

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ

Colegio de Posgrados

El nuevo rol del Analista Financiero en la Era de la Inteligencia Artificial: ¿Es posible crear un Hedge Fund gestionado por IA?

Alejandro Jhosue Aguilera Vélez

Juan Carlos Chanabá Guerrero Ph.D.

Director de Trabajo de Titularización

**Trabajo de titulación de posgrado presentado como requisito
para la obtención del título de Maestría en Finanzas**

Quito, 28 de junio 2025

UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**HOJA DE APROBACIÓN DE TRABAJO DE TITULACIÓN**

El nuevo rol del Analista Financiero en la Era de la Inteligencia Artificial: ¿Es posible crear un Hedge Fund gestionado por IA?

Alejandro Jhosue Aguilera Vélez

Quito, 28 de junio 2025

Nombre del Director del Programa:	Juan José Espinoza de los Monteros
Título académico:	MBA
Director del programa de:	Escuela de Empresas
Nombre del Decano del Colegio de	Ana Maria Novillo
Académico:	Ph.D.
Título académico:	Colegio de Administracion de empresas-
Decano del colegio:	CADE
Nombre del Decano del Colegio de	Dario Niebieskwiat
Posgrado:	Ph.D.
Título académico:	

© DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombre del estudiante: Alejandro Jhosue Aguilera Vélez

Código de estudiante: 344262

C.I: 1722275995

Quito, 28 de junio de 2025

ACLARACIÓN PARA PUBLICACIÓN

Nota: El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics (COPE) descritas por Barbour et al. (2017) Discussion Document on Best Practice for Issues Around Theses Publishing, disponible en <http://bit.ly/copetheses>.

UNPUBLISHED DOCUMENT

Note: The following graduation project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics (COPE) described by Barbour et al. (2017) Discussion Document on Best Practice for Issues Around Theses Publishing available on <http://bit.ly/copetheses>.

RESUMEN

El crecimiento de la inteligencia artificial (IA) en el ámbito de las inversiones y el trading ha experimentado un auge significativo en las últimas décadas, desde mediados de la década de 1990, la aplicación de la IA en los mercados financieros ha crecido de manera exponencial, alcanzando un punto de inflexión con el auge de la IA generativa en los últimos años un estudio bibliométrico reciente identificó más de 2,300 publicaciones entre 1995 y 2019, abarcando áreas clave como la optimización de portafolios, predicción bursátil, análisis de sentimiento financiero y enfoques híbridos. Estos avances han permitido el desarrollo de nuevas estrategias de inversión basadas en algoritmos inteligentes que superan los métodos tradicionales.

Las aplicaciones clave de la IA en las inversiones y el trading incluyen:

- Optimización de portafolios: La IA facilita una asignación dinámica de activos, adaptándose de manera eficiente a condiciones cambiantes del mercado y mejorando la gestión del riesgo.
- Predicción de precios: Modelos de aprendizaje profundo y redes neuronales permiten prever movimientos de precios con mayor precisión, adaptándose a patrones de mercado complejos.
- Análisis de sentimiento: Herramientas de procesamiento de lenguaje natural (PLN) analizan noticias y redes sociales, evaluando el sentimiento del mercado para predecir posibles movimientos en los activos.
- Trading algorítmico: La IA automatiza estrategias de trading, mejorando la velocidad y eficiencia de las operaciones, con un enfoque en optimización de la ejecución de órdenes y reducción de costos de transacción.

La integración de la IA en el sector financiero ha transformado radicalmente la toma de decisiones de inversión, permitiendo el análisis en tiempo real de grandes volúmenes de datos, la identificación de patrones complejos que no son detectables por métodos tradicionales, y la reducción de sesgos humanos en la evaluación de riesgos y oportunidades, sin embargo, a pesar de sus numerosos beneficios, la adopción de la IA en las finanzas presenta desafíos importantes, tales como la transparencia en los modelos algorítmicos, la necesidad de regulación adecuada para prevenir riesgos sistémicos y el manejo ético de los datos sensibles que alimentan estos sistemas.

Este estudio propone una reflexión sobre cómo la inteligencia artificial está redefiniendo el rol del analista financiero, el cual, más que nunca, debe integrar competencias tecnológicas y de supervisión ética, mientras se adapta a un entorno financiero cada vez más automatizado y dependiente de tecnologías emergentes como la IA generativa.

Palabras clave: IA, Trading algorítmico, optimización de portafolios, predicción de precios, análisis de sentimiento, machine learning, IA generativa, supervisión ética, riesgo sistémico.

Contenido

1.	Introducción	8
1.1.	Planteamiento del problema	13
1.2.	Objetivo general y específicos	15
1.3.	Pregunta de investigación	15
1.4.	Hipótesis	16
1.5.	ODS del estudio	16
1.6.	Metodología para utilizar	19
1.7.	Conclusión	20
2.	Marco teórico	22
2.1.	Evolución del rol del financiero	22
2.2.	Fundamentos de inteligencia artificial.....	24
2.2.1.	Conceptos básicos de IA, machine learning y deep learning.	24
2.3.	Aplicación de la IAs en finanzas	27
2.3.1.	El legado de Renaissance Technologies: De los modelos cuantitativos tradicionales a la IA generativa en la gestión de carteras.....	27
2.3.2.	Aplicaciones actuales de IA en análisis de datos, trading, optimización de carteras.	
2.3.2.	29	
2.4.	Transformación del perfil profesional	32
2.4.1.	Del analista tradicional al estratega tecnológico	32
2.4.2.	Etica algorítmica y supervisión humana	34
2.5.	Sustitución vs complementación: IA como tu aliado	35
3.	Fundamentos metodológicos para la construcción de portafolios	37
3.1.	Introducción al enfoque de optimización de portafolios.....	37
3.2.	Modelo de Markowitz: optimización media-varianza	38
3.3.	Hierarchical Risk Parity (HRP): una alternativa robusta	40
3.4.	Comparación real de HRP vs Markowitz vs ISHARES RUSSELL 2000	49
3.4.1.	Hierarchical Risk Parity (HRP) vs ISHARES RUSSELL 2000 ETF.....	50
3.4.2.	Hierarchical Risk Parity (HRP) vs Markowitz.....	54
3.5.	Limitaciones del modelo Hierarchical Risk Parity (HRP).....	63
3.6.	Conclusiones.....	66
3.7.	Referencias bibliográficas	68

1. Introducción

La inteligencia artificial (IA) ha atravesado décadas de expectativas, escepticismo y temor desde la década de 1950, sin embargo, con la disponibilidad generalizada de herramientas como ChatGPT a finales de 2022, se ha alcanzado un punto de inflexión significativo, estas tecnologías permiten a las máquinas comprender el lenguaje y generar contenido similar al producido por humanos, marcando un avance crucial en la democratización del acceso a la información, ¿Por qué este es el momento decisivo para la IA?.

La combinación de una necesidad creciente de procesamiento de datos y avances tecnológicos ha propiciado el auge de la IA generativa, actualmente, se crea más información en una hora que en todo un año hace dos décadas, pero solo se utiliza aproximadamente el 1% de estos datos, la IA generativa, como ChatGPT, permite a las máquinas comprender y generar contenido humano, facilitando la creación de

textos, imágenes, videos y más, a partir de datos existentes, este avance es crucial para los inversionistas y gestores de activos, ya que la IA generativa y los algoritmos predictivos pueden transformar significativamente los análisis financieros, las decisiones de inversión y la predicción de precios de activos. Este es un cambio de paradigma para el rol del analista financiero, debido a que ahora debe saber interpretar datos generados por IA, no solo tomar decisiones basadas en análisis de datos pasados.

El impacto económico de la IA generativa se espera que mejore la productividad y reduzca costos en diversas industrias, incluyendo creación de contenido, desarrollo de software, marketing, ventas y atención al cliente, estas mejoras beneficiarán tanto a empresas como a consumidores, se espera que el gasto global en TI relacionado con IA se proyecte que alcance los \$521 mil millones en 2027, frente a \$180 mil millones en 2023 según (*Bank of America Private Bank*) y la contribución al PIB mundial la IA podría aportar más de \$15 billones a la economía global para 2030.

Regiones y Sectores Más Beneficiados

- **Regiones:** Estados Unidos y China, las dos economías más grandes del mundo, probablemente experimentarán las mayores ganancias económicas derivadas de la IA, juntas se espera que representen alrededor del 70% del impacto económico global de la IA para 2030.
- **Sectores:** La tecnología de la información será una de las principales beneficiadas, incluyendo desarrollo de software, semiconductores, centros de datos, ciberseguridad y motores de búsqueda, además, se anticipan transformaciones en sectores como educación, salud, aeroespacial, legal e inversiones ahora la

pregunta que tenemos que responder es ¿Cómo podrían beneficiarse los inversionistas? aunque la promesa de la IA ayudó a impulsar los mercados en 2023, los inversionistas deben adoptar un enfoque paciente, estamos en las etapas iniciales de la IA generativa y otras formas de IA, la diversificación es especialmente importante para quienes consideran invertir en nuevas tecnologías.

Este análisis económico se incorpora para fundamentar la relevancia de la IA en la toma de decisiones económicas y de inversión se enfatiza, en particular, la fintech y las plataformas de asesoría financiera automatizada como los robo-advisors serán áreas clave que están transformando la industria financiera, permitiendo una mayor eficiencia en la asignación de activos y la creación de estrategias de inversión adaptativas.

Además, en relación con la adopción de IA en las finanzas, la detección de fraude y el asesoramiento automatizado son aspectos cruciales que afectan tanto a la gestión de carteras como al control de riesgos, áreas donde los algoritmos de machine learning son esenciales.

La IA ha cambiado el mercado laboral como ocurre con cualquier cambio tecnológico significativo, la adopción de la IA probablemente alterará algunas profesiones y podría eliminar ciertos empleos, sin embargo, también se espera que cree nuevas industrias, negocios, habilidades y carreras, la historia muestra que, aunque algunas ocupaciones desaparecen, surgen otras nuevas con el avance tecnológico, con la aparición de las IAs se generan nuevos riesgos como la accesibilidad y uso generalizado de sistemas de IA generativa aumentan los riesgos de ciberataques y fraudes, a medida que la tecnología mejora en la adopción del lenguaje humano y la creación de imágenes, los riesgos de robo de identidad, por ejemplo, también aumentan, además, la IA presenta nuevos desafíos

en términos de privacidad, ya que estos sistemas tienen una capacidad sin precedentes para recopilar, utilizar y potencialmente mal utilizar datos sobre individuos.

Según los investigadores (Dr. Anand S. Rao and Gerard Verweij, 2024) de la empresa pwc realizo un análisis sobre la ¿IA como motor económico global? la inteligencia artificial tiene el potencial de contribuir con \$15,7 billones al PIB mundial para 2030, donde \$6,6 billones provendrán del aumento de la productividad laboral, \$9,1 billones vendrán del aumento del consumo debido a productos y servicios más personalizados y de mayor calidad, además el impacto por regiones es significativa, china puede captar cerca de \$7 billones, el mayor impacto absoluto, Norteamérica sería el segundo beneficiado con mayor impacto cerca de \$3,7 billones y Europa del norte cerca de \$1,8 billones, la IA ayuda con el aumento de la productividad laboral como la automatización de tareas rutinarias y asistencia inteligente que permite a los empleados enfocarse en actividades de mayor valor, también se incrementa el consumo, mejora de la calidad de productos/servicios mediante personalización y IA permite nuevas categorías de productos y experiencias de cliente, las industrias clave para el crecimiento de las IAS son:

- Sector Salud: Diagnósticos más precisos y personalizados.
- Retail (comercio minorista): Personalización de la experiencia del cliente y gestión inteligente de inventarios.
- Finanzas: Detección de fraude y asesoramiento automatizado.
- Transporte y Logística: Vehículos autónomos, rutas optimizadas.

- Agricultura y Recursos Naturales: Monitoreo de cultivos y gestión eficiente de recursos.

Aunque no todo es bueno ya que tiene sus riesgos como: desigualdad entre países desarrollados y en desarrollo, necesidad de adaptar la fuerza laboral a nuevas habilidades (reskilling) y requiere colaboración entre gobiernos, empresas y sociedad civil para maximizar beneficios y mitigar efectos negativos.

Esta información se complementa con la transformación del perfil del analista financiero la adopción de la IA en las finanzas implica que los analistas ya no solo interpretarán datos tradicionales de mercado, sino que también deberán ser expertos en la supervisión ética de los algoritmos y comprender los impactos socioeconómicos de la automatización, además, los riesgos asociados a la privacidad y seguridad de los datos se convierten en una parte integral de las responsabilidades del analista financiero.

La referencia a la Norma WealthTech en Ecuador es un excelente ejemplo de cómo la regulación local está alineada con los ODS (Objetivos de Desarrollo Sostenible) esta norma promueve la transparencia, protección de datos y la innovación financiera responsable, lo cual refuerza la transformación digital en el sector financiero esta norma es un vínculo directo entre la teoría global de la IA y su implementación local en Ecuador lo que demuestra cómo la IA puede mejorar la inclusión financiera y la accesibilidad a servicios de inversión, pero también plantea la necesidad de formar profesionales híbridos que comprendan tanto la tecnología como la ética en un entorno regulado.

1.1. Planteamiento del problema

La rápida evolución de la inteligencia artificial (IA) está impulsando nuevas capacidades en el análisis de datos y la toma de decisiones financieras. Antes, el trabajo de los analistas financieros se centraba en el análisis descriptivo y predictivo, a partir de datos históricos, hoy con machine learning (ML) y algoritmos predictivos, los sistemas inteligentes no solo mejoran las predicciones de mercados, sino que también proporcionan soluciones proactivas en tiempo real.

Herramientas como ML, procesamiento de lenguaje natural (PLN) y redes neuronales ya están realizando tareas que anteriormente requerían una profunda intervención humana, como:

- Detección de patrones en grandes volúmenes de datos históricos.
- Evaluación y gestión de riesgos en mercados altamente volátiles.
- Optimización dinámica de carteras que se adaptan a las condiciones cambiantes del mercado.

Los sistemas inteligentes permiten, además, el uso de datos no estructurados (como las noticias, redes sociales, blogs, etc.), que complementan los tradicionales datos financieros, mejorando el análisis de sentimiento y la toma de decisiones. Este avance tecnológico no reemplaza al profesional financiero, sino que lo transforma: los analistas y gestores financieros ahora deben ser estrategas tecnológicos capaces de:

- Interaccionar con IA: Deben comprender cómo funcionan los modelos de machine learning y cómo estos generan recomendaciones de inversión.
- Interpretar resultados generados por IA: La capacidad de evaluar si las recomendaciones algorítmicas son válidas, éticas y rentables.

- Monitorear sistemas autónomos: La supervisión humana sigue siendo crucial, aunque las decisiones puedan ser automatizadas.

En lugar de tomar decisiones basadas solo en datos históricos, los analistas ahora también deben ser expertos en supervisión ética de IA, comprensión de algoritmos predictivos y verificación de la calidad de los datos generados por las máquinas como la interacción en tiempo real con sistemas inteligentes debido a que los sistemas de IA permiten realizar predicciones y tomar decisiones en tiempo real, lo cual es un cambio de paradigma en la toma de decisiones de inversión, puesto a que antes las decisiones de inversión se basaban en datos anteriores y supuestos históricos ahora la IA puede generar estrategias de inversión adaptativas basadas en condiciones del mercado en tiempo real, lo que lleva a una optimización continua de las carteras.

Plataformas de robo-advisors ya están implementando IA de manera efectiva para ofrecer recomendaciones de inversión personalizadas a miles de clientes simultáneamente la IA puede analizar, por ejemplo, comportamientos de consumidores o sentimientos de mercado a través de PLN, lo que ayuda a identificar oportunidades de inversión no evidentes para los analistas tradicionales.

La IA en el sector financiero ofrece enormes oportunidades, pero también desafíos significativos como la transparencia de las decisiones algorítmicas, la responsabilidad ética de los modelos predictivos y la seguridad de los datos deben ser abordados con seriedad, ya que una mala implementación de IA puede acarrear riesgos sistémicos y pérdidas económicas para los inversionistas.

En resumen el nuevo rol del analista financiero se trata en la adopción de IA como herramienta complementaria, no como sustituto, la tica y supervisión, debido a que a medida que los sistemas de IA toman decisiones automatizadas, el analista se convierte en el guardián de la ética y el marco regulatorio, asegurando que los algoritmos sigan principios éticos y legales, sin embargo mantener un enfoque híbrido es necesario para el analista del futuro por que será un estratega tecnológico, capaz de comprender tanto las técnicas tradicionales como los avances tecnológicos.

1.2. Objetivo general y específicos

El objetivo general es analizar el impacto de la inteligencia artificial en la transformación del rol del profesional financiero dentro de los procesos de gestión de inversiones, a nivel global los objetivos son examinar las principales tecnologías de inteligencia artificial aplicadas a la gestión de inversiones como machine learning (ML), procesamiento de lenguaje natural y robo-advisors, describir los cambios en las funciones, responsabilidades y habilidades requeridas al profesional financiero frente a la integración de IA, evaluar el efecto del uso de herramientas de inteligencia artificial sobre la toma de decisiones, rendimiento y gestión del riesgo en carteras de inversión, explorar las oportunidades y barreras para la adopción de inteligencia artificial en el sector financiero del Ecuador.

1.3. Pregunta de investigación

¿Cómo está transformando la inteligencia artificial el rol del profesional financiero en los procesos de toma de decisiones de inversión? Y con esta tecnología se podría crear un “Neo Head Fund”

1.4. Hipótesis

Como advierte López de Prado (2020), la verdadera ventaja competitiva en el uso de machine learning no radica únicamente en la predicción de precios, sino en la construcción de teorías financieras más robustas y en la mejora de la toma de decisiones bajo incertidumbre el ML no es una caja negra complementa, los métodos estadísticos clásicos, no los sustituye su mayor fortaleza es permitir el descubrimiento de especificaciones complejas y relaciones causales no lineales, ayudando al gestor a fundamentar y robustecer sus estrategias así, el profesional financiero debe trascender el rol tradicional y adoptar un perfil híbrido donde la tecnología, la teoría y la ética converjan.

La adopción de inteligencia artificial en los procesos de inversión está modificando significativamente el rol del inversionista, exigiendo nuevas competencias tecnológicas, redefiniendo los procesos de análisis y mejorando el rendimiento de las carteras de inversión, además, los métodos modernos de inteligencia artificial, especialmente el aprendizaje automático y las redes neuronales profundas están transformando significativamente las decisiones de inversión más ágiles, precisas y basadas en datos, lo que redefine su función de analista tradicional hacia un perfil híbrido de estratega-tecnólogo, por lo tanto se genera la siguiente pregunta ¿Se puede crear un head fund solo con IA? Y si es así ¿Cómo sería la estructura?

1.5. ODS del estudio

Según la ONU el significado de trabajo decente es:

“Significa oportunidades para todos de conseguir un trabajo que sea productivo proporcione unos ingresos dignos, seguridad en el lugar de trabajo y

protección social para las familias, así como mejores perspectivas de desarrollo personal e integración social. La continua falta de oportunidades de trabajo decente, la insuficiente inversión y el bajo consumo producen una erosión del contrato social básico subyacente en las sociedades democráticas: el derecho de todos a compartir el progreso.”

El avance de la inteligencia artificial y la digitalización en las finanzas no solo responde a tendencias globales, sino también a desarrollos normativos locales en Ecuador, la reciente Norma WealthTech (Resolución JPRF-F-2025-0155) regula la operación de entidades de servicios financieros tecnológicos, incluyendo asesoría financiera digital, administración de portafolios, y uso de algoritmos en la gestión de inversiones, esta norma promueve la transparencia, la protección de datos, la profesionalización y la innovación financiera responsable, alineándose directamente con los ODS 4 (educación de calidad), ODS 8 (trabajo decente y crecimiento económico) y ODS 9 (industria, innovación e infraestructura), ya que incentiva la capacitación de los profesionales, la inclusión de nuevas tecnologías y la creación de infraestructuras digitales seguras y eficientes

El ODS 4 plantea la necesidad de garantizar una educación inclusiva, equitativa y de calidad, promoviendo oportunidades de aprendizaje durante toda la vida en el sector financiero, esto implica actualizar los contenidos y competencias que se requieren para formar profesionales capaces de afrontar la digitalización y la inteligencia artificial.

Dentro de la tesis contribuye directamente a este objetivo al analizar cómo la irrupción de la IA redefine las competencias del analista financiero y al argumentar que la formación tradicional ya no es suficiente, además enfatiza la necesidad de currículos que incluyan programación, ética digital, manejo de datos

y teoría financiera moderna, lo que fomenta la adaptación curricular en las universidades y centros de formación técnica.

La regulación ecuatoriana exige títulos y experiencia específica en los responsables de las plataformas de asesoría financiera y wealthtech, incentivando la formación universitaria y técnica alineada con las demandas tecnológicas y regulatorias actuales

El ODS 8 aboga por promover el crecimiento económico sostenido, el empleo pleno y productivo, y el trabajo decente para todos en el contexto fintech y de IA, implica el desarrollo de nuevos perfiles profesionales, el surgimiento de startups y la digitalización del sector financiero dentro de la tesis analiza cómo la IA transforma el trabajo del analista financiero, generando empleos de mayor valor agregado, pero también demandando una constante actualización y reciclaje profesional donde promueve la idea de que la automatización y la digitalización, bien gestionadas, no sustituyen empleos sino que los redefinen y elevan su calidad dentro de la norma promueve la formalización del sector, establece requisitos de profesionalización y ética, y crea un entorno regulado donde la innovación tecnológica puede florecer, generando empleo calificado y oportunidades para el emprendimiento financiero

El ODS 9 tiene su enfoque en fomentar la construcción de infraestructuras resilientes, la promoción de la industrialización inclusiva y sostenible, y el fomento de la innovación dentro de la tesis el trabajo aborda cómo la inteligencia artificial impulsa la creación de nuevas plataformas tecnológicas (robo-advisors, sistemas de gestión de portafolios IA, asesoría financiera digital), catalizando la modernización de la infraestructura financiera argumenta que la innovación en wealthtech puede aumentar la eficiencia, la transparencia y la inclusión financiera.

La regulación ecuatoriana reconoce y regula a las entidades de servicios financieros tecnológicos, promoviendo el desarrollo y adopción de infraestructuras digitales seguras, trazables y eficientes. Esto incentiva la inversión en tecnología y la creación de ecosistemas fintech robustos que potencian la competitividad y la inclusión financiera a nivel nacional.

En resumen, la Norma WealthTech es el marco local que materializa estos ODS, al establecer estándares claros, promover la capacitación y la ética profesional, y exigir infraestructuras tecnológicas que garanticen la seguridad, la transparencia y la protección de los usuarios por tanto, esta investigación no solo tiene pertinencia académica, sino también impacto regulatorio y social real, alineándose con los compromisos internacionales del Ecuador y aportando a la construcción de una industria financiera más robusta, moderna y sostenible.

1.6. Metodología para utilizar

Esta metodología combina enfoque cualitativo y revisión documental, adecuada para analizar un fenómeno actual con implicaciones tecnológicas y profesionales.

Enfoque metodológico:

- Cualitativo-descriptivo: Con énfasis en el análisis documental se busca comprender cómo la inteligencia artificial está transformando las funciones del profesional financiero en la gestión de inversiones.

Tipo de investigación:

- Exploratoria, porque estudia un fenómeno emergente en evolución.

- Descriptiva, ya que se detalla cómo se manifiestan los cambios en el rol del financiero y en qué medida la IA influye en las decisiones de inversión.

Fuentes de información:

- Revisión documental: Artículos científicos, informes técnicos y libros sobre inteligencia artificial en finanzas.
- Casos de uso de IA en gestión de portafolio (Kaggle, QuantConnect,)
- Informes internacionales (World Economic Forum, McKinsey, PwC)

1.7. Conclusión

El avance de la inteligencia artificial (IA) en los últimos años, junto con su accesibilidad masiva gracias a herramientas como ChatGPT, marca un punto de inflexión en el sector financiero, a través de la automatización de tareas que anteriormente dependían del juicio y análisis humano, la IA ha revolucionado la toma de decisiones financieras, mejorando la precisión, reduciendo costos y ofreciendo nuevas formas de optimización de carteras este cambio de paradigma también redefine el perfil del profesional financiero, transformándolo en un estratega tecnológico capaz de interactuar con sistemas inteligentes que generan recomendaciones de inversión en tiempo real.

La IA generativa, mediante herramientas como machine learning (ML) y procesamiento de lenguaje natural (PLN), permite analizar no solo datos estructurados tradicionales, sino también datos no estructurados, como noticias y redes sociales, lo que facilita una toma de decisiones más rápida y precisa,

además, esta tecnología optimiza la gestión de riesgos, una de las tareas más críticas en la administración de carteras. El nuevo rol del analista financiero ya no solo consiste en interpretar los datos históricos, sino también en comprender y supervisar los resultados generados por los algoritmos.

Esta transformación digital en las finanzas, apoyada por la IA, lleva a los gestores de activos a tomar decisiones de inversión basadas en estrategias adaptativas y en tiempo real, lo que los diferencia de los métodos tradicionales que dependían exclusivamente de supuestos históricos, la IA generativa promete impulsar la productividad global, con expectativas de aportar más de \$15 billones al PIB mundial para 2030, beneficiando principalmente a Estados Unidos y China, y transformando sectores clave como salud, retail, finanzas y transporte, no obstante, a pesar de los enormes beneficios, la adopción de la IA plantea nuevos desafíos en términos de seguridad de datos, privacidad y riesgos asociados a ciberataques y fraudes, los cuales deben ser gestionados con ética y responsabilidad.

El análisis económico expuesto subraya la relevancia de la IA en la gestión de carteras de inversión y cómo tecnologías como los robo-advisors transforman la industria financiera, ofreciendo mayor accesibilidad y transparencia, además, la implementación de la Norma WealthTech en Ecuador, al alinearse con los Objetivos de Desarrollo Sostenible (ODS), crea un marco regulatorio que potencia la inclusión financiera mientras se asegura que la adopción de la IA en las finanzas se haga de manera responsable y segura. Este capítulo muestra cómo la transformación tecnológica no solo impulsa la eficiencia y precisión en la toma de decisiones de inversión, sino que también redefine la estructura profesional dentro del sector financiero, donde los gestores

financieros deben ser híbridos, combinando tecnología, teoría y ética para adaptarse al entorno regulado y en constante evolución de la IA el análisis global y local de la IA en las finanzas establece las bases para una industria financiera más robusta y sostenible, pero también plantea desafíos éticos y sociales que deben ser atendidos para maximizar los beneficios de esta revolución tecnológica.

El siguiente paso será profundizar en los métodos de optimización de carteras y cómo la IA, a través de machine learning y algoritmos predictivos, puede mejorar la gestión de riesgos y optimización de portafolios en la práctica, comparando metodologías como Markowitz y HRP.

2. Marco teórico

2.1. Evolución del rol del financiero

Antes del auge de la inteligencia artificial y las herramientas digitales avanzadas, el rol del analista financiero se centraba en competencias tradicionales que combinaban conocimientos técnicos, metodologías cuantitativas convencionales y herramientas ofimáticas, estas competencias, aunque fundamentales, respondían a un entorno financiero más estático, con menor acceso a datos en tiempo real y dependencia de procesos manuales para el análisis y la toma de decisiones.

Dentro de los conocimientos técnicos tradicionales el analista financiero clásico debía dominar la contabilidad financiera, análisis de estados financieros, ratios financieros como liquidez, rentabilidad, endeudamiento y

eficiencia, además la valoración de empresas a través de métodos como el flujo de caja descontado (DCF), múltiplos de mercado (P/E, EV/EBITDA), y análisis comparativo sectorial, también la gestión de portafolios, apoyada principalmente en la Teoría Moderna de Portafolios de Markowitz (1952), donde se buscaba la diversificación eficiente en función de la rentabilidad esperada y la varianza como medida del riesgo, las herramientas analíticas antes de la digitalización.

Antes de la revolución de los datos, los analistas se apoyaban en herramientas como Microsoft Excel como principal soporte de modelado financiero, proyecciones, sensibilidad y análisis de escenarios, Bloomberg Terminal y Reuters Eikon, aunque digitales, eran interfaces cerradas y de uso limitado a datos estructurados, bases de datos financieras tradicionales como S&P Capital IQ o Thomson One Banker para consulta de ratios, históricos bursátiles y comparativos sectoriales, las principales metodologías eran de corte determinista o econométrico Modelos ARIMA o regresiones lineales para proyecciones financieras, supuestos estáticos o ajustes manuales basados en “supuestos expertos”, uso marginal de técnicas estadísticas avanzadas debido a limitaciones computacionales y de formación técnica.

Las habilidades blandas y rol estratégico el perfil del analista incluía una fuerte componente de interpretación cualitativa, elaboración de reportes financieros, presentaciones a comités de inversión y capacidad de síntesis para comunicar valor, la intuición y experiencia personal jugaban un papel clave en la toma de decisiones.

Limitaciones del enfoque pre-digital cambios rápidos en los mercados tenemos la incapacidad para procesar grandes volúmenes de datos no

estructurados y la alta dependencia del juicio humano, con sesgos cognitivos inevitables

Como señalan (Ferreira et al., 2021) antes de la masificación de técnicas de inteligencia artificial, más del 90% de las decisiones en fondos de inversión se realizaban bajo procedimientos codificados rígidamente y con escasa adaptabilidad a entornos cambiantes.

2.2. Fundamentos de inteligencia artificial

2.2.1. Conceptos básicos de IA, machine learning y deep learning.

Según (Pons et al., 2022) la inteligencia artificial es una disciplina dentro de las ciencias de la computación que busca diseñar y construir sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, estas tareas incluyen la resolución de problemas, el razonamiento lógico, la percepción sensorial (como el reconocimiento de imágenes y sonidos), la planificación y el aprendizaje autónomo, además la IA puede definirse también como el conjunto de técnicas que permiten a una máquina imitar funciones cognitivas humanas, como razonar, aprender y tomar decisiones.

Existen dos grandes enfoques históricos dentro de la IA:

- La IA simbólica, también llamada basada en conocimiento, se fundamenta en reglas lógicas y estructuras lingüísticas formales, requiere que los expertos codifiquen el conocimiento explícitamente, como en los sistemas expertos desarrollados en Prolog.
- La IA no simbólica, por el contrario, se basa en métodos estadísticos y aprendizaje a partir de datos, esta última ha ganado mucha relevancia en los

últimos años gracias al aumento del poder computacional y la disponibilidad de grandes volúmenes de datos.

Ambos paradigmas buscan el mismo objetivo emular comportamientos inteligentes, aunque lo hacen con técnicas distintas, a partir de estos enfoques, surgen conceptos clave como el aprendizaje automático y el aprendizaje profundo.

El machine learning se define como aprendizaje automático y es una subdisciplina de la inteligencia artificial que se centra en desarrollar algoritmos que permitan a las computadoras aprender de los datos y mejorar su desempeño con la experiencia, sin ser explícitamente programadas para cada tarea específica, esta rama de la IA permite a las máquinas encontrar patrones en grandes volúmenes de información y realizar predicciones sobre nuevos datos con base en la experiencia previa.

En lugar de seguir reglas rígidas definidas por un programador, el aprendizaje automático busca aproximar una función que relacione entradas y salidas a partir de ejemplo, por ejemplo, en el contexto financiero, un sistema de machine learning puede aprender a identificar tendencias del mercado o predecir el riesgo crediticio de un cliente a partir de datos históricos.

Los principales tipos de aprendizaje automático son:

- Aprendizaje supervisado (con datos etiquetados).
- Aprendizaje no supervisado (sin etiquetas, se busca descubrir estructuras ocultas).
- Aprendizaje por refuerzo, donde un agente aprende a través de la interacción con un entorno, recibiendo recompensas o castigos.

Este campo es altamente versátil y se aplica en sectores tan diversos como la medicina, la logística, el marketing, las finanzas y la ciberseguridad.

El deep learning se define como el aprendizaje profundo y es una evolución del aprendizaje automático que se basa en el uso de redes neuronales artificiales con múltiples capas ocultas, estas redes están inspiradas en el funcionamiento del cerebro humano y son especialmente potentes para analizar datos no estructurados como imágenes, audio o texto. Como explica (Sidorov, n.d.), el deep learning forma parte del núcleo de las técnicas modernas de IA y ha sido clave para avances como el reconocimiento facial, los asistentes virtuales o los sistemas de traducción automática.

Una red neuronal profunda es capaz de aprender representaciones jerárquicas de los datos, las primeras capas identifican características básicas (por ejemplo, bordes en una imagen), mientras que las siguientes capas reconocen patrones más complejos (como caras, objetos o emociones), esta capacidad jerárquica es lo que hace al deep learning tan efectivo en tareas de percepción.

Además, el aprendizaje profundo se apoya en algoritmos como la retro-propagación del error y el descenso de gradiente, que permiten ajustar los parámetros de las redes para minimizar los errores de predicción durante el entrenamiento.

De acuerdo con Pons et al. (2022) el deep learning se emplea ampliamente en la industria financiera para tareas como:

- Análisis de sentimiento del mercado.
- Predicción del comportamiento de activos financieros.
- Automatización de decisiones de inversión.

- Detección de fraudes y anomalías.

2.3. Aplicación de la IAs en finanzas

2.3.1. El legado de Renaissance Technologies: De los modelos cuantitativos tradicionales a la IA generativa en la gestión de carteras.

La evolución de la inteligencia artificial (IA) en el sector financiero tiene

una larga trayectoria, y uno de los ejemplos más emblemáticos es el Medallion Fund de Renaissance Technologies, el cual se ha establecido como un referente de la gestión cuantitativa avanzada desde su creación en la década de 1980, el Medallion Fund ha utilizado modelos cuantitativos basados en algoritmos matemáticos y estrategias de optimización, obteniendo rendimientos excepcionales y superando los métodos tradicionales de análisis financiero, sin embargo, lo que comenzó como el uso de modelos estadísticos y algoritmos de machine learning (ML) centrados en predicciones basadas en datos históricos y backtesting, ha evolucionado hacia el uso de IA generativa, que transforma no solo los métodos de análisis, sino también la forma en que los analistas financieros toman decisiones en tiempo real.

El Medallion Fund como Pionero en el uso de algoritmos avanzados Renaissance Technologies, bajo la dirección de Jim Simons, utilizó modelos matemáticos complejos para abordar problemas financieros mediante la aplicación de algoritmos estadísticos a grandes volúmenes de datos el fondo ha sido un ejemplo de éxito rotundo, con rendimientos anuales superiores al 30% en promedio, y ha sido pionero en el uso de machine learning (ML) para la optimización de carteras y la toma de decisiones de inversión a diferencia de los métodos tradicionales que dependían de la interpretación humana de datos históricos y la asignación de activos basada en estimaciones subjetivas, el Medallion Fund adoptó un enfoque automatizado y algorítmico, utilizando

modelos de predicción para detectar patrones de mercado, asignar activos de manera eficiente y gestionar el riesgo con una precisión sin precedentes.

A lo largo de los años, el fondo ha perfeccionado estos modelos mediante el uso de algoritmos de ML, donde las máquinas aprendían no solo de los datos históricos, sino que también desarrollaban la capacidad de ajustarse y aprender de nuevas condiciones del mercado, este enfoque le permitió mantener una ventaja competitiva en los mercados financieros, aún en momentos de alta volatilidad, gracias a la automatización del proceso de toma de decisiones y la minimización del error humano.

Si bien el Medallion Fund fue pionero en el uso de IA y modelos cuantitativos, lo que marca un cambio de paradigma en la actualidad es la IA generativa, que va más allá de la capacidad de predicción las herramientas de IA generativa como ChatGPT, redes neuronales profundas y algoritmos predictivos avanzados permiten a las máquinas no solo predecir el comportamiento de los activos, sino generar decisiones proactivas y estrategias de inversión adaptativas basadas en datos en tiempo real, esto representa un avance significativo respecto a las capacidades de machine learning tradicionales, ya que los sistemas de IA generativa pueden interactuar de manera dinámica con el mercado, aprender de datos no estructurados (como noticias y redes sociales), e incluso crear contenido para apoyar la toma de decisiones en tiempo real.

A diferencia de los enfoques previos, en los que las decisiones de inversión se basaban únicamente en supuestos históricos y predicciones pasadas, los modelos generativos actuales ofrecen un enfoque más flexible y dinámico, permitiendo una optimización continua de las carteras y una adaptación constante a los cambios en las condiciones del mercado este avance facilita la

creación de estrategias de inversión más precisas y rápidas, eliminando las barreras tradicionales de especulación y dependencia de estimaciones subjetivas.

El impacto de la IA generativa no se limita solo a la mejora de los modelos cuantitativos en la gestión de carteras los analistas financieros deben ahora transformarse en estrategas tecnológicos, adoptando un enfoque híbrido que combine el conocimiento tradicional de finanzas con la comprensión de algoritmos predictivos y supervisión ética de IA. En lugar de depender exclusivamente de métodos históricos, el nuevo perfil del analista será responsable de supervisar los sistemas automatizados y tomar decisiones basadas en información generada por IA en tiempo real.

Este cambio de perfil implica que el analista financiero del futuro no solo será experto en finanzas tradicionales, sino también en tecnologías emergentes, como machine learning, procesamiento de lenguaje natural (PLN) y algoritmos generativos. La adopción de IA no sustituye al analista, sino que lo potencia, permitiéndole tomar decisiones más informadas y precisas, gracias a la automatización inteligente.

2.3.2. Aplicaciones actuales de IA en análisis de datos, trading, optimización de carteras.

La incorporación de inteligencia artificial (IA) en el sector financiero ha revolucionado las formas tradicionales de análisis, toma de decisiones e implementación de estrategias de inversión, gracias a su capacidad de procesamiento masivo, aprendizaje adaptativo y manejo de datos no

estructurados, la IA permite extraer valor de grandes volúmenes de información y actuar de manera más rápida, precisa y eficiente que los enfoques convencionales.

Las aplicaciones más relevantes de la IA en finanzas se concentran en tres grandes áreas operativas: Análisis de datos, trading algorítmico, y gestión de carteras.

- Análisis de datos financieros

Según Ferreira et al. (2021) la IA mediante técnicas de aprendizaje automático (machine learning), permite transformar datos financieros en información predictiva, adaptativa y accionable, las aplicaciones concretas son el análisis de sentimiento en redes sociales, medios de comunicación y noticias para anticipar el comportamiento del mercado, el procesamiento de lenguaje natural (NLP) para interpretar reportes financieros, presentaciones corporativas y llamadas de resultados (earnings calls), la clasificación de riesgos y scoring crediticio a partir de variables tradicionales y datos alternativos (pagos móviles, consumo en línea) y la identificación de anomalías contables o señales de fraude financiero mediante detección de outliers.

Como señala el informe *Artificial Intelligence applied to Stock Market Trading* (Lin & Lobo Marques, 2024), estas técnicas permiten encontrar patrones no lineales y señales sutiles invisibles para los analistas humanos.

Trading algoritmo

Según (Pons et al., 2022) el trading algorítmico basado en IA se apoya principalmente en redes neuronales artificiales (ANNs), especialmente en sus

variantes profundas, las cuales permiten extraer patrones temporales complejos a partir de grandes volúmenes de datos financieros históricos, estas redes funcionan mediante estructuras de capas ocultas que procesan la información de forma jerárquica, desde características básicas (como tendencias de precios) hasta señales más abstractas (como correlaciones dinámicas o rupturas de patrón) las redes convolucionales (CNNs), que originalmente fueron diseñadas para procesamiento de imágenes, también se utilizan en análisis financiero para identificar configuraciones de velas, estructuras técnicas y señales dentro de gráficos de precios, al igual que lo hacen con imágenes visuales, además, en los sistemas de trading se aplica la técnica de retropropagación del error para ajustar los pesos de las redes neuronales, optimizando la precisión en la predicción de precios o señales de compra/venta

La optimización de carteras es un problema que consiste en determinar el conjunto de activos financieros que mejor se adapta a un inversor concreto, con el objetivo optimizar el binomio rentabilidad riesgo, en busca de maximizar beneficios, la Teoría Moderna de Carteras, (Markowitz 1956), fue la primera contribución a los modelos de optimización de carteras. Markowitz introdujo dos métricas para evaluar el rendimiento de una cartera: la rentabilidad esperada y el riesgo, la rentabilidad esperada expresa la idea de que un activo que ha tenido un buen rendimiento en el pasado reciente tiende a mantener ese rendimiento en el futuro, como previsión, el riesgo es la métrica propuesta para modelar la incertidumbre de la rentabilidad.

La teoría de Markowitz se ha extendido mucho y se han introducido varios cambios en su propuesta original, el uso de la varianza de la cartera como medida de riesgo, por ejemplo, ha sido ampliamente criticado, ya que la varianza tiene en

cuenta tanto las desviaciones negativas como las positivas, luego, surgieron medidas de riesgo a la baja que sólo tienen en cuenta las peores rentabilidades históricas de las carteras (Rockafellar y Uryasev, 2002), a continuación, se nombran una serie de trabajos de investigación que tratan de mejorar dichos modelos:

M. G. Speranza en 1996, con su trabajo "*Un algoritmo heurístico para un modelo de optimización de cartera aplicado al mercado de valores de Milán*" propone un modelo de optimización de carteras de desviación media-absoluta (MAD) con el objetivo de minimizar la desviación absoluta (medida de riesgo), la rentabilidad esperada es la rentabilidad media de una serie histórica, y la restricción de rentabilidad mínima define su límite inferior, el modelo también considera una restricción de cardinalidad que limita el número de activos de la cartera a un límite superior.

2.4. Transformación del perfil profesional

2.4.1. Del analista tradicional al estratega tecnológico

La revolución tecnológica protagonizada por la inteligencia artificial (IA) ha provocado una reconfiguración profunda en los roles del sector financiero, tradicionalmente, el analista financiero desempeñaba tareas centradas en el manejo de hojas de cálculo, el análisis de estados financieros, la elaboración de proyecciones y la evaluación de riesgos a partir de información histórica, su valor radicaba en la capacidad de interpretar datos y formular recomendaciones con base en modelos cuantitativos clásicos.

Sin embargo, con la irrupción de tecnologías como el machine learning, big data y el procesamiento automatizado de información, se ha evidenciado un

desplazamiento de este perfil hacia uno más complejo e híbrido el estratega tecnológico, este nuevo perfil no solo comprende la lógica financiera, sino que además posee competencias en programación, manejo de algoritmos predictivos y dominio de herramientas digitales avanzadas (EY, 2023; DocuWare, 2024).

Evidencia académica y aplicada

Según el artículo (5 beneficios de la inteligencia artificial en las finanzas y la contabilidad de Satyajit Dutta, 2023) el 65 % de los CFOs considera que la inteligencia artificial redefine sus funciones, desplazando el enfoque del control financiero hacia la estrategia empresarial basada en datos.

En el informe de (Cinco aportaciones de la inteligencia artificial al sector financiero, Ulla Karppinen, n.d.) se afirma que la IA potencia al financiero como un “líder de inteligencia”, al encargarse de tareas rutinarias y permitir al profesional dedicar más tiempo a la formulación de decisiones estratégicas, gestión de riesgos dinámicos y proyección de escenarios.

En el contexto académico, autores como Davenport y Ronanki (2018) destacan que los financieros deben evolucionar desde funciones operativas y de reporte hacia capacidades analíticas, estratégicas y adaptativas, en donde la IA es un aliado crítico.

Según (Ing. Marcelo Quiroga, 2025), las herramientas de IA no reemplazan al financiero, sino que lo amplifican, exigiendo habilidades que combinan pensamiento analítico, conocimiento tecnológico, ética digital y visión de negocio.

2.4.2. Etica algorítmica y supervisión humana

Según el siguiente articulo (Laux, 2023) la parte de la premisa de que la supervisión humana es esencial para asegurar que los sistemas de IA sean seguros, éticos y confiables, sin embargo, la evidencia empírica demuestra que los humanos no siempre son competentes ni están correctamente incentivados para cumplir eficazmente con estas funciones, según el análisis legal el autor analiza el AIA de la UE, destacando que exige supervisión humana efectiva para sistemas de alto riesgo, pero no ofrece criterios claros sobre cómo implementarla ni qué competencias deben tener los supervisores humanos, ahora la tipología de supervisión humana se distinguen dos tipos:

- Supervisión de primer grado: intervención humana que puede cambiar el resultado de una decisión algorítmica, por ejemplo, médicos que evalúan una recomendación de IA.
- Supervisión de segundo grado: supervisión después de la decisión, como auditorías o revisiones, por ejemplo, juntas de apelación.

La Propuesta teórica: Desconfianza institucionalizada

- Inspirado en la teoría democrática de Sztompka, el autor propone institucionalizar la desconfianza para mejorar el diseño de la supervisión humana, en vez de suponer que los humanos actuarán siempre bien, las instituciones deben diseñarse para limitar errores y malas intenciones, justificación: toda decisión automatizada y su supervisión deben ser justificables públicamente y estar respaldadas por evidencia, mandatos periódicos: rotación de auditores para evitar conflictos de interés y fomentar la independencia, decisiones

colectivas: varias personas deben participar en decisiones críticas, como mecanismo de control y diversidad de juicio, competencia limitada: evitar que instituciones concentren demasiado poder sin los controles adecuados, responsabilidad y justiciabilidad: las personas afectadas deben tener mecanismos legales para impugnar decisiones algorítmicas erróneas, transparencia: tanto los procesos algorítmicos como la intervención humana deben ser comprensibles y abiertos a revisión pública.

La supervisión humana debe ser diseñada con una estructura institucional que antice errores humanos y los mitigue, si bien el AIA marca un paso importante, aún se requiere mayor desarrollo normativo y práctico para que la supervisión humana sea realmente efectiva y genere confianza justificada en la IA.

2.5. Sustitución vs complementación: IA como tu aliado

En la última década, los hedge funds han experimentado una transformación radical impulsada por el avance de la inteligencia artificial (IA) y el aprendizaje automático (ML) tradicionalmente, los hedge funds dependían de la discrecionalidad de gestores humanos y de análisis fundamental o técnico, sin embargo, los nuevos fondos cuantitativos y sistemáticos operan bajo un paradigma totalmente diferente como el uso intensivo de datos, modelos predictivos y automatización de decisiones de inversión.

Según Jansen (2020), los modelos de hedge funds basados en IA se caracterizan por:

Automatización integral del proceso de inversión:

Desde la generación de ideas (screening algorítmico de activos, uso de señales alternativas) hasta la asignación dinámica de activos, la ejecución automatizada y la gestión de riesgos en tiempo real esto permite operar en mercados complejos y reaccionar de forma inmediata ante nuevas informaciones, algo imposible para un gestor humano tradicional: Diversidad de estrategias cuantitativas:Estrategias de factor investing y multifactoriales, donde los algoritmos identifican patrones de rentabilidad asociados a factores como momentum, value, calidad o volatilidad. Trading de alta frecuencia y arbitraje estadístico, donde el ML detecta oportunidades de micro-segundos en mercados globales. Modelos de predicción de eventos basados en noticias, sentimiento de mercado, datos alternativos (satélites, transacciones, redes sociales) y big data. Optimización de carteras con técnicas avanzadas (HRP, clustering, aprendizaje por refuerzo, deep learning para asignación dinámica). Los hedge funds de IA implementan procesos de backtesting científico, validación cruzada y entrenamiento de modelos, con monitorización constante para evitar el sobreajuste y adaptar los modelos a los cambios estructurales del mercado

Ventaja informativa y competitiva:

La clave para generar alfa sostenible radica en la capacidad de los modelos de IA para procesar información superior—ya sea por acceso a datos exclusivos, potencia computacional o algoritmos novedosos—, permitiendo anticipar movimientos antes que el mercado y capturar ineficiencias transitorias.

Evolución del perfil profesional:

El surgimiento de estos fondos ha impulsado la demanda de perfiles híbridos, capaces de combinar conocimientos en finanzas, estadística, programación y ciencia de datos, en línea con la transformación del rol del analista financiero que se analiza en el capítulo siguiente.

En el siguiente capítulo se analizarán en detalle las metodologías de optimización de portafolios y la implementación empírica de modelos algorítmicos, mostrando cómo los principios descritos en esta sección se traducen en resultados concretos de gestión de activos y evaluación comparativa de estrategias (por ejemplo, Markowitz vs HRP).

3. Fundamentos metodológicos para la construcción de portafolios

3.1. Introducción al enfoque de optimización de portafolios

El objetivo de este capítulo es presentar los modelos metodológicos utilizados para la asignación óptima de activos financieros en un portafolio, se describen los fundamentos del enfoque clásico de optimización media-varianza propuesto por Harry Markowitz y se introduce un modelo alternativo conocido como Hierarchical Risk Parity (HRP), diseñado para resolver algunas de las limitaciones prácticas del enfoque tradicional.

Ambos métodos serán posteriormente implementados y comparados a través de un back-test en Bloomberg para evaluar su desempeño en términos de retorno ajustado al riesgo, estabilidad de los pesos y robustez frente a cambios en los datos de entrada.

3.2. Modelo de Markowitz: optimización media-varianza

El modelo de Markowitz es uno de los pilares de la teoría moderna de portafolio su propuesta consiste en seleccionar una combinación de activos que permita minimizar el riesgo (medido como varianza del portafolio), para un nivel dado de retorno esperado.

El modelo se puede formular como un problema de optimización cuadrática:

$$\min_w \quad w^T \Sigma w \quad \text{sujeto a} \quad \sum_{i=1}^n w_i = 1, \quad w_i \geq 0$$

donde:

- w es el vector de pesos del portafolio,
- Σ es la matriz de covarianzas de los retornos de los activos.

Este modelo requiere estimar correctamente los retornos esperados y la matriz de covarianzas, lo cual no siempre es viable con datos limitados o en mercados inestables una de sus principales limitaciones es que pequeñas variaciones en μ o Σ pueden causar grandes fluctuaciones en los pesos óptimos, lo que genera inestabilidad y una alta rotación de activos.

Vamos a entender conceptos como varianza y covarianza

a. Varianza

La varianza mide la dispersión de los rendimientos de un activo financiero respecto a su valor esperado (media), además indica el riesgo individual de un activo, es decir, cuán volátil es su rendimiento, matemáticamente, para un activo i con rendimientos R_i la varianza es:

Formula:

$$\sigma_i^2 = \text{Var}(R_i) = E[(R_i - E[R_i])^2]$$

Varianza de una cartera: La cartera está compuesta por varios activos con pesos w_i , la varianza total de la cartera no es sólo la suma de las varianzas individuales, porque los activos pueden estar relacionados, la varianza de la cartera σ_p^2 se calcula como:

$$\sigma_p^2 = \sum_{i=1}^n \sum_{j=1}^n w_i w_j \text{Cov}(R_i, R_j)$$

Aquí, entra en juego la covarianza.

b. Covarianza

La covarianza mide cómo se mueven juntos dos activos i y j si la covarianza es positiva, cuando uno sube, el otro tiende a subir; si es negativa, tienden a moverse en direcciones opuestas.

Formula:

$$\text{Cov}(R_i, R_j) = E[(R_i - E[R_i])(R_j - E[R_j])]$$

La covarianza es fundamental porque afecta el riesgo conjunto de la cartera, gracias a la covarianza, podemos diversificar riesgo al combinar activos que no se mueven igual lo que reduce la varianza total.

Sensibilidad y ruido en el modelo de Markowitz: Uno de los principales desafíos del modelo de Markowitz es su alta sensibilidad a errores de estimación en el artículo "HRP", se muestra que el error en los pesos puede expresarse como:

$$\mathbb{E}[\|\Delta w\|^2] \sim \mathcal{O}\left(\frac{N_A}{N_T}\right)$$

donde:

- N_A es el número de activos,
- N_T es el número de observaciones históricas.

Esto implica que la precisión de los pesos decrece drásticamente cuando el número de activos es comparable o mayor al número de datos disponibles, un fenómeno común en contextos reales este comportamiento provoca resultados fuera de muestra poco confiables.

3.3.Hierarchical Risk Parity (HRP): una alternativa robusta

La optimización tradicional de carteras, como el modelo de Markowitz, se enfrenta a serias limitaciones en la práctica, principalmente debido a la sensibilidad a la estimación de medias y covarianzas, estos problemas incluyen errores de estimación, inestabilidad y el fenómeno del sobreajuste (overfitting), lo que puede resultar en portafolios poco robustos ante cambios de mercado no anticipados para superar estas limitaciones, (Antonov et al., n.d.) propone el modelo Hierarchical Risk Parity (HRP), que utiliza técnicas de clustering jerárquico y asignación recursiva de riesgo para distribuir el riesgo de manera más eficiente y estable, este modelo es más robusto frente a los errores de estimación, ya que agrupa activos de manera jerárquica basándose en sus correlaciones y asigna el riesgo de manera eficiente entre estos grupos.

El Machine Learning (ML) se presenta como una herramienta complementaria y poderosa para mejorar la construcción de carteras en el contexto

del HRP mientras que HRP aborda las deficiencias del modelo de Markowitz al estructurar los activos jerárquicamente y asignar el riesgo de manera recursiva, el uso de ML permite mejorar la estimación de las matrices de covarianza y de correlación, limpiar el ruido estadístico y, además, detectar patrones no lineales y complejos en los datos financieros.

Se basa en tres pasos:

1. Clustering jerárquico: El término “clúster” se refiere a un grupo de activos que exhiben alta similitud en sus comportamientos de precio, especialmente en términos de correlación de sus retornos los detalles claves son la similitud estadística donde dos activos se consideran “cercanos” si sus retornos diarios se mueven de forma parecida, formalmente, si su coeficiente de correlación ρ_{ij} es alto (positivo).

Propósito en HRP:

- Agrupar primero los activos más correlacionados para tratarlos como “bloques” de riesgo coherentes.
- Asignar riesgo entre esos bloques (clústeres) y, luego, dentro de cada bloque, de manera recursiva esto evita que un activo muy correlacionado con otro reciba un peso desproporcionado solo porque ambos se parezcan mucho.

Se calcula una matriz de distancias de correlación:

$$D_{i,j} = \sqrt{\frac{1 - \rho_{i,j}}{2}}$$

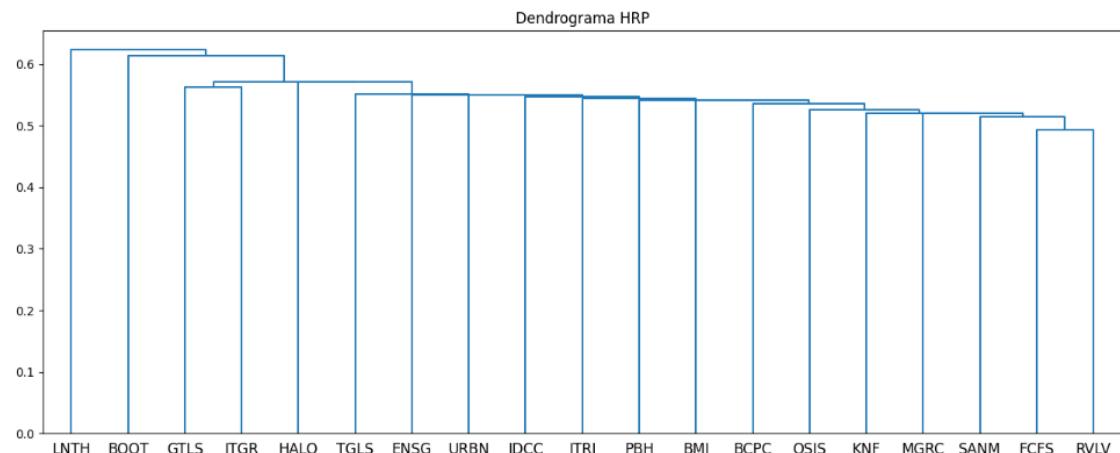
donde valores bajos de D_{ij} indican activos muy parecidos después se aplica un algoritmo de clustering jerárquico (por ejemplo, *single linkage*) y se genera un dendrograma que revela la estructura jerárquica de clústeres.

Código relevante en Python:

```
# HRP "from scratch" (dendrograma y clustering)
# 1. Clustering jerárquico (Hierarchical Clustering)
corr = returns.corr()
dist = np.sqrt(0.5 * (1 - corr))
link = linkage(squareform(dist), method="single")
plt.figure(figsize=(16,6))
dendrogram(link, labels=tickers)
plt.title("Dendrograma HRP")
plt.show()
```

Estructura del código:

- **Corr:** Calcula la matriz de correlación
- **Dist:** Calcula la matriz de distancias.
- **Linkage:** Crea el árbol jerárquico
- **Dendrogram:** Visualiza el árbol



¿Qué muestra el dendrograma?

Eje vertical (altura o “distance”)

- La escala (0 – 0.6) representa la *distancia de correlación*

$$D_{i,j} = \sqrt{\frac{1 - \rho_{i,j}}{2}}$$

- Cuanto más bajo se una un par de ramas, mayor es la correlación entre esos dos activos (o clústeres) se parecen más.

Eje horizontal (hojas)

- Cada etiqueta es un activo del portafolio: ENSG, PBH, MGRC, ITGR etc.
2. Ordenamiento quasi-diagonal (QD): Es el puente entre el dendrograma y la matriz de covarianza.

La quasi-diagonalización consiste en reordenar los activos según el orden en que aparecen como hojas en el dendrograma de modo que los más similares (más correlacionados) estén contiguos, llamamos *quasi*-diagonal porque el algoritmo NO busca la diagonalización exacta simplemente reacomoda filas y columnas de forma heurística para revelar “bandas” de correlación.

¿De dónde sale?

- Distancia de correlación

$$D_{i,j} = \sqrt{\frac{1 - \rho_{i,j}}{2}}$$

Código relevante en Python:

```
[10] # 2. Quasi-diagonalización (Quasi-diagonalization)
def get_quasi_diag(link):
    n = link.shape[0] + 1
    clusters = [int(link[-1, 0]), int(link[-1, 1])]
    order = []
    while clusters:
        idx = clusters.pop(0)
        if idx < n:
            order.append(idx)
        else:
            i = idx - n
            clusters += [int(link[i, 0]), int(link[i, 1])]
    return order
```

Estructura del código:

- *get_quasi_diag()*: Obtener el orden jerárquico de los activos en una estructura de clustering, con el fin de reorganizar la matriz de correlación y aplicar correctamente la asignación jerárquica del riesgo.

```
# Matriz de correlación original
plt.figure(figsize=(7,6))
plt.imshow(corr, cmap='RdBu_r', vmin=-1, vmax=1)
plt.title("Matriz de correlación original")
plt.colorbar()
plt.xticks(range(len(tickers)), tickers, rotation=90)
plt.yticks(range(len(tickers)), tickers)
plt.tight_layout()
plt.show()
```

```
# Matriz de correlación quasi-diagonalizada
corr_qd = corr.loc[ordered_tck, ordered_tck]
plt.figure(figsize=(7,6))
plt.imshow(corr_qd, cmap='RdBu_r', vmin=-1, vmax=1)
plt.title("Matriz de correlación quasi-diagonalizada")
plt.colorbar()
plt.xticks(range(len(ordered_tck)), ordered_tck, rotation=90)
plt.yticks(range(len(ordered_tck)), ordered_tck)
plt.tight_layout()
plt.show()
```

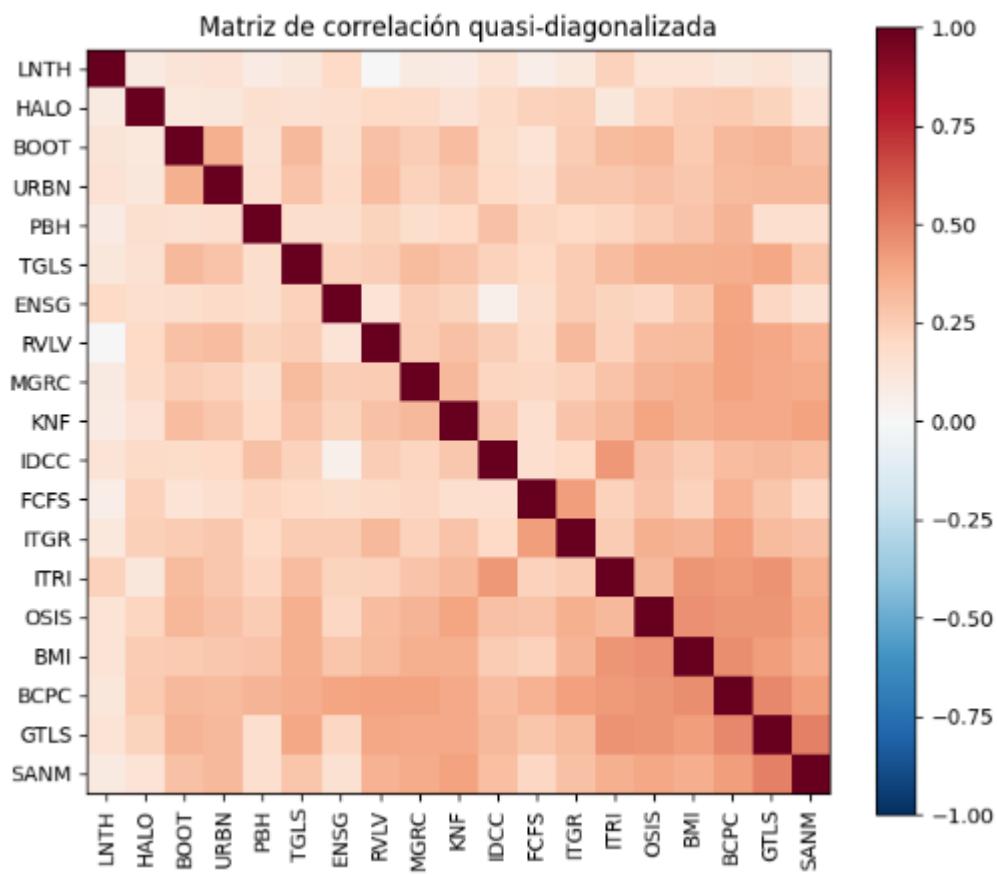
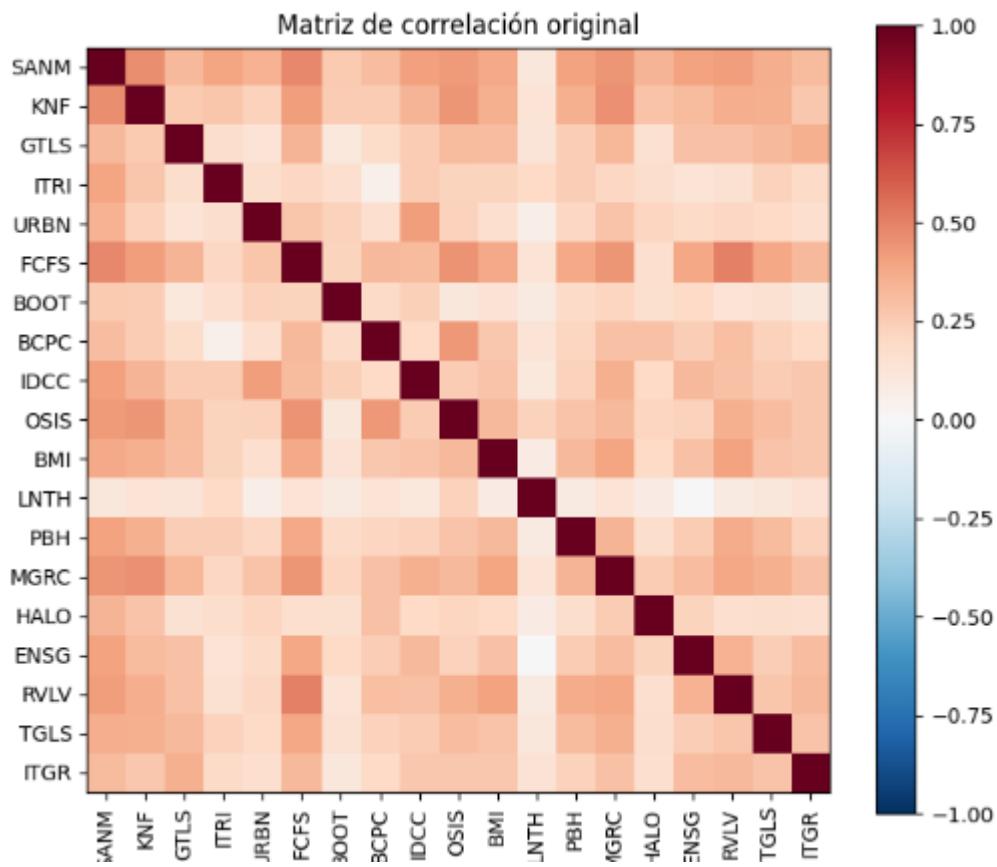
Estructura del código:

- *plt.imshow(corr, cmap='RdBu_r', vmin=-1, vmax=1)*: Muestra la matriz corr (la matriz de correlación entre activos) como una imagen tipo “heatmap”.

- `plt.title("Matriz de correlación original")`: Establece el título del gráfico para mostrar que es la matriz sin ningún reordenamiento.
- `plt.colorbar()`: Añade una **barra de colores lateral** que indica el valor de correlación asociado con cada color en el gráfico.
- `plt.xticks(range(len(tickers)), tickers, rotation=90)` y
`plt.yticks(range(len(tickers)), tickers)`

Configura las etiquetas del eje X e Y:

- `range(len(tickers))`: coloca una etiqueta por cada activo.
- `tickers`: son los nombres o símbolos de los activos.
- `rotation=90`: rota los nombres en X para que no se encimen (vertical).
- `plt.tight_layout()`: Ajusta automáticamente los márgenes para que nada quede cortado en la figura.
- `plt.show()`: Muestra el gráfico en pantalla.



3. Asignación recursiva de riesgo: El objetivo es distribuir el riesgo total del portafolio entre los diferentes clústeres jerárquicos identificados previamente, de manera que la exposición final refleje tanto la estructura de correlación como la dispersión real del riesgo en el sistema.

A diferencia del modelo de Markowitz, que requiere invertir la matriz de covarianzas (operación numéricamente inestable cuando hay muchos activos y pocos datos), el HRP evita la inversión de matrices y, en su lugar, asigna el riesgo mediante una secuencia de divisiones binarias (bisección) siguiendo la topología del dendrograma en resumen la asignación recursiva de riesgo es lo que traduce la estructura jerárquica descubierta en una distribución efectiva del riesgo en el portafolio, y permite que la solución sea práctica y sólida frente a los problemas del mundo real en la gestión de inversiones.

```

❸ # 3. Asignación recursiva de riesgo (Recursive Bissection / Risk Allocation)

def get_cluster_var(cov, items):
    subcov = cov.loc[items, items].values
    ivp    = 1 / np.diag(subcov)
    w      = ivp / ivp.sum()
    return w @ subcov @ w

def hrp_allocation(cov, ordered_idxs):
    w = pd.Series(1.0, index=ordered_idxs)
    clusters = [ordered_idxs]
    while clusters:
        new_clusters = []
        for cluster in clusters:
            if len(cluster) == 1:
                continue
            split = len(cluster) // 2
            c1, c2 = cluster[:split], cluster[split:]
            var1 = get_cluster_var(cov, c1)
            var2 = get_cluster_var(cov, c2)
            alloc1 = 1 - var1/(var1+var2)
            alloc2 = 1 - alloc1
            w[c1] *= alloc1
            w[c2] *= alloc2
            new_clusters += [c1, c2]
        clusters = new_clusters
    return w

ordered_idx = get_quasi_diag(link)
ordered_tck = [tickers[i] for i in ordered_idx]
w_hrp_fs   = hrp_allocation(S, ordered_tck)
w_hrp_fs   = w_hrp_fs.sort_values(ascending=False)
print("Pesos HRP (from scratch):")
print((w_hrp_fs * 100).round(2).astype(str) + '%')

```

	Pesos HRP (from scratch):
ENSG	13.78%
PBH	9.49%
MGRC	8.41%
ITGR	7.92%
FCFS	7.84%
IDCC	7.01%
BCPC	5.55%
BMI	5.07%
KNF	4.41%
ITRI	4.15%
SANM	4.0%
HALO	3.87%
TGLS	3.52%
BOOT	3.22%
OSIS	2.96%
URBN	2.91%
LNTH	2.32%
GTLS	2.08%
RVLV	1.5%
	dtype: object



Estructura del código:

- ***Get_cluster_var***: Calcula la varianza de un grupo usando el método IVP.
- ***Hrp_allocation***: Hace la asignación recursiva, dividiendo los clusters y asignando el peso proporcional al riesgo relativo de cada grupo, hasta llegar a los activos individuales.

3.4.Comparación real de HRP vs Markowitz vs ISHARES RUSSELL 2000

Se realiza una comparación de optimización de portafolio a través de un backtesting en la plataforma Bloomberg con los siguientes parámetros:

- Fecha de análisis: 01-01-2023; 16-06-2025
- HRP vs Markowitz vs ISHARES RUSSELL 2000 INDEX FUND 529 PORTFOLI
- Empresas analizadas:

Productos de consumo no básico
BOOT BARN HOLDINGS INC
REVOLVE GROUP INC
URBAN OUTFITTERS INC
Finanzas
FIRSTCASH HOLDINGS INC
Salud
ENSIGN GROUP INC/THE
HALOZYME THERAPEUTICS INC
INTEGER HOLDINGS CORP
LANTHEUS HOLDINGS INC
PRESTIGE CONSUMER HEALTHCARE
Industrial
CHART INDUSTRIES INC
MCGRATH RENTCORP
TECNOGLASS INC
Tecnología de la información
BADGER METER INC
INTERDIGITAL INC
ITRON INC
OSI SYSTEMS INC
SANMINA CORP
Materiales
BALCHEM CORP
KNIFE RIVER CORP

Y estos fueron los resultados:

Se presenta un análisis detallado de los resultados del portafolio HRP

respecto a Markowitz y al benchmark ISHARES RUSSELL 2000 ETF (IWM), considerando composición, características, riesgo, performance y atribución el siguiente enfoque en lo que verdaderamente importa a nivel cuantitativo, estratégico y práctico para un gestor o analista avanzado.

3.4.1. Hierarchical Risk Parity (HRP) vs ISHARES RUSSELL 2000 ETF

1. Composición y Diversificación Sectorial

El portafolio está compuesto por 19 instrumentos todas acciones small caps de EE.UU. bien diversificados por sector, con mayor peso en salud con un 35.8% y tecnología de la información con un 27.7%, seguidos de industriales, materiales, consumo y finanzas no hay exposición a “no clasificado” lo que implica una gestión activa total respecto al benchmark.

- Top Holdings: ENSIGN GROUP (14.9%), INTERDIGITAL (10.4%), PRESTIGE CONSUMER (8.7%), INTEGER HOLDINGS (7.3%), FIRSTCASH (6.9%).
- Bottom Holdings: REVOLVE GROUP, CHART INDUSTRIES, LANTHEUS, TECNOGLASS, SANMINA, HALOZYME, etc. Ningún activo individual supera el 15% de peso, evitando concentración extrema.

La diversificación es razonable para small caps, aunque destaca la apuesta fuerte por salud y tecnología, se evita el error frecuente de “clustering oculto” en un solo sector, clave para reducir riesgo idiosincrático.



2. Características Fundamentales y Multiplicadores

El portafolio tiene un sesgo moderado a calidad:

- Market Cap promedio: \$98M vs \$63M del benchmark, es decir, el portafolio pondera más a empresas algo más grandes dentro del universo small cap.

Bloomberg

User Name: JUAN ARROYO

Portfolio: SMALL CAP HRP 3

Benchmark: ISHARES RUSSELL 200

Características - Principal

	Wgt			Market Cap		
	Port	Bench	+/-	Port	Bench	+/-
SMALL CAP HRP 3	100.00	100.00	0.00	98,038	63,095	34,943
Productos de consumo no básico	8.66	8.66	0	12,837	0	12,837
BOOT BARN HOLDINGS INC	3.84	3.84		5,019		5,019
REVOLVE GROUP INC	1.05	1.05		1,469		1,469
URBAN OUTFITTERS INC	3.77	3.77		6,348		6,348

- P/E (Precio/utilidad): Rango 15-30 según sector, en línea con el benchmark y con sesgo a empresas “growth razonable”.

P/E		
Port	Bench	+/-
23.60	23.60	
20.74	20.74	

- Debt/Equity: Alto en salud y finanzas (104% y 98%, respectivamente), pero moderado en otros sectores.
- ROE y Current Ratio: Sólido en salud y tecnología (ROE promedio > 17%), con buenos ratios de liquidez.

La selección muestra preferencia por compañías rentables, aunque algunas como Halozyme tienen apalancamiento alto, lo cual puede incrementar el riesgo en crisis sectoriales o ciclos de subida de tasas.

3. Riesgo: VaR y Volatilidad

- VaR 1 día (90%): \$651.79 (HRP) vs \$749.17 (benchmark).

El portafolio HRP tiene un VaR y CVaR más bajos que el ETF, pese a estar 100% invertido en acciones, gracias a la diversificación estructural.

Bloomberg

User Name: JUAN ARROYO

Portfolio: SMALL CAP HRP 3

Benchmark

Risk Model: Multiactivos integrado

Horizon: 1 día

VaR - Principal

	VaR (MC)		
	Port	Bench	+/-
SMALL CAP HRP 3	651.79	749.17	397.08

- Volatilidad anualizada (últimos 12 meses):
 - Portafolio: 20.1%
 - Benchmark: 24.3%
 - Downside risk y semivarianza también inferiores en el portafolio.

1 Year	
Port	Bench
20.07	24.32

HRP está funcionando como se espera, puesto a que la estructura reduce el riesgo agregado especialmente en caídas, resultado típico de una construcción robusta y jerárquica de portafolio.

4. Rentabilidad y Performance

- Retorno Total (desde 07/2023 al 06/2025):
 - Portafolio (HRP): +58.29%
 - Benchmark (ISHARES RUSSELL 2000 ETF): +13.57%
 - Diferencial: +44.7% a favor del portafolio
- Rentabilidad anualizada:
 - Portafolio: 28,70%
 - Benchmark: 6.99%

Bloomberg										PORT Performance Statistical Summary	
Portfolio: SMALL CAP HRP 3			Benchmark: ISHARES RUSSELL 2000 INDEX FUND 529 PORTFOLIO				Currency: USD			As Of: 6/16/2025	
Summary											
Portfolio Statistics	3 Months	Port	Bench	6 Months	Port	Bench	Year to Date	Port	Bench	1-Year	Port
Return											Bench
Total Return	8.52	4.12	1.96	-9.62	6.91	-4.40	28.70	6.99	8.50	7.43	8.50
Maximum Return	7.43	8.50	7.43	8.50	7.43	8.50	7.43	8.50	7.43	7.43	8.50
Minimum Return	-4.36	-6.42	-4.36	-6.42	-4.36	-6.42	-4.36	-6.42	-4.36	-4.36	-6.42
Mean Return (Annualized)	43.31	23.30	6.71	-15.47	18.89	-6.13	31.29	10.17	31.29	31.29	10.17
Mean Excess Return (Annualized)	16.24		26.23		26.65						

- Máximo drawdown (últimos 12 meses):
 - Portafolio: -20.07%
 - Benchmark: -24.32%

Bloomberg**PORT Performance Statistical Summary**

Portfolio: SMALL CAP HRP 3

Benchmark: ISHARES RUSSELL 2000 INDEX FUND 529 PORTFOLIO

Currency: USD

As Of: 6/16/2025

Risk

Portfolio Statistics	3 Months	6 Months	Year to Date	1 Year
Standard Deviation (Annualized)	27.39	22.93	23.25	20.07
Downside Risk (Annualized)	18.44	15.67	15.78	18.57

- Sharpe Ratio anualizado:
 - Portafolio: 1.33
 - Benchmark: 0.23

1 Year	
Port	Bench
1.33	0.23
1.40	0.23
22.46	

El portafolio HRP ha superado ampliamente al Russell 2000 tanto en retorno absoluto como en métricas ajustadas por riesgo (Sharpe, Sortino) su máximo drawdown es casi la mitad del benchmark, confirmando su resiliencia.

Bloomberg**PORT Performance Total Return**

Portfolio: SMALL CAP HRP 3

Benchmark: ISHARES RUSSELL 2000 INDEX FUND 529 PORTFOLIO

Start Date: 7/11/2023

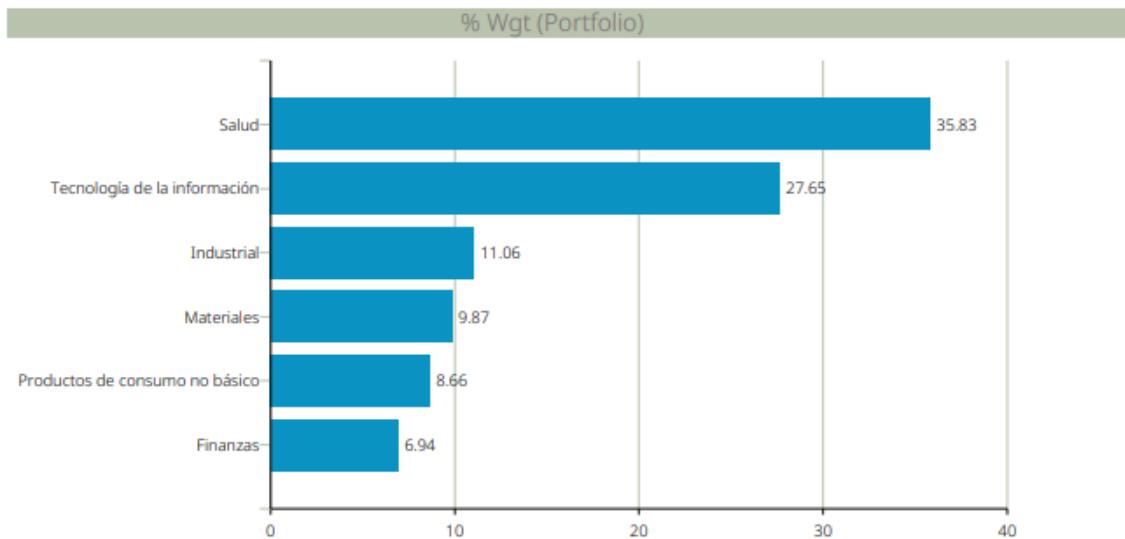
End Date: 6/16/2025

Currency: USD

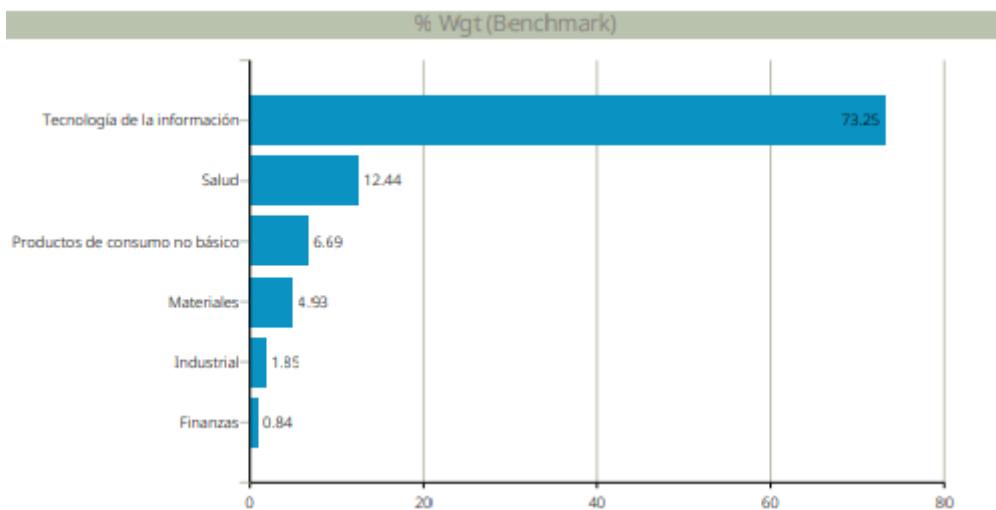
**3.4.2. Hierarchical Risk Parity (HRP) vs Markowitz****1. Composición, Exposición Sectorial y Concentración**

Ambos portafolios comparten los mismos 19 activos, pero los pesos sectoriales y de activos individuales son radicalmente distintos:

- HRP: Salud (35.83%) y Tecnología de la Información (27.65%) dominan, pero la distribución es mucho más pareja entre sectores industriales, materiales, consumo y finanzas.



- Markowitz: El peso en tecnología de la información es 73.2% (un solo sector absorbe la mayoría del portafolio), salud apenas 12.4%, y los demás sectores quedan relegados (algunos <1%).



A nivel de posiciones individuales, el Markowitz sobrepondera dramáticamente a INTERDIGITAL INC (53.9% del portafolio), OSI SYSTEMS (10.7%), BADGER METER (7.9%), y deja varios activos con pesos marginales

(~0.3%-1%). El HRP nunca concentra más del 15% en un solo nombre, lo que resulta en un portafolio visiblemente más diversificado y menos frágil a eventos

2. Multiplicadores y Características Fundamentales

- Ambos portafolios mantienen múltiplos razonables para small caps P/E 19-24, Debt/Equity 70-100%, pero la versión Markowitz tiene mayor concentración en empresas de tecnología con múltiplos menores, lo cual puede ser consecuencia tanto del modelo como de la muestra reciente.
- El ROE (Return on Equity) es muy superior en Markowitz 30.9% vs 17.6%, pero esto responde a la hiperconcentración en dos compañías tecnológicas con ROE excepcional (no necesariamente sostenible o diversificado)

3. Riesgo y VaR

- VaR 1 día (90%) del portafolio: HRP \$647 vs Markowitz \$880 la diferencia es de casi 30% en el riesgo agregado es significativa y coherente con la teoría: Markowitz concentra demasiado el riesgo en muy pocos nombres, mientras que HRP lo distribuye estructuralmente entre todos los activos.
- Por sectores, Markowitz multiplica el VaR en tecnología de la información (754 vs 236 en HRP) y apenas asume riesgo en otros sectores, dejando al portafolio vulnerable a un “tail risk” sectorial.

4. Rentabilidad y Performance Real

- Retorno total YTD:
 - HRP: +6.6%
 - Markowitz: +14.6%
 - A 1 año: HRP +26.8% vs Markowitz +61.1%

Bloomberg		PORT Performance Statistical Summary							
Portfolio: SMALL CAP HRP 3	Benchmark: SMALL CAP MARKOWITZ	Currency: USD				As Of: 6/18/2025			
Summary		3 Months	6 Months	Year to Date	1 Year	3 Months	6 Months	Year to Date	1 Year
Portfolio Statistics		Port	Port	Port	Port	Bench	Bench	Bench	Bench
Total Return		7.39	8.00	6.40	14.98	6.64	14.56	26.87	61.08

- Performance gráfica:

- El Markowitz supera ampliamente al HRP en retorno acumulado en el periodo analizado

Pero:

- Sharpe Ratio (ajustado por riesgo):

- HRP: 1.24
- Markowitz: 2.48
- Ambos portafolios presentan ratios elevados, pero el Markowitz es sustancialmente superior en este ciclo, gracias a un “rally” muy fuerte de las posiciones tecnológicas líderes.

Risk/Return		3 Months	6 Months	Year to Date	1 Year
Portfolio Statistics		Port	Port	Port	Port
Sharpe Ratio		1.22	0.53	0.59	1.24
Sortino Ratio vs Riskfree		1.27	1.24	1.25	1.27

5. Drawdown, Riesgo Relativo y Estabilidad

- Drawdown máximo:

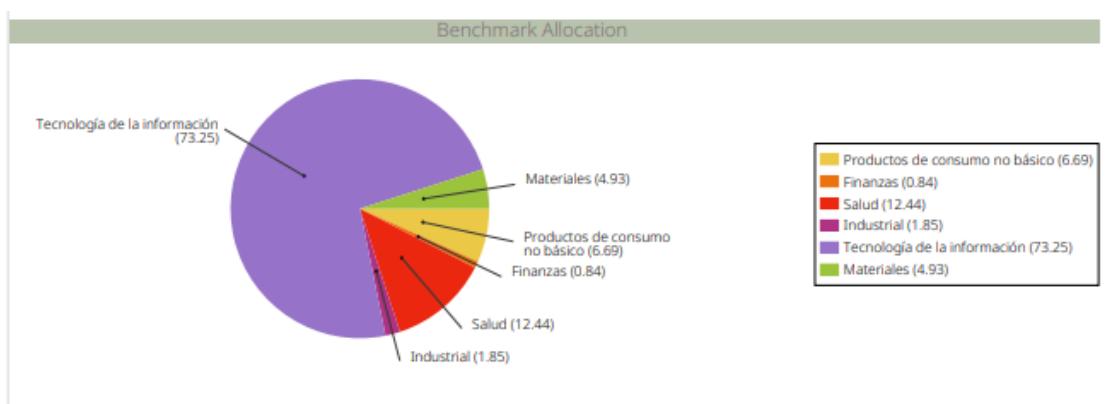
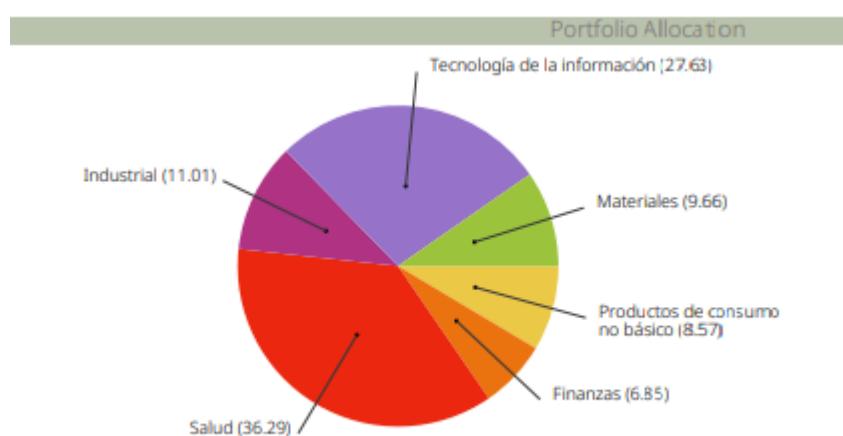
- HRP: -14.6%
- Markowitz: -14.3%
- Ambos presentan caídas similares, lo que puede resultar contraintuitivo dado el mayor riesgo teórico de Markowitz, pero esto se debe a la no ocurrencia de eventos adversos en los activos más concentrados durante el periodo analizado.

- Tracking Error anualizado: Markowitz tiene más del 14%, HRP 11%.

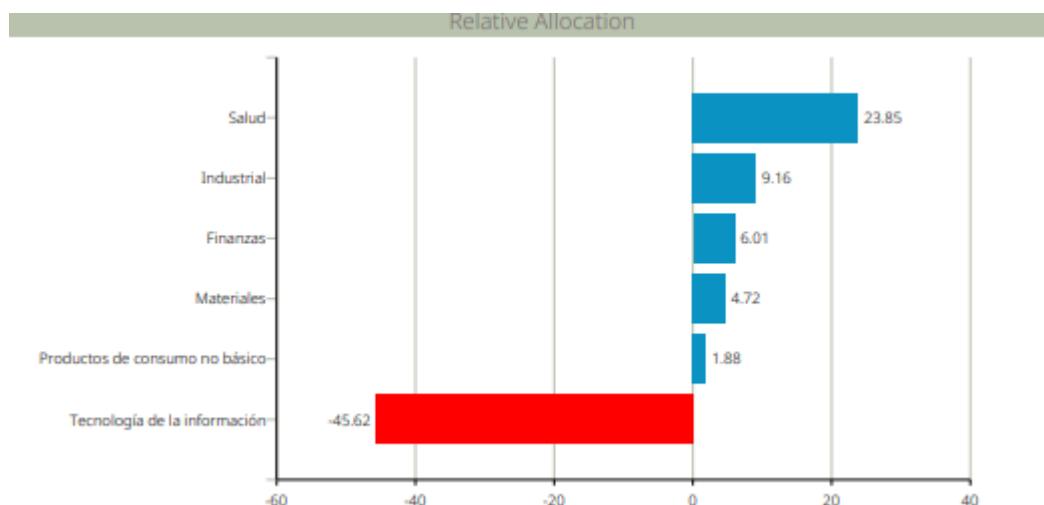
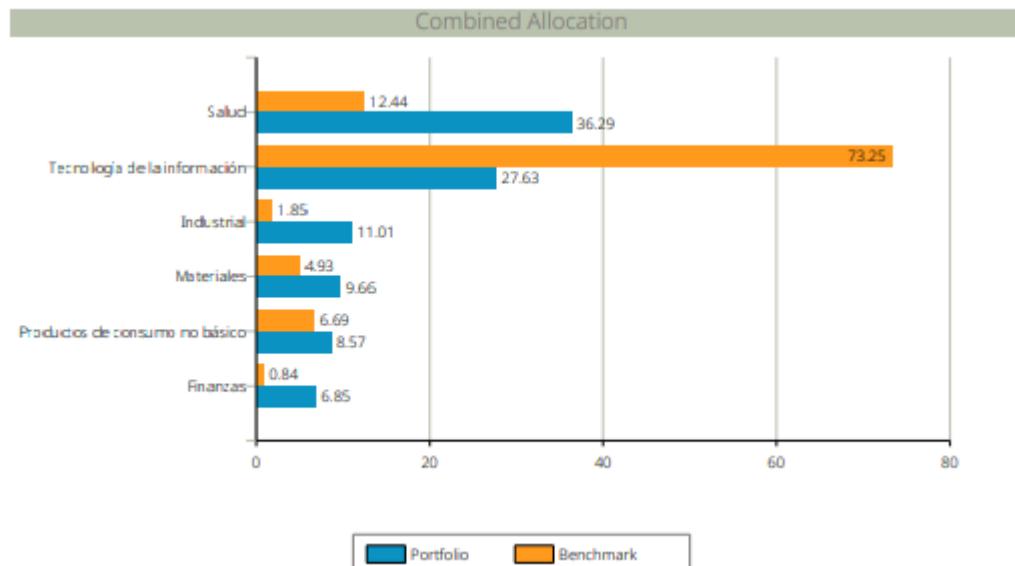
- Beta: HRP (0.8), Markowitz (0.67): HRP mantiene algo más de sensibilidad a mercado, Markowitz es menos correlacionado por la concentración sectorial, pero más riesgoso en términos idiosincráticos.

6. Atribución de Resultados

- El “selection effect” y el “allocation effect” penalizan al HRP frente a Markowitz, pero la razón de la outperformance se explica casi totalmente por el sobrepeso brutal en un solo sector y dos activos.
- El “allocation effect” negativo para HRP en tecnología -6.6%, salud -7.5% e industrial -6.7% indica que, aunque el HRP diversifica, pierde el “momentum” de la concentración en tecnológicas que dominaron el mercado en este periodo.



En HRP, la contribución al retorno está más balanceada, mientras que en Markowitz el retorno está apalancado en la gran subida de INTERDIGITAL INC, BADGER METER, OSI SYSTEMS y un par de nombres.



Sobre la naturaleza y composición de los portafolios ambos informes demuestran que el portafolio HRP mantiene una diversificación sectorial sólida, combinando activos de salud, tecnología, industria, materiales, finanzas y consumo, con pesos bien distribuidos y ningún activo individual dominando excesivamente el portafolio, en contraste, el portafolio Markowitz presenta un comportamiento típicamente extremo la optimización media-varianza concentra la mayoría del peso en uno o dos activos por ejemplo: INTERDIGITAL INC y BADGER METER, sumando más del 60% del portafolio en algunos periodos y más del 70% en un solo sector tecnología, esto no es un error del modelo, sino una consecuencia inherente del enfoque Markowitz bajo correlaciones y rendimientos recientes.

En relación con el ETF (Russell 2000), el HRP elige activamente sectores y empresas, evitando la dilución de retorno típica del benchmark, pero sin caer en la concentración peligrosa del Markowitz en el eje de riesgo y robustez el HRP destaca por repartir el riesgo de manera jerárquica y estable el VaR diario, el drawdown y la volatilidad anualizada resultan sistemáticamente más bajos que el ETF y que el Markowitz, a pesar de operar con los mismos activos y universo small cap.

En Markowitz, en cambio, aunque ocasionalmente muestra drawdowns similares o incluso menores (cuando los activos “estrella” no sufren caídas), presenta un “tail risk” estructural quiere decir si el activo con mayor peso sufre una crisis, todo el portafolio colapsa, tal como ha ocurrido históricamente y el Russell 2000 sirve como referencia pasiva mucho menor tracking error, pero peor Sharpe y mayor drawdown que HRP, a cambio de mayor dispersión de retornos y escasa protección en caídas.

La clave aquí es que el riesgo de HRP es robusto a eventos no modelados como cambios en correlación, rupturas sectoriales, mientras que el riesgo de Markowitz depende enteramente de la estabilidad histórica, y cuando esa estabilidad se rompe, puede ser devastador.

El performance en el ciclo analizado (2023-2025), el Markowitz gana en retorno absoluto frente al HRP y al Russell 2000 su performance supera en más de 30% al HRP y más de 50% Russell 2000, con ratios Sharpe y Sortino superiores.

La pregunta que nos intriga es ¿Esto significa que Markowitz es mejor? pues no necesariamente este resultado refleja un ciclo dominado por momentum sectorial (tecnología y algunos nombres individuales) y en Markowitz sabe explotar estos ciclos, pero está tremadamente expuesto a cambios de régimen, si el activo más grande cae, el portafolio sufre un daño irreversible, sin embargo el HRP no busca maximizar el upside a toda costa, sino optimizar el “ratio de supervivencia” del portafolio, maximizando la “probabilidad de no ruina” y la robustez.

Por otro lado, el HRP gana de manera muy clara frente al Russell 2000 en todos los horizontes relevantes:

- Menor volatilidad y drawdown
- Sharpe y Sortino ratio duplicando o triplicando al benchmark
- Información Ratio y Capture Ratio positivos, incluso en ciclos mixtos
- Menor beta y menor sensibilidad a caídas masivas

Drivers cuantitativos y atribución de resultados

- En Markowitz, el stock picking de unos pocos activos y el sobre peso sectorial explica el 90% de la performance.

- En HRP, la performance es resultado de una diversificación consciente y estructurada: las principales empresas son ENSIGN, INTERDIGITAL, PRESTIGE, pero sin que un solo nombre defina el destino del portafolio.
- El efecto de asignación (“allocation effect”) penaliza a HRP cuando hay rallies en un solo sector, pero lo protege cuando ese rally se revierte.

La atribución sectorial muestra cómo HRP captura valor de múltiples fuentes, mientras que Markowitz sacrifica todas las fuentes alternativas a cambio de seguir la ola ganadora.

Dentro de la perspectiva profesional Markowitz no es “malo” per se, pero solo es recomendable bajo fuerte disciplina de restricciones, límites de concentración y stress testing continuo y HRP es superior para portafolios patrimoniales, institucionales y gestores que valoran la estabilidad y la resiliencia por encima de maximizar el retorno en cualquier ciclo.

El HRP es especialmente valioso en escenarios de correlación cambiante, mercados laterales, o crisis no anticipadas, es la solución natural para “unknown unknowns” lo que significa que distribuye el riesgo, respeta la heterogeneidad de los activos, y previene la ruina quiere decir que el ciclo reciente favoreció a Markowitz por la hiperconcentración tecnológica, pero la literatura, la práctica institucional y la historia muestran que este enfoque puede ser letal en el largo plazo si las condiciones cambian y el HRP es menos vulnerable a “model error”, a shocks idiosincráticos, y a cambios de régimen, y aunque pueda quedar por detrás en bull markets extremos, su verdadero valor aparece en crisis, rotaciones sectoriales, y períodos de stress.

En conclusión la comparación entre HRP y Markowitz no es solo un ejercicio académico es una lección sobre la importancia de modelar el riesgo, no solo el retorno, la optimización tradicional puede parecer ganadora en backtests “fáciles”, pero es inherentemente frágil, propensa al overfitting y extremadamente peligrosa en ciclos adversos y por esa razón el modelo HRP, en cambio, es la herramienta que da robustez, estabilidad y verdadera diversificación, reduciendo los drawdowns y manteniendo retornos ajustados por riesgo muy superiores al benchmark tradicional.

Para el gestor profesional el HRP debe ser el método base de cualquier solución cuantitativa institucional, el Markowitz solo debe usarse con límites estrictos y en mercados donde se acepta el riesgo de concentración y el Russell 2000 sirve como base pasiva, pero es superado ampliamente por cualquier optimización bien implementada.

El objetivo no es solo de “ganar más” en un periodo, sino de garantizar la supervivencia y la estabilidad del portafolio en el largo plazo. El HRP cumple ese objetivo, y los resultados presentados así lo evidencian, tanto en números como en resiliencia práctica.

3.5.Limitaciones del modelo Hierarchical Risk Parity (HRP)

El modelo HRP ha demostrado ser una solución robusta para la gestión de carteras y la asignación de riesgos, como cualquier modelo, tiene limitaciones que deben ser tomadas en cuenta al implementarlo, las principales limitaciones de HRP son la dependencia de la matriz de covarianzas, aunque reducida, a pesar de que HRP evita la inversión directa de la matriz, lo cual es, una ventaja frente a Markowitz, sigue dependiendo de la estimación de las covarianzas entre los

activos para determinar los riesgos y asignar los pesos, además las matrices de covarianzas pueden ser ruidosas y volátiles, especialmente en mercados altamente volátiles o con datos limitados, aunque el modelo HRP incluye técnicas como clustering jerárquico y quasi-diagonalización para mitigar el ruido, la calidad de las estimaciones de covarianzas sigue siendo crítica, debido a que si los datos de entrada son incorrectos o imprecisos, HRP puede repartir el riesgo de manera ineficiente.

Tenemos también el tema de la sensibilidad a la calidad del clustering la quasi-diagonalización de la matriz de correlaciones y el clustering jerárquico dependen de la precisión con la que se identifiquen los grupos de activos, puesto a que, si el cluster asigna activos que no están correlacionados o si el número de clusters es mal estimado, esto puede dar lugar a una asignación de riesgo poco eficiente.

La calidad del agrupamiento jerárquico y la elección del número de clusters son decisivas, si los activos se agrupan incorrectamente o si se utilizan métricas de correlación mal definidas, HRP podría asignar pesos subóptimos, afectando el rendimiento y la diversificación. Una posible solución es la validación de los clusters utilizando otras métricas o técnicas de validación cruzada puede ayudar a mejorar esta parte del proceso.

Otra limitación en la captura de relaciones no lineales complejas, el modelo HRP está basado en correlaciones lineales entre los activos, lo que significa que puede pasar por alto relaciones no lineales complejas dentro de los mercados financieros son muy dinámicos y pueden contener interacciones no

lineales entre activos (por ejemplo, interacciones entre factores macroeconómicos o relaciones no lineales entre activos durante crisis financieras). El modelo HRP podría no ser capaz de capturar completamente estas interacciones no lineales que, de ser detectadas, podrían mejorar la diversificación y la asignación del riesgo, para solucionar este problema, se podría combinar HRP con métodos de machine learning que pueden capturar relaciones no lineales y mejorar las predicciones de riesgo.

La dificultad en la asignación de pesos a activos con baja correlación o sin correlación clara el modelo HRP asigna pesos basándose en correlaciones y distancias entre los activos, lo que significa que activos que no están correlacionados o tienen una relación débil pueden ser subvalorados o dejar de ser agrupados de manera eficiente, en mercados o sectores donde existen activos con poca correlación, el algoritmo puede no ser tan eficiente al determinar cómo deben ser pesados dentro de la cartera, por ejemplo, activos alternativos o commodities que no se correlacionan bien con los activos tradicionales pueden no ser tratados adecuadamente. Una posible solución es utilizar enfoques complementarios como análisis fundamental o algoritmos de machine learning para identificar activos que merecen más peso estratégico a pesar de su baja correlación con otros.

La complejidad computacional en carteras grandes

La implementación de HRP para universos grandes de activos requiere una gran capacidad computacional, debido al, proceso de clustering jerárquico, la asignación recursiva de riesgo y la necesidad de realizar múltiples simulaciones para determinar la mejor asignación de activos, por ese motivo a

medida que el número de activos en la cartera crece, el costo computacional se incrementa debido a la necesidad de realizar cálculos recursivos y la creación de estructuras jerárquicas, lo que puede ralentizar el proceso.

Este proceso se vuelve aún más desafiante con millones de activos o datos de alta frecuencia para poder resolver este problema es posible emplear métodos de reducción de dimensionalidad y algoritmos paralelizados o técnicas de optimización de alta eficiencia computacional puede ayudar a abordar este problema.

En conclusión a pesar de ser una herramienta poderosa, el HRP tiene limitaciones inherentes relacionadas con la estimación de matrices de covarianza ruidosas, la dificultad para capturar relaciones no lineales complejas y la complejidad computacional en carteras grandes son desafíos que deben ser manejados cuidadosamente, para maximizar su efectividad, HRP debe complementarse con técnicas avanzadas de machine learning y optimización computacional que ayuden a manejar la dinámica no lineal del mercado y las grandes dimensiones de datos en carteras complejas.

3.6. Conclusiones

La presente investigación demuestra que la inteligencia artificial (IA) está reconfigurando radicalmente el rol del analista financiero en el entorno contemporáneo, de ser un intérprete de datos históricos y creador de modelos estáticos, el profesional financiero actual y futuro evoluciona hacia un estratega tecnológico, capaz de interactuar con sistemas inteligentes, supervisar algoritmos y tomar decisiones de inversión apoyadas en aprendizaje automático, análisis de datos no estructurados y predicciones en tiempo real, el estudio confirma que es

técnica y operativamente posible crear un hedge fund gestionado por IA pero no al cien por ciento, siempre que se incorporen modelos robustos, como el HRP, que integren herramientas de machine learning, control de riesgo jerárquico, análisis de sentimiento y predicción de precios, a través del análisis comparativo entre modelos como Markowitz, HRP y fondos pasivos, se evidenció que los portafolios construidos con técnicas basadas en IA no solo superan en rendimiento ajustado por riesgo a los modelos tradicionales, sino que también ofrecen mayor resiliencia frente a cambios estructurales del mercado.

Sin embargo, esta evolución tecnológica no elimina la necesidad del juicio humano, por el contrario, resalta la importancia de un nuevo perfil profesional híbrido, que combine competencias en finanzas, programación, ética algorítmica y regulación, la supervisión humana sigue siendo indispensable para garantizar la transparencia, explicabilidad y responsabilidad de los sistemas autónomos, especialmente en escenarios donde las decisiones financieras afectan a clientes, fondos de inversión y ecosistemas económicos enteros, en el contexto ecuatoriano, el desarrollo de normativas como la Norma WealthTech demuestra que la regulación está avanzando hacia un entorno que permite, pero también exige, una adopción ética, profesional y responsable de la IA. Esto genera una oportunidad para formar analistas financieros que no solo dominen la técnica, sino que comprendan su impacto social, económico y legal.

Finalmente, la IA no sustituye al analista financiero sino lo potencia, la convergencia entre tecnología, teoría financiera y ética será la base de una nueva generación de gestores capaces de construir fondos de inversión inteligentes, resilientes y sostenibles en un mercado global cada vez más dinámico y competitivo.

3.7. Referencias bibliográficas

- Antonov, A., Lipton, A., & López de Prado, M. (2023, diciembre 4). *Overcoming Markowitz's instability with the help of the Hierarchical Risk Parity (HRP): Theoretical evidence*. SSRN. <https://ssrn.com/abstract=4748151>
- Sonja Kelly; Mehrdad Mirpourian. (2024, January 18). *Sesgo algorítmico, inclusión financiera y género*.
- Ing. Marcelo Quiroga. (2025, February 7). *La Influencia y el Impacto de la Inteligencia Artificial en las Finanzas*. La Influencia y El Impacto de La Inteligencia Artificial En Las Finanzas.
- Ulla Karppinen. (n.d.). Cinco aportaciones de la inteligencia artificial al sector financiero. <Https://Www.Bbva.Com/Es/Innovacion/Bbva-Automatiza-Servicios-Atencion-Cliente-Tecnologia-Inteligencia-Artificial-Ipsoft/>.
- Satyajit Dutta, C. H. (2023). 5 beneficios de la inteligencia artificial en las finanzas y la contabilidad.
- 5 Beneficios de La Inteligencia Artificial En Las Finanzas y La Contabilidad.* https://www.ey.com/es_co/insights/financial-accounting-advisory-services/5-beneficios-ia-finanzas-contabilidad.
- Khari Johnson. (2021, September 1). *La lucha por definir cuándo la IA es de “alto riesgo.”*
- Sonja Kelly; Mehrdad Mirpourian. (2024, January 18). *Sesgo algorítmico, inclusión financiera y género*.
- Bo Cowgill, F. D. S. D. H. N. V. A. C. (2020, December 4). *¿Programadores sesgados? ¿O datos sesgados? Un experimento de campo para operacionalizar la ética de la IA*.
- Ina Fried. (2020). *Nuevas preocupaciones sobre el sesgo de la IA en la era de la COVID-19*.
- Maple, C., Staykova, K., & Wang, Z. (n.d.). *The AI Revolution: Opportunities and Challenges for the Finance Sector*.
- Asia Business Herald. (n.d.). *Los servicios financieros enfrentan el mayor potencial de desplazamiento laboral impulsado por la IA*.
- Dr. Anand S. Rao and Gerard Verweij. (2024). *What's the real value of AI for your business and how can you capitalise?* patents.bankofamerica.com. (2025). *Inteligencia artificial: un verdadero punto de inflexión*.