500	1.400	1.620	8.3%
FCFEV	FF8	0.198	0.528	1.478	1.710	6.6%
INT	FF9	1.090	0.489	1.371	1.587	60.6%

Nota. Lambdas, errores estándar y MDE están expresados en porcentaje mensual. La potencia observada se interpreta como aproximación inferencial complementaria, no como prueba definitiva.

La potencia observada permite matizar la interpretación de los resultados. INT presenta la mayor potencia entre los factores candidatos, con 60.6%. Aunque este valor no alcanza el estándar convencional de 80%, sí indica que el estudio tiene una capacidad razonable, aunque no plena, para detectar una prima de la magnitud estimada. Este resultado ayuda a explicar por qué INT logra significancia convencional bajo Shanken, pero no supera el MDE de 80% ni el umbral Harvey. La conclusión apropiada es que INT tiene la evidencia más sólida entre los factores candidatos, pero todavía requiere validación adicional.

La combinación de lambda positiva, significancia convencional, no redundancia en spanning y mayor potencia observada convierte a INT en el factor con mayor respaldo dentro de la tesis. Esta conclusión es más fuerte que afirmar simplemente que FF9 tiene más factores y mejor R^2 . El punto central es que INT parece capturar una dimensión económica diferenciada que aporta tanto a la reducción de errores de pricing como a la explicación transversal de

retornos esperados. En ese sentido, la tesis aporta evidencia empírica a favor de incorporar la intensidad intangible en modelos multifactoriales contemporáneos, especialmente en un mercado donde una proporción creciente del valor corporativo se relaciona con activos no físicos y capacidades de innovación. No obstante, esta conclusión debe leerse en conjunto con la evidencia del umbral de Harvey y del MDE: INT es el factor adicional con mayor respaldo relativo dentro del estudio, pero no una prima de riesgo definitivamente validada bajo estándares estrictos de replicabilidad factorial.

5.2 Contribución teórica y empírica

La contribución principal de la tesis consiste en evaluar de manera ordenada, escalonada y empíricamente trazable una extensión del modelo FF5 hacia una especificación de nueve factores. El aporte no radica únicamente en proponer más factores, sino en someter esa ampliación a varias capas de evaluación: reducción de alfas, R^2 ajustado, prueba GRS, spanning test, Fama-MacBeth con corrección de Shanken, criterio Harvey, MDE, potencia observada y validación out-of-sample. Esta arquitectura metodológica permite distinguir entre mejora de especificación, evidencia de primas de riesgo y robustez estadística.

Por tanto, la contribución central no radica en la validación aislada de un factor individual, sino en la evaluación escalonada de una arquitectura multifactorial FF9 que integra factores tradicionales, factores ampliamente documentados y señales propias construidas desde Refinitiv Workspace. Esta aproximación permite distinguir entre mejora de especificación, evidencia de precios de riesgo y robustez inferencial.

Desde el punto de vista teórico, la tesis se ubica en la evolución natural de la literatura multifactorial. El modelo FF5 captura dimensiones centrales del riesgo sistemático: mercado, tamaño, value, rentabilidad e inversión. Sin embargo, la economía corporativa contemporánea

incorpora fuentes de valor que no siempre se reflejan adecuadamente en los estados financieros tradicionales, especialmente cuando la inversión en intangibles se reconoce como gasto en lugar de capitalizarse como activo. En este contexto, la incorporación de Intangible Intensity permite evaluar si la intensidad relativa en investigación y desarrollo contiene información que los factores tradicionales no absorben plenamente.

La investigación también aporta una distinción conceptual importante entre capacidad explicativa y precio de riesgo. En la primera etapa, FF9 mejora la especificación porque reduce errores de pricing y obtiene un mejor desempeño agregado frente a FF5. Esta contribución se relaciona con la capacidad del modelo para describir los retornos realizados y disminuir el componente residual no explicado. En la segunda etapa, la evidencia se concentra en INT como factor con lambda positiva y significativa al 5% bajo Shanken. Por tanto, la tesis no concluye que todos los factores añadidos sean precios de riesgo robustos; concluye que la especificación FF9 mejora la explicación de los retornos y que INT ofrece la señal más prometedora como prima de riesgo dentro del conjunto evaluado.

Esta distinción fortalece el aporte académico porque evita dos errores comunes. El primer error sería afirmar que todo factor que mejora el ajuste time-series necesariamente representa una prima de riesgo. El segundo sería descartar un modelo por completo si no todos sus factores tienen lambdas significativas. La evidencia de la tesis sugiere una lectura más fina: algunos factores pueden contribuir a la especificación y a la reducción de alfas, mientras que solo algunos logran evidencia transversal de precio de riesgo. En este caso, INT es el factor que conecta ambas dimensiones de forma más consistente.

En términos empíricos, el aporte más claro de la tesis es que FF9 reduce el alfa absoluto promedio en 22.2% frente a FF5 en la muestra completa y en 26.6% fuera de muestra. Estos

resultados indican que la extensión multifactorial mejora la medición del retorno ajustado por riesgo en los 25 portafolios evaluados. Además, la especificación no presenta evidencia de multicolinealidad severa, dado que los VIF se mantienen por debajo de umbrales críticos. Esto respalda la viabilidad estadística de estimar conjuntamente los nueve factores, aunque no elimina la necesidad de cautela por el tamaño muestral y el número de factores.

La prueba de redundancia factorial también refuerza el aporte empírico. INT no aparece como redundante frente a los ocho factores previos, lo cual es un resultado relevante porque el factor se evalúa contra una especificación exigente que ya incluye FF5, momentum, baja volatilidad y FCF/EV. Su alfa de spanning positivo y significativo indica que INT conserva un componente incremental no explicado por la combinación lineal de los factores existentes. En cambio, MOM y FCFEV aparecen como redundantes en sus respectivas pruebas, y LVOL, aunque no redundante, no presenta una lambda significativa en el segundo piso. Esta diferencia posiciona a INT como el factor candidato con mayor valor agregado empírico.

La contribución para la teoría de asset pricing se puede formular así: la tesis aporta evidencia de que una medida de intensidad intangible puede complementar los modelos Fama-French en la explicación de retornos accionarios, especialmente cuando se evalúa una economía de mercado caracterizada por innovación, software, plataformas, propiedad intelectual y capital organizacional. La evidencia no prueba de forma definitiva una nueva prima universal, pero sí muestra que INT contiene información incremental y económicamente interpretable en la muestra analizada. Esto conecta la literatura clásica de factores con discusiones más recientes sobre la medición de intangibles y la transformación de las fuentes de valor corporativo.

La contribución también es metodológica. La tesis muestra que la evaluación de nuevos factores debe ir más allá de la significancia individual. La combinación de spanning test, Fama-

MacBeth, corrección de Shanken, Harvey $|t| > 3$, MDE y potencia observada permite diferenciar entre evidencia fuerte, evidencia moderada y ausencia de evidencia concluyente. En particular, la potencia observada de INT, equivalente a 60.6%, ayuda a interpretar su significancia convencional sin sobredimensionarla. La potencia de MOM, de 46.0%, permite no descartar su relevancia económica aunque no alcance significancia convencional. En cambio, las potencias de LVOL y FCFEV sugieren que el diseño empírico tiene poca capacidad para detectar primas de la magnitud estimada en estos factores.

En síntesis, el valor agregado de la tesis para asset pricing se concentra en tres planos. Primero, propone y evalúa una especificación FF9 con disciplina empírica y temporal. Segundo, demuestra que dicha especificación reduce errores de pricing frente a FF5 en muestra completa y fuera de muestra. Tercero, identifica a INT como el factor candidato con mayor respaldo económico y estadístico, aunque bajo una conclusión prudente: evidencia prometedora, no validación definitiva bajo criterios estrictos de factor zoo.

5.3 Implicaciones para asset pricing y gestión de portafolios

Los resultados tienen implicaciones relevantes para la teoría de asset pricing, la medición de riesgo y la gestión profesional de portafolios. En términos generales, la evidencia sugiere que una especificación multifactorial ampliada puede ofrecer una descripción más completa de los retornos que el modelo FF5 cuando se incorporan dimensiones asociadas a momentum, baja volatilidad, generación de caja relativa e intensidad intangible. Sin embargo, la implicación práctica no es que todos estos factores deban ser usados como señales de inversión directa, sino que pueden enriquecer la atribución de desempeño, el control de riesgo y la evaluación de exposiciones sistemáticas.

Para asset pricing, la implicación más importante es que los factores tradicionales pueden no capturar completamente fuentes de valor asociadas a la economía intangible. En empresas intensivas en innovación, software, datos, marcas, conocimiento organizacional o propiedad intelectual, las métricas contables tradicionales pueden subrepresentar inversiones relevantes para la generación futura de flujos de caja. Por ello, una medida como INT puede aportar información complementaria a HML, RMW y CMA. La evidencia de una λ positiva para INT sugiere que el mercado puede estar remunerando una exposición relacionada con esta dimensión, aunque la robustez de la prima debe seguir siendo evaluada.

Para inversionistas institucionales, FF9 puede utilizarse como herramienta de diagnóstico y no únicamente como modelo académico. En procesos de atribución de desempeño, una especificación ampliada permite diferenciar si el rendimiento de un portafolio proviene de exposición al mercado, tamaño, value, rentabilidad, inversión, momentum, baja volatilidad, FCF/EV o intensidad intangible. Esto es especialmente útil cuando un gestor parece generar alfa bajo un modelo más simple, pero parte de ese alfa desaparece al controlar por factores adicionales. En ese caso, el modelo ayuda a distinguir entre habilidad del gestor, exposición sistemática y riesgo no compensado.

Para gestores de portafolio, la evidencia sobre INT puede servir como una dimensión adicional en la construcción de portafolios multifactoriales. Una exposición positiva a intensidad intangible podría ser relevante en estrategias orientadas a crecimiento innovador, tecnología, salud, software, investigación aplicada o modelos de negocio con fuerte componente de conocimiento. Sin embargo, la implementación debe ser cuidadosa. INT no debe ser tratado como una señal aislada de compra, sino como un factor que requiere controles por sector, tamaño, valoración, rentabilidad, inversión, liquidez y concentración. La intensidad intangible

puede capturar innovación productiva, pero también gasto riesgoso, modelos de negocio inciertos o inversión sin retorno económico claro.

Para fondos de pensiones, la implicación es principalmente estratégica y de largo plazo. Estos inversionistas suelen tener horizontes amplios, restricciones regulatorias, límites de riesgo y necesidades de estabilidad. La incorporación de un factor como INT puede ayudar a entender si el portafolio está subexpuesto o sobreexpuesto a compañías cuyo valor depende de activos intangibles e innovación. No obstante, por la naturaleza conservadora de estos vehículos, cualquier inclinación hacia INT debería evaluarse mediante benchmarks robustos, límites de tracking error, análisis de drawdowns, stress testing, costos de transacción y consistencia con la política de inversión.

Para hedge funds y gestores activos con mayor flexibilidad, la evidencia puede motivar estrategias de intensidad intangible, especialmente si se complementan con controles de valoración, calidad, momentum y riesgo sectorial. Sin embargo, el resultado de la tesis no es suficiente para justificar una estrategia implementable sin pruebas adicionales. Sería necesario evaluar turnover, costos de transacción, capacidad, liquidez, estabilidad por subperiodos, desempeño por sectores, sensibilidad a regímenes macrofinancieros y robustez fuera del universo de 400 acciones utilizado en esta investigación.

La evidencia sobre LVOL también tiene implicaciones de gestión de riesgo. Aunque LVOL no presenta una λ significativa, su comportamiento defensivo y su correlación negativa con el mercado pueden ser relevantes para construir portafolios con menor sensibilidad a caídas del mercado. En este sentido, un factor puede ser útil para control de riesgo incluso si no presenta una prima positiva estadísticamente significativa en el segundo piso. Para un gestor

institucional, LVOL podría funcionar como componente de estabilización, no necesariamente como fuente principal de retorno esperado.

La evidencia sobre FCFEV debe interpretarse con cautela. La señal tiene sentido económico porque relaciona generación de flujo de caja libre con valor empresarial; sin embargo, en la muestra analizada no se traduce en una prima significativa ni en alta potencia de detección. Esto no invalida el uso de FCF/EV como métrica fundamental en análisis de acciones individuales, pero sí sugiere que, dentro de esta arquitectura factorial y de los test assets evaluados, su aporte como factor de pricing es limitado. En gestión de portafolios, FCF/EV puede seguir siendo útil como variable de selección o filtro de calidad/valor, aunque no necesariamente como factor independiente remunerado.

La implicación general para el mercado es que los modelos factoriales deben adaptarse a la transformación de la economía corporativa. En un entorno donde el valor de muchas compañías depende de activos no físicos, capacidades tecnológicas, datos, investigación y propiedad intelectual, los modelos basados exclusivamente en variables contables tradicionales pueden dejar componentes de retorno sin explicar. La tesis aporta evidencia de que incluir una medida de intensidad intangible mejora la explicación de retornos en la muestra estudiada. No obstante, esta implicación debe traducirse en práctica con prudencia: el modelo mejora la lectura del riesgo y la atribución del retorno, pero no elimina incertidumbre ni garantiza retornos superiores.

Tabla 5.3. Implicaciones prácticas por tipo de usuario del modelo

Usuario	Uso potencial	Valor agregado	Precaución principal
Inversionistas institucionales	Atribución de desempeño y monitoreo de exposiciones factoriales.	Permite distinguir entre alfa aparente y exposición sistemática a factores de riesgo.	No utilizar INT como señal aislada sin validación econométrica, económica y fuera de muestra.
Gestores de portafolio	Construcción de portafolios multifactoriales y análisis de exposiciones factoriales.	Incorpora una dimensión asociada a inversión intangible e innovación corporativa.	Controlar efectos sectoriales, concentración, liquidez, costos de transacción y rotación del portafolio.
Fondos de pensiones	Evaluación estratégica de exposición a innovación, intangibles y riesgos de largo plazo.	Mejora el diagnóstico de fuentes de riesgo y retorno en horizontes de inversión prolongados.	Mantener límites de tracking error, stress testing y coherencia con mandatos fiduciarios.
Fondos de cobertura / hedge funds	Diseño exploratorio de estrategias long-short o de superposición factorial.	Permite evaluar una fuente potencial de retorno asociada a intangibles.	Requiere pruebas de capacidad, turnover, costos de implementación, robustez fuera de muestra y control de sobreajuste.

Nota. Las implicaciones se formulan como usos potenciales del modelo y no como recomendaciones de inversión.

5.4 Limitaciones de la investigación

La primera limitación corresponde al tamaño y cobertura temporal de la muestra principal. La ventana común 201407-202512 contiene 138 observaciones mensuales. Aunque esta frecuencia es estándar en la literatura de factores, el número de observaciones es limitado para estimar modelos con hasta nueve factores y para obtener inferencia robusta sobre lambdas. Esta restricción proviene principalmente de la disponibilidad del factor INT, cuya construcción exige información contable y de mercado suficiente desde 201407. En consecuencia, la potencia estadística para detectar primas moderadas es limitada, como lo muestran los resultados MDE y la potencia observada.

La segunda limitación se relaciona con el número de activos de prueba. La investigación utiliza 25 portafolios Size x Book-to-Market, reconocidos en la literatura de Fama-French. Estos

portafolios son útiles para evaluar errores de pricing en una estructura clásica de tamaño y value, pero pueden no ser suficientes para capturar completamente factores modernos como intangibles, FCF/EV o baja volatilidad. Es posible que portafolios formados directamente por intensidad intangible, inversión en R+D, industrias tecnológicas, rentabilidad ajustada por intangibles o características de calidad permitan evaluar de manera más directa la relevancia transversal de INT.

La tercera limitación corresponde al universo usado para construir los factores propios. Los factores LVOL, FCFEV e INT se construyen a partir de un universo depurado de 400 acciones estadounidenses, con exclusión de entidades financieras, Real Estate/REITs, microcapitalizaciones y acciones con problemas de disponibilidad o liquidez. Esta decisión mejora la comparabilidad financiera y la calidad de las señales, pero limita la generalización de los resultados al mercado accionario estadounidense completo. Por tanto, los resultados deben interpretarse como evidencia dentro del universo muestral definido, no como una caracterización universal de todas las acciones estadounidenses.

La cuarta limitación se relaciona con la adaptación de la metodología 2 x 3. La investigación mantiene la lógica de Fama-French mediante clasificación por tamaño y por señal, pero los puntos de corte se calculan sobre el universo elegible del estudio y no sobre el universo completo NYSE/AMEX/NASDAQ. Esta adaptación es necesaria por la disponibilidad de datos y por la construcción propia de factores, pero puede generar diferencias frente a factores académicos contruidos sobre universos más amplios. En futuras investigaciones sería conveniente contrastar la sensibilidad de los resultados a breakpoints alternativos.

La quinta limitación se refiere a la medición de Intangible Intensity. El factor INT se construye con gasto en investigación y desarrollo sobre ingresos. Esta métrica captura una

dimensión importante de inversión intangible, pero no agota el concepto de capital intangible. Muchas compañías desarrollan intangibles mediante software interno, marca, capital humano, procesos organizacionales, datos, redes de usuarios o gastos de venta y administración que no necesariamente aparecen como R+D. Por tanto, INT debe interpretarse como una aproximación parcial a la intensidad intangible, no como una medida completa de todos los activos intangibles generados internamente. Adicionalmente, la literatura reciente ha desarrollado aproximaciones relacionadas para construir factores de intangibles, en particular mediante señales de intensidad intangible basadas en R&D/Revenue. Por ello, la contribución de esta tesis no debe interpretarse como la introducción aislada de un proxy completamente inexplorado, sino como su evaluación dentro de una arquitectura FF9 escalonada, con una ventana temporal, universo muestral, construcción de factores propios y batería empírica específicos.

La sexta limitación corresponde a la inferencia sobre lambdas. Aunque se aplica corrección de Shanken para reconocer el error de estimación de las betas usadas en Fama-MacBeth, persisten desafíos asociados al número de factores, la sensibilidad a subperiodos y la baja potencia para detectar primas pequeñas. El hecho de que INT sea significativo al 5% bajo Shanken es relevante, pero no suficiente para superar criterios más estrictos como Harvey $|t| > 3$. Por tanto, la evidencia sobre la prima de INT debe presentarse como moderada y prometedora, no definitiva.

La séptima limitación corresponde a la ausencia de costos de transacción, restricciones de implementación, rotación de portafolios, impuestos, comisiones, diferenciales bid-ask y capacidad de mercado. Los factores se evalúan como construcciones empíricas de retorno y pricing, no como estrategias listas para implementación comercial. Esto es especialmente importante para factores long-short y para universos donde la recomposición periódica de las

carteras puede ser significativa. Un factor puede tener relevancia estadística y aun así ser difícil de explotar después de costos.

Finalmente, la investigación se concentra en el mercado estadounidense y en una frecuencia mensual. Esto favorece la comparabilidad con la literatura de Fama-French, pero limita la evaluación de microestructura, reacción a noticias, rebalanceos de mayor frecuencia y diferencias internacionales. La relevancia de INT, LVOL o FCFEV podría variar por ejemplo en mercados emergentes, y/o sectores específicos.

5.5 Recomendaciones para futuras investigaciones

Una primera recomendación consiste en ampliar la ventana temporal de análisis. Dado que la potencia estadística es una restricción importante, futuras investigaciones deberían intentar reconstruir los factores propios para periodos más largos, siempre que la disponibilidad de datos permita mantener consistencia temporal y evitar sesgo de anticipación.

Una segunda recomendación es evaluar el modelo con conjuntos alternativos de test assets. Además de los 25 portafolios Size x Book-to-Market, podrían utilizarse portafolios por industria, portafolios formados por momentum, inversión, rentabilidad, intangibles, volatilidad, calidad, crecimiento, payout, liquidez o combinaciones de características. Esto permitiría analizar si la evidencia de INT depende de los portafolios clásicos de Fama-French o si se mantiene en activos de prueba más directamente relacionados con la economía intangible.

Una tercera recomendación es probar definiciones alternativas de intensidad intangible. Además de R+D sobre ingresos, podrían evaluarse R+D sobre activos, R+D sobre capitalización de mercado, inversión intangible capitalizada, gastos SG&A como proxy parcial de capital organizacional, patentes, marcas, software, datos, activos intangibles reportados en balance o medidas combinadas de capital intangible. Esta línea permitiría distinguir si el resultado depende

de una métrica específica o si existe una dimensión intangible más amplia asociada a retornos esperados. En particular, futuras investigaciones podrían evaluar una señal expandida de intensidad intangible definida como $(R\&D + SG\&A)/Revenue$, en la medida en que SG&A puede capturar parcialmente inversión en capital organizacional, marcas, capacidades comerciales, tecnología interna y otros activos intangibles no reconocidos plenamente en balance. Esta extensión no se implementa en la presente investigación por restricciones de cobertura homogénea y comparabilidad temporal de SG&A en Refinitiv Workspace para el universo muestral analizado, así como por el alcance metodológico definido para esta tesis.

Una cuarta recomendación es incorporar controles sectoriales. La intensidad en R+D y el peso de los intangibles varían fuertemente entre sectores. Tecnología, salud, comunicación, industria farmacéutica y software pueden comportarse de forma distinta a sectores tradicionales. Por tanto, futuras investigaciones deberían evaluar versiones sector-neutral del factor INT o estimaciones por sectores para determinar si la prima proviene de una exposición general a intangibles o de concentración en industrias específicas.

Una quinta recomendación es comparar FF9 con modelos alternativos de la literatura, como el modelo q-factor, modelos de calidad, modelos de inversión y rentabilidad ampliados, modelos de betting-against-beta, modelos de características o aproximaciones modernas basadas en machine learning. Esta comparación permitiría determinar si la mejora de INT se mantiene frente a otras arquitecturas de asset pricing y no solo frente a FF5.

Una sexta recomendación es evaluar implementabilidad. Para pasar de evidencia académica a aplicación de mercado, sería necesario calcular turnover, costos de transacción, capacidad, liquidez, drawdowns, Sharpe ratio, Information ratio, exposición sectorial,

concentración y desempeño después de costos. Esto permitiría distinguir entre un factor útil para pricing y un factor explotable en una estrategia real de inversión.

Finalmente, futuras investigaciones deberían extender el análisis a otros mercados. La importancia de los intangibles puede variar entre Estados Unidos, Europa, Asia y mercados emergentes. En economías con menor profundidad de mercado, distinta regulación contable o menor presencia de compañías tecnológicas, el comportamiento de INT podría ser diferente. Una comparación internacional permitiría evaluar si la prima de intensidad intangible es específica del mercado estadounidense o si representa una regularidad más amplia.

5.6 Conclusiones

La investigación evaluó empíricamente una extensión escalonada del modelo de cinco factores de Fama-French hacia una especificación de nueve factores para explicar retornos accionarios en el mercado estadounidense durante el periodo 201407-202512. La especificación FF9 incorpora Momentum, Low Volatility, FCF/EV e Intangible Intensity sobre la base FF5 y se compara con modelos intermedios mediante un enfoque de dos pisos: regresiones time-series para evaluar reducción de errores de pricing y regresiones Fama-MacBeth para estimar precios de riesgo.

La primera conclusión es que FF9 es la especificación empíricamente más favorable del estudio. Frente al benchmark FF5, reduce el alfa absoluto promedio de 0.121% a 0.094% mensual, equivalente a una disminución aproximada de 22.2% en errores de pricing. También obtiene el mayor R^2 ajustado promedio y el p-valor GRS más alto. Estos resultados indican que la especificación ampliada mejora la capacidad explicativa del modelo sin que la mejora dependa únicamente de agregar más regresores.

La segunda conclusión es que la mejora de FF9 se mantiene fuera de muestra. En el periodo 201801-202512, FF9 alcanza el menor alfa absoluto promedio out-of-sample y reduce los errores de pricing en 26.6% frente a FF5. Esta evidencia es relevante porque el periodo posterior incluye condiciones de mercado exigentes y shocks macrofinancieros importantes. Por tanto, la especificación ampliada no solo mejora el ajuste dentro de la muestra completa, sino que conserva capacidad explicativa en un bloque posterior.

La tercera conclusión es que no todos los factores añadidos aportan de la misma manera. MOM presenta una prima positiva económicamente relevante, pero sin significancia estadística suficiente y con potencia observada intermedia. LVOL no es redundante en spanning, pero no presenta lambda significativa. FCFEV aparece como factor redundante y con baja potencia para detectar su prima estimada. INT, en cambio, es el factor con evidencia más consistente: no es redundante frente a los factores previos, tiene lambda positiva y significativa al 5% bajo corrección de Shanken y presenta la mayor potencia observada entre los factores candidatos.

La cuarta conclusión es que la prima de INT tiene sentido económico. Una lambda positiva para Intangible Intensity sugiere que la exposición a empresas con mayor intensidad relativa en investigación y desarrollo respecto a ingresos está asociada con mayores retornos esperados en la muestra analizada. Este resultado es coherente con la idea de que la economía moderna depende cada vez más de activos intangibles, innovación, software, propiedad intelectual, conocimiento organizacional y capacidades tecnológicas que no siempre son capturadas por variables contables tradicionales. En este sentido, INT aporta una dimensión complementaria a los factores clásicos de Fama-French.

La quinta conclusión es que la evidencia debe interpretarse con prudencia. Aunque INT es significativo bajo inferencia convencional y con corrección de Shanken, ningún factor supera

el criterio conservador de Harvey $|t| > 3$. Además, la potencia observada de INT es 60.6%, inferior al estándar convencional de 80%. Por tanto, INT no debe presentarse como una prima definitivamente validada bajo estándares estrictos de factor zoo, sino como una señal empíricamente prometedora, económicamente interpretable y merecedora de validación adicional.

La sexta conclusión es metodológica. La tesis muestra que la evaluación de modelos multifactoriales debe separar tres niveles: la mejora de especificación, la existencia de precios de riesgo y la robustez inferencial. FF9 mejora la especificación porque reduce alfas y mantiene buen desempeño fuera de muestra. INT muestra evidencia de precio de riesgo porque su lambda es positiva y significativa al 5%. Sin embargo, la robustez bajo criterios más estrictos todavía no es plena. Esta separación evita conclusiones binarias y permite una lectura más rigurosa de los resultados.

En conclusión, el aporte central de la tesis debe entenderse como evidencia favorable sobre la utilidad de una arquitectura multifactorial FF9 construida de forma escalonada, y no como una validación definitiva de nuevas primas de riesgo. Los resultados muestran que la especificación FF9 mejora la capacidad explicativa frente al modelo FF5 en la muestra 201407–202512, al reducir errores de pricing, mejorar el ajuste del modelo y ofrecer una lectura más amplia de las exposiciones factoriales. Dentro de esta arquitectura, INT se identifica como una dimensión prometedora y económicamente interpretable, al conectar la literatura tradicional de asset pricing con la creciente relevancia económica de los activos intangibles. Sin embargo, su magnitud estimada, la existencia de literatura reciente directamente relacionada y el hecho de que no supere el umbral conservador de Harvey sugieren que su interpretación debe mantenerse prudente. En consecuencia, la evidencia no cierra el debate, sino que contribuye a una línea de

investigación reciente orientada a evaluar si la intensidad intangible constituye una dimensión relevante y robusta para explicar retornos esperados en mercados accionarios contemporáneos. Futuras investigaciones podrían extender esta discusión mediante ventanas más amplias, test assets alternativos y proxies complementarios de intangibles.

Referencias

- Amihud, Y. (2002). Illiquidity and stock returns: Cross-section and time-series effects. *Journal of Financial Markets*, 5(1), 31-56. [https://doi.org/10.1016/S1386-4181\(01\)00024-6](https://doi.org/10.1016/S1386-4181(01)00024-6)
- Amihud, Y. y Mendelson, H. (1986). Asset pricing and the bid-ask spread. *Journal of Financial Economics*, 17(2), 223-249. [https://doi.org/10.1016/0304-405X\(86\)90065-6](https://doi.org/10.1016/0304-405X(86)90065-6)
- Ang, A. (2014). *Asset management: A systematic approach to factor investing*. Oxford University Press.
- Ang, A., Hodrick, R. J., Xing, Y. y Zhang, X. (2006). The cross-section of volatility and expected returns. *The Journal of Finance*, 61(1), 259-299. <https://doi.org/10.1111/j.1540-6261.2006.00836.x>
- Ang, A., Hodrick, R. J., Xing, Y. y Zhang, X. (2009). High idiosyncratic volatility and low returns: International and further U.S. evidence. *Journal of Financial Economics*, 91(1), 1-23. <https://doi.org/10.1016/j.jfineco.2007.12.005>
- Baker, M., Bradley, B. y Wurgler, J. (2011). Benchmarks as limits to arbitrage: Understanding the low-volatility anomaly. *Financial Analysts Journal*, 67(1), 40-54. <https://doi.org/10.2469/faj.v67.n1.4>
- Blitz, D. y van Vliet, P. (2007). The volatility effect: Lower risk without lower return. *The Journal of Portfolio Management*, 34(1), 102-113.
- Bongaerts, D., van Dijk, M. y Kang, X. (2025). Revisiting asset pricing models: The case for an intangibles factor. *Financial Management*. Publicación anticipada en línea. <https://doi.org/10.1111/fima.70001>
- Carhart, M. M. (1997). On persistence in mutual fund performance. *The Journal of Finance*, 52(1), 57-82. <https://doi.org/10.1111/j.1540-6261.1997.tb03808.x>

- Cochrane, J. H. (2005). *Asset pricing* (Rev. ed.). Princeton University Press.
- Cochrane, J. H. (2011). Presidential address: Discount rates. *The Journal of Finance*, 66(4), 1047-1108. <https://doi.org/10.1111/j.1540-6261.2011.01671.x>
- Dai, Y. (2019). Net cash flow yield and the cross-section of stock returns. *SSRN Electronic Journal*.
- Damodaran, A. (2012). *Investment valuation: Tools and techniques for determining the value of any asset* (3.^a ed.). Wiley.
- Dechow, P. M., Richardson, S. A. y Sloan, R. G. (2008). The persistence and pricing of the cash component of earnings. *Journal of Accounting Research*, 46(3), 537-566. <https://doi.org/10.1111/j.1475-679X.2008.00283.x>
- Eisfeldt, A. L. y Papanikolaou, D. (2013). Organization capital and the cross-section of expected returns. *The Journal of Finance*, 68(4), 1365-1406. <https://doi.org/10.1111/jofi.12034>
- Fama, E. F. y French, K. R. (1992). The cross-section of expected stock returns. *The Journal of Finance*, 47(2), 427-465. <https://doi.org/10.1111/j.1540-6261.1992.tb04398.x>
- Fama, E. F. y French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3-56. [https://doi.org/10.1016/0304-405X\(93\)90023-5](https://doi.org/10.1016/0304-405X(93)90023-5)
- Fama, E. F. y French, K. R. (2006). Profitability, investment and average returns. *Journal of Financial Economics*, 82(3), 491-518. <https://doi.org/10.1016/j.jfineco.2005.09.009>
- Fama, E. F. y French, K. R. (2015). A five-factor asset pricing model. *Journal of Financial Economics*, 116(1), 1-22. <https://doi.org/10.1016/j.jfineco.2014.10.010>
- Fama, E. F. y MacBeth, J. D. (1973). Risk, return, and equilibrium: Empirical tests. *Journal of Political Economy*, 81(3), 607-636. <https://doi.org/10.1086/260061>

- Frazzini, A. y Pedersen, L. H. (2014). Betting against beta. *Journal of Financial Economics*, 111(1), 1-25. <https://doi.org/10.1016/j.jfineco.2013.10.005>
- French, K. R. (s.f.-a). Description of Fama/French 5 factors (2x3). Kenneth R. French Data Library. Recuperado el 6 de mayo de 2026, de https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/Data_Library/f-f_5_factors_2x3.html
- French, K. R. (s.f.-b). 25 portfolios formed on size and book-to-market (5 x 5). Kenneth R. French Data Library. Recuperado el 6 de mayo de 2026, de https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/Data_Library/tw_5_ports.html
- French, K. R. (s.f.-c). Detail for monthly momentum factor (Mom). Kenneth R. French Data Library. Recuperado el 6 de mayo de 2026, de https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library/det_mom_factor.html
- Gibbons, M. R., Ross, S. A. y Shanken, J. (1989). A test of the efficiency of a given portfolio. *Econometrica*, 57(5), 1121-1152. <https://doi.org/10.2307/1913625>
- Harvey, C. R., Liu, Y. y Zhu, H. (2016). ... and the cross-section of expected returns. *The Review of Financial Studies*, 29(1), 5-68. <https://doi.org/10.1093/rfs/hhv059>
- Haugen, R. A. y Heins, A. J. (1975). Risk and the rate of return on financial assets: Some old wine in new bottles. *Journal of Financial and Quantitative Analysis*, 10(5), 775-784. <https://doi.org/10.2307/2330270>
- Hou, K., Xue, C. y Zhang, L. (2020). Replicating anomalies. *The Review of Financial Studies*, 33(5), 2019-2133. <https://doi.org/10.1093/rfs/hhy131>
- Ilmanen, A. (2011). Expected returns: An investor's guide to harvesting market rewards. Wiley.

- Jegadeesh, N. y Titman, S. (1993). Returns to buying winners and selling losers: Implications for stock market efficiency. *The Journal of Finance*, 48(1), 65-91.
<https://doi.org/10.1111/j.1540-6261.1993.tb04702.x>
- Jegadeesh, N. y Titman, S. (2001). Profitability of momentum strategies: An evaluation of alternative explanations. *The Journal of Finance*, 56(2), 699-720.
<https://doi.org/10.1111/0022-1082.00342>
- Jensen, M. C. (1968). The performance of mutual funds in the period 1945-1964. *The Journal of Finance*, 23(2), 389-416. <https://doi.org/10.1111/j.1540-6261.1968.tb00815.x>
- Jensen, M. C. (1986). Agency costs of free cash flow, corporate finance, and takeovers. *The American Economic Review*, 76(2), 323-329.
- Lev, B. (2001). *Intangibles: Management, measurement, and reporting*. Brookings Institution Press.
- Lev, B. y Gu, F. (2016). *The end of accounting and the path forward for investors and managers*. Wiley.
- Lintner, J. (1965). The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. *The Review of Economics and Statistics*, 47(1), 13-37.
<https://doi.org/10.2307/1924119>
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77-91.
<https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- Mossin, J. (1966). Equilibrium in a capital asset market. *Econometrica*, 34(4), 768-783.
<https://doi.org/10.2307/1910098>
- Nareit. (s.f.). Funds from operations (FFO). Recuperado el 6 de mayo de 2026, de <https://www.reit.com/glossary/funds-operation-ffo>

- Pástor, L. y Stambaugh, R. F. (2003). Liquidity risk and expected stock returns. *Journal of Political Economy*, 111(3), 642-685. <https://doi.org/10.1086/374184>
- Peters, R. H. y Taylor, L. A. (2017). Intangible capital and the investment-q relation. *Journal of Financial Economics*, 123(2), 251-272. <https://doi.org/10.1016/j.jfineco.2016.03.011>
- Shanken, J. (1992). On the estimation of beta-pricing models. *The Review of Financial Studies*, 5(1), 1-33. <https://doi.org/10.1093/rfs/5.1.1>
- Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19(3), 425-442. <https://doi.org/10.1111/j.1540-6261.1964.tb02865.x>
- Sloan, R. G. (1996). Do stock prices fully reflect information in accruals and cash flows about future earnings? *The Accounting Review*, 71(3), 289-315.

Anexos

RMSE/MAE promedio por modelo — muestra común 201407–202512

Tabla A.1. RMSE/MAE promedio por modelo - muestra común 201407-202512

Modelo	RMSE promedio	MAE promedio	Alfa abs. prom.	R ² ajustado prom.	Reducción RMSE vs. FF5	Reducción MAE vs. FF5	Reducción alfa vs. FF5
FF3	1.671	1.256	0.113	0.916	-5.5%	-4.7%	6.2%
FF5	1.583	1.200	0.121	0.923	0.0%	0.0%	0.0%
FF6	1.578	1.197	0.118	0.923	0.3%	0.3%	1.7%
FF7	1.551	1.183	0.112	0.925	2.0%	1.4%	7.2%
FF8	1.532	1.166	0.113	0.927	3.2%	2.8%	6.4%
FF9	1.506	1.145	0.094	0.929	4.9%	4.6%	22.2%

Nota. La tabla reporta métricas complementarias de error promedio para la muestra común 201407-202512.

El modelo FF9 vuelve a ubicarse como la especificación con mejor desempeño en términos de RMSE y MAE promedio para la muestra común 201407–202512. Si bien la ganancia frente al benchmark FF5 resulta más moderada que la observada en la reducción de alfas, la dirección de los resultados es plenamente consistente con una mejora de especificación. En este sentido, la evidencia sugiere que FF9 no solo atenúa los errores promedio de pricing, sino que también contribuye a reducir, aunque de forma más acotada, la magnitud del componente residual mensual.