

MiraltaBank

Advanced Banking



# INTELIGENCIA ARTIFICIAL EN LA GESTIÓN DE INVERSIONES: EXAGERACIÓN VERSUS REALIDAD

Conferencia - Asociación de Mercados Financieros (AMF)

23 de Abril de 2024

Alejandro Rodríguez Domínguez –

Responsable de Análisis Cuantitativo en Miralta Bank S.A.

[arodriguez@miraltabank.com](mailto:arodriguez@miraltabank.com)

## Especialistas en tipo de interés y crédito.

/ EXPERIENCIA. INDEPENDENCIA. SOLVENCIA /

Fundada en 2010 por un equipo de profesionales que acumulan una amplia experiencia en las principales entidades internacionales de gestión de activos y banca inversión.

Más de  
**40 años**

De experiencia en gestión de activos en las principales entidades y mercados globales.

Más de  
**350M euros**

De gestión discrecional en estrategias de Renta Fija.

Más de  
**1000M euros**

Servicios de gestión y asesoramiento en estrategias de renta fija.

Más de  
**1.100M euros**

De activos bajo gestión y asesoramiento.

**69**

Empleados.

**21M euros**


De capital: somos una de las principales entidades independientes con mejor ratio de solvencia a nivel nacional.

**100%**

De capital privado: total independencia.

# Agenda

- **Introducción**
- **Motivaciones en la aplicación del ML en la gestión de inversiones**
- **Soluciones de ML en la gestión de inversiones**
- **Principales Obstáculos**





# Introducción

# Crisis Cuantitativa

- La fórmula que mató a Wall Street”(1)
- “La fórmula que hizo caer a Wall Street”(2)
- “Los magos de las matemáticas de Wall Street olvidaron algunas variables”(3)
- “Confianza fuera de lugar en modelos (matemáticos) sofisticados”(4)
- ¿PERO CUÁL ES ESTA FÓRMULA EXACTAMENTE?

$$\int_{-\infty}^{+\infty} \prod_{i=1}^{125} \phi \left( \frac{\phi^{-1}(1 - \exp(-\Lambda_i(T))) - \sqrt{\rho_i} m}{\sqrt{1 - \rho_i}} \right) \varphi(m) dm.$$

- 1) Receta para el desastre. Revista cableada, 17.03.
- 2) El Financial Times, Jones, S. (2009). 24 de abril de 2009.
- 3) Lohr (2009), New York Times del 12 de septiembre.
- 4) Turner, J.A. (2009). La revisión de Turner. 03/2009. FSA, Reino Unido.

- David Li, 2005, Wall Street Journal [...] "La parte más peligrosa", dice el propio Sr. Li sobre el modelo, "es cuando la gente cree todo lo que se deriva de ello". Inversores que también ponen mucha confianza en él o no entienden todas sus sutilezas pueden pensar que han eliminado sus riesgos cuando no lo han hecho.
- De hecho, estos modelos son estáticos, ignoran las volatilidades de los diferenciales de crédito, que en crédito puede ser del 100%.




Figura 1: Las fotografías de arriba son de condominios que estuvieron involucrados en un fraude hipotecario. La tasación describía “condominios recientemente renovados” e incluía madera de roble brasileña, encimeras de granito y un valor de 275.000 dólares.

# Taxonomía de la hipótesis de mercados eficientes

- **Pruebas de predictibilidad: (forma débil)**
  - Análisis de series temporales
  - Análisis cross-sectional
- **Estudios de eventos: (Forma semifuerte)**
  - Investigar estudios basados en información después de la divulgación de información pública (consulte la definición de Malkiels) para detectar retornos anormales.
- **Pruebas de información privada/rendimiento superior: (Formulario fuerte)**
  - Rendimiento de fondos mutuos/fondos de cobertura (hedge funds)
  - uso de información privilegiada

Resulta que **casi el 100% de la volatilidad del rendimiento de los dividendos** proviene de **predicciones de rentabilidad**.

Estas predicciones son **debidas a las variaciones de la prima de riesgo**, Cochrane (2007).




Figura 2: Retorno vs dividend yield (D/P)

Las tradicionales variables explicativas de los retornos de los activos se vuelven con el tiempo correlacionadas con los retornos, Stambaugh (1999).

# El hombre que descifró Wall Street

- El fondo que convierte 100 dólares en 400 millones en 30 años
- La misteriosa firma Renaissance Technologies ha logrado un retorno medio anual del 66% desde el año 1988

- Al principio, los datos consistían en informes de ganancias anuales y trimestrales, registros de transacciones bursátiles por parte de ejecutivos corporativos, informes gubernamentales y predicciones y artículos económicos.
- Luego comenzaron a recopilar todas las órdenes de mercado, incluidas aquellas que no se habían ejecutado. También recopilaron patrones climáticos, feeds de redes sociales e imágenes satelitales, noticias, llegando incluso a recopilar datos astrológicos.
- Los datos se utilizaron para detectar picos, caídas o brechas inusuales e idiosincráticas en sus predicciones de precios. Al identificar situaciones de mercado comparables y rastrear lo que sucedió posteriormente con los precios, podrían desarrollar un modelo de pronóstico sofisticado y preciso capaz de detectar patrones y anomalías que otros pasaban por alto.
- El modelo se adaptó dando un grado de probabilidad a cada suposición y actualizando sus mejores estimaciones a medida que recibía nueva información.
- El modelo pudo analizar grandes cantidades de datos de precios para predecir precios futuros, discerniendo señales verdaderas de fluctuaciones aleatorias del mercado.
- El modelo tuvo en cuenta el riesgo, el costo, el impacto y la estructura del mercado, optimizando sus ejecuciones.



Figura 3: Rendimiento Fondo Medallion. Fuente: Expansión

# Máquina de gestión de inversiones

## ■ La mayor prueba de que los mercados no son eficientes

■ Renaissance Technologies concluyó que existen relaciones matemáticas confiables entre todos estos datos. Al aplicar **la ciencia de datos**, los investigadores lograron entender cuándo, varios **factores, eran relevantes, cómo se interrelacionaban y la frecuencia con la que influían en los activos financieros.**

■ Pero el factor más importante de su éxito y de su fondo de cobertura fueron sus empleados: 250 empleados y **más de sesenta doctores, incluidos expertos en inteligencia artificial, físicos cuánticos, lingüistas computacionales, estadísticos y teóricos de números.**

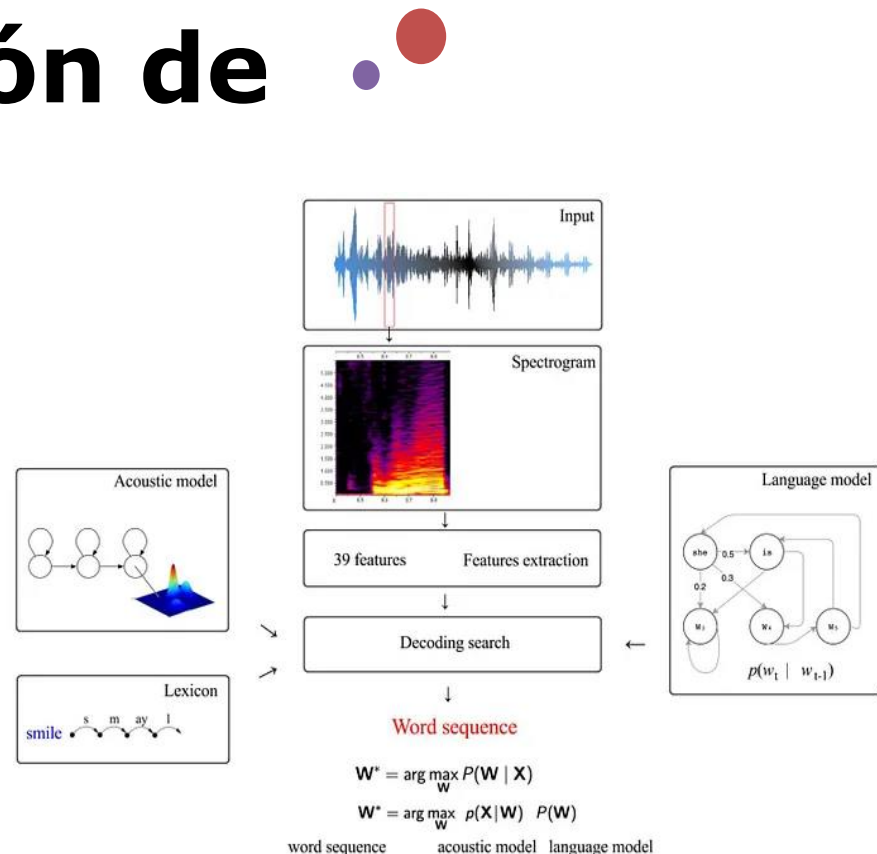


Figura 4: Modelo similar al del fondo Medallion. El número 2 del fondo y CEO actual fue pionero en lenguaje e IA en IBM.

# Predictibilidad relativa entre activos (Cross-section)

- **CAPM** no hace un mal trabajo al explicar el **binomio riesgo-retorno** de las diferentes clases de activos. En particular, en el **largo plazo los bonos corporativos** tienen **retornos medios en línea** con sus **betas bajas**, a pesar de sus **desviaciones estándar casi tan altas** como las de las **acciones**
- **Las empresas más pequeñas** parecen **obtener unos retornos medios unos tantos por ciento más** que los previstos por CAPM. Este es el famoso ¡"Efecto de pequeña empresa"! (Banz, 1981).

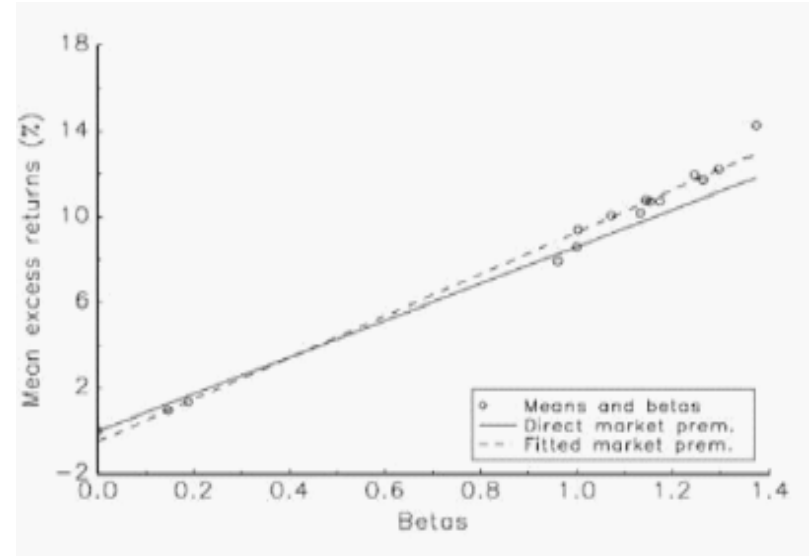


Figura 5: CAPM Cochrane 2004, Asset Pricing.

# Inversión en Factores

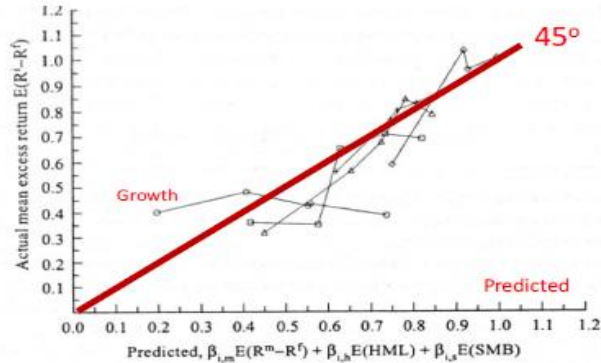


Figura 6: Media de exceso de retorno vs predicción del modelo de Fama French. Las líneas conectan portfolios con diferentes tamaños de compañías dentro de la misma book/market category. Fuente: Andrea Burachi. Imperial College MSc

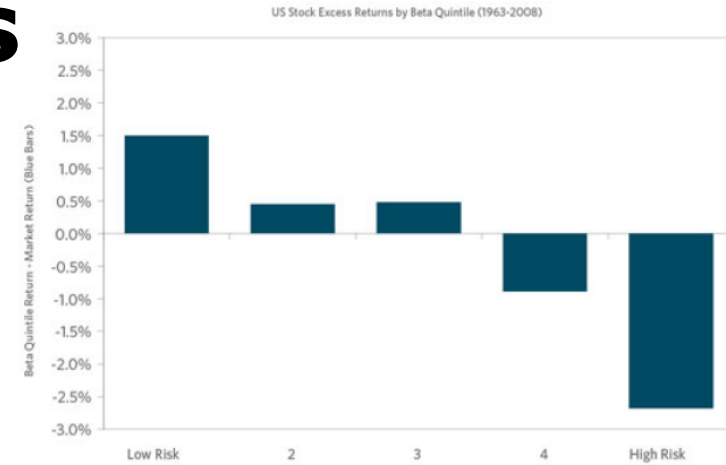


Figura 7: Acciones con menor beta generan retornos superiores históricamente. Fuente: Research affiliates.

**Reversión:** Los perdedores del pasado cargan más en SMB (Growth) y HML (Value), y el modelo predice que los perdedores del pasado a largo plazo tendrán rendimientos promedio más altos en el futuro. El efecto de reversión puede explicarse por este modelo.

**Momentum:** Sin embargo, el modelo no tiene en cuenta el efecto momentum. Los perdedores del pasado a corto plazo también cargan más en las Growth y Value que los ganadores anteriores a corto plazo: por lo tanto, el modelo de Fama-French predice que deberían tener rendimientos promedio altos. Su modelo no puede explicar el momentum.

**Las acciones de baja volatilidad** han tenido mejores resultados que las de alta volatilidad, en términos relativos.




Figura 8: Retornos acumulados para portfolios de baja volatilidad o riesgo. Fuente: Andrea Burachi. Imperial College MSc

# ¿Por qué ha fallado la inversión en factores?

- Después de 17 años de desempeño fuera de la muestra, el índice de **Sharpe** de la inversión en factores es **estadísticamente insignificante en cualquier nivel de confianza razonable**.
- Realiza un seguimiento del rendimiento **largo/corto del momentum, value, quality y low volatility** en acciones estadounidenses.
- **Ratio de Sharpe anualizado: 0,22.**
- El **exceso de rentabilidad anualizado medio** ha sido del **0,82%**.

## Motivos:

- **Error al especificar bien los modelos.**
- **No linealidad, no estacionariedad** de los mercados.
- **Crowding** – Demasiados participantes en el factor.




Figura 9: Bloomberg – Goldman Sachs Asset Management US Equity Multi-Factor Index (BBG code: BGSUSEMF <Index>). Fuente: Marcos Lopez de Prado.


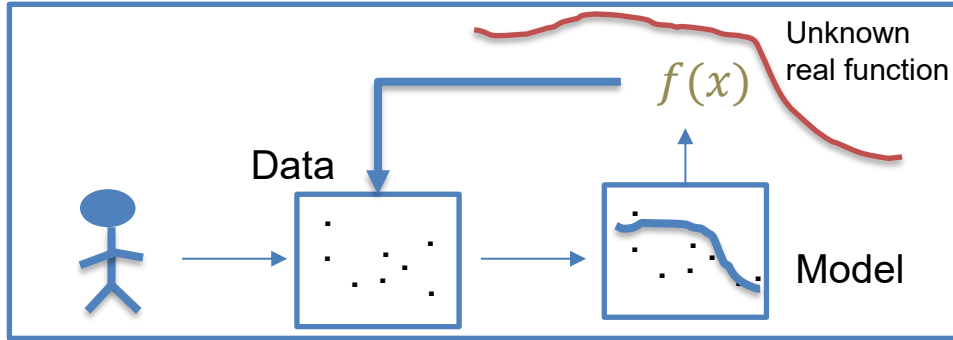



Figura 10: Fuente: Marcos Lopez de Prado, The Case for Causal Factor Investing 27-03-2024

# AI vs Computational Statistics = Machine Learning (ML)



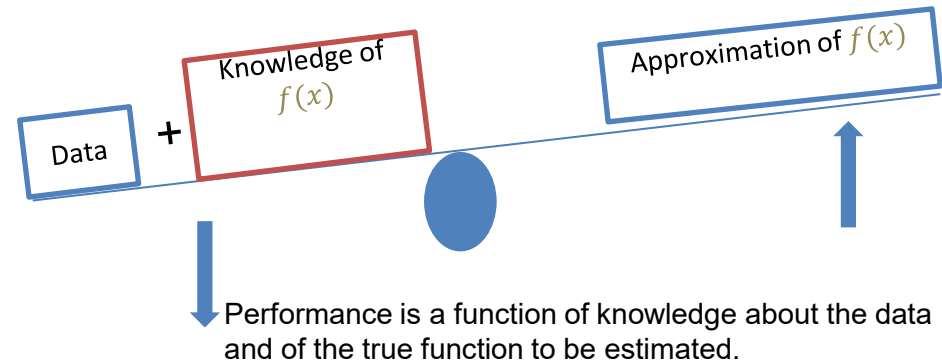
The function to be estimated is approximated using a model and observations of that function.



Machine Learning aims to estimate functions using observations in the form of data.


**Reduce the error** between the model and the data. There are no guarantees that the model replicates the unknown function.

**Data scientist:** Uses data to make decisions and has deep knowledge of the underlying business behind the data. Knows many things about  $f(x)$ .



Performance is a function of knowledge about the data and of the true function to be estimated.


## Time taken to reach 1 million users




Time to reach 1 million users. Source: Exploding Topics

## U.S. Alternative Data Market


size, by data type, 2020 - 2030 (USD Billion)



The alternative data market. Source: Teneralpha



Amount of data generated globally each year. Source: Statista (2024)



Types of alternative data. Source: Wikipedia


# Realidad vs Hype

## Evolución Real

- **Un incremento exponencial en la cantidad de datos accesible.**
  - En los años 90s, mil filas de Excel era un dataset grande, ahora 1 billón de registros no supone un problema de procesamiento para un ordenador de usuario.
  - Se mezcla la estadística con talento en software.
- **Aumento en la utilidad de datos alternativos permitiendo una mejora en la aproximación de funciones.**
- **Acceso en internet a librerías de datos y modelos gratuitos. Democratización de la analítica de datos. (LLAMA Meta (gratis)).**

## Hype o marketing

- **Los modelos no razonan, solo aprenden la distribución en los datos.**
  - Se acercan más a la función que se quiere aproximar, pero cuanto más complejo es el problema más lejos se está de esta.
- **Capacidades de los modelos se confunde con la accesibilidad del público.**
  - Chatgpt tiene éxito por su sencillez de uso, no por su rendimiento.
- **Problemas de interpretabilidad y explicabilidad de los modelos.**
- **Exceso de datos alternativos, falta de datos financieros (falta de historia).**
- **Necesidad de tratar con regímenes de mercado. No estacionariedad.**
- **Incorporar causalidad.**



# Motivaciones en la aplicación del ML en la gestión de inversiones.

# ¿Por qué el aprendizaje automático (ML) es tan potente?

- La principal conclusión de los profesionales y académicos es que debido a que los algoritmos de **ML no necesitan definir una función entre las variables de predicción** (rendimiento de acciones, ganancias futuras, etc.) **y los predictores** (métricas de estados financieros, rendimientos pasados, etc.), los algoritmos de **ML no están restringidos a un formato lineal** como es típico de otras técnicas, sino que pueden descubrir **interacciones y relaciones no lineales entre los datos de entrada y las variables de salida.**

## Interacciones (Figura 18)

- Dos datos de entrada: ganancias declaradas y una señal de peligro contable**, donde la entrada de la señal de peligro es binaria: 0 (sin motivo de preocupación) y 1 (grave preocupación).
- Objetivo: Predecir retorno** futuro de una acción.

- El resultado de ML con estas dos variables puede ser que cuando **la variable de señal de peligro es 0**, el retorno está **relacionado lineal y positivamente con las ganancias declaradas**; por el contrario, cuando **la variable de señal de alerta es 1**, el resultado es una **disminución del 50% en el precio**, independientemente de las ganancias declaradas.




Figura 18. Ilustración del efecto de interacción entre las señales de alerta contables y la ganancia declarada (Robeco)

# ¿Por qué el aprendizaje automático es tan potente?

## ■ Efectos no lineales (Figura 19)

- La predicción de ML superar la predicción del modelo lineal tradicional debido a **efectos no lineales**.
- **Hay infinidad de efectos no lineales** observados empíricamente en los mercados financieros.
- **Relación no lineal entre el diferencial de swap de incumplimiento crediticio (CDS) de una empresa y los rendimientos de sus acciones (Figura 19).**
- Tanto la **interacción como los efectos no lineales** contribuyen positivamente al **rendimiento superior de los modelos de aprendizaje automático** (ver, por ejemplo, Abe y Nakayama 2018; Swinkels y Hoogteijling 2022; Choi, Jiang y Zhang 2022).




Figura 19. Cuadro 2. Ilustración de la relación no lineal entre un CDS y la rentabilidad de las acciones (Robeco)

## ■ Minería de datos: descubrimiento de conocimientos

- La cantidad de datos financieros está creciendo a un ritmo rápido, los tipos y fuentes de datos son nuevos, muchos inversores no tienen una opinión previa sólida sobre si pueden ser útiles y cómo.
- Los algoritmos de ML buscan relaciones. Sin especificar una hipótesis sobre la relación económica, el algoritmo ML descubrirá el vínculo entre entradas y salidas.

# Desafíos para el aprendizaje automático (ML) en gestión de inversiones

## ▪ Relación señal-ruido y complejidad del sistema.

- Los datos financieros tienen una **relación señal/ruido baja**.
- **Los mercados financieros** es uno de los sistemas creados por el hombre **más complejos del mundo**.

## ▪ Small vs. big data

- Algunas de las fuentes de datos más nuevas, o “**datos alternativos**”, como publicaciones en redes sociales o artículos de noticias, son mucho **más abundantes que los datos financieros tradicionales**. Sin embargo, en general, **la cantidad de datos financieros sigue siendo pequeña** en comparación con otros ámbitos (física o consumo basado en Internet).

## ▪ Estacionariedad versus mercado adaptativo, irracionalidad

- Los mercados **no son estacionarios**, se adaptan y cambian con el tiempo.

- En las últimas décadas, los académicos han logrado descubrir y publicar **los factores de los retornos del mercado** (Fama y French (1993); sus investigaciones también **incremientaron el conocimiento de todos los participantes del mercado y cambiaron el comportamiento del mercado** (McLean y Pontiff (2016)).

- Los algoritmos de aprendizaje automático entrenados para la inversión **no tienen una historia lo suficientemente larga para entrenar el modelo**.

- **Las reglas y dinámicas** que gobiernan los retornos que los modelos intentan predecir **también cambian con el tiempo**.

- **Afortunadamente, muchos algoritmos de aprendizaje automático son adaptativos o pueden diseñarse para adaptarse a sistemas en evolución.**

- **Pero:** Los retornos de los mercados son el conjunto de acciones humanas individuales, **y los seres humanos a menudo se comportan de manera irracional**: desafío para los algoritmos de aprendizaje automático.

# Aplicaciones de ML en la gestión de inversiones

- Classification and pattern recognition can be used for:
- Incorporating alternative data into the investment process
- Fund classification, inference, and decomposition
- News and sentiment analysis
- Risk detection from corporate documents
- Reinforcement learning can be used for:
- Goal-based wealth management
- Construction and risk management of investment portfolios
- Retirement and financial planning
- Network analysis and clustering can be used for:
- Portfolio optimization
- Analysis and improvement of portfolio diversification
- Clustering of financial time series

- Prediction can be used for:
- Forecasting returns and risks over the short, medium, and long term for asset classes and investment vehicles
- Estimating alternative risk premia
- Identifying market regimes and structural breaks in time series
- Forecasting company fundamentals and balance sheets
- Other practical applications in investment management include:
- Regime-based investing
- Testing and analysis of trading and investment strategies
- Scenario generation and synthetic data generation for financial time series
- ESG-based investing
- Factor-based quantitative investing
- Due diligence and document analysis
- Nowcasting
- Compliance with internal policies and external regulations
- It can also support most portfolio construction tasks, such as:
- Idea generation



# Soluciones de ML en la gestión de inversiones

## ■ Predecir la rentabilidad relativa de las acciones (Cross-Seccional)

- **Ranking** de predicciones de **retornos o riesgo**.
- **Rankings parciales** agrupando activos por características cualitativas: **Sector, industria, país**. Así como cuantitativas: **Nivel de deuda, ingresos, beneficios, sentimiento**.
- **Construcción de carteras** robustas basadas en rankings de activos gracias a las **conexiones entre rankings parciales**.

## ■ Predecir Crashes de mercado

- El **rendimiento** de la cartera de acciones con **mayor probabilidad de problemas versus** el del **mercado**.
- Si observamos la **composición sectorial** de las acciones probablemente **en dificultades**, como se muestra en la **Figura 21**, vemos que las opciones del algoritmo ML son razonables, ya que las **acciones tecnológicas** dominaron durante el estallido de la **burbuja de las puntocom** a principios de la década de 2000 y las **acciones financieras** en la **gran crisis** del 2008.

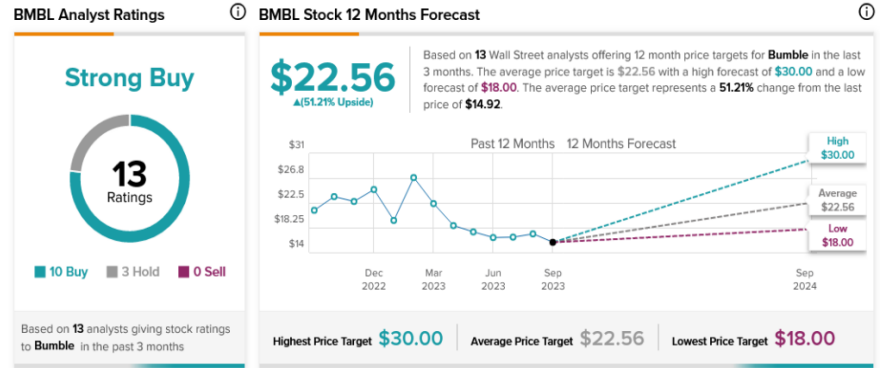


Figura 20: Tipranks, compañía especializada en rankings de acciones. Fuente: Tipranks.




Figura 21: Composición sectorial de las acciones probablemente en dificultades pronosticadas por ML (Swinkels and Hoogteijling (2022))

## ■ Predecir variables de valoración

- **fondos Quantamentales** combinan métodos **cuantitativos** con análisis de **valoración de empresas** tradicionales.
- Se usan métodos de ML para predecir las métricas de **valoración de empresas y variables económicas**, así como su relación con los retornos de las acciones.

## ■ Procesamiento del lenguaje natural en diversos idiomas

- las técnicas de ML **no solo son útiles para tareas numéricas de predicción de resultados**, sino que también pueden ser útiles en otras tareas, **como la comprensión de idiomas extranjeros**.




Figura 22: Palabras chinas incrustadas de blogs de inversores de A-Share proyectadas en un espacio tridimensional

## ■ ESG

- Más del **75%** de los propietarios de activos y el **60%** de los gestores de activos mantienen el **25%** de sus inversiones en fondos que incorporan criterios ESG.
- Hay problemas: Los **datos** pueden ser **demasiado infrecuentes**, la **medición** de eventos a veces es demasiado **extrema** y la captura de eventos puede ser **demasiado tardía**.
- El **ML** puede analizar grandes cantidades de datos ESG en un sector donde la **información proviene de muchas fuentes** y a menudo se presenta de manera no estructurada debido a la falta de regulaciones en la presentación de informes.

## ■ Clasificación y partición del universo de inversión

### ■ Proceso de 2 pasos

1. identificar los ejes de riesgo más relevantes y las categorías de activos correspondientes.
2. identificar las características más relevantes de una categoría de activos.

■ ML es muy útil cuando la clasificación sectorial no está clara o necesita ajustarse rápidamente. Es fácilmente reproducible.

■ La clasificación es más sólida cuando se basa en análisis de clustering y redes en lugar de únicamente en información tradicional (sector, geografía, emisor, calificaciones crediticias).

■ El ML puede agrupar mejor los activos y **predecir cambios de régimen basado en la dinámica de precios y las noticias.**

■ ML ofrece predicciones muy fiables sobre la **clasificación de empresas según el sector de actividad económica basada** en las descripciones comerciales de los informes financieros.

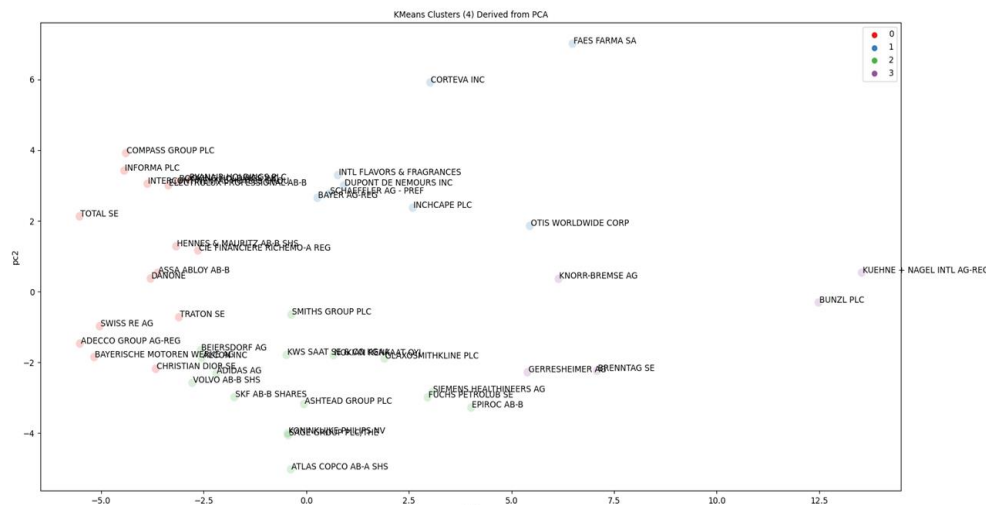


Figura 23: Clustering de fondo Miraltabank Narval (2020).  
Fuente: Miraltabank)




Figura 24: Red construida a partir de correlaciones, coloreada por sector industrial. David Dindi et al. (2015)



## ■ Análisis de sentimiento

- Las **redes sociales y las noticias** tienen un poder significativo para **explicar la variación** de las series temporales en los **rendimientos de las acciones**.
- El **sentimiento y las redes sociales**, los **artículos de noticias**, el **consumo de información** y los **datos de los motores de búsqueda (Google)** tienen un impacto significativo en la **volatilidad del mercado de valores**.
- **Cuantifica el impacto de las noticias** en los rendimientos financieros futuros de **acciones específicas**.
- Se ha demostrado que el sentimiento del mercado es relevante para una **mejor optimización de la cartera**. La información incorporada en las noticias tiene un **poder predictivo** que **no captan los predictores económicos** establecidos.

## ■ Análisis textual de documentos oficiales

- El ML en combinación con los **datos de la SEC** resulta eficaz en términos de **clonación de carteras y para predicción**.
- Analizar el **contenido y las noticias de los correos electrónicos corporativos** para evaluar los factores que predicen un **riesgo creciente o un posible malestar empresarial** antes de que se manifiesten en datos observables y **resultados financieros**.
- El ML aplicado a las **presentaciones resultados de empresas** ofrece factores **alfa no correlacionados con los factores tradicionales**, lo que ofrece importantes beneficios de **diversificación**.
- Uso de los datos de los **estados financieros y análisis del tono de voz** en las transcripciones de las **conferencias telefónicas** sobre resultados para predecir el **signo y magnitud de movimiento** de acciones.

## Optimización de carteras basada en clustering

- **Matriz de covarianzas no está bien especificada y se ha probado desde casi una década que las carteras construidas con clústeres superan los métodos tradicionales.**
- **Se puede usar la matriz de correlaciones para obtener jerarquías entre grupos de activos dentro de la matriz, (Lopez de Prado, 2016).**
- **Otras distancias se pueden usar que incorporan información de sentimiento o dinámicas de mercado (Rodríguez Domínguez, 2023).**
- **Permite diversificar escenarios de cola o crisis previniendo el contagio al diversificar los activos más concentrados en el clustering.**

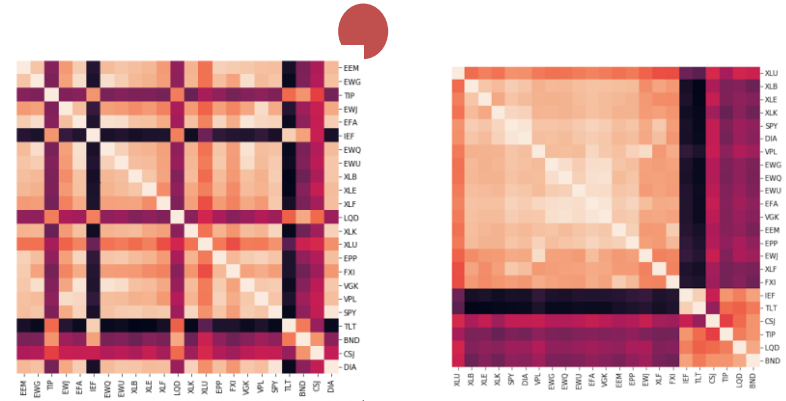


Figura 25: Matriz de correlaciones antes y después de ordenar.




Figura 26: Cluster jerárquico a partir de matriz de correlaciones

## ■ Optimización de carteras basada en redes

- Construcción de redes financieras en las que los **nodos están representados por activos** y donde los ejes se basan en **correlaciones de largo plazo**.
- Uso práctico de conceptos de **centralidad alta/baja**. **Riesgo de interconexión significativo** (los eventos de cola se propagan más rápidamente) debido a activos con puntuaciones de **centralidad altas**. (Ej: Red de Metro).
- Los "**activos periféricos**" conllevan un **riesgo de interconexión** relativamente **menor**: inversiones en acciones periféricas (ubicadas en regiones de redes financieras mal conectadas) **mejor diversificadas**.
- **Supera los métodos tradicionales fuera de muestra**. Las **carteras óptimas basadas** en redes se componen principalmente de **activos periféricos**.
- La **centralidad de la red** es una medida **inversa de diversificación**.

Minimum Spanning Tree for the S&P 500 - Extracted from Wikipedia articles using Sentence Transformers




Figura 27: Red del SP500, formada solo por información obtenida de Wikipedia. Fuente: Gautier Marti Blog.

- **Análisis de clustering para obtener clases de fondos homogéneas con respecto a los niveles de riesgo.**
- **Análisis y selección de fondos utilizando distancias y similitudes entre medidas clave de rendimiento basadas en agrupaciones.**

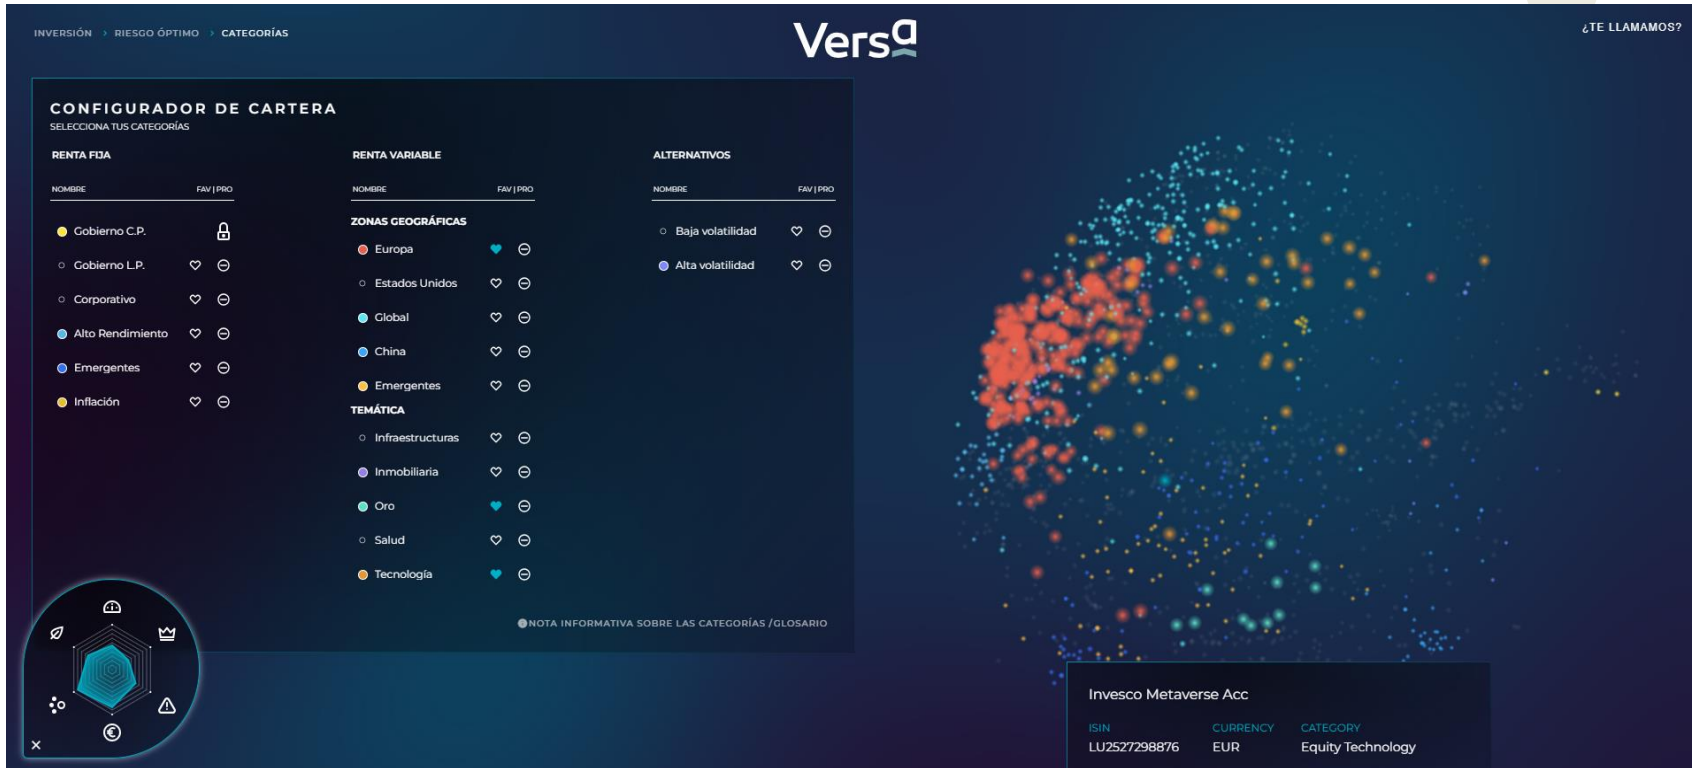



Figura 28: Servicio de carteras gestionadas de fondos mutuales de Miraltabank. Fuente: Versa, Miraltabank.

Consumer Discretionary BBB (5-10) EUR	1	1	0,7414	0,6665	0,6305	0,6486	0,7486	0,7315	0,7116	0,5931	0,5165	0,5022	0,6165	0,4262	0,5825	0,6159	0,5068	0,5785	0,2058	0,1019	0,5063
Consumer Discretionary BBB (10-15) EUR	1	1	0,776	0,7214	0,694	0,6352	0,7502	0,7809	0,7627	0,6583	0,5172	0,5711	0,6578	0,4638	0,6013	0,6567	0,3315	0,6188	0,2471	0,2176	0,3835
Consumer Discretionary BBB (15+) EUR	1	1	0,8738	0,8747	0,9047	0,5941	0,7847	0,8691	0,8887	0,825	0,4923	0,5827	0,6911	0,4281	0,5879	0,6923	0,28	0,6741	0,1819	0,1664	0,3976
Consumer Discretionary BB (1-3) EUR	-0	-0	-0,219	-0,265	-0,303	-0,182	-0,179	-0,223	-0,248	-0,248	-0,133	-0,176	-0,16	-0,105	-0,096	-0,17	-0,093	-0,099	-0,071	0,0376	0,0197
Consumer Discretionary BB (3-5) EUR	-0	-0	-0,104	-0,136	-0,192	-0,037	-0,063	-0,108	-0,131	-0,197	0,0202	-0,004	-0,049	0,0702	0,0191	-0,009	-0,022	-0,023	-0,131	0,1007	0,1195
Consumer Discretionary BB (5-10) EUR	-0	-0	-0,163	-0,213	-0,255	-0,149	-0,123	-0,164	-0,181	-0,205	-0,008	-0,052	-0,074	-0,022	0,0185	-0,068	-0,038	-0,038	-0,093	0,0353	0,0985
Consumer Discretionary BB (15+) EUR	0	1	0,7475	0,7559	0,7758	0,4997	0,6591	0,7431	0,7739	0,7958	0,3468	0,45	0,6098	0,2155	0,5303	0,564	0,2579	0,5945	0,1466	0,1666	0,2977
Consumer Discretionary B (1-3) EUR	-0	-0	-0,022	-0,026	-0,037	-0,071	-0,009	-0,011	-0,006	-0,032	0,0967	0,1558	0,1654	0,0489	0,1503	0,1493	0,0478	0,1218	-0,011	-0,012	0,5019
Consumer Discretionary B (3-5) EUR	-0	-0	-0,224	-0,263	-0,299	-0,184	-0,181	-0,222	-0,229	-0,268	-0,063	-0,11	-0,124	-0,049	-0,06	-0,114	-0,055	-0,063	-0,109	-0,011	0,032
Consumer Discretionary B (5-10) EUR	-0	-0	-0,128	-0,176	-0,211	-0,081	-0,092	-0,128	-0,145	-0,21	-0,019	-0,067	-0,068	0,0192	-0,043	-0,063	0,099	0,0034	-0,058	0,063	0,0406



Banks/Financials BBB (5-10) EUR	1	1	0,6987	0,6142	0,5764	0,5692	0,7068	0,7086	0,6709	0,5388
Banks/Financials BBB (10-15) EUR	1	1	0,6685	0,6174	0,5942	0,4937	0,6305	0,6594	0,6426	0,5465
Banks/Financials BBB (15+) EUR	0	0	0,403	0,3846	0,3765	0,304	0,3597	0,3976	0,3977	0,4172
Banks/Financials BB (1-3) EUR	-0	-0	-0,119	-0,162	-0,218	-0,074	-0,08	-0,119	-0,154	-0,265
Banks/Financials BB (3-5) EUR	0	0	0,2729	0,2179	0,1675	0,2066	0,2882	0,274	0,2383	0,0942
Banks/Financials BB (5-10) EUR	0	0	0,0651	0,0471	0,0037	-0,059	0,0897	0,0706	0,039	0,0366
Banks/Financials BB (15+) EUR	0	0	0,4696	0,4572	0,4329	0,2985	0,4157	0,4652	0,4794	0,3995
Banks/Financials B (1-3) EUR	-0	-0	-0,125	-0,155	-0,155	-0,097	-0,097	-0,109	-0,104	-0,18
Banks/Financials B (5-10) EUR	0	0	0,2722	0,2657	0,2397	0,1627	0,2394	0,2511	0,2498	0,2455
Banks/Financials B (15+) EUR	0	0	0,4189	0,4021	0,3773	0,2729	0,3717	0,4052	0,4053	0,3076
Bank/Financials CCC+ down (5-10) EUR	-0	-0	-0,221	-0,244	-0,25	-0,092	-0,197	-0,213	-0,222	-0,206
Bank/Financials CCC+ down (15+) EUR	0	0	0,0569	0,0239	0,0344	0,0216	0,0538	0,0539	0,0642	0,1373
Consumer Discretionary A (1-3) EUR	1	1	0,6475	0,5558	0,522	0,6114	0,71	0,6645	0,5944	0,4512
Consumer Discretionary A (3-5) EUR	1	1	0,8534	0,7751	0,7412	0,7392	0,8834	0,8627	0,8074	0,661

Figura 29: Matriz de correlaciones formadas por grupos cualitativos en mercados de renta fija en forma de portfolios equal-weighted de bonos. Fuente Propia.




Figura 30: Cluster jerárquico formado con los portfolios equal-weighted de los grupos cualitativos de la Figura 29. Fuente propia.

## Descomposición de fondos, inferencia y replicación

- Identificar los componentes de un ETF con una precisión del 88% al 98%.
- replicar fondos menos líquidos (como fondos de cobertura o fondos de capital privado) utilizando vehículos de inversión líquidos
- negociar acciones en el mercado público para replicar el riesgo/rendimiento de los fondos de capital privado.
- ML se puede usar para la selección de fondos mutuales en función de los activos que poseen.

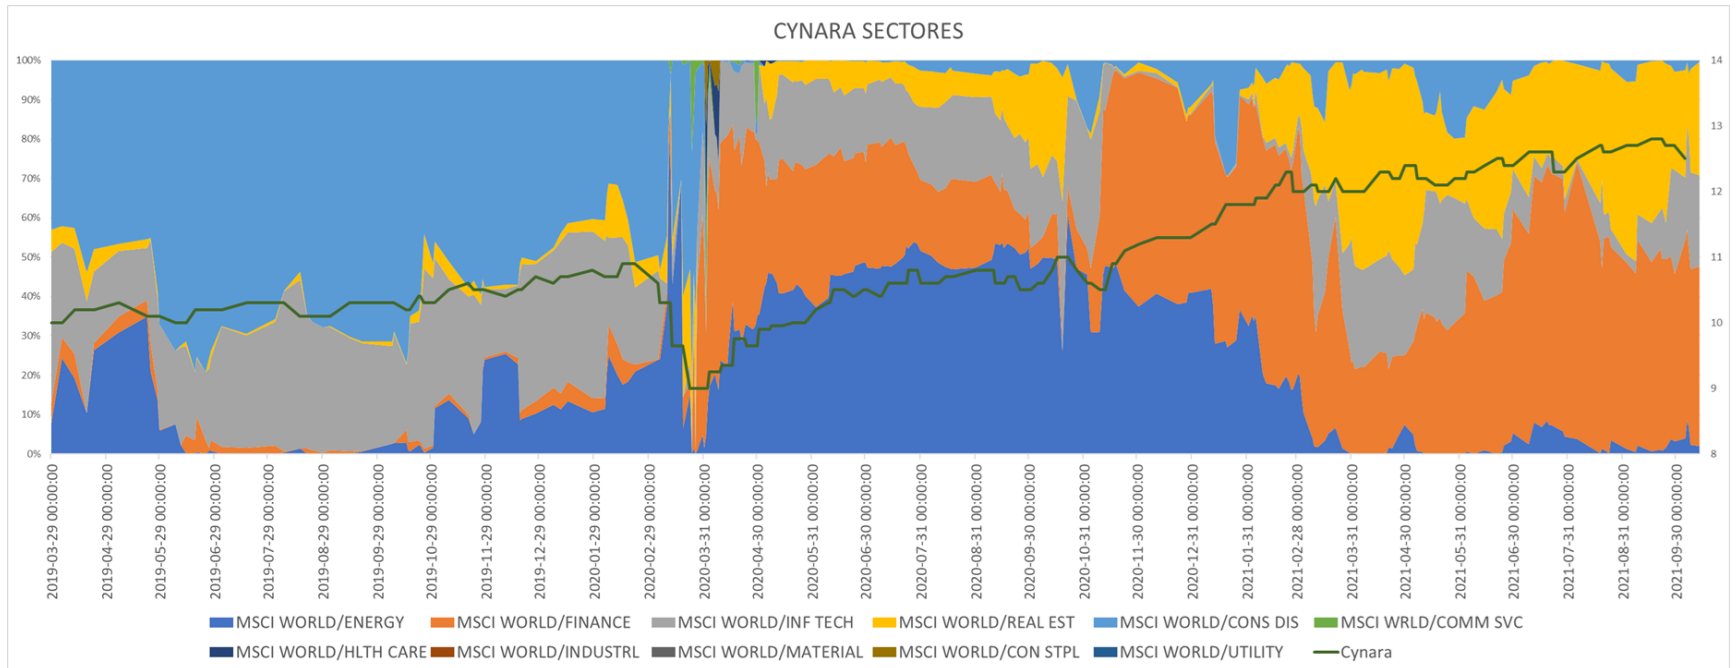


Figura 31: Análisis de exposición del fondo de inversión Cynara a índices sectoriales por medio de un PCA beta weighted.

# Los servicios financieros intentan adoptar la IA generativa

- Las herramientas de inteligencia artificial basadas en LLM pueden revolucionar la gestión de inversiones:
  - Recomendaciones a escala de inversión personalizadas
  - Gestión de una cartera personalizada
  - Gestión integral de riesgos y mitigación de riesgos gracias a automatizaciones (incluidos informes y cumplimiento)
- Sin embargo, la complejidad y la terminología única del ámbito financiero justifican un modelo de dominio específico.
- La mayor parte de las aplicaciones ofrecidas en el sector no son generativas ni IA.
- La mayoría de las entidades esta experimentando con sus datos internos.
  - Bloomberg por ejemplo con su chatgpt especializado en finanzas.
- Los derechos de autor se convierten en el primer problema.
- Los chatgpt internos desafían los modelos de las grandes tecnológicas.
- Ejemplos de aplicaciones:
  - Optimización operativa de instituciones financieras (ayuda con **preguntas y respuestas sobre datos internos, ingeniería de software**, cualquier función "de cara al usuario" como **recursos humanos, sitios de acceso de clientes, formación, etc**).
  - Mejor **cumplimiento y supervisión regulatoria**
  - **Modelado cuantitativo** (mejoras e innovaciones de modelos, gestión de riesgos, análisis [integrados] de diversos tipos, predicción)
- ESG y riesgo climático: LLM en aplicaciones ESG, es decir, **para resumir e interpretar los informes de sostenibilidad de las empresas para extraer información E, S y G para calificaciones ESG internas.**




Figura 32: Número de menciones (millones) de IA generativa en los transcripts de empresas, Russell 3000

# Problemas de la aplicación de LLM/chatgpt en la gestión de inversiones

- **Problema del backtesting: el principal obstáculo** en la aplicación del LLM a las estrategias de inversión

**Falta de datos del presente:** ChatGPT 4 usa datos para su ajuste **hasta September 2021**. Se entrenan con un corpus de datos textuales hasta una fecha, y luego se congelan. **Se necesita el estado del modelo en cada instante de tiempo** pasado para hacer un backtesting correcto de la estrategia.

- **Alucinaciones:** Las alucinaciones se refieren a la tendencia de los LLM a producir **información aparentemente plausible pero inexacta**.
- **Diseñados principalmente para la generación del lenguaje en lugar del razonamiento abstracto y la inteligencia, actualmente enfrentan desafíos con tales tareas.**

- **Hype con posibilidad futura:**
  - análisis de **riesgos** y el desarrollo de **sistemas de alerta temprana** de riesgos
  - generación **alfa** y la creación de **estrategias de inversión rentables**




Figura 33: Numero de empresas que consideran el uso de chatgpt un riesgo

# Predicción de series temporales

- El aprendizaje profundo puede **detectar y explotar interacciones de datos invisibles** para cualquier teoría económica financiera existente.
- **reducción del 85 %** en las tasas de error en comparación con **modelos econométricos**.
- **buena predicción fuera de muestra de movimientos direccionales**. La superioridad de ML no es evidente cuando se trata de **inversiones, donde la disponibilidad de datos a menudo es limitada**.

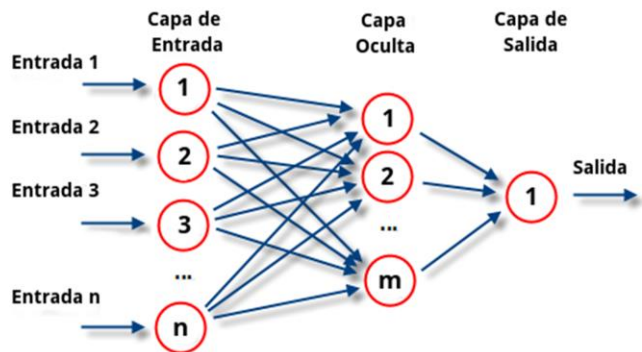


Figura 34: Red neuronal. Fuente propia.

## Actual vs Predicho BMW




Figura 34: Predicción de la cotización de BMW. Fuente propia.

# Aprendizaje por refuerzo (RL)

- **Reinforcement Learning** (RL o aprendizaje por refuerzo) aplicado a la gestión **supera** a las **estrategias de cartera tradicionales**.
- **RL inverso aprende la intención de los gestores de fondos** según lo sugiere su historial comportamental y aprende su **función de recompensa implícita**.
- RL utiliza la **función de recompensa** para **optimizar las decisiones** de asignación de activos.
- Al utilizar RL en los **roboadvisors**, aprenden de **forma dinámica en el tiempo** la **preferencia de riesgo** de los inversores.
- Permite optimizar directamente los **objetivos de la gestión de carteras vs enfoques estándar de maximización de retornos ajustados por riesgo (Markowitz)** provenientes de estimaciones históricas no necesariamente repetibles a futuro.
- RL es capaz de manejar la complejidad en la **planificación financiera** del mundo real; **impuestos, inflación, longevidad**, etc.
- RL realiza la **asignación de activos** teniendo en cuenta las **condiciones de mercado y los objetivos del gestor** en cada instante de tiempo

# Inversión basada en Objetivos (GBI)

- Enfoque de inversión con **rendimiento medido por las probabilidades de éxito** en el logro de los **objetivos financieros de los inversores** (en horizontes temporales determinados y para niveles de prioridad específicos)
- El objetivo es invertir sistemáticamente y gestionar una cartera **coherente con el perfil de riesgo del inversor y el horizonte temporal de sus objetivos**.
- La combinación de RL y GBI es muy prometedora, ya que **los objetivos de los inversores** en GBI pueden conectarse con la **función de recompensa en RL**




Figura 34: Izquierda: Función recompensa en cada instante de tiempo junto con la función de presupuesto de varianza y de aversión al riesgo. Centro: El nivel de riqueza (arriba) junto con la asignación de activos en función de riesgo. Derecha: Distribuciones de probabilidad de éxito en función de los diferentes periodos y posibles niveles de riqueza. Fuente: Matlab.

# Estados de Mercado y regímenes

- Dos estados de mercado diferenciados: mercado de **baja incertidumbre** (relativamente estable y resistente) mercado de **alta incertidumbre** (relativamente caótico y frágil)

- Los **profesionales** utilizan un concepto relativamente similar de **risk on y risk off**.

- **Mercados en estado de baja incertidumbre:**

- Estadísticamente bien comportados
- Se puede modelar utilizando herramientas estadísticas estándar.
- Volatilidad estable y baja, correlaciones relativamente estables
- Los eventos de cola (3 desviaciones estándar en cualquier dirección) son bastante raros.

- **Mercados en estado de alta incertidumbre:**

- No se porta bien estadísticamente
- Las volatilidades y correlaciones cambian significativamente de forma regular.
- Los eventos de cola ocurren con mucha más regularidad
- **El estado de alta incertidumbre puede incorporar cambios significativos en las series temporales:**
- Regímenes de mercado, puntos de cambio, burbujas/caídas.
- Los cambios de régimen, algunos transitorios, otros recurrentes, algunos permanentes, prevalecen en una amplia gama de mercados financieros y variables macroeconómicas.

# Regímenes de mercado .

- **Ejemplos de regímenes considerados en el mundo académico y/o profesionales:**

- Regímenes de mercado alcista versus bajista
- Regímenes inflacionarios versus recesivos
- Regímenes de alta y baja volatilidad
- Regímenes de reversión versus regímenes de tendencia

- Los cambios de régimen **suponen un desafío para los inversores** porque hacen que el **retorno, el riesgo y el comportamiento de la cartera se aparten significativamente de los rangos implícitos en los promedios de medias y covarianzas a largo plazo** (tradicionales **perfiles de riesgo**).

- La asignación de activos basada en regímenes **permite conocer las distribuciones y ofrecer mejores rendimientos de las primas de riesgo** que los **tradicionales perfiles de riesgo** cuando son **golpeados por correlaciones anómalas**.

- Existen distintos regímenes de correlación detectados

- Las correlaciones entre (y dentro de) las clases de activos están lejos de ser estables y varían significativamente.

# La predicción depende de los regímenes de mercado

- **Pregunta: ¿Es superior el poder predictivo a lo largo del ciclo económico?**

- La respuesta es importante ya que existe un **comportamiento asimétrico**

- El rendimiento de los recientes modelos de inversiones basados en **predicciones depende del régimen:**

- **Más preciso en mercados alcistas**, durante expansiones y períodos de baja volatilidad, **menos preciso en mercados bajistas**, durante recesiones y períodos de alta volatilidad.

- El rendimiento de las estrategias de inversión **mejoró enormemente con la introducción de modelos de cambio de régimen (Regime Switching Models)**

- Los RSM **calculan la probabilidad de pasar de un régimen o estado a otro.**

- **El aprendizaje automático** puede ser eficaz para detectar cambios (incluso en sistemas caóticos), por ejemplo, **mediante una sólida detección de anomalías.**

- tienen en común la **capacidad de producir probabilidades de cambiar a otro régimen.** El ML también puede **detectar condiciones previas de una ruptura.**

# Identificar regímenes de mercado



Los algoritmos de aprendizaje no supervisados pueden encontrar grupos naturales y agrupaciones de datos de mercado según criterios de similitud predefinidos.




Figura 35: Análisis de clustering para identificar 3 regímenes. Fuente: Two Sigma.

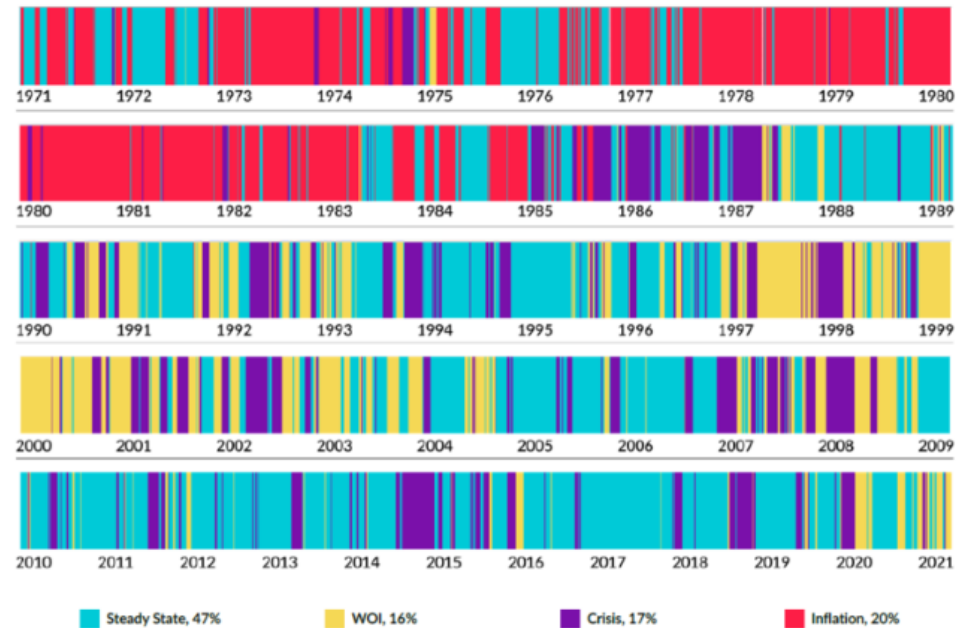


Figura 36: 4 regímenes en función de 50 años de historia. WOI: alta vol, reversion a la media. Fuente: Two Sigma.

# Cambios estructurales

- Es el problema de **encontrar cambios abruptos** en los datos cuando cambia una propiedad de la serie de tiempo
- **Cambios en matrices de correlación o identificación de grupos cambiantes dentro de la matriz** (Rodriguez Dominguez and Stynes, 2022)




Figura 37: Matriz de correlaciones de altas dimensiones. Fuente: (Rodriguez Dominguez and Stynes, 2022).




Figura 38: La correlación oscila mas con mayor frecuencia de datos. Fuente: (Rodriguez Dominguez y Stynes, 2022).




Figura 39: Identificación de variables que cambian la correlación en matriz de 100x100. Fuente: (Rodriguez Dominguez y Stynes, 2022).

# Estrategias de inversión basadas en factores

- Los modelos **tradicionales (lineales)** de factores de riesgo suelen tener **una especificación errónea del modelo**.
- **ML** es muy bueno para **identificar patrones en un espacio de alta dimensión**. Estos patrones asocian características (factores) con resultados.
- La **probabilidad de sobreajuste es alta**, debido a la pequeña proporción entre el **tamaño de las muestras (rendimientos)** vs el **número de factores potenciales**.
- Para poder generalizar el modelo el aprendizaje automático debe **combinarse con la intuición económica y el conocimiento financiero**.




Figura 40: Diferentes tipos de redes o Grafos entre factores.  
Fuente: Propia.




Figura 41: Diferentes tipos de redes o Grafos entre factores.  
Fuente: Propia.

# Estrategias de inversión basadas en factores

- **dos tipos de métodos para identificar predictores de rentabilidad:**

- **Clasificación** de cartera basada en una o varias **características**, como el tamaño (**Size**) o el valor contable al mercado (**Book Value**).

- **regresión lineal** (datos de panel o en espíritu de Fama-French 1996).

- Se descubrió que ML **mejora significativamente el proceso de selección, ya que:**

- Las **regresiones lineales** son **sensibles** a los **valores atípicos**.

- ML se adapta a **muchas más variables predictivas potenciales**.

- ML se adapta a **especificaciones no lineales**.

- Necesidad de **identificar las características más relevantes** (conocidas como factores de riesgo) y analizar si un nuevo factor añade **poder explicativo**.

- La **selección de características** es un componente esencial para ML: encontrar qué características tienen **poder predictivo** incremental para los **retornos esperados**, dadas las otras características.

- Es necesario **mejorar las técnicas** convencionales de **selección de características** **para** tener en cuenta explícitamente los errores de selección de modelos (**como las variables o factores omitidos**).

# Estrategias de inversión basadas en factores

- Estrategias de inversión basadas en factores son **particularmente adecuadas para el ML**.
- La medición de la **prima de riesgo** de un activo es, de hecho, **una predicción**. Es probable que sea necesaria una **gran cantidad de variables predictoras** para lidiar con la **no linealidad de la prima de riesgo**.
- las no linealidades son importantes; **con los mismos 11 factores seleccionados por el modelo no lineal, ML tiene una relación de Sharpe 3 veces mayor fuera de muestra en comparación con un modelo lineal**.
- Esto puede describirse como la **búsqueda de un modelo de reducción de dimensiones a partir de miles de variables**.
- Con una mejor medición a través del aprendizaje automático, **las primas de riesgo** quedan **menos envueltas en errores de estimación**.

# Estrategias de inversión basadas en factores

## Selección de drivers comunes: De un universo de mil candidatos de entre los cuales:

Variables macroeconómicas, de precio (CDS, volatilidades implícitas, skews, asset swaps).

Tipo de interés (Bonos de gobierno y swaps), crédito, materias primas (futuros) ETFs, índices de renta variable, risk premia y smart beta, índices sectoriales.

## Aproximación dinámica:

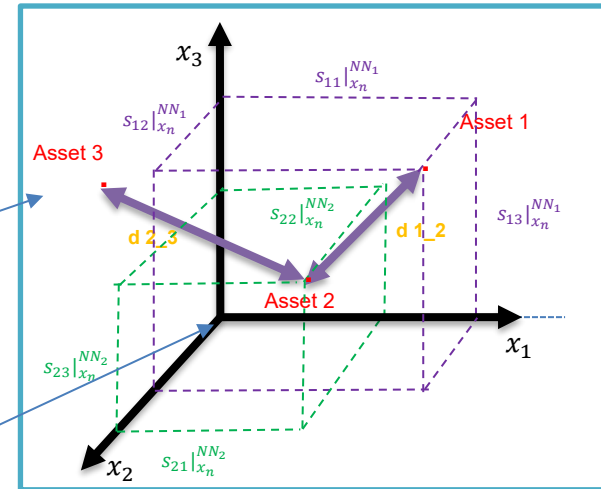



Figura 42: Arquitectura de embebito de activos de una cartera en un espacio de sensibilidades respecto sus drivers comunes. Sensibilidades obtenidas con redes neuronales (Rodríguez 2023).

# Estrategias de inversión basadas en factores

$$w_p = \underset{w}{\operatorname{argmin}} F(\operatorname{Risk}_p(w)) \quad \longleftarrow \quad w_s = \underset{w}{\operatorname{argmin}} F(\operatorname{Risk}_s(w_s))$$




Figura 43: Mapeo de pesos de una cartera del espacio de sensibilidades a un espacio con la medida de riesgo de interés (volatilidad) gracias a un clúster jerárquico. (Rodríguez Dominguez 2023)




Figura 44: Espacio de sensibilidades. (Rodríguez 2023)

# Datos sintéticos de series temporales

- Que la **distribución posterior** de los escenarios tenga que ser **coherente** con la de los datos **reales**, no es suficiente, porque **otras propiedades** relacionadas con la evolución de las **series de tiempo** (stylized facts) **no han sido evaluadas** o son desconocidos como discriminantes.
- **Existen 10 características típicas de las series temporales financieras (Stylized facts).**
- Falta de autocorrelación
- Crisis, extremos y grandes fluctuaciones.
- Asimetría en pérdidas y ganancias
- Volatility clustering,
- ...




Figura 45: Generador de series temporales con redes neuronales de tipo (GAN). Fuente: <https://github.com/FernandoDeMeer>



# Principales Obstáculos

# Principales obstáculos



## Desafíos en los datos

- **Datos insuficientes y/o** calidad de los datos algo pobre.
- Necesidad de satisfacer requisitos de **privacidad, equidad y reglamentaciones.**
- Comportamiento **fuera de muestra no contemplado** en el ajuste de modelos (**fallo al capturar la distribución real**)
- Los riesgos de **sobreajuste de modelos y minería de datos.**
- Características de las series de tiempo financieras (**como los regímenes de mercado o 10 stylized facts**)
- Los conjuntos de datos de entrenamiento y test de modelos deben ser **representativos de la realidad.**

## Interpretabilidad / explicabilidad

- Según una **encuesta** realizada a **profesionales**, esta pregunta se vuelve **especialmente relevante** cuando se utiliza ML en inversiones. **Inversores** y los **reguladores** requieren niveles significativos de **interpretabilidad y/o explicabilidad** .
- La explicabilidad y la interpretabilidad a menudo se usan indistintamente, aunque no son similares: **interpretabilidad** (que describe **CÓMO** llegó ML a sus **conclusiones**) **explicabilidad** (respondiendo **POR QUÉ** ML llegó a sus **conclusiones**).

# Principales obstáculos

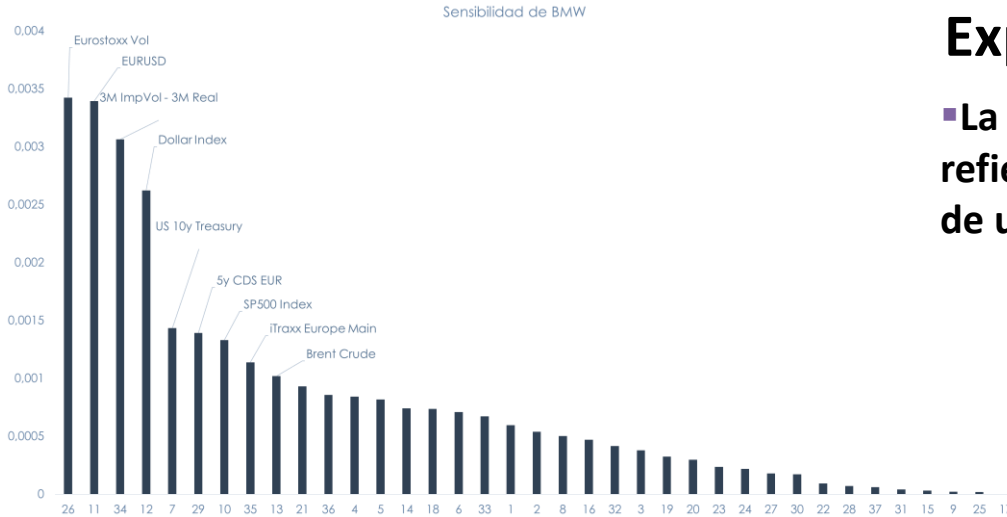


Figura 46: Selección de predictores ordenados por importancia en la predicción de la acción de BMW. Fuente: Propia.

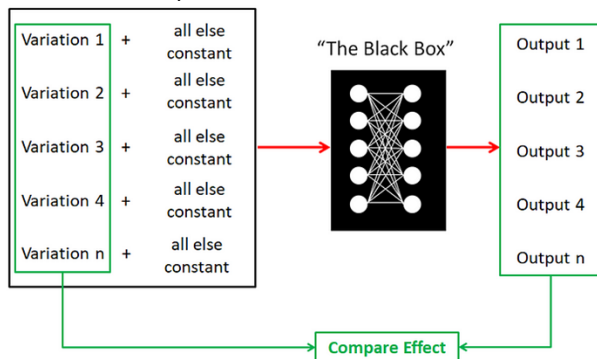


Figura 46: Método de explicabilidad de un modelo Blackbox.

## Explicabilidad

- La explicabilidad en el aprendizaje automático se refiere a la capacidad de comprender el resultado de un modelo en función de los datos de entrada. una regresión logística para la aceptación de crédito se explica bien en términos de las características del solicitante: si el **salario y el LtV** son determinantes significativos de la calidad crediticia, un crédito **podría rechazarse** si el salario del solicitante está un **20% por debajo del promedio o el préstamo**. O si el valor de la casa es un **20% superior al promedio**.
- La necesidad de los roboadvisors de ser menos IA y más XIA (IA - Explicable) .
- Según DARPA, la inteligencia artificial explicable XAI tiene como objetivo (Gunning, D. et al. 2021): producir modelos **más explicables**, manteniendo al mismo tiempo un **alto nivel de aprendizaje**.

# Principales obstáculos

## Interpretabilidad

- La exploración de modelos predictivos se basa en **métodos locales (nivel de instancia) y globales (nivel de conjunto de datos)** para evaluar la importancia de las **variables individuales**.
- **no utilizar** información sobre la **correlación**.
- **Incapacidad para saber hasta qué punto se puede aplicar una explicación local.**
- Dependencia de supuestos de linealidad, conceptos bastante vagos de cercanía/distancia.

## Igualdad, parcialidad y privacidad de datos

- Metodologías y herramientas para preservar la **privacidad de los datos**
- **El sesgo potencial**, es decir, **el trato injusto de diferentes grupos de personas**, reflejado en datos pasados, se replicará (y posiblemente se amplificará) en los resultados de un algoritmo de aprendizaje automático, y los LLM no son una excepción.
- **Eliminar el sesgo y añadir igualdad en los frameworks.** Conceptos, métricas y procesos añadiendo igualdad en ML.

# Principales obstáculos

## Incorporar causalidad en ML

- Cuando los humanos **racionalizamos el mundo**, a menudo pensamos en términos de **causa y efecto**.
  - La inferencia causal es una herramienta estadística para ML que **permite validar los modelos ML**.
  - Es muy importante integrar [la causalidad] en la IA y aprendizaje automático.
- Supongamos que el **sistema de IA** entrenado se aplicará al **mismo tipo de datos** que los datos de entrenamiento. En **la vida real** muchas veces **no es así**.




Figura 47: Fuente: Marcos Lopez de Prado, The Case for Causal Factor Investing 27-03-2024




Figura 48: Fuente: Sadeghi, A. et al. (2023) Grafo Causal de factores, HML (value), SMB (Growth), Mkt-RF (prima libre de riesgo), AAPL-RET (Retorno de Apple)

The logo for MiraltaBank, featuring the word "MiraltaBank" in a white, sans-serif font. The letter "a" in "Bank" is stylized with a circular cutout. The background is a teal-tinted landscape of mountains and a forest.

Advanced Banking

## Aviso Legal

**Naturaleza de este material:**

Este documento únicamente contiene la presentación de nuestro Fondo. El inversor debe revisar el Folleto, el documento de Datos Fundamentales para el Inversor y los informes periódicos del Fondo, todos ellos a su disposición en [www.miraltabank.com](http://www.miraltabank.com). Asimismo se puede consultar la referida información legal en la página web de la CNMV. Este material no debe ser considerado en modo alguno una oferta, recomendación, asesoramiento, análisis financiero, invitación a invertir, ni de ninguna otra forma entendiéndose como base para tomar decisiones de inversión.

**Exención de responsabilidad:**

Ni Miralta Asset Management SGIC, S.A.U. ni sus representantes o asesores responderán en forma alguna de daños que se deriven del uso de este documento o de su contenido o que traigan causa en cualquier otra forma del mismo. El lector es el único responsable de su interpretación, uso o decisiones de inversión.

**Derechos reservados:**

Todos los derechos de propiedad intelectual e industrial de estas páginas son titularidad de Miralta Asset Management SGIC, S.A.U. Queda prohibida su reproducción, distribución, comunicación pública y transformación. Igualmente, todos los nombres comerciales, marcas o signos distintos de cualquier clase contenidos en este documento están protegidos.

# Referencias

1. Cochrane, J. 2004, Asset Pricing.
2. Gunning, D. & Vorm, E.s & Wang, J. & Turek, M. (2021). DARPA 's explainable AI ( XAI ) program: A retrospective. Applied AI Letters. 2. 10.1002/ail2.61.
3. López de Prado, M. and Lipton, A. and Zoonekynd, V., The Case for Causal Factor Investing (March 27, 2024)
4. Rodriguez Dominguez, A. and Stynes, D. "A Clustering Algorithm for Correlation Quickest Hub Discovery Mixing Time Evolution and Random Matrix Theory," 2022 IEEE 34th International Conference on Tools with Artificial Intelligence (ICTAI), Macao, China, 2022, pp. 1007-1014
5. Rodriguez Dominguez, A. Portfolio optimization based on neural networks sensitivities from assets dynamics respect common drivers, Machine Learning with Applications, Volume 11, 2023, 100447, ISSN 2666-8270
6. Sadeghi, A. and Gopal, Achintya and Fesanghary, Mohammad, Causal Discovery in Financial Markets: A Framework for Nonstationary Time-Series Data (December 28, 2023).
7. Swinkels, L., and Hoogteijling, T., June 2022,. "Forecasting stock crash risk with machine learning",. Robeco white paper. 11.